

## ارزیابی اثر پارامترهای عملیاتی TBM بر نرخ نفوذ با رویکرد یادگیری ماشین و انتخاب ویژگی چندمرحله‌ای

آرمین فلاحی<sup>۱</sup>؛ سید مصلح افتخاری<sup>۱\*</sup>؛ احسان طاهری<sup>۱</sup>

۱- گروه مکانیک سنگ، بخش مهندسی معدن، دانشکده معدن و مواد، دانشگاه تربیت مدرس، تهران، ایران.

دریافت: ۱۴۰۴/۰۱/۲۰ پذیرش: ۱۴۰۴/۰۳/۲۸

(نویسنده مسئول: [mosleh.eftkhari@modares.ac.ir](mailto:mosleh.eftkhari@modares.ac.ir))

### چکیده

در سال‌های اخیر، مدل‌های یادگیری ماشین به‌طور گسترده برای پیش‌بینی نرخ نفوذ ماشین حفاری تمام‌مقطع (TBM) استفاده شده‌اند. نرخ نفوذ یکی از شاخص‌های کلیدی عملکرد در پروژه‌های تونل‌سازی است و به همین دلیل، بهبود روش‌های پیش‌بینی آن اهمیت زیادی دارد. با این حال، بسیاری از مطالعات پیشین تنها به مقایسه محدود چند الگوریتم پرداخته و کمتر به انتخاب ویژگی جامع یا تحلیل دقیق حساسیت پارامترهای عملیاتی پرداخته‌اند. این پژوهش با هدف پر کردن این شکاف، رویکردی چندمرحله‌ای در انتخاب ویژگی‌ها با ترکیب روش اطلاعات متقابل (MI) و الگوریتم بهینه‌سازی گرگ خاکستری (GWO) ارائه داد تا از میان ۱۷ ویژگی اولیه، مؤثرترین پارامترها انتخاب شوند. پایگاه داده‌ی واقعی شامل ۱۲۵۸ رکورد عملکرد TBM در پروژه تونل بلند زاگرس، برای آموزش و ارزیابی چهار الگوریتم نزدیک‌ترین همسایه (KNN)، ماشین بردار پشتیبان (SVM)، درخت تصمیم (DT) و جنگل تصادفی (RF) مورد استفاده قرار گرفت. عملکرد مدل‌ها با شاخص‌های استاندارد RMSE، MAE و ضریب تعیین ( $R^2$ ) ارزیابی شد. در میان مدل‌های بررسی شده، مدل جنگل تصادفی با  $R^2$  حدود ۰/۹۳ و RMSE برابر با ۰/۰۵ بهترین دقت را نشان داد و با استفاده از روش اعتبارسنجی متقابل پنج‌بخشی از تعمیم‌پذیری مناسبی برخوردار بود. در گام نهایی، تحلیل حساسیت با استفاده از مدل RF انجام شد. نتایج نشان داد که تنظیم متعادل پارامترهای عملیاتی شامل نیروی محوری پیشران، گشتاور و سرعت چرخش کله‌حفار نقشی کلیدی در بهینه‌سازی نرخ نفوذ دارد. این پژوهش علاوه بر بهبود دقت پیش‌بینی نرخ نفوذ، نشان می‌دهد که مدل‌های یادگیری ماشین می‌توانند به‌عنوان ابزاری کارآمد برای پشتیبانی تصمیم و بهینه‌سازی راهبردهای عملیاتی در پروژه‌های حفاری مکانیزه مورد استفاده قرار گیرند.

ماشین حفاری تمام‌مقطع (TBM)، یادگیری ماشین، پیش‌بینی نرخ نفوذ، تحلیل حساسیت، انتخاب ویژگی، پارامترهای عملیاتی

### واژگان کلیدی

### ۱- مقدمه

زیست‌محیطی و افزایش سرعت عملیات، جایگاه ممتازی در صنعت تونلسازی یافته‌اند [۱،۲]. یکی از شاخص‌های کلیدی در ارزیابی عملکرد TBM، نرخ نفوذ (Penetration Rate) است که تأثیر مستقیمی بر زمان‌بندی، هزینه و برنامه‌ریزی پروژه دارد. این شاخص متأثر از عوامل متعددی از جمله خواص ژئومکانیکی سنگ، ویژگی‌های ماشین حفاری، شرایط تنش، و وضعیت هیدروژئولوژیکی است [۳-۶]. همچنین در

در دهه‌های اخیر، توسعه سریع پروژه‌های زیرزمینی و زیرساختی، ضرورت استفاده از فناوری‌های نوین در حفاری را بیش از پیش آشکار کرده است. در این میان، ماشین‌های حفاری تمام‌مقطع (Tunnel Boring Machine, TBM) به دلیل مزایایی همچون ایمنی بالا، کاهش آسیب‌های

استفاده از الگوریتم گرگ خاکستری (*GWO*) مدل‌های ترکیبی قدرتمندی را توسعه دادند [۲۳]، در حالی که زو و همکاران (۲۰۱۹) و یانگ و همکاران (۲۰۲۰) عملکرد مدل‌های *ANN*، *KNN*، *CHAIID*، *SVR* و مدل ترکیبی *GWO-SVR* را با موفقیت در پروژه‌های مختلف مورد آزمایش قرار دادند [۲۴، ۲۵]. لی و همکاران (۲۰۲۱) نیز در مطالعه‌ای بر تونلی با طول ۷۲ کیلومتر در چین، اهمیت انتخاب ویژگی و حذف متغیرهای زائد را در افزایش دقت مدل مورد تأکید قرار دادند [۲۶]. یانگ و همکاران (۲۰۲۲) با استفاده از رگرسیون چند جمله‌ای تکاملی جنگل تصادفی، دو مدل پیش‌بینی جدید را برای عملکرد ماشین حفاری تونل توسعه دادند [۲۷].

در سال‌های اخیر، مطالعات جدیدتری با بهره‌گیری از الگوریتم‌های به‌روز و مدل‌های ترکیبی منتشر شده‌اند. برای مثال، افتخاری و افتخاری ۲۰۲۲ با ترکیب الگوریتم‌های رقابت‌استعماری- شبکه عصبی مصنوعی و تحلیل پوششی داده‌ها- تحلیل سلسله مراتبی توانسته‌اند مدل پیش‌بینی کارآمدی برای نرخ نفوذ توسعه دهند [۲۸]. لطیف و همکاران ۲۰۲۳ چارچوبی مبتنی بر دیجیتال‌توین و یادگیری ماشین برای پیش‌بینی عملکرد *TBM* معرفی کردند که دقت بالایی در زمان واقعی ارائه می‌دهد [۲۹]. یو و همکاران ۲۰۲۳ نیز با استفاده از الگوریتم *XGBoost* بهینه‌شده با روش‌های هوش جمعی، مدلی دقیق برای پیش‌بینی نرخ نفوذ توسعه دادند [۳۰]. در حوزه مدل‌های قابل‌تفسیر، هو و همکاران ۲۰۲۵ از ترکیب بهینه‌سازی بیزی و روش *SHAP* برای بهینه‌سازی و تحلیل اهمیت ویژگی‌ها در پیش‌بینی همگرایی تونل‌های حفاری‌شده با *TBM* استفاده کردند [۳۱]. از سوی دیگر، توسعه مدل‌های یادگیری عمیق نیز سهم قابل توجهی در این حوزه داشته است. به‌عنوان نمونه، لی و همکاران ۲۰۲۴ با معرفی مدل *TCN-SENet++* امکان پیش‌بینی چندمرحله‌ای نرخ نفوذ با دقت بالا را فراهم کردند [۳۲]. ژانگ و همکاران ۲۰۲۴ نیز با ترکیب شبکه‌های *Transformer* و *BiLSTM*، پیش‌بینی زمان واقعی نرخ نفوذ *TBM* را با موفقیت اجرا کرده است [۳۳]. علاوه بر این، کاربرد الگوریتم‌های بهینه‌سازی مدرن نیز مورد توجه قرار گرفته است؛ چنان‌که در مطالعه کلیک و همکاران ۲۰۲۴، از بهینه‌سازی خودکار برای تنظیم ابرپارامترها در پیش‌بینی

زمینه عملکرد عملی *TBM*، تحلیل اثر ویژگی‌های مهندسی زمین‌شناسی و شرایط سنگ‌های آهکی و سنگ‌های بسیار مقاوم بر نفوذ ماشین ارائه شده است [۷-۹]. افزون بر این، نقش جایگزینی ابزار برشی و فرآیندهای سایش و تراشه‌شدگی زیر دیسک‌کاترها نیز در کارایی *TBM* بررسی شده است [۱۰، ۱۱].

برای مدل‌سازی و پیش‌بینی نرخ نفوذ، مدل‌های تجربی و نیمه‌تجربی متعددی نظیر مدل‌های *CSM* و *NTNU* توسعه یافته‌اند که عمدتاً بر اساس پارامترهایی چون مقاومت فشاری تک‌محوری، شاخص کیفیت سنگ و مشخصات عملیاتی ماشین عمل می‌کنند [۱۲-۱۴]. همچنین در برخی مطالعات، از سیستم‌های طبقه‌بندی مهندسی توده‌سنگ مانند *Q* و *RMR* استفاده شده است [۱۵-۱۷]. با این حال، دقت پایین، عدم تعمیم‌پذیری و ضعف در مدل‌سازی رفتار غیرخطی، محدودیت‌های جدی این مدل‌ها در شرایط واقعی پروژه‌ها هستند [۱۸]. به همین دلیل، مطالعات اولیه داخلی نیز از همان ابتدا به سمت استفاده از مدل‌های داده‌محور مانند شبکه‌های عصبی برای پیش‌بینی نرخ نفوذ *TBM* حرکت کردند [۱۹].

در سال‌های اخیر، روش‌های یادگیری ماشین (*Machine learning*) به‌عنوان ابزاری توانمند در مدل‌سازی سیستم‌های پیچیده و چندمتغیره در مهندسی ژئوتکنیک مطرح شده‌اند. الگوریتم‌هایی نظیر شبکه‌های عصبی مصنوعی (*ANN*)، ماشین بردار پشتیبان (*SVM*)، جنگل تصادفی (*RF*)، درخت تصمیم (*DT*) و نزدیک‌ترین همسایه (*KNN*) برای پیش‌بینی نرخ نفوذ *TBM* به کار گرفته شده‌اند. به‌عنوان نمونه، یانگیز و کاراهان (۲۰۱۱) با استفاده از *PSO* و داده‌های پروژه کوپینز، مدلی دقیق برای پیش‌بینی نرخ نفوذ ارائه کردند [۲۰]. جیمز ماهر (۲۰۱۳) با استفاده از الگوریتم *RF* و روش انتخاب ویژگی جستجوی رو به جلو در متروی سیاتل، تأثیر پارامترهای ماشین و سنگ را تحلیل کرد [۲۱]. مختاریان و همکاران (۲۰۱۴) نیز با استفاده از تحلیل مؤلفه‌های اصلی و شبکه عصبی مصنوعی در تونل زاگرس، نقش انتخاب ویژگی در بهبود دقت مدل را اثبات کردند [۲۲]. مطالعات دیگری نیز نشان داده‌اند که ترکیب الگوریتم‌های فراابتکاری با مدل‌های یادگیری ماشین می‌تواند دقت پیش‌بینی را به‌طور قابل توجهی ارتقاء دهد. به‌عنوان مثال، یانگیز و کاراهان (۲۰۱۵) با

انجام تحلیل حساسیت چندمتغیره پارامترهای عملیاتی است؛ موضوعی که تاکنون کمتر در مطالعات پیشین به آن پرداخته شده است.

## ۲- مواد و روش‌ها

### ۲-۱- مشخصات پروژه و پایگاه داده

مطالعه حاضر مبتنی بر داده‌های حاصل از عملکرد ماشین حفاری در بخشی از قطعه دوم تونل بلند زاگرس است. این تونل، بخشی از پروژه انتقال آب از سرشاخه‌های رودخانه سیروان به نواحی مرکزی ایران بوده و در منطقه‌ای با ساختار زمین‌شناسی پیچیده و شرایط تکنیکی فعال در غرب کشور واقع شده است. طول قطعه دوم تونل ۲۶ کیلومتر و قطر حفاری آن ۶/۷۳ متر است که عملیات حفاری آن به‌وسیله ماشین حفاری تمام‌مقطع دو سپره (*Double Shield TBM*) انجام شده است. این ماشین با ۴۲ دیسک برشی با قطر ۴۳۲ میلی‌متر و فاصله ۹۰ میلی‌متر، توانایی حفاری در زمین‌های سخت را داراست و سرعت چرخش کله‌حفار آن در بازه ۰ تا ۹/۰۵ دور بر دقیقه قرار دارد. بیشینه عمق تونل در این قطعه ۱۰۰۰ متر و میانگین عمق آن در حدود ۴۰۰ متر گزارش شده است.

بررسی زمین‌شناسی مهندسی مسیر تونل نشان می‌دهد که مسیر حفاری شده از میان واحدهای متنوعی با ترکیب‌های مختلف عبور کرده است. این واحدها شامل سنگ‌هایی با ترکیب‌هایی از آهک (*LI*)، شیل (*SH*)، مارن (*MA*)، آهک مارنی (*ML*) و شیل آهکی (*LS*) هستند که در مجموع، ۲۱ واحد زمین‌شناسی مهندسی در محدوده مطالعه قابل تفکیک گزارش شده‌اند. این تنوع لیتولوژیکی موجب شده تا عملکرد ماشین حفاری تحت شرایط بسیار متغیر و واقعی ثبت شود و پایگاه داده‌ای متنوع و قابل‌اتکا فراهم گردد. پایگاه داده مورد استفاده شامل اطلاعات مربوط به ۱۰ کیلومتر از مسیر حفاری شده است و از ترکیب داده‌های ثبت‌شده توسط سیستم کنترل *TBM* و گزارش‌های اپراتوری استخراج شده است. برش زمین‌شناسی از قطعه مورد مطالعه از مسیر تونل در شکل ۱ نشان داده شده است.

این پایگاه داده دربردارنده مجموعه‌ای از پارامترهای عملیاتی ماشین حفاری نظیر نیروی محوری پیشران، گشتاور، سرعت چرخش کله‌حفار دستگاه است. همچنین اطلاعات مربوط به


سرعت چک و گشتاور *TBM* استفاده شد [۳۴]. عباسی و همکاران ۲۰۲۴ در پژوهش خود نشان دادند که حتی مدل‌های خطی مانند رگرسیون چندگانه می‌توانند دقتی قابل مقایسه با شبکه‌های عصبی چندلایه داشته باشند، در حالی که عملکرد درخت تصمیم پایین‌تر گزارش شد [۳۵]. همچنین، در پژوهش قربانی و یاگیز در سال ۲۰۲۴ این نتیجه حاصل شد که الگوریتم‌های تقویت‌شده‌ای مانند *Gradient Boosting* نسبت به مدل‌های کلاسیک عملکرد بهتری در پیش‌بینی نرخ نفوذ *TBM* داشتند [۳۶]. در نهایت، لیو و همکاران در سال ۲۰۲۵ با ترکیب تحلیل ابعادی و رگرسیون *Elastic Net* موفق شدند مدلی با قابلیت تعمیم بالا برای پیش‌بینی سرعت چرخش کله‌حفار ارائه دهند [۳۷].

با وجود این پیشرفت‌ها، بررسی جامع پیشینه پژوهش نشان می‌دهد که بیشتر مطالعات پیشین یک یا دو الگوریتم را در نظر گرفته‌اند و کمتر به مقایسه نظام‌مند عملکرد چند الگوریتم با یک مجموعه داده یکسان پرداخته‌اند. همچنین در بسیاری از این مطالعات، فرآیند انتخاب ویژگی با استفاده از الگوریتم‌های بهینه‌سازی کمتر مورد توجه قرار گرفته و تحلیل حساسیت مدل نسبت به پارامترهای کلیدی عملکرد ماشین، غالباً مغفول مانده است.

مطالعه حاضر با هدف رفع این شکاف‌ها، به بررسی و مقایسه چهار الگوریتم یادگیری ماشین شامل *SVM*، *KNN*، *DT* و *RF* در پیش‌بینی نرخ نفوذ *TBM* می‌پردازد. داده‌های مورد استفاده، حاصل عملکرد واقعی ماشین حفاری در قطعه دوم تونل بلند زاگرس است. در گام نخست، با استفاده از روش‌های انتخاب ویژگی بر پایه اطلاعات متقابل و الگوریتم گرگ خاکستری (*GWO*)، مهم‌ترین متغیرها از میان ۱۷ پارامتر اولیه شناسایی شده‌اند. سپس مدل‌های مذکور در محیط *MATLAB* پیاده‌سازی و آموزش داده شده‌اند و با بهره‌گیری از شاخص‌های آماری نظیر میانگین قدر مطلق خطا (*MAE*)، میانگین مربعات خطا (*RMSE*) و ضریب تعیین ( $R^2$ )، دقت پیش‌بینی آن‌ها مقایسه شده است. در پایان نیز با بهره‌گیری از مدل منتخب، تحلیل حساسیت نسبت به پارامترهای عملیاتی ماشین (گشتاور، نیروی پیشران و سرعت چرخش کله‌حفار) انجام شده است. نوآوری این پژوهش در به‌کارگیری راهبرد چندمرحله‌ای انتخاب ویژگی در ترکیب با الگوریتم‌های یادگیری ماشین برای پیش‌بینی نرخ نفوذ *TBM* و همچنین

دستگاه استخراج شده است. برای تمامی پارامترهای فوق، مقادیر حداقل، حداکثر و میانگین در جدول ۱ آمده است. همچنین، نحوه‌ی توزیع چند پارامتر پرکاربرد و شاخص در مطالعات حفاری مکانیزه از جمله گشتاور، سرعت چرخش کله حفار، مقاومت فشاری تک محوره و همچنین نرخ نفوذ، با استفاده از نمودار ویولونی در شکل ۲ نمایش داده شده است.

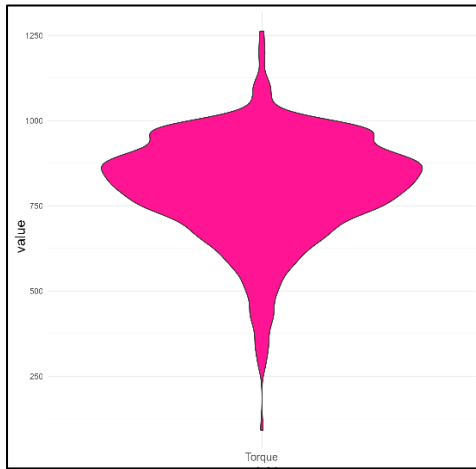
ویژگی‌های ژئومکانیکی توده‌سنگ از جمله مقاومت فشاری تک‌محوره، مقاومت کششی برزیلی، مدول الاستیسیته، شاخص کیفیت سنگ ( $RQD$ )، فاصله درزه‌ها، درصد کوارتز، و شاخص‌های طبقه‌بندی مانند  $GSI$ ،  $RMR$ ،  $Q$  در آن ثبت شده‌اند. پارامتر هدف، نرخ نفوذ ماشین حفاری در موقعیت‌های مختلف مسیر حفاری است که از داده‌های واقعی عملکرد




شکل ۱- برش زمین‌شناسی قطعه‌ای از مسیر تونل زاگرس [۳۸]

جدول ۱- دامنه و میانگین تغییرات پارامترهای بانک اطلاعاتی [۳۸]


پارامتر	حداقل	حداکثر	میانگین
نیروی محوری پیشران (kN)	2000	9940	7096
سرعت چرخش تاج حفار (rev/min)	3.0	7.4	5.2
گشتاور (kN.m)	92	1263	805
توان (%)	23	60	39.4
مقاومت فشاری تک‌محوره (MPa)	22.5	125	37.9
مدول الاستیک (MPa)	3.0	22.5	5.7
درصد کوارتز (%)	0.5	3.5	1.3
دانسیته خشک ( $g/cm^3$ )	2.4	2.5	2.4
دانسیته تر ( $g/cm^3$ )	2.5	2.6	2.6
تخلخل (%)	3.5	10.0	7.6
مقاومت کششی برزیلی (MPa)	2.0	5.0	3.0
فاصله درزه‌ها	20	100	47
RQD	37.5	85.0	64.8
RMR	28	60	44.7
GSI	19	57	33.2
Q	0.3	4.7	2.2
RSR	26	54	39.4
نرخ نفوذ (m/h)	1.0	4.9	2.4




ب



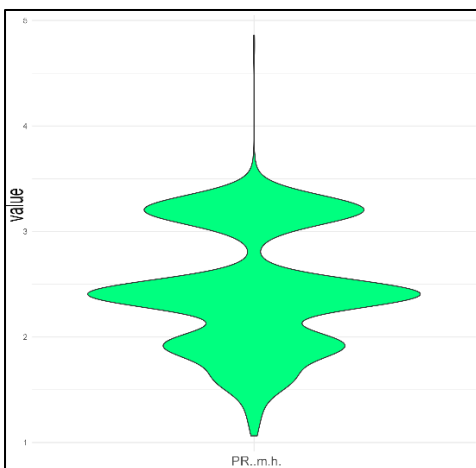
الف




د



ج



و



ه

شکل ۲- نمودار ویولونی پارامترهای الف) RPM ب) گشتاور ج) مقاومت فشاری تک محوره د) RQD ه) RMR و) نرخ نفوذ

## ۲-۲- انتخاب ویژگی‌ها

در مسائل یادگیری ماشین، استفاده از تمام ویژگی‌های موجود در داده لزوماً به بهبود دقت مدل منجر نمی‌شود. وجود ویژگی‌های غیرمؤثر و یا وابسته می‌تواند باعث کاهش تعمیم‌پذیری مدل، افزایش پیچیدگی محاسباتی و بروز پدیده بیش‌برازش شود. از این‌رو، انتخاب ویژگی‌ها (*Feature Selection*) به‌عنوان یکی از مراحل اساسی در طراحی مدل‌های کارآمد مطرح است. در این پژوهش، یک رویکرد ترکیبی برای انتخاب ویژگی‌ها به کار گرفته شد که شامل دو مرحله مجزا است: (۱) غربال‌گری اولیه بر اساس اطلاعات متقابل (*Mutual Information*)، و (۲) بهینه‌سازی ترکیب ویژگی‌ها با الگوریتم گرگ خاکستری (*Grey Wolf Optimizer - GWO*).

## ۲-۲-۱- روش اطلاعات متقابل

اطلاعات متقابل (*MI*) ابزاری از نظریه اطلاعات است که میزان وابستگی آماری بین دو متغیر تصادفی را اندازه‌گیری می‌کند. اطلاعات متقابل معیاری برای سنجش همبستگی کلی (اعم از خطی و غیرخطی) میان متغیرها است. اطلاعات متقابل بین دو متغیر  $x$  و  $y$ ، طبق رابطه ۱ و براساس تابع چگالی احتمال  $P(x, y)$  و  $P(x)$ ،  $p(y)$  که به ترتیب نشان دهنده تابع توزیع احتمال هدف، تابع توزیع احتمال ویژگی‌ها و تابع توزیع احتمال مشترک  $x$  و  $y$  به دست می‌آید [۳۹]:

$$I(x, y) = \sum_{y \in Y} \sum_{x \in X} P(x, y) \log \left( \frac{P(x, y)}{P(x)P(y)} \right) \quad (1)$$

هر چه مقدار آن بزرگ‌تر باشد، اطلاعات بیشتری از  $x$  برای پیش‌بینی  $y$  قابل استخراج است. در این تحقیق، ابتدا اطلاعات متقابل بین هر یک از ویژگی‌های ورودی و متغیر هدف (نرخ نفوذ) محاسبه شد و ویژگی‌هایی با مقادیر بالاتر به‌عنوان نامزدهای اولیه انتخاب شدند. برای بهبود دقت این مرحله، از معیار *MRMR* (*Minimal Redundancy Maximal Relevance*) (حداقل افزونگی، حداکثر ارتباط) نیز استفاده شد تا همپوشانی اطلاعاتی بین ویژگی‌ها به حداقل برسد.

## ۲-۲-۲- الگوریتم گرگ خاکستری

برای انتخاب ترکیب بهینه‌ای از ویژگی‌ها، از الگوریتم گرگ

خاکستری (*GWO*) به‌عنوان یک روش فراابتکاری الهام‌گرفته از رفتار شکار جمعی گرگ‌های خاکستری استفاده شد. ساختار سلسله‌مراتبی این الگوریتم شامل چهار دسته گرگ  $\alpha$ ،  $\beta$ ،  $\delta$  و  $\omega$  است که به ترتیب بهترین، دومین و سومین جواب‌ها و سایر اعضای جمعیت را تشکیل می‌دهند. در فرآیند بهینه‌سازی، موقعیت گرگ‌ها در فضای جستجو بر اساس موقعیت گرگ‌های راهبر به‌روزرسانی می‌شود. در مدل ریاضی الگوریتم، به‌روزرسانی موقعیت‌ها با استفاده از روابط زیر انجام می‌شود [۴۰]:

$$D = |C \cdot X_{p(t)} - X(t)| \quad (2)$$

$$X(t+1) = X_{p(t)} - A \cdot D \quad (3)$$

که در آن،  $X_{p(t)}$  موقعیت طعمه (یا بهترین راه‌حل فعلی)،  $X(t)$  موقعیت گرگ، و ضرایب  $A$  و  $C$  به ترتیب از روابط زیر محاسبه می‌شوند:

$$A = 2ar_1 - a \quad (4)$$

$$C = 2r_2 \quad (5)$$

پارامتر  $a$  در طول تکرارها از ۲ به ۰ به صورت خطی کاهش می‌یابد،  $r_1$  و  $r_2$  بردارهای تصادفی در بازه [۰، ۱] هستند. موقعیت گرگ‌ها در فضای جستجو بر اساس موقعیت گرگ‌های راهبر به‌روزرسانی می‌شود:

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (6)$$

در این پژوهش، نسخه دودویی (*Binary GWO*) از الگوریتم برای انتخاب ویژگی به کار گرفته شده است. در این نسخه، موقعیت‌های پیوسته به مقادیر صفر و یک تبدیل می‌شوند تا بیانگر حذف یا انتخاب هر ویژگی باشند. تبدیل مقادیر پیوسته به دودویی از طریق تابع تانژانت هایپربولیک و آستانه‌گذاری تصادفی انجام شده است. در پیاده‌سازی الگوریتم گرگ خاکستری برای انتخاب ویژگی، فرآیند جستجو تا زمانی ادامه می‌یابد که یا به حداکثر تعداد تکرار مشخص شده برسد یا تغییرات تابع هدف در بین تکرارهای متوالی به حدی ناچیز کاهش یابد که نشان‌دهنده همگرایی جستجو باشد. این سازوکار موجب می‌شود الگوریتم در شرایطی پایدار متوقف

شود و امکان تکرارپذیری و ارزیابی نتایج فراهم گردد.

## ۲-۳- الگوریتم‌های یادگیری ماشین

### ۲-۳-۱- الگوریتم نزدیک‌ترین همسایه

الگوریتم نزدیک‌ترین همسایه (*K-Nearest Neighbors*) یکی از روش‌های پایه، غیرپارامتری و پرکاربرد در یادگیری ماشین برای مسائل رگرسیون و طبقه‌بندی است. این الگوریتم بر مبنای شباهت هندسی بین نمونه‌ها عمل می‌کند و از ساده‌ترین و درعین‌حال مؤثرترین روش‌های تصمیم‌گیری است، به‌ویژه در شرایطی که توزیع داده‌ها پیچیده یا غیرخطی باشد. در *KNN*، فرض بر این است که نمونه‌هایی که در فضای ویژگی به یکدیگر نزدیک‌اند، رفتار مشابهی دارند. بنابراین، برای پیش‌بینی مقدار خروجی یک نمونه جدید، الگوریتم فاصله آن را با تمام داده‌های آموزش محاسبه کرده و سپس  $k$  نمونه نزدیک‌تر را انتخاب می‌کند. در حالت رگرسیونی، خروجی نهایی با میانگین‌گیری از خروجی  $k$  همسایه نزدیک تخمین زده می‌شود.

برای یک بردار ورودی جدید  $x$ ، فاصله آن با هر یک از نمونه‌های آموزشی  $x_i$  با یک معیار فاصله (معمولاً فاصله اقلیدسی) محاسبه می‌شود. سپس  $k$  نمونه‌ای که کمترین مقدار فاصله را دارند انتخاب شده و مقدار خروجی تخمینی (در حالت رگرسیونی) به‌دست می‌آید [۴۱].

### ۲-۳-۲- الگوریتم درخت تصمیم

الگوریتم درخت تصمیم (*Decision Tree*) یکی از روش‌های محبوب و تفسیرپذیر در حوزه یادگیری ماشین است که به‌ویژه در مسائل دسته‌بندی و رگرسیون کاربرد دارد. این الگوریتم از ساختاری سلسله‌مراتبی متشکل از گره‌ها و شاخه‌ها تشکیل شده و از رویکرد «تقسیم و تسخیر» برای آموزش مدل استفاده می‌کند. روند آموزش از گره ریشه آغاز شده و با انتخاب بهترین ویژگی برای تقسیم داده‌ها ادامه می‌یابد. این فرایند به‌صورت بازگشتی تا زمانی ادامه می‌یابد که تقسیم داده‌ها دیگر بهبود قابل توجهی در عملکرد مدل ایجاد نکند یا شرایط توقف (مانند حداقل تعداد نمونه در هر گره) برقرار شود. در هر گره تصمیم، یک تابع تست برای یکی از ویژگی‌های ورودی تعریف می‌شود که داده‌ها را به دو یا چند زیرمجموعه تقسیم می‌کند. اگر ویژگی ورودی گسسته باشد،

انشعاب بر اساس تعداد مقادیر گسسته آن انجام می‌شود، ولی در حالت پیوسته، یک مقدار آستانه به عنوان معیار مقایسه به‌کار می‌رود [۴۲].

برای مسائل رگرسیون، هدف الگوریتم تعیین مقادیری عددی برای خروجی است، نه برچسب‌های طبقه. در این حالت، در هر گره، مقدار خروجی پیش‌بینی شده معمولاً برابر با میانگین خروجی نمونه‌های موجود در آن گره فرض می‌شود. معیار تقسیم در درخت رگرسیون معمولاً مبتنی بر کاهش واریانس یا حداقل‌سازی میانگین مربعات خطا (*MSE*) است. در واقع، گره‌ها به‌گونه‌ای ایجاد می‌شوند که مجموع خطاهای زیرگره‌ها در مقایسه با گره والد کاهش یابد. رشد درخت بدون کنترل می‌تواند منجر به بیش‌برازش شود. برای مقابله با این پدیده، معمولاً از روش‌های هرس (*pruning*) استفاده می‌شود. در این روش، ابتدا درخت به‌صورت کامل آموزش داده می‌شود و سپس برخی از شاخه‌هایی که تأثیر چندانی بر کاهش خطا ندارند، حذف می‌شوند. این عمل باعث ساده‌تر شدن مدل و بهبود دقت آن در داده‌های تست می‌گردد [۴۲].

یکی از مزایای مهم درخت تصمیم، قابلیت تفسیر بالای آن است. ساختار سلسله‌مراتبی درخت به راحتی به مجموعه‌ای از قوانین «گر-آنگاه» (*If-Then*) تبدیل می‌شود که درک آن برای کاربران و تصمیم‌گیرندگان آسان است. علاوه بر این، ویژگی‌هایی که در نزدیکی ریشه قرار دارند به‌عنوان مهم‌ترین ویژگی‌های مسئله شناخته می‌شوند و می‌توانند در تحلیل ویژگی‌ها و انتخاب متغیرهای کلیدی به‌کار روند.

### ۲-۳-۲- الگوریتم ماشین بردار پشتیبان

ماشین بردار پشتیبان (*Support Vector Machine-SVM*) یکی از الگوریتم‌های قدرتمند یادگیری با نظارت است که برای هر دو نوع مسائل طبقه‌بندی و رگرسیون به‌کار می‌رود. در حالت رگرسیونی، نسخه‌ی خاصی از این الگوریتم تحت عنوان رگرسیون بردار پشتیبان (*SVR*) استفاده می‌شود که هدف آن یافتن یک تابع تقریبی از داده‌ها با کمترین میزان خطا در یک حاشیه تعریف شده است. این الگوریتم بر پایه نظریه یادگیری آماری بنا شده و به‌گونه‌ای طراحی شده است که از بین تمام توابع ممکن، تابعی را انتخاب کند که در عین سادگی، دقت کافی در پیش‌بینی داشته باشد. مدل *SVR*، به‌صورت تابع زیر تعریف می‌شود [۴۳]:

درخت‌ها شده و در نهایت با میانگین‌گیری خروجی‌ها، خطای کلی مدل کاهش می‌یابد [۴۴].

در مسائل رگرسیونی مانند مطالعه حاضر، پیش‌بینی نهایی مدل به صورت میانگین خروجی تمام درخت‌های ساخته‌شده انجام می‌شود. معیار تقسیم در هر گره درخت، معمولاً بر اساس کاهش میانگین مربعات خطا ( $MSE$ ) یا کاهش واریانس تعریف می‌شود. در واقع، درخت به‌گونه‌ای رشد می‌کند که مجموع خطاهای دو زیرگره حاصل، حداقل باشد. انتخاب ویژگی در هر گره به‌صورت تصادفی از میان  $m$  ویژگی از کل ویژگی‌ها انجام می‌شود و عمق درخت‌ها نیز معمولاً بدون محدودیت تعیین می‌شود، مگر آن‌که به‌منظور جلوگیری از بیش‌برازش، پارامترهای خاصی برای هرس یا حداکثر عمق تنظیم شده باشد.

### ۳- نتایج و بحث

در این بخش، نتایج حاصل از مراحل مختلف مدل‌سازی ارائه و تحلیل می‌شود. ابتدا خروجی روش‌های انتخاب ویژگی بررسی شده و سپس عملکرد مدل‌های یادگیری ماشین ارزیابی می‌گردد.

#### ۳-۱- نتایج انتخاب ویژگی‌ها

در این تحقیق، به‌منظور کاهش ابعاد فضای ویژگی و افزایش دقت و کارایی مدل‌های یادگیری ماشین، انتخاب ویژگی در چند مرحله به‌صورت ترکیبی انجام شده است. ابتدا به کمک تحلیل همبستگی، پارامترهای دارای هم‌بستگی بسیار بالا شناسایی و حذف شدند و در مراحل بعدی از روش‌های پیشرفته‌تری برای انتخاب مؤثرترین ویژگی‌ها استفاده شد. در گام نخست، با استفاده از ضریب همبستگی پیرسون، میزان وابستگی بین پارامترهای عددی مورد بررسی قرار گرفت. در صورتی که ضریب همبستگی بین دو ویژگی برابر یا بزرگ‌تر از  $0/9$  (یا کوچک‌تر از  $-0/9$ ) بود، تنها یکی از آن دو پارامتر حفظ شده و دیگری از مجموعه داده‌ها حذف شد. این تصمیم بر پایه این واقعیت اتخاذ شد که در صورت وجود چنین سطحی از هم‌بستگی، یکی از پارامترها عملاً می‌تواند دیگری را با دقت بالا تخمین بزند و تأثیر مستقلاً بر خروجی ندارد. در شکل ۳ ماتریس همبستگی پیرسون بین پارامترهای ورودی عددی ارائه شده است.

$$f(x) = w\phi(x) + b \quad (7)$$

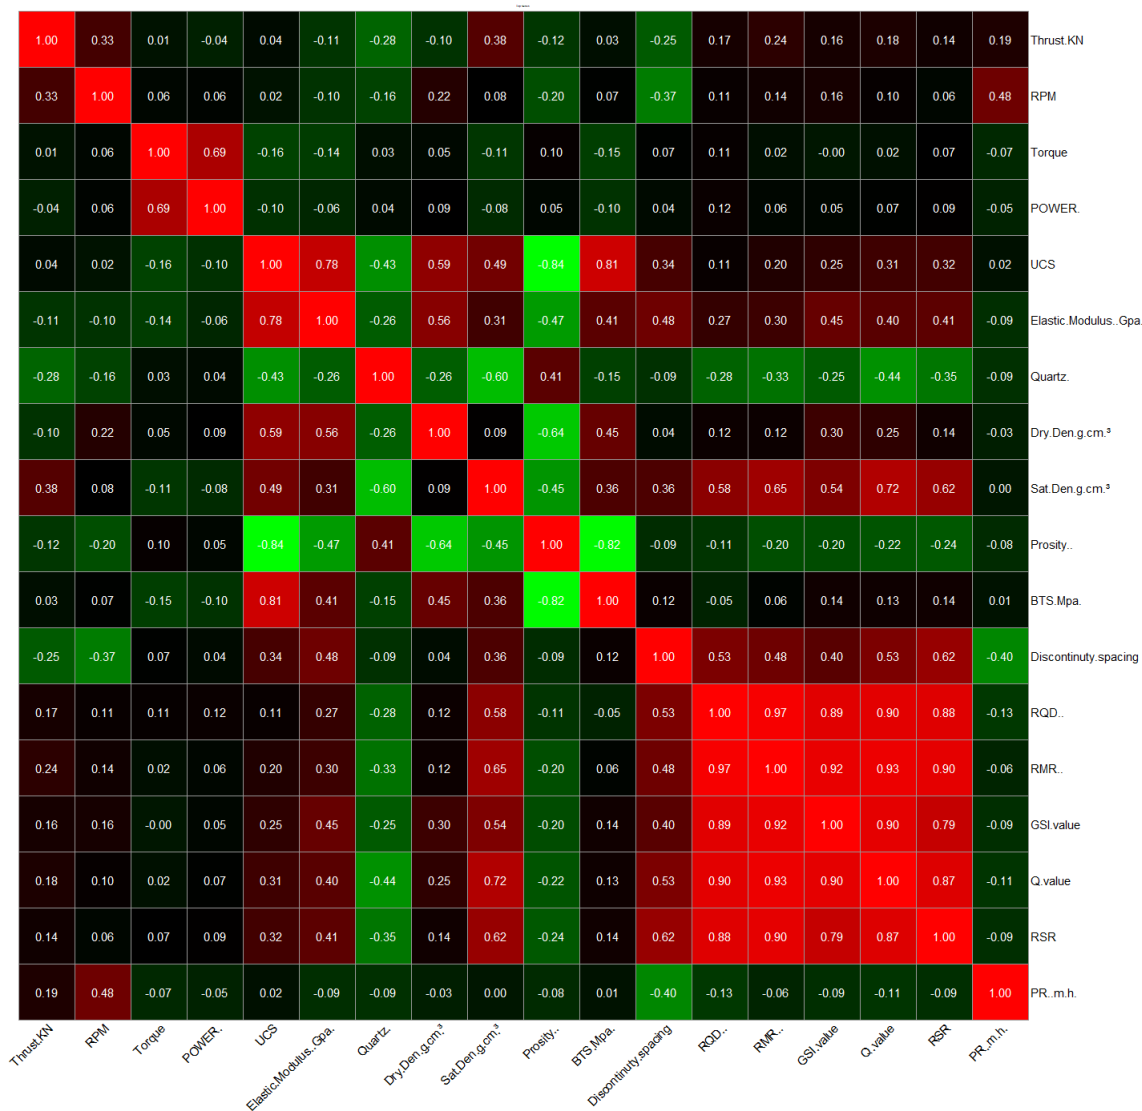
که در آن  $w$  و  $b$  به ترتیب بایاس یا عرض از مبدا و بردار وزن‌ها است و  $\phi(x)$  نگاشتی است که داده‌ها را از فضای ورودی به فضای ویژگی با ابعاد بالاتر منتقل می‌کند. هدف الگوریتم، یافتن مقادیر بهینه  $w$  و  $b$  است که تابع  $f(x)$  را طوری تنظیم کند که اختلاف بین خروجی مدل و مقادیر واقعی کمتر از یک حاشیه مشخص  $\epsilon$  باشد. برای کنترل انحراف‌های خارج از این ناحیه، از متغیرهای افزایشی  $\xi_i$  و  $\xi_i^*$  استفاده می‌شود. فرمول بهینه‌سازی مدل به صورت زیر تعریف می‌شود:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i^* + \xi_i) \quad (8)$$

که در آن  $C$  پارامتر جریمه برای کنترل تعادل بین دقت مدل و پیچیدگی آن است. برای مدل‌سازی روابط غیرخطی بین متغیرها، از توابع هسته‌ای ( $Kernel Functions$ ) استفاده می‌شود. این توابع امکان اعمال مدل خطی  $SVR$  را در فضای غیرخطی ویژگی‌ها فراهم می‌کنند. در نهایت، خروجی مدل به صورت ترکیبی از ضرایب وزن آموزش‌دیده و مقادیر تابع هسته برای نمونه‌های آموزشی به‌دست می‌آید.

#### ۳-۲-۴- الگوریتم جنگل تصادفی

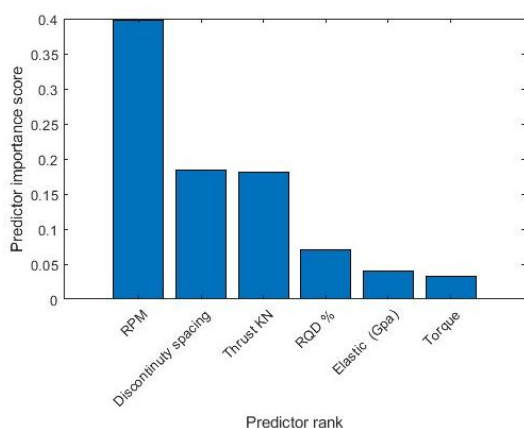
الگوریتم جنگل تصادفی ( $Random Forest$ ) یکی از روش‌های قدرتمند یادگیری ماشین مبتنی بر درخت‌های تصمیم و از نوع یادگیری جمعی ( $Ensemble Learning$ ) است که به‌ویژه در مدل‌سازی‌های رگرسیونی و طبقه‌بندی عملکرد بسیار مناسبی دارد. این روش برای افزایش دقت مدل و کاهش بیش‌برازش از ترکیب چندین درخت تصمیم استفاده می‌کند. در جنگل تصادفی، مجموعه‌ای از درخت‌های تصمیم به‌صورت مستقل آموزش داده می‌شوند. هر درخت با استفاده از یک زیرمجموعه تصادفی از داده‌های آموزشی (از طریق نمونه‌برداری با جایگزینی یا  $Bootstrapping$ ) ساخته می‌شود. علاوه بر این، در هر گره از درخت، به‌جای بررسی تمام ویژگی‌ها، فقط یک زیرمجموعه تصادفی از ویژگی‌ها برای انتخاب بهترین تقسیم بررسی می‌شود. این دو لایه تصادفی‌سازی (در داده‌ها و در ویژگی‌ها) منجر به تنوع بین




شکل ۳- تحلیل همبستگی پیرسون بین پارامترهای ورودی و همچنین پارامتر خروجی

بین هر ویژگی و خروجی مدل اندازه‌گیری شده و ویژگی‌هایی که بیشترین مقدار اطلاعات متقابل با نرخ نفوذ داشتند، رتبه‌بندی شدند. نتایج حاصل از این مرحله در شکل ۴ نمایش داده شده‌اند.

همان‌طور که در این شکل مشاهده می‌شود، ضریب همبستگی بین پارامترهای  $Q$  و  $GSI$ ،  $RSR$ ،  $RMR$  با شاخص کیفیت سنگ ( $RQD$ ) بیشتر از ۰/۹ بوده و لذا این چهار ویژگی به‌دلیل هم‌پوشانی اطلاعاتی از مجموعه حذف شدند. در نتیجه، از میان ۱۷ پارامتر عددی اولیه، ۴ پارامتر حذف شده و ۱۳ پارامتر باقی ماندند. در ادامه، برای ارزیابی میزان ارتباط مستقیم هر ویژگی باقی‌مانده با متغیر هدف (نرخ نفوذ)، از روش اطلاعات متقابل استفاده شد. در این روش، ارتباط آماری



جدول ۵- ویژگی‌های منتخب نهایی برای مدل‌های یادگیری ماشین



جدول ۴- رتبه‌بندی ویژگی‌ها بر اساس اطلاعات متقابل با نرخ نفوذ

### ۳-۲- ارزیابی عملکرد مدل‌های یادگیری ماشین

پس از تعیین ویژگی‌های مؤثر برای مدل‌سازی، در این بخش، عملکرد مدل‌های یادگیری ماشین در پیش‌بینی نرخ نفوذ دستگاه *TBM* مورد ارزیابی قرار می‌گیرد. در این مطالعه، چهار الگوریتم شامل نزدیک‌ترین همسایه (*KNN*)، درخت تصمیم (*DT*)، رگرسیون بردار پشتیبان (*SVR*) و جنگل تصادفی (*RF*) برای مدل‌سازی نرخ نفوذ به کار گرفته شده‌اند.

پایگاه داده نهایی پس از پردازش شامل ۱۲۸۵ رکورد بود. در مرحله‌ی پیش‌پردازش، ابتدا داده‌های پرت و مقادیر ناقص حذف شدند. سپس، برای یکنواخت‌سازی مقیاس متغیرها، نرمال‌سازی انجام شد تا تمامی ویژگی‌ها در بازه‌ی [۰, ۱] قرار گیرند. این اقدام مانع از غالب شدن متغیرهای با دامنه بزرگ‌تر بر فرآیند آموزش شده و شرایط برابر برای داده‌ها فراهم کرد. برای ارزیابی عملکرد مدل‌ها از روش اعتبارسنجی متقابل پنج‌بخشی (*5-fold Cross-Validation*) استفاده شد. در این روش داده‌ها به پنج زیرمجموعه تقریباً برابر تقسیم شدند. در هر تکرار، چهار زیرمجموعه برای آموزش و یک زیرمجموعه برای آزمون به کار رفت و این فرآیند پنج بار تکرار شد تا هر زیرمجموعه دقیقاً یک بار در نقش داده آزمون قرار گیرد. در نهایت، میانگین مقادیر شاخص‌ها به عنوان عملکرد نهایی مدل‌ها گزارش شد. این روش نسبت به تقسیم‌بندی ساده داده‌ها مزیت دارد زیرا همه‌ی نمونه‌ها در فرآیند آموزش و آزمون مشارکت می‌کنند و نتایج به‌طور میانگین پایدارتر و قابل‌تعمیم‌تر خواهند بود.

به‌منظور افزایش دقت مدل‌ها و جلوگیری از بیش‌برازش،

برای تقویت روند انتخاب ویژگی و دستیابی به ترکیبی بهینه از پارامترها، در گام بعدی از الگوریتم بهینه‌سازی گرگ خاکستری در نسخه دودویی استفاده شد. این الگوریتم با شبیه‌سازی رفتار اجتماعی گرگ‌ها، فضای جستجوی ویژگی‌ها را پیمایش کرده و مجموعه‌ای از ویژگی‌ها را تعیین کرد که منجر به حداکثر دقت پیش‌بینی و حداقل تعداد ورودی شدند. در این فرایند، موقعیت هر ویژگی به صورت متغیر دودویی (۰ یا ۱) در نظر گرفته شد و تابع هدف الگوریتم برای بیشینه‌سازی دقت مدل و کاهش پیچیدگی طراحی گردید. در نهایت، با ترکیب نتایج دو روش اطلاعات متقابل و الگوریتم گرگ خاکستری، ۷ پارامتر نهایی برای ورود به مدل‌های یادگیری ماشین انتخاب شدند. این پارامترها که در شکل ۵ نمایش داده شده‌اند، شامل موارد زیر هستند:

- نیروی محوری پیشران (*Thrust*)
- گشتاور (*Torque*)
- سرعت چرخش تاج حفار (*Cutterhead Rotation Speed*)
- مدول الاستیسیته (*Elastic Modulus*)
- فاصله درزه‌ها (*Discontinuity Spacing*)
- شاخص کیفیت سنگ (*RQD*)
- نرخ نفوذ گذشته (*Previous Penetration Rate*)

این ویژگی‌ها به عنوان مؤثرترین متغیرهای پیش‌بینی نرخ نفوذ شناسایی شده و در مراحل بعدی برای آموزش مدل‌ها مورد استفاده قرار گرفتند.

ضریب تعیین ( $R^2$ )

$$R^2 = 1 - \frac{\sum(y_{act} - y_{pre})^2}{\sum(y_{act} - \bar{y}_{act})^2} \quad (11)$$

خطای مربع نسبی ( $RSE$ )

$$RSE = \frac{\sum(y_{pre} - y_{act})^2}{\sum(y_{act} - \bar{y}_{act})^2} \quad (12)$$

توزیع امتیاز واریانس ( $EVS$ )

$$EVS = 1 - \frac{std(y_{pre} - y_{act})}{std(y_{act})} \quad (13)$$

در این روابط،  $y_{act}$  مقدار واقعی،  $y_{pre}$  مقدار پیش‌بینی شده،  $\bar{y}_{act}$  میانگین مقادیر واقعی و  $n$  تعداد نمونه‌ها است. در ادامه، نتایج عددی حاصل از اجرای مدل‌ها بر اساس این معیارها گزارش و مقایسه خواهند شد.

تنظیم ابرپارامترهای الگوریتم‌های یادگیری ماشین با استفاده از الگوریتم گرگ خاکستری انجام شد. در این روش، الگوریتم با شبیه‌سازی رفتار شکار گروهی گرگ‌ها، فضای جستجوی ابرپارامترها را کاوش کرده و مقادیر بهینه را تعیین می‌کند. مقادیر نهایی ابرپارامترهای بهینه‌شده برای هر الگوریتم در جدول ۲ ارائه شده است. برای سنجش دقت مدل‌ها، از شاخص‌های آماری استفاده شده است که روابط آن‌ها به شرح زیر است:

جذر میانگین مربعات خطا ( $RMSE$ )

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{pre} - y_{act})^2}{n}} \quad (9)$$

میانگین قدرمطلق خطا ( $MAE$ )

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{pre} - y_{act}}{y_{act}} \right| \times 100 \quad (10)$$

جدول ۲- مقادیر بهینه‌ی ابرپارامترهای مدل‌های یادگیری ماشین


الگوریتم	ابریارامترهای بهینه‌شده
مدل نزدیک‌ترین همسایه (KNN)	تعداد همسایگان $k = 10$
رگرسیون بردار پشتیبان (SVR)	هسته (Kernel) = تابع پایه شعاعی (RBF) پارامتر جریمه $C = 10/5$ اپسیلون $\epsilon = 0/1$ مقیاس هسته $\gamma = 0/5$
درخت تصمیم (DT)	حداقل اندازه گره والد $(MinParentSize) = 2$ حداقل اندازه برگ $(MinLeafSize) = 2$
جنگل تصادفی (RF)	تعداد درختان $(NumTrees) = 500$ حداقل اندازه برگ $(MinLeafSize) = 2$ تعداد ویژگی‌های نمونه‌گیری شده در هر انشعاب $= 3$

### ۳-۲-۱- ارزیابی مدل درخت تصمیم

است. در مرحله آموزش، مقدار ضریب همبستگی میان مقادیر واقعی و پیش‌بینی شده برابر با  $0/96$  به دست آمد (شکل ۶) و مقدار  $RMSE$  تنها  $0/002$  حاصل شد که بیانگر دقت بسیار بالای مدل در بازسازی داده‌های آموزشی است.

در ادامه، عملکرد مدل درخت تصمیم در پیش‌بینی نرخ نفوذ دستگاه TBM بر اساس داده‌های آموزش و آزمون بررسی شده است. ساختار درخت نهایی، که تحت کنترل ابرپارامترهای بهینه‌شده قرار داشت، نشان‌دهنده توانایی مدل برای انطباق با الگوهای پیچیده و غیرخطی موجود در داده‌های آموزشی


آزمون انجام شده است. داده‌های آموزش صرفاً به‌عنوان مرجع برای یافتن همسایگان استفاده شده‌اند و مدل در حین پیش‌بینی، هیچ پارامتر آموزشی از قبل آموخته‌شده‌ای ندارد. شکل ۸ نمایی از همبستگی میان خروجی پیش‌بینی‌شده و نرخ نفوذ واقعی را نشان می‌دهد. در این حالت، مقدار  $R$  برابر با  $0/96$  و  $RMSE$  معادل  $0/22$  بدست آمد که نشان‌دهنده عملکرد رضایت‌بخش مدل در بازتولید روند داده‌های واقعی است. به‌طور کلی،  $KNN$  به‌عنوان روشی ساده و غیرپارامتری، موفق شد رفتار نرخ نفوذ را تا حد مناسبی بازسازی کند، هرچند ممکن است حساسیت بیشتری نسبت به داده‌های نویزی داشته باشد.



شکل ۶- ضریب همبستگی بین مقادیر واقعی و

پیش‌بینی‌شده مدل درخت تصمیم در مرحله آموزش

در مرحله آزمون نیز مدل عملکرد خوبی از خود نشان داد؛ به‌طوری‌که مقدار  $R$  معادل  $0/95$  و  $RMSE$  برابر با  $0/22$  بدست آمد. شکل ۷ ضریب همبستگی در مرحله آزمون را نمایش می‌دهد.




شکل ۸- ضریب همبستگی بین مقادیر واقعی و

پیش‌بینی‌شده مدل نزدیک‌ترین همسایه در مرحله آزمون

### ۳-۲-۳- ارزیابی مدل رگرسیون بردار پشتیبان

عملکرد مدل رگرسیون بردار پشتیبان نیز در هر دو مرحله آموزش و آزمون بررسی شده است. نتایج به‌دست‌آمده حاکی از دقت بالا در آموزش است؛ به‌طوری‌که مقدار  $R$  برابر با  $0/97$  (شکل ۹) و  $RMSE$  معادل  $0/1$  گزارش شده است. در مرحله آزمون، مقدار ضریب همبستگی به  $0/94$  کاهش یافت (شکل ۱۰)، در حالی‌که مقدار  $RMSE$  به  $0/07$  رسید. این اعداد نشان‌دهنده توانایی مدل در تعمیم‌پذیری به داده‌های جدید هستند و در عین حال از دقت مناسب در فاز آموزش نیز حکایت دارند.




شکل ۷- ضریب همبستگی بین مقادیر واقعی و

پیش‌بینی‌شده مدل درخت تصمیم در مرحله آزمون


### ۳-۲-۳- ارزیابی مدل نزدیک‌ترین همسایه

با توجه به ذات الگوریتم نزدیک‌ترین همسایه ( $KNN$ ) که فاقد فرآیند آموزش صریح است، ارزیابی عملکرد آن فقط در مرحله


تنها ۰/۰۱ حاصل شد. در مرحله آزمون نیز، نتایج مطلوبی حاصل شد به گونه‌ای که ضریب همبستگی برابر ۰/۹۶ (شکل ۱۲) و مقدار  $RMSE$  برابر با ۰/۰۵ به دست آمده است. این نتایج بیانگر تعمیم‌پذیری مناسب مدل و پایداری آن در مواجهه با داده‌های جدید است. اختلاف محدود بین دقت مدل در مراحل آموزش و آزمون نیز نشان می‌دهد که الگوریتم جنگل تصادفی تا حد زیادی از بیش‌برازش جلوگیری کرده است.




شکل ۱۱- ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده مدل جنگل تصادفی در مرحله آموزش



شکل ۱۲- ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده مدل جنگل تصادفی در مرحله آزمون



شکل ۹- ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده رگرسیون بردار پشتیبان در مرحله آموزش



شکل ۱۰- ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده مدل رگرسیون بردار پشتیبان در مرحله آزمون

### ۳-۲-۴- ارزیابی مدل جنگل تصادفی

مدل جنگل تصادفی به عنوان یکی از قدرتمندترین الگوریتم‌های یادگیری گروهی، ترکیبی از درخت‌های تصمیم متعدد است که پیش‌بینی نهایی را با میانگین‌گیری از خروجی آن‌ها انجام می‌دهد. مطابق با شکل ۱۱، در مرحله آموزش به ضریب همبستگی برابر با ۰/۹۷ دست یافت و مقدار  $RMSE$

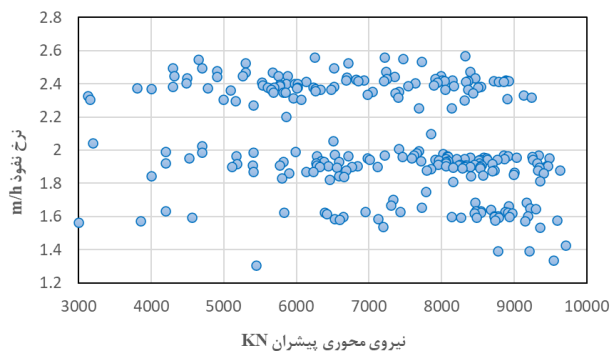
## ۳-۲-۵- مقایسه عملکرد مدل‌ها

برای ارزیابی نهایی و انتخاب دقیق‌ترین مدل، عملکرد چهار الگوریتم یادگیری ماشین مورد بررسی، با استفاده از مجموعه‌ای از معیارهای عددی شامل  $RMSE$ ،  $MAE$ ،  $RSE$ ، ضریب تعیین ( $R^2$ )، و مقدار توضیح داده‌شده واریانس ( $EVS$ )


ارزیابی و امتیازدهی شد. به‌منظور ایجاد امکان مقایسه یکپارچه، برای هر معیار، الگوریتم‌ها بین ۱ تا ۴ امتیاز دریافت کردند؛ به‌طوری که بهترین مقدار برای هر معیار، بالاترین امتیاز (۴) را به خود اختصاص داد. نتایج این امتیازدهی در جدول ۳ ارائه شده است.

جدول ۳- ارزیابی عددی و امتیازدهی الگوریتم‌های یادگیری ماشین برای پیش‌بینی نرخ نفوذ در مرحله آزمون

الگوریتم	$RMSE$ امتیاز	$MAE$ امتیاز	$RSE$ امتیاز	$R^2$ امتیاز	$EVS$ امتیاز	امتیاز جمع
DT	۰/۲۲	۲	۰/۲۱	۲	۰/۰۵	۱۱
KNN	۰/۲۲	۲	۰/۲۱	۲	۰/۰۱	۱۰
SVR	۰/۰۷	۳	۰/۰۶	۱	۰/۱۵	۱۳
RF	۰/۰۵	۴	۰/۰۴	۴	۰/۳۵	۲۰



شکل ۱۳- پراکندگی نرخ نفوذ در برابر نیروی محوری پیشران در شرایط زمین ثابت



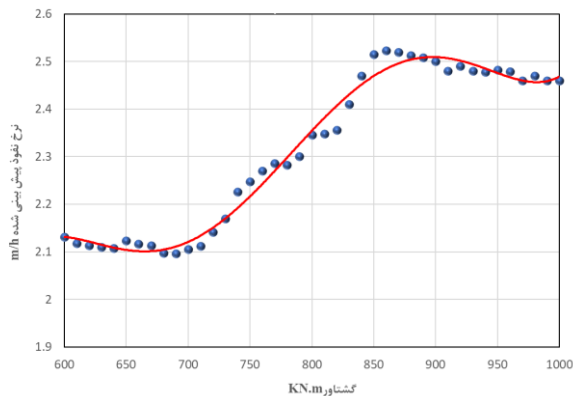
شکل ۱۴- پراکندگی نرخ نفوذ در برابر گشتاور در شرایط زمین ثابت

مطابق این جدول، الگوریتم جنگل تصادفی ( $RF$ ) با کسب مجموع ۲۰ امتیاز از حداکثر ممکن ۲۰، بهترین عملکرد را در میان مدل‌های بررسی شده داشته است. پس از آن، الگوریتم  $SVR$  با ۱۶ امتیاز، در رتبه دوم قرار گرفت. مدل‌های درخت تصمیم و  $KNN$  نیز به ترتیب با ۱۲ و ۹ امتیاز در جایگاه‌های بعدی قرار گرفتند.


۳-۲-۶- تحلیل حساسیت پارامترهای عملیاتی  $TBM$ 

یکی از اهداف اصلی در به‌کارگیری مدل‌های یادگیری ماشین در پروژه‌های حفاری مکانیزه می‌تواند ارائه ابزارهایی برای پشتیبانی تصمیم اپراتور در حین حفاری باشد. در این راستا، پس از انتخاب مدل جنگل تصادفی به‌عنوان مدل برتر، از آن برای تحلیل حساسیت نسبت به پارامترهای عملیاتی دستگاه  $TBM$  در شرایط زمین‌شناسی ثابت استفاده شده است.


پیش از اجرای تحلیل حساسیت، برای بررسی مقدماتی، پراکندگی نرخ نفوذ در برابر تغییرات جداگانه هر یک از پارامترهای عملیاتی شامل نیروی محوری پیشران، گشتاور، و سرعت چرخش کله حفار تحلیل گردید (شکل‌های ۱۳ تا ۱۵).



شکل ۱۷- پیش‌بینی نرخ نفوذ با تغییر گشتاور




شکل ۱۵- پراکندگی نرخ نفوذ در برابر سرعت چرخش کله حفار در شرایط زمین ثابت



شکل ۱۸- پیش‌بینی نرخ نفوذ با تغییر سرعت چرخش تاج حفار

این نمودارها نشان می‌دهند که رابطه‌ی مشخص و یکنواختی میان هر پارامتر به‌تنهایی و نرخ نفوذ وجود ندارد. این موضوع بیانگر آن است که پارامترهای عملیاتی به‌صورت متقابل بر یکدیگر اثر می‌گذارند و تنظیم مستقل آن‌ها نمی‌تواند منجر به عملکرد بهینه *TBM* شود. به همین دلیل، از تحلیل حساسیت چندمتغیره با استفاده از مدل آموزش‌یافته *RF* بهره گرفته شد. در این تحلیل، با استفاده از سه مجموعه داده که دارای شرایط زمین‌شناسی یکسان بودند، تغییرات سه پارامتر عملیاتی یادشده بررسی و تأثیر آن‌ها بر نرخ نفوذ پیش‌بینی‌شده ارزیابی شد. نتایج این تحلیل در شکل‌های ۱۶ تا ۱۸ نمایش داده شده‌اند.



شکل ۱۶- پیش‌بینی نرخ نفوذ با تغییر نیروی محوری پیشران

بر اساس این نتایج، افزایش نیروی محوری پیشران در ابتدا منجر به افزایش نرخ نفوذ می‌شود؛ اما پس از گذشتن از مقدار بهینه، ادامه افزایش آن ممکن است باعث کاهش نرخ نفوذ گردد. این کاهش می‌تواند به دلیل اعمال بار بیش‌ازحد و ایجاد مشکلاتی نظیر گیر کردن ابزار برش‌دهنده باشد. همچنین ممکن است ناشی از افزایش غیرمتوازن نیروی پیشران نسبت به گشتاور باشد؛ شرایطی که در آن اپراتور بدون توجه به هماهنگی پارامترها، تنها یکی از آن‌ها را افزایش داده است. رفتار مشابهی در مورد گشتاور نیز مشاهده شد؛ به طوری که تا یک مقدار بهینه باعث افزایش نرخ نفوذ شده، اما پس از آن، کاهش جزئی در عملکرد دستگاه رخ داده است. این نتایج نشان می‌دهند که نیروی پیشران و گشتاور باید به‌صورت هماهنگ و متناسب تنظیم شوند تا عملکرد بهینه حاصل

بالا تری در پیش‌بینی دارد و در برابر بیش‌برازش مقاوم است. در ادامه، تحلیل حساسیت مبتنی بر مدل  $RF$  نشان داد که تنظیم بهینه و متوازن پارامترهای عملیاتی (به‌ویژه نیروی پیشران و گشتاور) نقش مهمی در کنترل نرخ نفوذ دارد، در حالی که سرعت چرخش تأثیری تقریباً یکنواخت و مثبت دارد. این یافته‌ها نشان می‌دهند که مدل‌های یادگیری ماشین نه تنها در پیش‌بینی عملکرد، بلکه در ارائه توصیه‌های عملیاتی برای بهبود راندمان حفاری نیز کاربردی هستند. به‌طور کلی، رویکرد ترکیبی ارائه شده در این تحقیق می‌تواند به‌عنوان الگویی برای طراحی سیستم‌های تصمیم‌یار در پروژه‌های حفاری مکانیزه مورد استفاده قرار گیرد.

در این پژوهش به تحلیل عدم قطعیت برای پیش‌بینی‌های مدل (مانند محاسبه باند اطمینان) پرداخته نشده است. همچنین، تحلیل حساسیت انجام شده بر روی اثرات منفرد پارامترها متمرکز بوده و اثرات متقابل بین پارامترهای عملیاتی به‌طور سیستماتیک مورد بررسی قرار نگرفت. بر اساس این محدودیت‌ها، زمینه‌های پژوهشی آتی از جمله توسعه مدل‌های عمومی‌تر با ادغام داده‌های چندین پروژه، انجام تحلیل عدم قطعیت، و بررسی اثرات متقابل پارامترها پیشنهاد می‌شود.

گردد. در مقابل، بررسی تغییرات سرعت چرخش نشان داد که این پارامتر به‌طور یکنواخت و مثبت بر نرخ نفوذ تأثیر می‌گذارد. به‌علاوه، مقادیر حداکثر نرخ نفوذ حاصل از این تحلیل با مقادیر مشاهده شده در شکل‌های ۱۳ تا ۱۵ هم‌خوانی دارند. در مجموع، این تحلیل نشان می‌دهد که مدل‌های یادگیری ماشین، به‌ویژه مدل  $RF$ ، می‌توانند ابزارهای قدرتمندی برای تحلیل حساسیت و ارائه راهکارهای بهینه‌سازی تنظیمات عملیاتی  $TBM$  فراهم کنند و در بهبود عملکرد میدانی حفاری نقش مؤثری داشته باشند.

#### ۴- نتیجه‌گیری

مطالعه حاضر با هدف افزایش دقت پیش‌بینی نرخ نفوذ  $TBM$  و تحلیل حساسیت پارامترهای کلیدی عملکرد ماشین حفاری، به مقایسه چهار الگوریتم یادگیری ماشین بر مبنای داده‌های واقعی پروژه تونل زاگرس پرداخته است. با ترکیب دو روش انتخاب ویژگی (اطلاعات متقابل و بهینه‌سازی گرگ خاکستری)، مجموعه‌ای از پارامترهای مؤثر استخراج شد که مبنای آموزش مدل‌ها قرار گرفت. نتایج ارزیابی نشان داد که مدل جنگل تصادفی ( $RF$ ) نسبت به سایر الگوریتم‌ها دقت

#### ۵- منابع

1. Maidl B, Schmid L, Ritz W, Herrenknecht M. *Hardrock tunnel boring machines*. John Wiley & Sons; 2008.
2. Askilrud OG. Development of TBM technology for hard rock conditions. *Norwegian TBM Tunnelling*. 1998;35.
3. Rostami J. Design optimization, performance prediction and economic analysis of tunnel boring machines for the construction of the proposed yucca mountain nuclear waste repository. 1992.
4. Gong Q, Jiao Y, Zhao J. Numerical modelling of the effects of joint spacing on rock fragmentation by TBM cutters. *Tunnelling and Underground Space Technology*. 2006;21(1):46-55.
5. Eftekhari S, Baghbanan A, Bagherpour R. Numerical modeling of the effect of geometrical parameters of fractures on penetration rate of TBM in fractured rock mass. *Journal of Mining Engineering*. 2013;8(18):1-12.
6. Eftekhari M, Baghbanan A, Bagherpour R. The effect of fracture patterns on penetration rate of TBM in fractured rock mass using probabilistic numerical approach. *Arabian Journal of Geosciences*. 2014;7(12):5321-5331.
7. Pourhashemi SM, Ahangari K, Hassanpour J, Eftekhari SM. Evaluating the influence of engineering geological parameters on TBM performance during grinding process in limestone strata. *Bulletin of Engineering Geology and the Environment*. 2021;80(4):3023-3040.
8. Pourhashemi SM, Ahangari K, Hassanpour J, Eftekhari SM. TBM performance analysis in very strong and massive rocks; case study: Kerman water conveyance tunnel project, Iran. *Geomechanics and Geoengineering*. 2022;17(4):1110-1122.
9. Pourhashemi SM, Ahangari K, Hassanpour J, Eftekhari SM. Penetration rate analysis for tunnel boring machine in grinding conditions. *Journal of Mining Engineering*. 2021;16(52):79-88.

10. Pourhashemi SM, Ahangari K, Hassanpour J, Eftekhari SM. Analysis of Grinding and Chipping Processes beneath Disc Cutters of Hard Rock Tunnel Boring Machines (Case study: Uma-Oya water Conveyance Tunnel, SriLanka). *Journal of Mining and Environment*. 2021;12(1):281-297.
11. Eftekhari SM, Bastami M. Effect of the replacement of cutting tools on the performance of TBM in Tehran metro line 6. *Journal of Analytical and Numerical Methods in Mining Engineering*. 2020;10(24):63-76.
12. Bruland A. Hard rock tunnel boring advance rate and cutter wear. *Trondheim: Norwegian Institute of Technology*. 1999.
13. Ozdemir L. CSM computer model for TBM performance prediction. *Colorado School of Mines*. 2003.
14. Nilsen B, Ozdemir L. Hard rock tunnel boring prediction and field performance. Paper presented at: Proceedings of the rapid excavation and tunneling conference1993.
15. Barton N. TBM performance estimation in rock using QTBM. *T & T international*. 1999;31(9):30-34.
16. Sapigni M, Berti M, Bethaz E, Busillo A, Cardone G. TBM performance estimation using rock mass classifications. *International Journal of Rock Mechanics and Mining Sciences*. 2002;39(6):771-788.
17. Hamidi JK, Shahriar K, Rezai B, Rostami J. Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system. *Tunnelling and Underground Space Technology*. 2010;25(4):333-345.
18. Farrokh E, Rostami J, Laughton C. Study of various models for estimation of penetration rate of hard rock TBMs. *Tunnelling and Underground Space Technology*. 2012;30:110-123.
19. Eftekhari M, Baghbanan A, Bayati M. Predicting penetration rate of a tunnel boring machine using artificial neural network. Paper presented at: ISRM International Symposium-Asian Rock Mechanics Symposium2010.
20. Yagiz S, Karahan H. Prediction of hard rock TBM penetration rate using particle swarm optimization. *International Journal of Rock Mechanics and Mining Sciences*. 2011;48(3):427-433.
21. Maher J. A Machine learning approach to predicting and maximizing penetration rates in Earth Pressure Balance Tunnel Boring Machines. *Special Interest Group in Computer Science Education (SIGCSE)*. 2013.
22. Mokhtarian M, Eftekhari M, Baghbanan A. Application of principal component analysis in prediction of penetration rate of TBM using artificial neural networks. *Journal of Analytical and Numerical Methods in Mining Engineering*. 2014;3(6):33-43.
23. Yagiz S, Karahan H. Application of various optimization techniques and comparison of their performances for predicting TBM penetration rate in rock mass. *International Journal of Rock Mechanics and Mining Sciences*. 2015;80:308-315.
24. Xu H, Zhou J, G. Asteris P, Jahed Armaghani D, Tahir MM. Supervised machine learning techniques to the prediction of tunnel boring machine penetration rate. *Applied sciences*. 2019;9(18):3715.
25. Yang H, Wang Z, Song K. A new hybrid grey wolf optimizer-feature weighted-multiple kernel-support vector regression technique to predict TBM performance. *Engineering with Computers*. 2022;38(3):2469-2485.
26. Li J, Li P, Guo D, Li X, Chen Z. Advanced prediction of tunnel boring machine performance based on big data. *Geoscience Frontiers*. 2021;12(1):331-338.
27. Yang J, Yagiz S, Liu Y-J, Laouafa F. Comprehensive evaluation of machine learning algorithms applied to TBM performance prediction. *Underground space*. 2022;7(1):37-49.
28. Eftekhari M, Eftekhari N. A predictive model for estimating the TBM penetration rate based on hybrid ICA-ANN and DEA-AHP algorithms. *Geotechnical and Geological Engineering*. 2022;40(6):3191-3209.
29. Latif K, Sharafat A, Seo J. Digital Twin-Driven Framework for TBM Performance Prediction, Visualization, and Monitoring through Machine Learning. *Applied Sciences*. 2023;13(20):11435.
30. Yu Z, Li C, Zhou J. Tunnel Boring Machine Performance Prediction Using Supervised Learning Method and Swarm Intelligence Algorithm. *Mathematics*. 2023;11(20):4237.
31. Hu W, Wu K, Liu H, Luo W, Li X, Guan P. Interpretable machine learning approach for TBM tunnel crown convergence prediction with Bayesian optimization. *Frontiers in Earth Science*. 2025;13:1608468.
32. Li L, Liu Z, Fang X, Qi W. Multi-step real-time prediction of hard-rock TBM penetration rate combining temporal convolutional network and squeeze-and-excitation block. *Scientific Reports*. 2024;14(1):14326.
33. Zhang M, Ji A, Zhou C, Ding Y, Wang L. Real-time prediction of TBM penetration rates using a transformer-based ensemble deep learning model. *Automation in Construction*. 2024;168:105793.
34. Kilic K, Narihiro O, Ikeda H, Adachi T, Kawamura Y. Soft ground micro TBM jack speed and torque prediction using machine learning models through operator data and micro TBM-log data synchronization. *Scientific Reports*. 2024;14:9728.
35. Abbasi M, Namadchi AH, Abbasi M, Abbasi M. Evaluation of machine learning algorithms in tunnel boring machine applications: a case study in Mashhad metro line 3. *International Journal of Geo-Engineering*. 2024;15(1):28.
36. Ghorbani E, Yagiz S. Estimating the penetration rate of tunnel boring machines via gradient boosting

- algorithms. *Engineering Applications of Artificial Intelligence*. 2024;136:108985.
37. Liu J, Liang F, Wei K, Zuo C. Prediction Model for Cutterhead Rotation Speed Based on Dimensional Analysis and Elastic Net Regression. *Applied Sciences*. 2025;15(3):1298.
۳۸. ساحل مم. مهندسين مشاور ساحل، مطالعات زمين شناسی مهندسی مسير تونل، گزارش. ۲۰۲۶، ۱۳۸۶.
39. Peng H, Long F, Ding C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on pattern analysis and machine intelligence*. 2005;27(8):1226-1238.
40. Singh H, Saxena S, Sharma H, et al. An integrative TLBO-driven hybrid grey wolf optimizer for the efficient resolution of multi-dimensional, nonlinear engineering problems. *Scientific Reports*. 2025;15(1):11205.
41. Cover T, Hart P. Nearest neighbor pattern classification. *IEEE transactions on information theory*. 1967;13(1):21-27.
42. Quinlan JR. Induction of decision trees. *Machine learning*. 1986;1(1):81-106.
43. Cortes C, Vapnik V. Support-vector networks. *Machine learning*. 1995;20(3):273-297.
44. Breiman L. Random forests. *Machine learning*. 2001;45(1):5-32.

## Assessing the Impact of TBM Operational Parameters on Penetration Rate through Machine Learning and Multi-Stage Feature Selection

Armin Fallahi<sup>1</sup>, Seyed Mosleh Eftekhari<sup>1\*</sup>, Ehsan Taheri<sup>1</sup>

1. Faculty of Mining and Materials, Tarbiat Modares University, Tehran, Iran

Received: 09 April 2025 Accepted: 18 June 2025

(Corresponding Author: mosleh.eftekhari@modares.ac.ir)

### Keywords

**Tunnel Boring Machine (TBM)**  
**Machine Learning**  
**Penetration Rate Prediction**  
**Sensitivity Analysis**  
**Feature Selection**  
**Operational Parameters**

### Final English Extended Abstract

#### Summary

This study presents a machine learning (ML)-based framework for predicting the penetration rate (PR) of tunnel boring machines (TBMs), using real operational data from the Zagros long tunnel project. A hybrid feature selection approach combining mutual information (MI) and the grey wolf optimizer (GWO) was applied to identify the most influential parameters from 17 initial features. Four ML algorithms—K-nearest neighbors (KNN), support vector machine (SVM), decision tree (DT), and random forest (RF)—were evaluated using a five-fold cross-validation procedure. Among them, RF achieved the best performance with an  $R^2$  of approximately 0.93 and RMSE of 0.05. Sensitivity analysis using the RF model revealed that balanced adjustment of thrust force, torque, and cutterhead rotation speed plays a key role in optimizing TBM performance. The results demonstrate the potential of ML models as effective decision-support tools in mechanized tunneling.

### Introduction

The penetration rate (PR) is a fundamental indicator of TBM performance and directly influences project cost and schedule. Accurate prediction of PR is therefore essential for planning and operational optimization. Previous studies often compared a limited number of ML algorithms without comprehensive feature selection or sensitivity analysis of operational parameters. This research addresses these gaps by applying a multi-stage feature selection process and evaluating multiple ML models to improve prediction reliability and provide practical insights for TBM operation.

### Methodology and Approaches

A dataset of 1258 records from the Zagros tunnel project was compiled, covering both rock mass properties and machine operational variables. Initially, 17 features were considered, from which the most relevant were selected using a hybrid MI–GWO approach. Four ML algorithms (KNN, SVM, DT, and RF) were then trained and validated. Model performance was measured using RMSE, MAE, and  $R^2$ , with five-fold cross-validation ensuring robustness and minimizing dependency on a single train-test split. Finally, sensitivity analysis was carried out using the RF model, identified as the best-performing algorithm.

### Results and Conclusions

The RF model outperformed other algorithms, achieving an  $R^2$  of about 0.93 and RMSE of 0.05, indicating high predictive accuracy and generalization capability. Sensitivity analysis highlighted the crucial role of operational parameters, particularly thrust force, torque, and cutterhead rotation speed. Results demonstrated that these parameters have interactive effects, and their balanced adjustment is essential for achieving optimal PR. Overall, the study provides both methodological advances—through integrated feature selection and robust ML modeling—and practical contributions by offering guidance for TBM operators to optimize drilling strategies.