

مقایسه قابلیت ها و کارآیی روش های مختلف در پیش بینی عملکرد ماشین حفر تونل و پیشنهاد بهترین روش برای ارائه مدل

سیدامیراسعد فاطمی^{۱*}؛ مرتضی احمدی^۲؛ محمدجواد آذین فر^۳؛ امین چمنی^۴

۱- استادیار گروه مهندسی معدن، عضو هسته پژوهشی مکانیک سنگ، دانشکده مهندسی، دانشگاه سیستان و بلوچستان

۲- استادیار گروه مهندسی معدن، دانشکده مهندسی مواد و معدن، دانشگاه تربیت مدرس

۳- استادیار گروه مهندسی معدن، عضو هسته پژوهشی مکانیک سنگ، دانشکده مهندسی، دانشگاه سیستان و بلوچستان

۴- استادیار گروه مهندسی معدن، دانشکده مهندسی، دانشگاه بیرجند

پذیرش: ۱۴۰۱/۰۶/۰۱

دریافت: ۱۴۰۰/۱۲/۰۱

چکیده

برآورد نرخ نفوذ ماشین در سنگ اولین و مهمترین گام در پیش بینی زمان اجرای حفر مکانیزه تونل است. در چند دهه اخیر مطالعات زیادی برای پیش بینی نفوذ *TBM* انجام شده است که در آنها از روش های مختلفی استفاده شده است. در این تحقیق روش های مختلف استفاده شده برای پیشنهاد یک رابطه برای پیش بینی نرخ نفوذ پیاده سازی شد تا نقاط ضعف و قوت آن ها با هم مقایسه شوند. به همین منظور پایگاه داده ای از اطلاعات حین حفر تونل گلاب شامل پارامترهای عملیاتی ماشین و ژئومکانیکی سنگ ایجاد شد. با استفاده از اطلاعات پایگاه داده ایجاد شده، میزان تاثیر پارامترهای مختلف ژئومکانیکی بر عملکرد ماشین بررسی شد که تاثیر فاصله داری درزه ها و *RQD* بیشتر از سایر پارامترها بود و مقاومت فشاری تک محوری تاثیر کمی بر مقدار نفوذ داشت. با استفاده از روش های مختلف تحلیل رگرسیون روابطی برای پیش بینی نرخ نفوذ ارائه شد که روش *SMO* رگرسیون دقت بالاتری نشان داد، برای تعیین ضرایب پارامترهای موثر بر عملکرد ماشین از الگوریتم *PSO* نیز بهره گرفته شد. بعلاوه از روش شبکه عصبی مصنوعی نیز استفاده شد که اگرچه دقت بالاتری از سایر روش ها داشت اما به علت عدم ارائه یک رابطه مشخص کارآیی کمتری نسبت به سایر روش ها دارد. با کمک روش های یادگیری ماشین و ساخت درخت تصمیم و با اولویت دهی به پارامترهای ژئومکانیکی موثرتر، یک سیستم طبقه بندی برای پیش بینی نرخ نفوذ پیشنهاد شده است. با توجه به نتایج بدست آمده و مقایسه روش های استفاده شده، بهترین کارآیی را روش استفاده از درخت تصمیم نشان داد و نتیجه حاصله به عنوان یک سیستم رده بندی پیش بینی نرخ نفوذ پیشنهاد شد

واژگان کلیدی

عملکرد ماشین حفر تونل، نرخ نفوذ، مدل پیش بینی، تونل گلاب

۱- مقدمه

در نتیجه علاقه روز افزون به توسعه فضاهای زیرزمینی، حفر تونل ها نقش مهم تری نسبت به گذشته در فعالیتهای مهندسی ایفا می کنند. تونل های زیادی در مهندسی هیدرولیک (تونل های انتقال آب، تونل های زهکشی و تونل های فاضلاب) و در مهندسی ترافیک (تونل های جاده ای و مترو) در حال ساخت هستند. بنابراین،

تلاش های علمی قابل توجهی برای توسعه روش ها، تکنیک ها و نظریه های پیشرفته برای بهبود ایمنی و کارایی ساخت وسازهای تونل صورت گرفته است. در دهه های اخیر، ماشین حفاری تونل (*TBM*) به طور گسترده در ساخت و سازهای تونل، به طور کلی، و تونل های طولانی به طور خاص، به دلیل عملکرد بسیار برتر آن نسبت به روش سنتی حفاری انفجاری و تونل زنی *NATM* استفاده شده است.

*نویسنده مسئول: استادیار دانشیار دانشگاه سیستان بلوچستان،

پست الکترونیک: afatemi@eng.usb.ac.ir

(ANN) [۱۷-۲۰]، ماشین بردار پشتیبان (SVM) [۲۱، ۲۲]، روش فازی [۲۳-۲۶]، روشهای هوشمند (الگوریتم ژنتیک، یادگیری ماشین، PSO و ...) [۲۷] و روشهای ترکیبی مانند روش فازی-عصبی، استنتاج عصبی فازی تطبیقی (ANFIS) [۲۸-۳۳]، برای پیش‌بینی نرخ نفوذ استفاده شده‌اند. این مدل‌ها یک مزیت معمولی دارند که می‌توانند رابطه غیرخطی پیچیده‌ای را بین نرخ نفوذ و عوامل مؤثر مختلف بدون نیاز به در نظر گرفتن فرآیندهای مکانیکی نامشخص ایجاد کنند، که مشکل تخمین نرخ نفوذ را ساده‌تر می‌کند. با این حال، آنها همچنین دارای کمبودهایی هستند. به عنوان مثال، تعیین توپولوژی شبکه مناسب و مقادیر معقول هاپیر پارامتر برای ANN دشوار است. در مورد SVM، پارامترهای آن همیشه با آزمایش‌های دستی به دست می‌آیند که اغلب دارای درجه خاصی از عدم قطعیت و قضاوت شخصی پردازشگر هستند. به علاوه بسیاری از روشها قابلیت ارائه یک رابطه برای پیش‌بینی نرخ نفوذ را ندارند که قابلیت کاربرد آنها را در سایر پروژه‌ها سخت یا غیر ممکن می‌کند.

برای دور زدن این مشکلات، بسیاری از محققان ترجیح می‌دهند از روش‌ها یا الگوریتم‌های بهینه‌سازی مانند بهینه‌سازی ازدحام ذرات (PSO)، جستجوی فاخته (CS)، برنامه‌ریزی ژنتیکی (GP) و سایر الگوریتم‌ها برای جستجوی فرآیندهای بهینه برای مدل‌های پیش‌بینی استفاده کنند [۳۴]. به همین دلیل، برخی از مدل‌های ترکیبی با ترکیب روش‌های بهینه‌سازی با مدل‌های هوشمند، از جمله PSO-ANN [۳۵]، PSO-SVM [۳۶] و GP-ANN [۳۷] توسعه یافته‌اند. اگرچه این مدل‌های ترکیبی می‌توانند مشکل تعیین پارامتر را حل کنند، اما همچنان محدودیت‌هایی مانند دقت نسبتاً پایین مدل‌های مبتنی بر SVM و هزینه/زمان محاسباتی نسبتاً بالا مدل‌های مبتنی بر ANN دارند. تا به حال، یک مدل شناخته شده که بتواند بر تمام مشکلات ذکر شده در بالا غلبه کند، پیشنهاد نشده است. بنابراین، برای ارائه یک مدل با کارایی بالا و به حد کافی دقیق برای پیش‌بینی نرخ نفوذ، ضروری است که مدل پیشنهادی نه تنها بتواند مشکل تعیین پارامتر را حل کند، بلکه نتایج پیش‌بینی بهتری را نیز به دست آورد.

پژوهش‌های متعددی در سالیان اخیر برای پیش‌بینی نرخ نفوذ TBM توسط محققین مختلف و با استفاده از مدل‌های هوشمند انجام شده است، اما کارایی و برتری این مدل‌ها نسبت به همدیگر مقایسه نشده‌اند. هدف این تحقیق پیش‌بینی نرخ نفوذ TBM با استفاده از تعدادی از روش‌های مختلف است تا علاوه بر اینکه توانایی‌های هر روش در ارائه مدل پیش‌بینی مقایسه گردد، نقاط ضعف و قوت آن‌ها نیز شناسایی شوند. به همین منظور پایگاه داده ای متشکل از اطلاعات جمع‌آوری شده تونل گلاب ایجاد شد تا با استفاده از این پایگاه داده روش‌های مختلف پیاده‌سازی شود و بهترین روش برای پیش‌بینی نرخ نفوذ انتخاب شود.

برتری استفاده از TBM آلودگی کمتر محیط اطراف و ایمنی، کارایی و کیفیت بالاتر است.

یکی از کلیدی‌ترین پارامترها در عملکرد مناسب و اقتصادی استفاده از TBM پیش‌بینی نرخ نفوذ سنگ است. نرخ نفوذ TBM نه تنها بر زمانبندی ساخت و ساز و مقدار سرمایه اولیه، بلکه بر پایداری توده سنگ اطراف در طول تونل‌زنی نیز تأثیر می‌گذارد. از این رو، پیش‌بینی دقیق نرخ نفوذ بسیار مهم است. نرخ نفوذ ماشین حفر تونل نه تنها پارامتر تأثیرگذار بر زمان و هزینه اجرای تونل است، بلکه در ارجحیت روش حفر مکانیزه بر سنتی نیز تعیین کننده است. مدل‌های مختلفی در سالیان اخیر برای تخمین نفوذ ماشین پیشنهاد شده است. در این مدل‌ها از پارامترهای هدف مختلف برای سنجش عملکرد ماشین استفاده شده است. نرخ نفوذ (PR) میزان مسافت حفاری شده تقسیم بر زمان مفید حفاری است که پارامترهای عملیاتی ماشین در محاسبه آن نقش ندارند. نفوذ به ازاء هر چرخش (PREV) و سایر پارامترهای ترکیبی مانند نفوذ ویژه (SP)، اندیس حفر پذیری (BI) [۱] و نفوذ میدانی (FPI) [۲] که از ترکیب پارامترهای عملیاتی ماشین و مشخصات زمین محاسبه می‌شوند از دیگر پارامترهای هدف مشخصه نفوذ ماشین در سنگ هستند.

مدل‌های مختلف را بر اساس نحوه تامین داده‌های مورد نیاز و روش انجام تحلیل می‌توان به مدل‌های نظری و تجربی تقسیم نمود. مدل‌های نظری با توجه به مکانیزم خردایش سنگ و با بهره‌گیری از تجهیزات آزمایشگاهی خاص توسعه یافته‌اند. در حالیکه مدل‌های تجربی با توسعه یک پایگاه داده از اطلاعات حین حفر تونل‌های حفر شده با TBM و ارتباط مقادیر واقعی ثبت شده نفوذ ماشین با خصوصیات زمین و پارامترهای عملیاتی ماشین پیشنهاد شده‌اند. در این روش‌ها یکی از پارامترهای هدف و تعدادی پارامترهای مؤثر بر عملکرد ماشین انتخاب می‌شوند و از روش‌های گوناگون رابطه بین پارامتر هدف و پارامتر مؤثر پیشنهاد می‌شود.

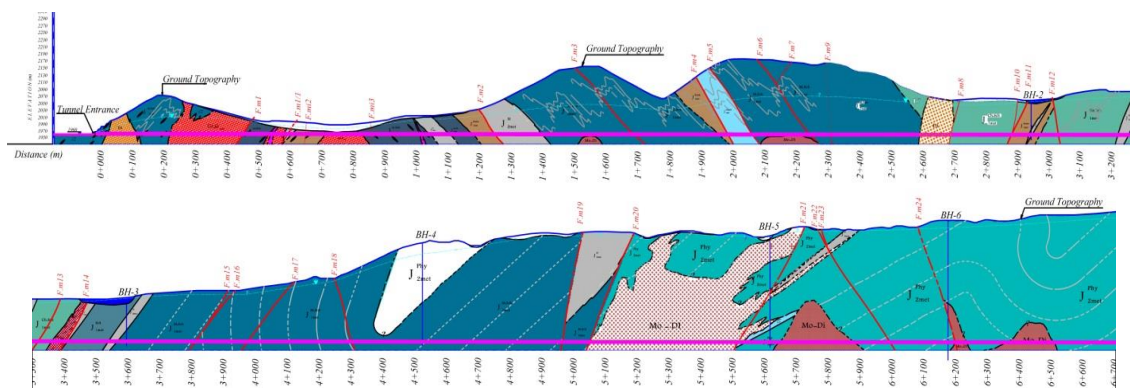
محققان از زمان اختراع TBM هرگز دست از توسعه مدل‌های تجربی و نظری برای ارزیابی نرخ نفوذ/عملکرد TBM برنداشته‌اند. برخی از مدل‌های معمولی عبارتند از مدل QTBM [۳]، مدل CSM [۴]، و مدل (NTNU) [۵] از جمله مدل‌های معتبر و رایج استفاده شده جهت پیش‌بینی نرخ نفوذ TBM هستند. محققین زیادی نیز از روش‌های آماری مانند تحلیل رگرسیون برای پیشنهاد مدل استفاده کرده‌اند [۶-۱۱]. اما با توسعه استفاده از رایانه‌ها و توانایی محاسباتی بالای آنها، روشهای جدیدی که عمدتاً روش‌های هوش مصنوعی هستند نیز برای ارائه مدل استفاده شده است [۱۲-۱۵]. همچنین بعضی محققین تلاش کرده‌اند تا با مقایسه دقت روشهای مختلف یک روش را برای پیش‌بینی نرخ نفوذ استفاده نمایند [۱۶].

بسیاری از مدل‌های هوشمند مانند شبکه عصبی مصنوعی

۲- پایگاه داده آماده شده

تونل گلاب به طول حدود ۱۰ کیلومتر و با قطر ۴،۵۸ متر جهت انتقال آب از رودخانه زاینده رود به شهر کاشان طراحی شده است. جهت تکمیل داده های لازم برای طراحی و حفاری تونل مطالعات زمین شناسی مهندسی در مسیر تونل با مقیاس ۱/۲۰۰۰ انجام شد. ساختگاه تونل از نظر زمین شناسی در پهنه دگرگونی سنندج- سیرجان قرار گرفته است. بخش شمال شرقی شامل مجموعه ای از سنگهای آهکی و کنگلومرایی، بخش میانی تناوبی از شیل های آرژلیتی و ماسه سنگ دگرگون شده است و بخش انتهایی شامل سنگ های دگرگونی مشتمل بر تناوبی از انواع شیست ها، آمفیبولیتها و مرمرهای دگرگونی - آهکی می باشد. گسل های محدوده تونل بر اساس رخنمون های سطحی شناسایی شده اند اما با توجه به عمق قابل ملاحظه سازه تونل، تعمیم

داده های اندازه گیری شده در سطح به عمق مورد نظر از دقت کافی برخوردار نیست و پیش بینی محل برخورد گسل ها با امتداد تونل با عدم قطعیت همراه خواهد بود. به همین دلیل جهت تعیین ساختارهای زمین شناسی در مسیر تونل و میزان جابجایی احتمالی ساختارها ناشی از گسل ها، اطلاعات زمین شناسی در حین حفر ثبت و نقشه حفر تونل ترسیم شد. موقعیت دقیق ساختارهای زمین شناسی جهت تطبیق با پارامترهای عملیاتی ماشین نیز بدست آمد. توده سنگ های مسیر تونل بر اساس تفاوت خصوصیات زمین شناسی لایه ها، تفاوت ساختاری و خصوصیات ژئومکانیکی واحدها به واحدهای مختلف تقسیم شدند. شکل ۱ تصویر پروفیل و جدول ۱ واحدهای زمین شناسی مسیر تونل و مترآژ حفاری در این واحدها را نشان می دهند.



شکل ۱: شکل پروفیل واحدهای زمین شناسی مسیر تونل

جدول ۱: واحد های زمین شناسی مسیر تونل گلاب

سنگ شناسی	توصیف	واحد زمین شناسی مهندسی	مجموع مترآژ در مسیر تونل
کوارتز موسکویت بیوتیت شیست	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Met-Sch	۴۰۷،۷۵
سنگ آهک خاکستری توده ای	نسبتا مقاوم، نسبتا ضخیم لایه، نسبتا خرد شده	Li	۱۰۹،۸۳
شیل خاکستری با دگرگونی کم	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Met-Sh	۱۱۴۷،۲۲
فیلیت	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Met-Phy	۱۰۶۹،۵۴
اسلیت خاکستری ضعیف	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Met-Sl	۶۷۲،۴۵
سنگ آذرین دانه ریز تا متوسط	مقاوم، توده ای، پایدار	Ig	۱۷۳۷،۶۳
سنگ آذرین دگرگون شده	نسبتا مقاوم، نسبتا ضخیم لایه، نسبتا خرد شده	Met-Ig	۴۲۲،۲
ماسه سنگ دگرگونی	نسبتا مقاوم، نسبتا ضخیم لایه، نسبتا خرد شده	Met-Sa	۲۹۹،۵۶
سنگ آهک آرژلیتی	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Ar-Li	۱۲۶،۱۴
کنگلومرای قرمز	ضعیف تا نسبتا مقاوم، لایه بندی متوسط، شکسته شده	Cg.r	۵۷،۶۲
کنگلومرای خاکستری با ماسه سنگ آهکی	نسبتا مقاوم، نسبتا ضخیم لایه، نسبتا خرد شده	Cg-Li.Sn	۱۳۰،۹
ناحیه خرد شده	زون خرد شده گسلی	CZ	۱۳،۴۱
ناحیه شکسته شده	بسیار ضعیف، لایه بندی نازک، شکسته شده و ناپایدار	FZ	۱۱۳،۷۵

جدول ۲: خصوصیات زمین شناسی مهندسی و مترائز حفاری واحدها در تونل گلاب

شرایط درزه	فاصله		Q	GSI	RMR	RQD %	$I_s(50)$ (MPa)	UCS (MPa)	نوع سنگ
	JCS (MPa)	JRC							
۱۲-۲۰	۶-۱۰	۰.۲-۰.۶	۰.۴-۰.۹۵	۳۵-۴۰	۴۰-۴۵	۲۵-۳۵	۱.۵-۳	۱۲-۱۷	Met-Sch
۳۵-۶۵	۸-۱۲	۰.۶-۰.۵	۱.۲-۲.۲	۴۴-۵۲	۴۹-۵۷	۷۰-۸۰	۲-۴.۵	۵۰-۶۰	Li
			۰.۰۹-۰.۱۷	۲۵-۳۰	۲۸-۳۳	۲۰-۲۵	۰.۱-۰.۸۳	۲-۶.۵	Met-Sh
۱۰-۲۰	۴-۸	۰.۱-۰.۸	۰.۱۸-۰.۲۵	۳۰-۳۵	۳۴-۴۰	۲۰-۳۰	۰.۶۵-۱.۵	۷-۱۲	Met-Phy
۱۲-۲۰	۶-۱۲	۰.۲-۱	۰.۱۵-۰.۲۵	۲۸-۳۴	۳۲-۳۷	۲۰-۲۵	۰.۲-۱	۴-۸	Met-SI
۶۰-۱۱۰	۱۰-۱۶	۰.۶-۳	۸.۵-۲۰.۵	۶۲-۶۵	۷۲-۷۶	۷۵-۹۰	۵.۸-۷	۱۰۸-۱۳۰	Ig
۴۰-۶۵	۸-۱۴	۰.۶-۳	۳.۵-۷	۵۵-۶۰	۶۰-۶۸	۵۰-۷۰	۳.۵-۵.۵	۶۰-۶۵	Met-Ig
۱۵-۲۵	۶-۱۰	۰.۶-۳	۰.۸-۱.۴	۴۵-۴۹	۴۸-۵۲	۳۵-۵۰	۱.۸-۳	۲۵-۳۰	Met-Sa
۱۰-۳۰	۶-۱۰	۰.۵-۲	۰.۳-۱	۴۳-۴۸	۴۸-۵۳	۴۵-۵۵	۱-۲.۲	۱۰-۱۳.۵	Ar-Li
۲۵-۵۵	۴-۱۲	۰.۳-۲	۰.۸-۱.۵	۴۴-۵۲	۴۶-۵۵	۵۰-۶۰	۲-۴	۲۱-۳۱	Cg.r
۶۰-۷۵	۴-۱۰	۱-۱۰	۱.۸-۴	۴۸-۵۴	۶۰-۶۷	۹۰-۱۰۰	۴.۱-۵	۷۱-۸۵	Cg-Li.Sn

دهنده در مرکز، ۲۶ عدد در صفحه برش و ۳ عدد در حاشیه نصب شده اند.

جدول ۳: پارامترهای موجود در پایگاه داده گسترش یافته

پارامترهای عملیاتی ماشین	مشخصات زمین
گشتاور، نیروی پیشران، دور در دقیقه، توان و نرخ نفوذ	مقاومت فشاری تک محوره، مقاومت کششی، مشخصات ناپیوستگی ها، زاویه آلفا، درصد کوارتز، مدول الاستیک، چسبندگی، تنش روبراه و سیستمهای رده بندی سنگ (RQD)، RME و RMi ، GSI ، Q ، RMR

۳- ارائه مدل پیش بینی نرخ نفوذ از روش های مختلف

برای ارائه مدل می توان از پارامترهای هدف مختلف استفاده نمود. بعضی از پارامترهای هدف مانند، نفوذ ماشین در واحد زمان (PR) و یا نفوذ به ازاء هر دور چرخش (PR_{ev})، فقط میزان نفوذ در توده سنگ را بدون توجه به نوع ماشین و نیروهای وارد شده از ماشین به توده سنگ محاسبه می نمایند. اندیس نفوذ میدانی یا FPI شاخص نرمال شده نیروی وارده بر هر تیغه برش به ازاء نرخ نفوذ در هر دور چرخش کله حفار است که واحد آن بر حسب $(KN/cutter)/(mm/rev)$ است. در محاسبه پارامتر FPI مقدار نرخ نفوذ در هر دور چرخش و نیروی وارد بر دیسک در نظر گرفته می شود بنابراین این پارامتر نسبت به پارامترهای ماشین نرمال سازی شده است؛ بنابراین تنها تابعی از خصوصیات زمین خواهد بود و امکان مقایسه عملکرد ماشین ها با ابعاد و توان مختلف فراهم می شود. حسن پور نیز به برتری پارامتر FPI بر سایر پارامترهای هدف اشاره نموده است. در این تحقیق نیز از مقدار FPI جهت برآورد ارتباط خصوصیات زمین با عملکرد ماشین استفاده شده است.

مطالعات زمین شناسی مهندسی به منظور تعیین خصوصیات و ویژگی های واحدهای مختلف و ارزیابی رفتار مکانیکی توده سنگ های مسیر تونل انجام گرفته است. همچنین تعداد ۱۰ گمانه در مسیر تونل نیز حفر شده است. از نتایج آزمایشات انجام شده بروی نمونه های اخذ شده از گمانه های اکتشافی پارامترهایی شامل مقاومت فشاری تک محوری، مقاومت کششی، آزمایش بارنقطه ای، تعیین چگالی خشک و اشباع، درصد تخلخل، درصد کوارتز، ضریب الاستیسیته، ضریب پواسون، چسبندگی و زاویه اصطکاک داخلی سنگ تعیین گردید.

بر اساس نتایج بدست آمده و مطالعه رخنمون های سطحی واحدهای زمین شناسی مهندسی در مسیر تونل مشخص گردید. خصوصیات کلی واحدهای زمین شناسی مهندسی در جدول ۲ آمده است.

همچنین با ارزیابی صحرایی و نمونه های اخذ شده از گمانه های حفاری و ترانسه ها، مشخصات هندسی و مکانیکی ناپیوستگی ها در واحدهای مختلف تعیین گردید. این اطلاعات شامل موقعیت فضایی (شیب، جهت شیب، تعداد دسته درزه ها، فاصله داری و تداوم) و ویژگی های مکانیکی (زبری، موجداری، مقاومت دیواره، بازشدگی و پرکننده) می باشد.

پایگاه داده استفاده شده در این تحلیل شامل اطلاعات حین حفر تونل گلاب می باشد. اطلاعات عملکرد ماشین حفر تونل گلاب و پارامترهای عملیاتی حین حفر توسط سیستم جمع آوری اطلاعات ماشین جمع آوری شده است. پایگاه داده گسترش یافته شامل دو بخش مشخصات زمین و عملیاتی ماشین است. جدول ۳ پارامترهای موجود در پایگاه داده گسترش یافته را نشان می دهد.

ماشین استفاده شده در تونل گلاب از نوع دو سپره با قطر ۴،۴۹۵ متر است که توسط شرکن ویرث ساخته شده است. تعداد ۳۵ دیسک با قطر ۴۳۲ میلیمتر روی کله برش قرار گرفته اند. ۶ برش

مقادیر UCS ساختارهای زمین شناسی مهندسی تونل گلاب نیز ارتباط کمی با مقدار FPI ثبت شده دارد. شکل ۲ ارتباط فاصله داری درزه ها و مقدار FPI را نشان می دهد. بیشترین ضریب همبستگی در حالتی است که نمودار حالت توانی از درجه ۲ داشته باشد. RQD نیز مانند فاصله داری متوسط می تواند معرف فرکانس درزه داری باشد. ارتباط بین RQD و FPI در شکل ۲ نشان داده شده است. بیشترین مقدار ضریب همبستگی به صورت خطی است. ضریب همبستگی بین پارامترهای RQD و فاصله داری درزه ها بسیار شبیه بهم است.

امتداد ناپیوستگی ها می تواند نقش عمده ای در عملکرد ماشین داشته باشد. زاویه آلفا که زاویه بین امتداد ناپیوستگی و محور تونل است برای هر یک از دسته درزه های ساختارهای زمین شناسی مهندسی تونل گلاب تعیین گردید. همبستگی بین مقادیر مختلف آلفا و FPI محاسبه شد و مقدار آلفایی که بیشترین همبستگی را داشت به عنوان آلفای آن ساختار در نظر گرفته شد. شکل ۲ ارتباط بین آلفا و مقادیر FPI را نشان می دهد. با افزایش مقدار آلفا مقدار FPI کاهش پیدا می کند که به معنی نیروی کمتر مورد نیاز جهت نفوذ در سنگ است.

جدول ۴: ضرایب همبستگی بین FPI و پارامترهای ژئومکانیکی

	تونل گلاب		FPI	
	Log FPI		FPI	
	خطی	درجه ۲	خطی	درجه ۲
UCS	0.39	0.52	0.26	0.36
فاصله داری	0.64	0.76	0.72	0.51
RQD	0.73	0.73	0.52	0.67
زاویه آلفا	0.53	0.46	0.53	0.28

محققین زیادی از روش های مختلف تلاش کرده اند تا روابطی برای پیش بینی نرخ نفوذ ماشین حفر تونل ارائه نمایند. با توجه به تنوع روش های قابل استفاده، در این تحقیق سعی شده است که با استفاده از روش های مختلف، پیش بینی نرخ نفوذ برای پایگاه داده تونل گلاب انجام شود تا نقاط ضعف و قوت هر روش مشخص گردد. و بهترین روش برای ارائه مدل پیشنهاد گردد. با توجه به اینکه در هر فاصله ۱/۵ متری از طول حفاری اطلاعات ماشین ثبت و مقدار FPI محاسبه می شود، مجموعه داده های ثبت و محاسبه شده در حین حفاری تعداد قابل قبولی برای استفاده در روش های مختلف از جمله روش های هوش مصنوعی است.

با توجه به اینکه پارامترهای عملیاتی ماشین در حین حفر مدام توسط کاربر ماشین برای حصول به حفاری بهتر و بیشتر در حال تغییر می باشد، به تبع مقدار FPI نیز در زمان های مختلف، متفاوت است. اطلاعات حین حفر ماشین در فاصله هر ۱/۵ متر حفاری توسط دستگاه ثبت می شود و بنابراین در هر ۱/۵ متر از طول واحد زمین شناسی مقدار FPI قابل محاسبه است که به طور طبیعی ممکن است مقادیر متفاوتی باشد.

برای یافتن چگونگی تاثیر خصوصیات زمین در عملکرد ماشین ارتباط بین پارامترهای ژئومکانیکی توده سنگ موجود در پایگاه داده با مقدار FPI واقعی بررسی شد. از آنجائیکه که خصوصیات ژئومکانیکی ساختارهای زمین شناسی مقادیر ثابتی هستند اما در این ساختارها مقادیر FPI متفاوتی ثبت شده باشد (به علت تفاوت پارامترهای عملیاتی ماشین) برای یافتن ارتباط بین پارامتر هدف حفاری (FPI) و خصوصیات ژئومکانیکی از مقادیر FPI ثبت شده هر ساختار میانگین گرفته شد و ارتباط آن با پارامترهای ژئومکانیکی بررسی شد. لازم به ذکر است میانگین گیری داده ها در هر ساختار زمین شناسی صرفا جهت یافتن نوع ارتباط (خطی یا غیر خطی بودن) پارامتر هدف با پارامتر ژئومکانیکی مورد نظر است و برای ارائه فرمول پیش بینی از تمام داده ها استفاده شده است.

از پارامترهای مشخصات زمین ذکر شده در جدول ۳ تعدادی از پارامترها اثر یکسانی بر تابع هدف دارند و ورود همزمان دو پارامتر کمکی به بالا رفتن دقت مدل نخواهد کرد. به عنوان مثال مقاومت فشاری و ضریب الاستیسیته پارامترهای وابسته هستند که تاثیر یکسانی بر حفرپذیری سنگ دارد. به علاوه بعضی از پارامترها نظیر درصد کوارتز تاثیر معنا داری بر نرخ نفوذ نداشت. بنابراین از مشخصات زمین فاصله داری، مقاومت فشاری تک محوره، زاویه ناپیوستگی (آلفا) و RQD برای یافتن ارتباط با حفرپذیری توده سنگ استفاده شد.

جدول ۵ میزان ضرایب همبستگی مقدار FPI متوسط در ساختارهای زمین شناسی تونل گلاب را با هر کدام از خصوصیات ژئومکانیکی مورد بررسی و شکل ۲ نحوه تغییرات آن ها را نشان می دهد. مطابق شکل ۲ مقدار UCS ارتباط مستقیم با FPI دارد. این ارتباط به طور کلی در سایر موارد نیز مشاهده شده است [۹، ۱۱، ۳۸، ۳۹]. در بعضی از موارد ارتباط قابل توجه بوده است و مقدار UCS در فرمول عملکرد ماشین آورده شده است، اما در بعضی موارد به علت ارتباط کم از آن صرف نظر شده است.

کاربرد بیشتری دارد.

۱ $\log FPI = 0.0808 n + 0.0083 q + 0.0021 UCS - 3.7252 S + 7.2841 S^2 + 0.0133 RQD + 0.0018 \alpha - 0.0643$
روش رگرسیون $pace$ یک روش رگرسیون خطی است که ضرایب با استفاده از روش دسته بندی و ارزیابی اثر هر متغیر و میزان مشارکت آن را در رگرسیون کلی تخمین می زند. در نهایت این روش انجام عمل رگرسیون را بر اساس حداقل مربعات را بهبود می دهد. این روش رگرسیون به خصوص در شرایطی که تعداد ویژگی ها زیاد باشد بهره وری بالایی دارد. نتایج تحلیل داده های تونل گلاب بر اساس روش رگرسیون $pace$ نیز در جدول ۶ نشان داده شده است.

روش SMO رگرسیون یک الگوریتم بهینه سازی حداقل ترتیبی است که از روش ماشین بردار پشتیبان استفاده می نماید. ماشین بردار پشتیبان به ۲ نوع مدل طبقه بندی و رگرسیون تقسیم می شود. مدل طبقه بندی جهت حل مسائل طبقه بندی داده ها در کلاس های مختلف و مدل رگرسیون ماشین بردار در حل مسائل پیش بینی با انجام رگرسیون با تعداد الگو های یادگیری محدود استفاده می شود. مبانی رگرسیون ماشین بردار که در نظریه یادگیری آماری واپنیک [۳۶] آمده است، داده های غیر خطی را به فضایی با ابعاد بالاتر می برد. سپس از توابع خطی ساده برای ایجاد مرزهای جدا کننده در فضای جدید استفاده می کند. از ویژگی های این روش، فرمولاسیون رگرسیون آن بر اساس حداقل کردن ریسک ساختاری به جای ریسک تجربی است که منجر به عملکرد بهتر این روش می شود. در این روش داده ها باید نرمال سازی شوند تا در دامنه بین صفر تا یک قرار گیرند. با توجه به اینکه داده های ورودی، دامنه تغییرات و واحد متفاوتی دارند، نرمال سازی باعث بدون بعد شدن داده ها و در نتیجه افزایش سرعت یادگیری و پایداری مدل می شود. نرمال سازی با رابطه ۲ انجام می شود.





$$X_{Norm}^j = \frac{X^j - X_{min}^j}{X_{max}^j - X_{min}^j} \quad 2$$

در اینجا X_{Norm}^j مقدار نرمال شده پارامتر X ، X^j داده اصلی i ام، X_{min}^j و X_{max}^j به ترتیب بیشترین و کمترین مقدار X در مجموعه داده ها است.

با استفاده از روش SMO رگرسیون و داده های ورودی تونل گلاب، مدل پیش بینی عملکرد ماشین ارائه شد. رابطه بدست آمده در جدول ۶ نشان داده شده است. در این رابطه α_N ، RQD_N و S_N مقادیر نرمال شده فاصله داری درزه ها، RQD و زاویه آلفا بر اساس رابطه ۲ هستند. همانطور که نتایج نشان می دهند، رابطه ارائه شده با روش Smo رگرسیون دقت بالاتری از سایر روش های رگرسیون دارد.

۲-۲- الگوریتم پرواز پرندگان

روش ازدحام ذرات یا پرواز پرندگان (PSO) یک روش محاسباتی



شکل ۲: تغییرات FPI بر حسب خصوصیات ژئومکانیکی ساختارهای تونل گلاب

۲-۱- تحلیل رگرسیون

با توجه به نتایج نشان داده شده در جدول ۵، $\log FPI$ به علت ارتباط بهتر با پارامترهای زمین نسبت به FPI به عنوان پارامتر هدف انتخاب شده است. تحلیل رگرسیون چند متغیره جهت ارائه مدل پیش بینی نرخ نفوذ ماشین با استفاده از داده های تونل گلاب استفاده شد. پارامترهای مستقل ورودی مطابق جدول ۳ و پارامتر مستقل $\log FPI$ انتخاب شدند. نتیجه تحلیل مطابق رابطه ۱ خواهد بود. چنانچه پارامترهای کم اثر که ارتباط کمتری با مقدار FPI دارند از پارامترهای ورودی حذف شوند، ضریب همبستگی رابطه جدید که با رابطه ۶ در جدول ۶ نشان داده شده است، تغییر زیادی نخواهد داشت اما رابطه ارائه شده نسبت به رابطه ۱ سهولت

ورودی داده شده ارائه کند. برای این منظور، FPI به عنوان پارامتر هدف و طبق رابطه ۳ انتخاب شد.

$$FPI = \sum_{i=1}^n W_i \cdot p_i^{\alpha_i} \quad 3$$

که W_i و α_i به ترتیب وزن و توان پارامتر P_i و n تعداد پارامترها هستند. برای تخمین W_i و α_i در معادله بالا، PSO با انبوهی از ذرات تصادفی شروع می‌شود، یعنی ذراتی با مقادیر تصادفی برای وزن و توان انتخاب می‌شوند و سپس از طریق تکرارهای مختلف، ذرات به سمت ناحیه بهترین مقدار تابع هدف جذب می‌شوند. در واقع، PSO به یک تابع هدف از پیش تعریف شده نیاز دارد تا نشان دهد که وزن و توان پارامترها چقدر خوب برآورد شده اند. تابع هدف در نظر گرفته شده در این تحقیق ضریب همبستگی می‌باشد.

روش PSO بر روی داده های تونل گلاب پیاده سازی شد. در مرتبه اول تمام پارامترهای ژئومکانیکی موجود در پایگاه داده به عنوان پارامترهای ورودی در نظر گرفته شدند. رابطه ۴ نتیجه بدست آمده از این روش است. در مرتبه دوم پارامترهای کم تاثیر حذف و پارامترهای موثر استفاده شده در روش های رگرسیون به عنوان پارامترهای ورودی الگوریتم PSO انتخاب شد. دقت رابطه بدست آمده نزدیک به رابطه ۴ است اما پیچیدگی کمتری دارد. رابطه پیشنهادی بدست آمده از PSO در جدول ۶ با رابطه ۸ نشان داده شده است.

است که یک مسئله را با تلاش مکرر برای بهبود راه حل کاندید با توجه به معیار از پیش تعریف شده کیفیت بهینه می‌کند. PSO یک الگوریتم الهام گرفته از طبیعت است که رفتار پرندگان و پرورش ماهی را شبیه‌سازی می‌کند و با موفقیت در بسیاری از زمینه‌ها مانند بهینه‌سازی توابع استفاده شده است.

PSO با جمعیتی از افراد به نام $swarm$ شروع می‌شود. هر عضو در گروه، که یک ذره نامیده می‌شود، یک راه حل بالقوه را نشان می‌دهد که یک نقطه در فضای جستجوی n بعدی است. این ذرات به طور مکرر در یک فضای جستجو حرکت می‌کنند و با تبادل اطلاعات در مورد آنچه در مکان‌هایی که بازدید کرده اند، به دنبال بهترین راه حل هستند. هر ذره دارای یک بردار موقعیت x است که یک راه حل در نظر گرفته شده برای مسئله را به همراه بردار سرعت آن ذره رمزگذاری می‌کند. علاوه بر این، هر ذره حاوی یک حافظه کوچک است که بهترین موقعیت خود را ($pbest$) که تاکنون کسب کرده است، و بهترین موقعیت کلی ($gbest$)، که از طریق ارتباط با ذرات کناری خود به دست آمده را ذخیره می‌کند. در هر مرحله زمانی، هر ذره بردار سرعت خود را به کمک ارتباط با ذرات همسایه خود به سمت مکان‌های $pbest$ و $gbest$ خود به روز می‌کند و به موقعیت جدیدی حرکت می‌کند. انتظار می‌رود که این گروه را به سمت بهترین راه حل‌ها سوق دهد.

به منظور پیش‌بینی نرخ نفوذ TBM از الگوریتم PSO استفاده شده است. پیش‌بینی نرخ TBM یک مسئله بهینه‌سازی است که سعی می‌کند معادله‌ای برای پیش‌بینی نرخ نفوذ بر اساس پارامترهای

جدول ۵: نتایج مدل های مختلف پیش بینی عملکرد تونل گلاب از روش های مختلف

روش	معادله	R^2	شماره معادله
رگرسیون خطی	$\text{Log FPI} = -3.0074 S + 4.928 S^2 + 0.0106 \text{RQD} + 0.0046 \alpha - 0.0608$	0.75	۱
Pace رگرسیون	$\text{Log FPI} = -2.8251 S + 4.6756 S^2 + 0.0105 \text{RQD} + 0.0054 \alpha + 0.5378$	0.77	۲
SMo رگرسیون	$\text{Log FPI} = -5349 S_N + 0.7018 S_N^2 + 0.3455 \text{RQD}_N + 0.0844 \alpha_N + 0.3549$	0.78	۳
PSO	$\text{Log FPI} = -0.3791 S + 0.6287 S^2 + 0.0013 \text{RQD} + 0.0006 \alpha + 0.2262$	0.782	۴

ورودی) و فضای بهینه (لایه خروجی) دارد. یک یا چند لایه مخفی در شبکه وجود دارد که داده های دریافتی از لایه های ورودی را پردازش کرده و به لایه خروجی می‌رسد. هر شبکه بر اساس مجموعه ای از مثال های آموزشی برای تعیین وزن لایه ها به گونه ای آموزش داده می‌شود که تفاوت بین مقادیر پیش بینی شده و محاسبه شده قابل قبول باشد. شبکه عصبی می‌تواند برای پیش بینی مناسب با توجه به مجموعه جدید داده ها استفاده شود.

۲-۳- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یکی از روش های محاسباتی الهام گرفته از مغز انسان است که پردازش داده ها توسط بسیاری از پردازنده های کوچک به نام نورون ها انجام می‌شود. شبکه ای از نورون های به هم پیوسته به موازات یکدیگر برای حل یک مشکل عمل می‌کنند. به عبارت دیگر روش شبکه عصبی سعی در شناسایی ارتباط بین داده ها با استفاده از نورون ها و ارائه نقشه ای بین فضای ورودی (لایه

به منظور استفاده از روش شبکه عصبی یک مجموعه تست مورد نیاز است. برای ساخت این مجموعه آزمایشی، از تکنیک اعتبارسنجی متقاطع ۱۰ برابری استفاده می شود که در آن ۱۰ درصد مجموعه ورودی به عنوان مجموعه آزمایشی نگه داشته می شود. به طور دقیق تر، مجموعه ورودی به طور تصادفی به ۱۰ زیر مجموعه مساوی تقسیم می شود. در هر تکرار، یک زیر مجموعه به عنوان مجموعه تست و نه زیر مجموعه دیگر به عنوان مجموعه آموزشی انتخاب می شود. در نهایت، نتایج اعتبارسنجی در طول تکرارها میانگین می شوند. نتیجه به دست آمده از اجرای ANN در جدول ۷ نشان داده شده است.

جدول ۶: نتایج پیش بینی نرخ نفوذ با روش شبکه عصبی

ضریب همبستگی	۰.۶۸
میانگین مطلق خطا (MAE)	۶.۸۴
خطای مجموع مربعات (RMSE)	۹.۲۶
درصد خطای نسبی	٪۱۷

اگرچه شبکه عصبی دقت بالاتری در مقایسه با سایر روش ها دارد، اما این روش فرمول یا معادله خاصی را ارائه نمی دهد و نتایج به راحتی قابل تفسیر نیستند. در روش شبکه عصبی مجموعه آزمون و مجموعه آموزشی معمولاً هر دو از یک مجموعه داده انتخاب می شوند، بنابراین دقت بالایی به دست می آید. اگر مجموعه تست و مجموعه آموزشی از دو مجموعه داده متفاوت باشند، احتمالاً خطای مدل افزایش خواهد یافت. با توجه به اینکه ساختارهای زمین شناسی یک تونل با تونل دیگر متفاوت است، پیش بینی نرخ نفوذ با شبکه آموزش دیده یک تونل دیگر ممکن است خطای پیش بینی را افزایش دهد. از دیگر معایب روش استفاده از شبکه عصبی عدم ارائه یک رابطه مشخص است که تعمیم این روش را به سایر پروژه ها سخت می کند.

۲-۴- درخت تصمیم

درخت تصمیم یکی از مشهورترین الگوریتم های یادگیری استقرائی است که بصورت موفقیت آمیزی در کاربردهای مختلف بکار گرفته شده است. یکی از کاربردهای رایج درخت تصمیم پیش بینی و تقریب تابع هدف است. با توجه به این که اکثر سیستم های مهندسی، اجرایی و محاسباتی را می توان در قالب یکسری داده (ویژگی ها و خروجی منطبق با آنها) تعریف کرد، می توان با بکارگیری الگوریتم های ایجاد درخت این ویژگی ها و خروجی ها را آنالیز کرد و سیستم را بر اساس این داده ها در قالب یک درخت تصمیم ارائه کرد. درخت تصمیم یک ابزار برای پشتیبانی از تصمیم است که از شکل ظاهری درختان برای مدل کردن استفاده می کند. این مدل درختی داده ها را به نحوی دسته بندی می کند که از ریشه به سمت

مدل های مختلفی از شبکه های عصبی ارائه شده است. در این مطالعه از شبکه پرسپترون چندلایه (MLP) استفاده شده است که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. برای آموزش شبکه، معمولاً از الگوریتم پس انتشار (BP) استفاده می شود. ابتدا محاسبه از ورودی به خروجی شبکه آغاز می شود. خروجی واقعی با خروجی مورد نظر مقایسه می شود. برای ایجاد مدل مناسب، مقادیر خطای محاسبه شده در لایه های قبلی منتشر شده و وزن لایه ها تنظیم می شود. برای پیش بینی نرخ نفوذ ماشین با استفاده از روش شبکه عصبی، مقادیر واقعی ثبت شده نفوذ به عنوان لایه خروجی و پارامترهای تاثیرگذار به عنوان لایه ورودی تعریف می شود. یک ماتریس وزن تصادفی که همان ضرایب پارامترهای اولیه هستند به هر یک از اتصالات داده می شود. بردار ورودی و خروجی مناسب آن انتخاب می شود. خروجی نرون در هر لایه محاسبه می شود و وزن ها بر اساس میزان اختلاف بین خروجی واقعی و خروجی محاسبه شده، تصحیح می شوند. عملکرد شبکه ی آموزش دیده با برخی شاخص های تعریف شده مانند جذر میانگین مربعات خطا ارزیابی می شود. در صورت حصول به نتیجه مطلوب آموزش پایان می یابد در غیر اینصورت مجدداً وزن های داده شده تصحیح می گردد تا نتیجه مورد نظر حاصل شود.

در این مقاله از شبکه عصبی مصنوعی (ANN) برای گزاره FPI استفاده شده است. یک شبکه عصبی بر اساس پارامترهای ژئومکانیکی موجود در پایگاه داده تونل گلاب به عنوان پارامترهای ورودی و FPI به عنوان پارامتر خروجی آموزش داده شد. الگوریتم های یادگیری پس انتشار در شبکه استفاده شد و بهترین رویکرد یافت شد. به این ترتیب می توان فرمول جدیدی برای پیش بینی FPI با استفاده از وزن های شبکه تولید کرد. اساساً معادله کدگذاری شده توسط ANN به شرح معادله ۹ است.

$$Y_j = F(\text{Sum}(X_i W_{ij})) \quad 5$$

در اینجا $X = (x_1, x_2, \dots, x_n)$ بردار ورودی است، Y خروجی و W_{ij} وزن اتصال بین ورودی ها و واحدهای پنهان است. $F(\cdot)$ تابع فعال سازی ANN است. در اینجا، تابع سیگمود در لایه پنهان استفاده می شود که به صورت معادله ۶ تعریف می شود.

$$F(k) = 1/(1 + \exp(-k)) \quad 6$$

آستانه، که بایاس نیز نامیده می شود، به فعال سازی واحدی که به آن متصل است اضافه می شود. بنابراین FPI از معادله ۷ محاسبه می شود. با این حال، معادله مذکور به طور کلی، به یک معادله طولانی پیچیده از جمله ورودی ها، وزن ها، سوگیری ها و غیره ختم می شود.

$$FPI = 0.0383 - 0.0191 Y_1 + 0.0348 Y_2 - 0.0448 Y_3 \quad 7$$

فاصله درزه ها و زاویه آن ها نسبت به محور تونل در عملکرد ماشین تأثیری چندانی نخواهد گذاشت. در سیستم ارائه شده حد آستانه RQD مقدار ۴۶ در نظر گرفته شده است و بدون در نظر گرفتن فاصله داری و زاویه ناپیوستگی ها، رابطه ای برای مقدار نرخ نفوذ پیشنهاد شده است.

با توجه به کاهش درزه داری و خردشدگی سنگ در RQD بالای ۴۶، زاویه و فاصله داری اهمیت پیدا می کنند که با پیاده سازی الگوریتم درخت تصمیم این دو پارامتر در گره های تصمیم قرار می گیرند. مقادیر آستانه آن ها و روابط ارائه شده در هر شاخه در سیستم بندی نشان داده شده است. همچنین همانطور که در این سیستم طبقه بندی مشاهده می شود، در پایگاه داده موجود، به علت تأثیر کم پارامتر مقاومت فشاری تک محوری، این پارامتر در فرآیند تصمیم گیری نقشی نداشته است و در گره های تصمیم و همچنین روابط پیشنهاد شده در برگ ها وارد نشده است. این مطلب قبلاً نیز در نتایج تحلیل رگرسیون و نمودار همبستگی FPI و UCS مشاهده شده بود.

در نهایت سیستم رده بندی پیشنهادی با توجه به اینکه بازه های تصمیم گیری را محدود می نماید، دقت بالاتری نسبت به یک رابطه ارائه شده کلی برای تمام مجموعه داده دارد.

۴- بررسی کارآیی مدل های مختلف برای پیش بینی عملکرد ماشین حفر تونل

در این تحقیق جهت چند روش پیش بینی عملکرد ماشین حفر تونل استفاده شد. روش آماری رگرسیون یکی از رایجترین و ساده ترین تکنیک هایی است که استفاده می شود. این روش با ارائه یک رابطه خطی یا غیر خطی کاربرد آسانی دارد و به راحتی قابل تعمیم دادن است. با کمک ابزار ماشین بردار پشتیبان می توان انعطاف پذیری و تا حدودی دقت این روش را نیز افزایش داد. اما دقت و توانایی آن در پیش بینی تابع هدف در مقایسه با روش های هوش مصنوعی پایینتر است.

شبکه عصبی مصنوعی قابلیت سازماندهی به صورت خودکار را دارد. یک شبکه عصبی به حد کافی پایدار است تا اطلاعات فراگرفته خود را حفظ کند و با قابلیت انعطاف پذیری و تطبیق بالا، بدون از دست دادن اطلاعات قبلی، با اطلاعات جدید آموزش داده شود. این خاصیت باعث می شود که بتوان شبکه آموزش داده شده با یک پایگاه داده را با آموزش بر اساس اطلاعات پایگاه جدید، به روزرسانی کرد.

پائین رشد می کنند و در نهایت به گره های برگ می رسد. در درخت گره تصمیم جایی است که بر اساس مقادیر و اثر پارامترهای ورودی باید تصمیمی اتخاذ گردد. مسیرهای منشعب شده از گره نشان دهنده قاعده دسته بندی است و هر مسیر پاسخ هر تصمیم است. گره پایانی برگ درخت است که کلاس یا طبقه ای با یک جواب (رابطه) داده شده را نشان می دهد.

روشهای متعددی برای ساخت درخت تصمیم پیشنهاد شده است. در این مقاله از الگوریتم $M5$ و روابط آن برای ساخت درخت تصمیم و روابط استفاده شده است. الگوریتم اولیه $M5$ توسط کوئینلان بیان شده و توسط وانگ بهبود یافته است [۴۰، ۴۱]. در این الگوریتم از مفهوم بی نظمی^۱ و معیار بهره اطلاعات^۲ (IG) برای ساخت درخت تصمیم استفاده می شود. اگر S مجموعه ای از داده های هدف (در اینجا FPI) باشد، بی نظمی آن طبق رابطه ۱۲ محاسبه می شود.

$$\text{Entropy (s)} = \sum_{i=1}^c -P_i \log_2 P_i \quad ۸$$

C تعداد دسته ها یا رده های در نظر گرفته شده برای S و P_i سهم S در دسته A است. برای انتخاب اینکه کدام ویژگی به عنوان ویژگی برتر در ریشه درخت و اولین گره تصمیم، قرار بگیرد از معیار بهره اطلاعات استفاده می شود که مطابق رابطه ۱۳ بدست می آید.

۹

$$IG(S, S_A) = \text{entropy}(S) - \sum_{V \in \text{value}(A)} \frac{|S_V|}{|S|} \text{entropy}(S_V)$$

A ویژگی های مورد نظر (پارامترهای موثر بر نرخ نفوذ) است، $value(A)$ مجموعه همه مقادیر ویژگی های A و S_V زیر مجموعه ای از S است که برای A دارای مقدار V است. هر ویژگی که بیشترین بهره اطلاعات را داشته باشد به عنوان گره تصمیم انتخاب می شود و حرکت به سمت پایین ادامه پیدا می کند. ریشه، اولین گره موجود در درخت است که ویژگی معین شده توسط این گره معین می گردد که مقدار مشاهده شده به کدام شاخه تعلق دارد. منطبق با ارزش ویژگی در گره، حرکت در طول شاخه ها به سمت برگ انجام می شود. در گره های تصمیم بعدی نیز سایر ویژگی ها با بیشترین بهره اطلاعات قرار می گیرند تا نهایتاً درخت به گره پایانی یا برگ خاتمه یابد. در این روش ویژگی هایی که تأثیر زیادی در پارامتر هدف ندارند باعث افزایش بی نظمی شده و در فرآیند تصمیم حذف خواهند شد. با استفاده از پایگاه داده تونل گلاب روش درخت تصمیم استفاده شد. نتیجه این تحلیل در جدول ۷ نشان داده شده است. در این سیستم طبقه بندی مهمترین پارامتر تأثیرگذار بر عملکرد ماشین میزان خردشدگی توده سنگ است. ساختارهایی که RQD کمی دارند به علت بالا بودن میزان خرد شدگی و تعداد زیاد درزه های موجود،

¹ Entropy

² Information Gain

جدول ۷: طبقه بندی روابط پیش بینی نرخ نفوذ بر اساس اطلاعات تونل گلاب

RQD > 46	S ≤ 0.5	$\alpha \leq 35^\circ$	$Log FPI = 0.026 n + 0.001 q - 0.8724 S + 0.0039 RQD + 0.0043 \alpha + 0.3763$
		$35 < \alpha < 39$	$Log FPI = 0.026 n + 0.0005 q - 0.8724 S + 0.0039 RQD + 0.0029 \alpha + 0.384$
		$\alpha \geq 39^\circ$	$Log FPI = 0.026 n + 0.0002 q - 0.8724 S + 0.0039 RQD + 0.0029 \alpha + 0.4276$
	S > 0.5		$Log FPI = 0.0521 n + 0.0049 q + 1.8378 S + 0.0039 RQD + 0.0029 \alpha + 0.053$
RQD ≤ 46			$Log FPI = -0.0372 n + 0.0004 q - 0.0589 S + 0.0025 RQD + 0.0018 \alpha + 0.8696$

۵- نتیجه گیری

در این تحقیق سعی شد یک مدل و راهکار جدید برای پیش بینی نرخ نفوذ ارائه شود. بر این اساس یک پایگاه داده از اطلاعات ثبت شده حین حفر تونل گلاب ایجاد شد. مقایسه مدل‌های رایج نشان داد که کمترین خطا در پیش بینی متعلق به مدل پیشنهادی فرخ است. یکی از دلایل بالا بودن دقت این مدل در نظر گرفتن عددی بر حسب نوع و نحوه تشکیل سنگ است. همچنین مدل گانگ عملکرد متفاوتی دارد به گونه‌ای که علیرغم کمترین خطای کلی بعد از مدل فرخ، اما با توجه به منشاء تشکیل سنگ مقدار خطای آن بسیار متغیر است. خطای این مدل در سنگ‌های رسوبی کمترین خطا و در سنگ‌های آذرین و دگرگونی بیشترین مقدار ثبت شده است.

ارتباط پارامترهای مختلف ژئومکانیکی با مقادیر FPI ثبت شده تونل گلاب بررسی شد. در بین پارامترها فاصله داری درزه ها و RQD بیشترین و مقاومت فشاری تک محوری کمترین ارتباط را با FPI دارد. روش تحلیل رگرسیون خطی با استفاده از تمام ویژگی‌ها و سپس با حذف ویژگی‌های کم اثر انجام شد که نتایج حاصل نشان دادند که تفاوت چندانی در دقت رابطه بدست آمده حاصل نمی‌شود، اما با توجه به اینکه در رابطه جدید متغیرهای کمتری وجود دارد، سادگی و سهولت استفاده از آن بیشتر است. با کاهش تعداد پارامترها و انجام روش‌های دقیق‌تر رگرسیون، بهترین رابطه پیشنهادی از روش تحلیل آماری رگرسیون با استفاده از روش SMO رگرسیون حاصل شد.

تخمین ضرایب و توان متغیرهای تعریف شده برای ارائه رابطه با استفاده از روش PSO نیز انجام شد. در این روش نیز ارتباط بدست آمده برای فاصله داری درزه ها از روش PSO نیز به صورت توان ۲ بود. همچنین ضرایب هر کدام از متغیرهای مستقل تعیین گردید. رابطه ارائه شده توسط این روش تفاوت فاحشی نسبت به روش تحلیل SMO رگرسیون نشان نداد.

روش استفاده از شبکه عصبی مصنوعی نیز برای پیش بینی نرخ نفوذ استفاده شد. این روش دقت به مراتب بالاتری از روش‌های تحلیل رگرسیون و PSO نشان داد. اما درک فیزیکی حل مسئله در

در عین حال شبکه عصبی به صورت یک جعبه سیاه عمل می‌کند و نتایج آن به راحتی قابل تفسیر نمی‌باشد. به عبارت دیگر مرتبط ساختن پارامترها یا ساختار شبکه به پارامترهای فرایند معمولاً غیر ممکن است. بعلاوه این روش رابطه یا دستورات مشخصی برای طراحی به کاربر ارائه نمی‌کند که این امر باعث می‌شود عمومیت یافتن آن به سادگی امکان پذیر نباشد. این موضوع در تحقیقات سایر محققینی که از این روش استفاده کرده اند نیز مشاهده می‌شود. به طوری که نتایج منتشر شده ی آن‌ها منجر به ارائه رابطه ای نشده است. اگرچه شبکه عصبی با تعداد محدودی داده می‌تواند نتایج را به موارد مشاهده شده تعمیم دهد و مقدار خروجی را تخمین بزند، اما دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد و در بعضی موارد ممکن است آموزش شبکه مشکل و یا حتی غیر ممکن باشد.

درخت تصمیم یکی از روش‌هایی است که می‌توان برای پیش بینی تابع هدف استفاده کرد. نتیجه حاصل شده از الگوریتم ساخت درخت تصمیم به راحتی قابل فهم و درک مدل ایجاد شده توسط درخت آسان است. هر کاربر با اندکی مطالعه و آموزش می‌تواند، طریقه کار با درخت تصمیم را بیاموزد. درخت تصمیم در عین سادگی می‌تواند با داده‌های بزرگ و پیچیده به راحتی کار کند و از روی آنها تصمیم (قانون) بسازد. درخت تصمیم بر خلاف شبکه‌های عصبی به تولید قاعده می‌پردازد. در حالی که در شبکه‌های عصبی تنها نتیجه پیش‌بینی بیان میشود و چگونگی به دست آمدن آن در خود شبکه پنهان می‌ماند.

با توجه به اینکه در درخت بازه های تصمیم گیری محدود می‌شود دقت بدست آمده از این روش بالا است. بعلاوه این روش را می‌توان با تکنیک‌های دیگر تصمیم گیری ترکیب نمود و نتایج بهتری بدست آورد. به عنوان مثال در هر کدام از برگ‌های درخت می‌توان از روش‌های رگرسیون، PSO و غیره برای بدست آوردن رابطه نهایی در برگ‌ها استفاده کرد. اما باید توجه داشت که با بزرگ شدن مسئله (دسته داده‌های ورودی)، درخت به صورت نمایی بزرگ می‌شود و ممکن است استفاده از آن را مشکل سازد.

درخت تصمیم بر اساس ویژگی‌هایی با بیشترین تاثیر و سودمندی در فرآیند تصمیم، بازه های تصمیم گیری را محدود می‌نماید؛ بنابراین روابط ارائه شده در سیستم پیشنهادی دقت بالاتری از یک فرمول کلی پیشنهادی برای تمام داده‌ها دارد. در بین روش های استفاده شده در این تحقیق درخت تصمیم بیشترین کارآیی در پیش بینی نفوذ ماشین حفر تونل را نشان داد. در این تحقیق یک سیستم طبقه بندی پیشنهادی پیش بینی نرخ نفوذ پیشنهاد شده است که در صورت استفاده از این سیستم دقت پیش بینی افزایش خواهد یافت.

این روش به علت مخفی بودن محاسبات در لایه های میانی به راحتی انجام نمی شود. روش شبکه مصنوعی به صورت یک جعبه سیاه است که یک رابطه مشخص برای حل مسئله ارائه نمی کند و بنابراین قابلیت عمومیت یافتن ندارد. بعلاوه هر کاربر برای استفاده از آن نیاز به شبکه آموزش دیده دارد که بتواند با استفاده از آن و با وارد کردن اترهای ورودی مقدار خروجی تخمین زده شده را مشاهده نماید.

برعکس روش شبکه مصنوعی درخت تصمیم یک شیوه تصمیم گیری و بهترین رابطه ممکن را به صورت قابل درکی ارائه می کند.

۶- منابع ها

machine in rocks. 2020. 2020.

14. Koopialipoor, M., et al., Predicting tunnel boring machine performance through a new model based on the group method of data handling. 2019. 78(5): p. 3799-3813.

15. Wei, M., et al., Prediction of TBM penetration rate based on Monte Carlo-BP neural network. 2021. 33: p. 603-611.

16. Afradi, A. and A.J.S.A.S. Ebrahimabadi, Comparison of artificial neural networks (ANN), support vector machine (SVM) and gene expression programming (GEP) approaches for predicting TBM penetration rate. 2020. 2(12): p. 1-16.

17. Gao, B., et al., TBM penetration rate prediction based on the long short-term memory neural network. 2021. 6(6): p. 718-731.

18. Koopialipoor, M., et al., Application of deep neural networks in predicting the penetration rate of tunnel boring machines. 2019. 78(8): p. 6347-6360.

19. Benardos, A., D.J.T. Kaliampakos, and U.S. Technology, Modelling TBM performance with artificial neural networks. 2004. 19(6): p. 597-605.

20. JAVAD, G., T.J.M.S. NARGES, and Technology, Application of artificial neural networks to the prediction of tunnel boring machine penetration rate. 2010. 20(5): p. 727-733.

21. Mahdevari, S., et al., A support vector regression model for predicting tunnel boring machine penetration rates. 2014. 72: p. 214-229.

22. Gao, L. and X.-b.J.J.o.C.S.U. Li, Utilizing partial least square and support vector machine for TBM penetration rate prediction in hard rock conditions. 2015. 22(1): p. 290-295.

23. Mikaeil, R., et al., Multifactorial fuzzy approach to the penetrability classification of TBM in hard rock conditions. 2009. 24(5): p. 500-505.

24. Ghasemi, E., et al., Predicting penetration rate of hard rock tunnel boring machine using fuzzy logic. 2014. 73(1): p. 23-35.

25. Mikaeil, R., et al., An extended multifactorial fuzzy prediction of hard rock TBM penetrability. 2018. 36(3): p. 1779-1804.

26. Hamidi, J.K., et al., Application of fuzzy set theory to rock engineering classification systems: an illustration of the rock mass excavability index. 2010.

1. Gong, Q., et al., In situ TBM penetration tests and rock mass boreability analysis in hard rock tunnels. 2007. 22(3): p. 303-316.

2. Yagiz, S.J.A.J.o.G., New equations for predicting the field penetration index of tunnel boring machines in fractured rock mass. 2017. 10(2): p. 33.

3. Barton, N.J.T. and T. international, TBM performance estimation in rock using QTBM. 1999. 31(9): p. 30-34.

4. Rostami, J., Development of a force estimation model for rock fragmentation with disc cutters through theoretical modeling and physical measurement of crushed zone pressure. 1997, Colorado School of Mines Golden.

5. Bruland, A., Hard rock tunnel boring. 2000: Fakultet for ingeniørvitenskap og teknologi.

6. Yagiz, S., et al., Application of two non-linear prediction tools to the estimation of tunnel boring machine performance. 2009. 22(4-5): p. 808-814.

7. Gong, Q., J.J.I.j.o.R.m. Zhao, and m. sciences, Development of a rock mass characteristics model for TBM penetration rate prediction. 2009. 46(1): p. 8-18.

8. Farrokh, E., et al., Study of various models for estimation of penetration rate of hard rock TBMs. 2012. 30: p. 110-123.

9. Hamidi, J.K., et al., Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system. 2010. 25(4): p. 333-345.

10. Hassanpour, J., et al., TBM performance analysis in pyroclastic rocks: a case history of Karaj water conveyance tunnel. 2010. 43(4): p. 427-445.

11. Hassanpour, J., et al., Developing new equations for TBM performance prediction in carbonate-argillaceous rocks: a case history of Nowsod water conveyance tunnel. 2009. 4(4): p. 287-297.

12. Wang, Y., et al., An extreme gradient boosting technique to estimate TBM penetration rate and prediction platform. 2022. 81(1): p. 1-19.

13. Zhang, Y., et al., A novel intelligent method for predicting the penetration rate of the tunnel boring

34. Bui, D.T., V.-H. Nhu, and N.-D.J.A.E.I. Hoang, Prediction of soil compression coefficient for urban housing project using novel integration machine learning approach of swarm intelligence and multi-layer perceptron neural network. 2018. 38: p. 593-604.
35. Armaghani, D.J., et al., Blasting-induced flyrock and ground vibration prediction through an expert artificial neural network based on particle swarm optimization. 2014. 7(12): p. 5383-5396.
36. Zhao, H.-b. and S.J.A.M.M. Yin, Geomechanical parameters identification by particle swarm optimization and support vector machine. 2009. 33(10): p. 3997-4012.
37. Nazari, A. and S.J.C.P.B.E. Riahi, Prediction split tensile strength and water permeability of high strength concrete containing TiO₂ nanoparticles by artificial neural network and genetic programming. 2011. 42(3): p. 473-488.
38. Delisio, A., et al., Analysis and prediction of TBM performance in blocky rock conditions at the Lötshberg Base Tunnel. 2013. 33: p. 131-142.
39. Yagiz, S.J.T. and U.S. Technology, Utilizing rock mass properties for predicting TBM performance in hard rock condition. 2008. 23(3): p. 326-339.
40. Quinlan, J.R. Learning with continuous classes. in 5th Australian joint conference on artificial intelligence. 1992. Singapore.
41. Wang, Y. and I.H. Witten, Induction of model trees for predicting continuous classes, in 9th European Conference on Machine Learning. 1997. 43(3): p. 335-350.
27. Yagiz, S., H.J.I.J.o.R.M. Karahan, and M. Sciences, Prediction of hard rock TBM penetration rate using particle swarm optimization. 2011. 48(3): p. 427-433.
28. Oraee, K., M.T. Khorami, and N. Hosseini. Prediction of the penetration rate of TBM using adaptive neuro fuzzy inference system (ANFIS). in Proceeding of SME Annual Meeting and Exhibit. 2012.
29. Li, Z., et al., A hybrid GEP and WOA approach to estimate the optimal penetration rate of TBM in granitic rock mass. 2021. 25: p. 11877-11895.
30. Mahmoodzadeh, A., et al., Forecasting tunnel boring machine penetration rate using LSTM deep neural network optimized by grey wolf optimization algorithm. 2022. 209: p. 118303.
31. Yang, H., X. Liu, and K.J.A.J.o.G. Song, A novel gradient boosting regression tree technique optimized by improved sparrow search algorithm for predicting TBM penetration rate. 2022. 15(6): p. 461.
32. Yang, H., Z. Wang, and K.J.E.w.C. Song, A new hybrid grey wolf optimizer-feature weighted-multiple kernel-support vector regression technique to predict TBM performance. 2020: p. 1-17.
33. Zhou, J., et al., Predicting TBM penetration rate in hard rock condition: a comparative study among six XGB-based metaheuristic techniques. 2021. 12(3): p. 101091.

