

### پیش‌بینی نرخ نفوذ TBM با استفاده از شبکه‌های عصبی و سیستم‌های فازی-عصبی (مطالعه موردی از ۱۴ تونل حفر شده در سنگ سخت)

#### پژوهشی

میلااد عامری<sup>۱\*</sup>؛ ابراهیم فرخ<sup>۲</sup>؛ حامد ملاداوودی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد؛ دانشکده مهندسی معدن، دانشگاه صنعتی امیرکبیر، milad.a70@aut.ac.ir

۲- استادیار؛ دانشکده مهندسی معدن، دانشگاه صنعتی امیرکبیر، e.farrokhi@aut.ac.ir

۳- استادیار؛ دانشکده مهندسی معدن، دانشگاه صنعتی امیرکبیر، davoodi@aut.ac.ir

دریافت دست‌نوشته: ۱۴۰۰/۰۵/۱۰؛ پذیرش دست‌نوشته: ۱۴۰۰/۱۰/۲۶

شماره صفحات: ۳۵ تا ۵۶

شناسه دیجیتال (DOI): 10.22044/TUSE.2022.10987.1424

واژگان کلیدی	چکیده
نرخ نفوذ شبکه عصبی شبکه فازی-عصبی ماشین تونل‌زنی (TBM) پارامترهای ماشین پارامترهای توده سنگ	پیش‌بینی نرخ نفوذ TBM ها یکی از مهمترین موضوعات برای تخمین هزینه‌های حفاری و مدت زمان اجرا در پروژه‌های تونل‌سازی است، اما این موضوع همچنان برای مهندسين و سرمایه‌گذاران یک چالش مهم محسوب می‌شود. نتایج تحقیقات گذشته نشان می‌دهد که برای پیش‌بینی نرخ نفوذ، روش‌های متفاوتی ارائه شده‌اند که از جمله‌ی این روش‌ها می‌توان به روش‌های تجربی و تئوری به‌عنوان روش‌های کلاسیک و قدیمی‌تر و شبکه‌های عصبی، شبکه‌های فازی و یا شبکه‌های فازی-عصبی به‌عنوان روش‌های هوشمند و جدید اشاره کرد. روش‌های مدرن در تحلیل روابط پیچیده و غیرخطی، از توانایی بالاتری نسبت به روش‌های کلاسیک برخوردار هستند؛ لذا استفاده از آن‌ها سبب رسیدن به نتایج دقیق‌تری برای پیش‌بینی نرخ نفوذ خواهد شد. در این پژوهش از یک بانک اطلاعاتی شامل ۱۴ تونل از سراسر جهان بهره‌گرفته شده است. پارامترهای انتخاب شده برای پیش‌بینی نرخ نفوذ شامل ترکیبی از پارامترهای مربوط به ماشین و توده سنگ است، از جمله نیروی عمودی وارد بر تیغه ( $F_n$ )، تعداد دور در دقیقه ( $RPM$ )، قطر تونل ( $TD$ )، امتیاز رده‌بندی توده سنگ ( $RMR$ )، شاخص کیفی سنگ ( $RQD$ ) و مقاومت فشاری تک‌محوری ( $UCS$ ). با تحلیل و بررسی نتایج مربوطه مشخص گردید که حذف یا عدم استفاده از پارامترهای مناسب می‌تواند سبب کاهش چشم‌گیری در پیش‌بینی نرخ نفوذ شود. بر این اساس نتایج نشان می‌دهد که پارامترهای $UCS$ و $RQD$ مهم‌ترین پارامترهای تأثیرگذار در پیش‌بینی نرخ نفوذ هستند. این نتایج همچنین نشان می‌دهد که استفاده از شبکه‌های فازی-عصبی ( $RMSE=0.13$ ) در مقایسه با روش‌های عصبی ( $RMSE=0.18$ ) از دقت بیشتری برخوردار است.

#### ۱- پیش‌گفتار

کاربرد در شرایط مختلف زمین‌شناسی همچنان در حال گسترش است. علی‌رغم اینکه استفاده از TBM ها نیازمند سرمایه اولیه بسیار زیاد است اما کیفیت بالای حفاری و سرعت، مزیت آن‌ها را نسبت به روش‌های سنتی مانند آتشیاری، بیشتر کرده است (Yavari & Mahdevari, 2006). پیشرفت‌های به دست آمده در تکنولوژی در سالیان

در اوایل قرن ۱۹ با گسترش استفاده از حمل و نقل زیرزمینی، لزوم استفاده از تونل‌های طولانی‌تر، بیش از پیش احساس شد. گسترش استفاده از این تونل‌ها، باعث افزایش کاربرد حفاری مکانیزه با ماشین‌های تونل‌زنی (TBM) گردید. استفاده از TBM ها به علت انعطاف‌پذیری

شناخته شده‌ترین مدل‌های تجربی، مدل مدرسه معدنی کلرادو (CSM) است که طی سالیان گذشته بارها مورد بازبینی قرار گرفته است. از جمله این بازبینی‌ها می‌توان به (Ozdemir, et al., 1978) و (Rostami, 1997) اشاره نمود. این مدل براساس مشخصات سنگ و تیغه‌ها و شکل تیغه‌ها بنا نهاده شده است، که قادر است نیروی مورد نیاز تیغه را برای یک میزان مشخص نفوذ محاسبه نماید. همچنین (Yagiz, 2002) اصلاحاتی شامل اضافه کردن شکنندگی سنگ بکر و مشخصات ترک‌خوردگی را انجام داد. (Gong & Zhao, 2009) رابطه‌ای را با استفاده از آنالیز رگرسیون غیرخطی روی داده‌هایی از دو تونل که در توده‌سنگ‌های گرانیتی در سنگاپور جمع‌آوری شده بود، ارائه دادند. (Khademi Hamidi, Cassinelli, et al., 1982)، (Hassanpour, et al., 2011) et al., 2011)، (Farrokh, et al., 2012)، (Medel-Morales & Botello-Rionda, 2013) نیز برخی از سایر مدل‌های موجود هستند که در هرکدام از پارامترهای ورودی متفاوتی برای پیش‌بینی نرخ نفوذ استفاده شده است. مطالعه مدل‌های قبلی نشان می‌دهد که روش خاص و یکتایی برای پیش‌بینی نرخ نفوذ وجود ندارد.

طی سالیان اخیر روش‌های مبتنی بر هوش مصنوعی به‌صورت گسترده‌ای مورد استفاده قرار گرفته‌اند. برای پیش‌بینی و تخمین پارامترهای عملکردی TBM مانند نرخ نفوذ و نرخ پیشروی از تکنیک‌های زیادی مانند منطق فازی، شبکه‌های عصبی مصنوعی و کلاس‌بندی داده‌ها استفاده شده است. این روش‌ها با استفاده از روشی به نام روش ترکیبی یا Hybrid با هم قابل استفاده هستند که این مهم توسط روش فازی-عصبی قابل ارائه است.

در این مقاله سعی شده است با بررسی بیشتر پارامترهای ورودی و انتخاب مناسب‌ترین آن‌ها و همچنین استفاده از بانک اطلاعاتی کامل‌تر نسبت به غالب مطالعات صورت گرفته که شامل ۱۴ تونل از سراسر دنیا می‌باشد، در جهت پیش‌بینی دقیق‌تر نرخ نفوذ پیش رفت. با توجه به برتری هوش مصنوعی در حل مسائل پیچیده و غیر خطی، ابتدا به شبکه‌های عصبی مصنوعی پرداخته می‌شود و سپس سیستم‌های فازی-عصبی استفاده شده است که در این پژوهش برای دقت بیشتر در پیش‌بینی نرخ نفوذ، علاوه بر

اخیر در TBMها، تاثیرات شگرفی بر صنعت تونل‌سازی و سازه‌های زیرزمینی گذاشته است که در نتیجه آن‌ها حفاری‌های ایمن‌تر با نرخ تولید بیشتر و هزینه‌های کمتر فراهم آمده است. یکی دیگر از مزایای TBMها، کاربری بالای آن‌ها و کم بودن اختلالات ایجاد شده در زمین‌های اطراف تونل است (Adoko, et al., 2019; Gong, et al., 2016; Liu, et al., 2016).

پیش‌بینی نرخ نفوذ به علت تاثیر زیاد آن بر روی هزینه‌های پروژه و برنامه‌ریزی، یکی از اصلی‌ترین کارهایی است که باید در پروژه‌ها مدنظر قرار گیرد (Hedayatzadeh, et al., 2010) این مساله از آغاز استفاده از TBMها تا به امروز بین محققان و دانشمندان به عنوان یک موضوع چالشی وجود داشته است (Gholami, et al., 2012) وجود متغیرهای زیاد و وجود عدم قطعیت در پارامترهای زمین، و همینطور وجود اثر متقابل زمین و ماشین، برآورد نرخ نفوذ را به امری دشوار تبدیل کرده است. طی دهه‌های گذشته، تکنیک‌های زیادی برای پیش‌بینی دقیق‌تر نرخ نفوذ توسط محققان، مورد استفاده قرار گرفته است. این تکنیک‌ها به ۲ دسته اصلی تقسیم می‌شوند که شامل روش‌های تئوری، تجربی (براساس آزمایش‌های آزمایشگاهی و مشاهدات میدانی و فواین ریاضی) و روش‌های هوشمند (براساس تکنیک‌های هوش مصنوعی) (Koopialipoor, et al., 2019) می‌شوند.

مدل‌های تئوری و تجربی متفاوتی برای پیش‌بینی پارامترهای عملکردی TBMها ارائه شده‌اند. (Tarkoy, 1973) یکی از اولین مدل‌های تجربی را ارائه داد که در آن از سختی کل برای پیش‌بینی نرخ نفوذ استفاده شده است. (Farmer & Glossop, 1980) مدلی برای پیش‌بینی نرخ نفوذ (PR) ارائه دادند که از پارامترهایی مانند مقاومت کششی سنگ و نیروی عمودی وارد آمده به دیسک استفاده کرده است. (Sanio, 1985) رابطه‌ای بین مقاومت فشاری تک‌محوری سنگ (UCS) و انرژی ویژه معرفی کرد. (Graham, 1976) ارتباط بین مقاومت فشاری تک‌محوری و نیروی تیغه را مدنظر قرار داد (Salimi, et al., 2015). در سال ۱۹۹۱، (Innaurato, et al., 1991) مدل دیگری را ارائه دادند که مقاومت فشاری تک‌محوری و سیستم طبقه‌بندی RSR پارامترهای اثرگذار در آن بودند. یکی از

استفاده از تولباکس فازی-عصبی در نرم‌افزار متلب از کدنویسی نیز استفاده شده است و در انتها به مقایسه‌ای بین این دو روش با توجه به بانک داده‌ها پرداخته می‌شود.

## ۲- شبکه‌های عصبی

تلاش برای توسعه شبکه‌های عصبی مصنوعی برای دست یافتن به نحوه عملکرد مغز انسان و شبیه‌سازی قابلیت‌های تشخیصی آن آغاز شده است. به عبارتی دیگر، برای تصمیم‌گیری و عمل تحت شرایط خاص و وجود عدم قطعیت‌ها می‌توان از شبکه‌های عصبی استفاده کرد. کاربرد شبکه‌های عصبی در مسائل مختلف به علت توانایی بالای آن در یافتن ارتباط مناسب بین متغیرهای مستقل و وابسته، روش قابل قبولی است که توسط محققان رشته‌های متفاوت تأیید شده است (Gholami, et al., 2012). شبکه‌های عصبی شامل ساختار لایه‌ای هستند که میان اجزای پردازش (نورون) آن که در لایه‌های شبکه وجود دارند، ارتباطات گسترده‌ای برقرار است. این شبکه‌ها توانایی برقراری ارتباط بین ورودی‌ها و خروجی‌ها را داراست. برای این مهم، ارتباطات یا وزن‌های بین اجزا به واسطه استخراج ارتباط بین ورودی‌ها و خروجی‌ها اصلاح می‌شود (Salimi, et al., 2015). در حین مرحله یادگیری نمونه‌های آزمایشی به عنوان سیگنال‌هایی برای لایه‌های ورودی و خروجی استفاده می‌شوند. در نهایت بعد از یادگیری، در مرحله فراخوانی یا ارزیابی، پیش‌بینی برای داده‌های ورودی جدید قابل انجام خواهد بود. در واقع می‌توان گفت مرحله ارزیابی، توانایی شبکه برای ارائه جواب قابل قبول در قبال ورودی‌هایی است که در مجموعه آموزشی نبوده‌اند. در شبکه‌های عصبی برای اعمال ورودی‌ها از هر لایه به لایه بعدی از توابع فعال‌سازی استفاده می‌شود تا بتوانند خروجی هر لایه را به عنوان ورودی برای لایه بعدی مورد استفاده قرار دهند. هیچ‌گونه فرمول ثابتی برای محاسبه تعداد لایه‌ها و نورون‌ها وجود ندارد (Khademi Hamidi, et al., 2012) و تعداد آن‌ها به پیچیدگی مساله مدنظر بستگی دارد. تا به امروز تعداد زیادی از الگوریتم‌های یادگیری در شبکه‌های عصبی مورد استفاده قرار گرفته است؛ اما می‌توان گفت که بهترین و کارآمدترین آن‌ها در غالب مسائل، روش پس انتشارخطا است (Wang, et al., 2020). این نوع از شبکه‌ها حداقل از

۳ لایه تشکیل شده است که شامل لایه ورودی، یک لایه مخفی و لایه خروجی است. در این روش، حرکت شبکه‌های عصبی از لایه ورودی به سمت لایه خروجی هم به صورت پیش‌رونده اتفاق می‌افتد و هم به صورت پس‌رونده. در واقع در حالت پیش‌رونده، یک دسته داده از ورودی و خروجی‌ها مدنظر قرار می‌گیرند و به مدل معرفی می‌شوند. سپس مقادیر خروجی مربوط به الگوهای اولیه در انتهای مسیر توسط مدل محاسبه می‌شوند. در حالت پس‌رونده، خروجی محاسبه شده با الگوی هدف مقایسه خواهد شد. اگر اختلاف (خطا) به دست آمده از تفاضل بین حالت پیش‌رونده و پس‌رونده کمتر از آستانه تعریف شده باشد، فاز یادگیری به پایان رسیده است. در غیر این صورت، خطا برای تعدیل شدن به سیستم برمی‌گردد که به این روند آموزش، پس انتشار خطا می‌گویند. برای تعدیل خطا نیز از تغییر در وزن‌های تعریف شده استفاده خواهد شد (Salimi, et al., 2015).

## ۳- سیستم‌های فازی-عصبی

درک سیستم استنتاجی تطبیقی فازی با شناخت مفهوم مجموعه فازی آغاز می‌شود. یک مجموعه فازی به علت داشتن تابع عضویت با یک مجموعه عادی بسیار متفاوت است. به عبارت دیگر، مجموعه فازی مجموعه‌ای است که مرزهای دقیقی را شامل نمی‌شود و می‌تواند شامل مجموعه‌هایی شود که درجه عضویت اجزای آن عددی بین ۰ و ۱ باشد (Adoko & Yagiz, 2018)، (Zadeh, 1965). مزیت این مجموعه‌ها آن است که بسیاری از عدم قطعیت‌ها در مسائل را می‌توان به واسطه آن‌ها مورد ارزیابی قرار داد. سیستم‌های فازی-عصبی شامل یک ابزار محاسباتی ترکیبی است که سیستم‌های فازی و شبکه‌های عصبی را با یکدیگر ترکیب می‌کند (Grima, et al., 2000)، که هرکدام از این روش‌ها مزایا و معایب خود را دارا هستند. شبکه‌های عصبی توانایی شناسایی الگو و تعمیم برای شرایط جدید را دارا هستند. سیستم‌های فازی نیز قادر به دخالت دانش انسانی و عدم قطعیت‌های موجود در مسائل گوناگون هستند. از این رو، طی سالیان اخیر استفاده از سیستم‌ها فازی-عصبی در مسائل گوناگون مهندسی زمین‌شناسی مورد استفاده قرار گرفته است (Salim, et al., 2015). شبکه‌های فازی-عصبی از یک جزء منطقی و یک جزء عددی تشکیل شده‌اند

توصیف دقیق سیستم‌های پیچیده، چند متغیره و غیرخطی برخوردار نیستند. (Grima, et al., 2000)، از دو روش یاد شده، با توجه به توانایی آن‌ها در حل مسائل پیچیده و غیرخطی و همچنین امکان دخالت و توصیف عدم قطعیت‌ها، برای برآورد نرخ نفوذ TBM استفاده می‌شود.

#### ۴- بانک داده‌ها

بانک داده‌های استفاده شده در این مقاله شامل ۲۱۷ دسته داده مربوط به ۱۴ تونل از سراسر جهان است که در سنگ‌های سخت حفاری شده‌اند. در جدول ۱، مشخصات این تونل‌ها را نشان می‌دهد.


که جزء منطقی شامل مجموعه‌های فازی، منطق فازی و استدلال تقریبی است و جزء عددی شامل شبکه‌های عصبی، خوشه‌بندی و آنالیز داده‌ها می‌باشد. فاکتورهای زیادی در تونل‌سازی دخیل هستند که روی نرخ نفوذ تأثیر گذارند. فاکتورهایی مانند مشخصات توده‌سنگ و ماشین که اثر متقابل بین این فاکتورها پویا، غیرقطعی، پیچیده و غیرخطی است. علاوه براین، رفتار غالب توده‌سنگ‌ها ناهمسانگرد، غیرخطی و ناپیوسته است. واضح است که تحت این شرایط مدل‌سازی ریاضی برای پیش‌بینی نرخ نفوذ کافی به نظر نمی‌رسد. به عبارتی، مدل‌های ریاضی از قدرت کافی برای

جدول ۱- مشخصات تونل‌های استفاده شده در بانک داده‌ها


شماره‌ی تونل	اسم پروژه	تعداد دسته داده‌ها	طول تونل (km)	نوع TBM	قطر TBM	زمین‌شناسی	منبع
۱	گلاس (ایران)	۱۱	۳۵/۶	Dual Mode	۵/۵	گرانیت، شیل، دولومیت	(Report, 2020)
۲	زاگرس (ایران)	۲۴	۵/۳	DS	۶/۷۳	لایم‌استون، مارل، شیل	(Mohammadi, et al., 2014) (Moradi & Farsangi, 2014)
۳	گلاب (ایران)	۶	۱۰	DS	۴/۵	دبورت، شیست	(Mobarra, et al., 2013)
۴	کرج (ایران)	۲۹	۱۶	DS	۴/۶۳		
۵	پاهانگ (مالزی)	۱۰۰	۴۴/۶	Open	۵/۲۳	گرانیت	(Armaghani, et al., 2019)
۶	میلیانگ (کره جنوبی)	۸	۰/۶	Open	۲/۶	گرانیت، آندزیت	(Farrokh, 2020)
۷	ماناپوری (نیوزلند)	۱	۱/۷	Open	۱۰/۵	گنایس	(Farrokh, 2020)
۸	منهتن (آمریکا)	۱۰	۵/۶	Open	۳/۸۴	گنایس، شیست	(Farrokh, 2020)
۹	KCRC1 (هنگ کنگ)	۳	۱/۳	Mixed S	۸/۷۵	گرانیت	(Farrokh, 2020)
۱۰	KCRC2 (هنگ کنگ)	۳	۱/۴	Mixed S	۸/۷۵	گرانیت	(Farrokh, 2020)
۱۱	فراسنادلو-پایلو (ایتالیا)	۱۰	۱/۶	Open	۳/۹	دولومیت، لایم‌استون، آرژیلیت	(Farrokh, 2020)
۱۲	آنتیا-پایلو (ایتالیا)	۱	۰/۷	Open	۳/۹	دولومیت	(Farrokh, 2020)
۱۳	فراسنادلو (ایتالیا)	۱۰	۱/۶	SS	۱۱/۸	دولومیت، لایم‌استون، آرژیلیت	(Farrokh, 2020)
۱۴	آنتیا (ایتالیا)	۱	۰/۷	SS	۱۱/۸	دولومیت	(Farrokh, 2020)

کرد. علاوه بر این موضوع، برهم‌کنش بین ماشین و توده‌سنگ پویا، پیچیده، غیرخطی و مبهم است؛ همچنین در بیشتر پروژه‌ها رفتار توده‌سنگ آنیزوتروپیک، غیرخطی و ناپیوسته است. تحت این شرایط مدل‌سازی عملکردی


فاکتورهای زیادی در عملیات حفاری توسط TBM دخالت دارند که از میان آن‌ها می‌توان به پارامترهای مربوط به توده‌سنگ، پارامترهای سنگ‌بکر، مشخصات زمین‌شناسی، مشخصات ماشین، مهارت اپراتور و دانش متخصص اشاره



شکل ۳- تاثیر  $RPM$  روی نرخ نفوذ



شکل ۴- تاثیر  $RQD$  روی نرخ نفوذ




شکل ۵- تاثیر  $RMR$  بر نرخ نفوذ


با مشاهده نتایج شکل ۱ تا شکل ۶ می‌توان گفت که در بانک اطلاعاتی حاضر بیشترین تاثیر روی نرخ نفوذ به ترتیب توسط قطر تونل،  $UCS$  و  $RPM$  اعمال می‌شود؛ همچنین با مطالعه مدل‌های قبلی و بانک داده جمع‌آوری شده می‌توان به این نکته پی‌برد که در اغلب مدل‌ها، دو پارامتر  $UCS$  و  $RQD$  با توجه به تاثیر زیاد روی نرخ نفوذ مورد استفاده قرار گرفته است، از این رو در این‌جا نیز با توجه به این موضوع و همبستگی زیاد موجود بین نرخ نفوذ و ۲ پارامتر ذکر شده در داده‌های بانک اطلاعاتی، همین رویه

ماشین با استفاده تنها از تکنیک‌های ریاضی امری بسیار سخت خواهد بود.

همانطور که قبلاً نیز اشاره شد، تعداد پارامترهای تأثیرگذار در پیش‌بینی نرخ نفوذ زیاد است. انتخاب تعداد مناسبی از این پارامترها از اهمیت زیادی برخوردار است. در این راستا، پارامترها باید به گونه‌ای باشند که بتوانند توصیف مناسبی از شرایط واقعی تونل را شامل شوند. به عبارتی باید پارامترهای مربوط به توده‌سنگ و همچنین پارامترهای مربوط به ماشین را همزمان مورد استفاده قرار داد. برای انجام این مهم پارامترهای موجود در بانک داده را مورد بررسی قرار داده و با مقایسه بین پارامترهای ورودی با یکدیگر و همین‌طور با پارامتر خروجی، بهترین پارامترها انتخاب شده‌اند. شکل ۱ تا شکل ۶ به ترتیب میزان اثر پارامترهای قطر تونل،  $UCS$ ،  $RPM$ ،  $RQD$ ،  $RMR$  و  $F_n$  را نشان می‌دهد. این مقایسه‌ها و میزان تاثیر هر کدام از پارامترهای موجود روی نرخ نفوذ را نشان می‌دهد.



شکل ۱- تاثیر قطر تونل روی نرخ نفوذ



شکل ۲- تاثیر  $UCS$  روی نرخ نفوذ

پیش‌گرفته شده است.

روش‌های شبکه عصبی و سیستم‌های فازی-عصبی استفاده شده است. هرکدام از این روش‌ها خروجی‌های مختلفی را با استفاده از تحلیل‌های منحصر به فرد خود ارائه می‌دهند که در ادامه آورده شده‌اند.

#### ۵-۱- انتخاب پارامترهای ورودی


همانطور که قبلاً اشاره شد، با توجه به بانک داده‌ها پارامترهای ورودی شامل  $UCS$ ,  $RQD$ ,  $RMR$ ,  $TD$ ,  $RPM$  و  $F_n$  می‌باشند. همانطور که در جدول ۲، مشاهده می‌شود ترکیبات متفاوتی از پارامترهای ورودی برای پیش‌بینی نرخ نفوذ مورد استفاده قرار گرفته است که برای هرکدام به صورت جداگانه ضریب همبستگی  $R^2$  محاسبه شده است و در نهایت بهترین ترکیب پارامترها برای پیش‌بینی نرخ نفوذ مورد استفاده قرار خواهد گرفت.

جدول ۲- انواع پارامترهای انتخاب شده برای پیش‌بینی نرخ نفوذ

شماره مدل	پارامترهای ورودی
۱	$TD$ , $UCS$ , $RQD$ , $RMR$ , $RPM$
۲	$TD$ , $UCS$ , $RQD$ , $RPM$ , $F_n$
۳	$TD$ , $UCS$ , $RQD$ , $RMR$ , $F_n$
۴	$TD$ , $UCS$ , $RQD$ , $F_n$
۵	$TD$ , $UCS$ , $RMR$ , $F_n$
۶	$UCS$ , $RQD$ , $F_n$
۷	$UCS$ , $RMR$ , $F_n$
۸	$TD$ , $UCS$ , $RMR$ , $RPM$ , $F_n$
۹	$UCS$ , $RQD$ , $RMR$ , $RPM$ , $F_n$
۱۰	$TD$ , $UCS$ , $RQD$ , $RMR$ , $RPM$ , $F_n$

برای هرکدام از پارامترها در جدول ۲، ضریب همبستگی محاسبه شده است که در نهایت بالاترین ضریب مدل انتخابی نهایی را مشخص می‌کند. محاسبه ضرایب همبستگی به وسیله شبکه عصبی انجام گرفته است که برای هر مدل از ۴ شبکه با لایه‌های ۱، ۲، ۳ و ۴ لایه استفاده شده و در انتها بهترین ضریب همبستگی برای مقایسه انتخاب شده است. شکل ۷ تا شکل ۱۶ بهترین خروجی رگرسیونی شبکه عصبی را برای مدل‌های ۱ تا ۱۰ نشان داده است.

همان‌طور که مشاهده می‌شود، بهترین ضریب همبستگی مربوط به مدل شماره ۱۰ می‌باشد که برابر با



شکل ۶- تاثیر  $F_n$  روی نرخ نفوذ


همانطور که مشاهده گردید، فاکتور قطر تونل تاثیر بسزایی بر روی سرعت چرخش کله حفار و همچنین نرخ نفوذ دارد، اما از آنجایی که قطر  $TBM$ ها در پروژه‌های مختلف محدوده وسیعی را شامل نمی‌شود، در غالب مدل‌های قبلی به عنوان پارامتر ورودی در نظر گرفته نشده است. یکی دیگر از پارامترهایی که بسیار مورد توجه محققان در مطالعات قبلی قرار گرفته است، اطلاعات مربوط به ناپیوستگی‌هاست که این فاکتور نیز تا حد امکان در پارامترهای ورودی گنجانده شده است. برای این مهم از پارامتر  $RMR$ ، با توجه به وجود فاکتورهایی مانند فاصله‌داری ناپیوستگی‌ها، وضعیت ناپیوستگی‌ها و جهت‌گیری ناپیوستگی‌ها، استفاده شده است. قابل ذکر است که با توجه به همپوشانی بین  $RMR$  و  $RQD$  اثر هرکدام از آن‌ها به طور مستقل روی نرخ نفوذ محاسبه شده است. در نهایت پارامترهای مهم دیگری که باید در نظر قرار داد، مربوط به ماشین هستند که می‌توان گفت، از مهمترین آن‌ها سرعت چرخش کله حفار ( $RPM$ ) و نیروی عمودی تیغه‌ها ( $F_n$ ) می‌باشند که این دو پارامتر نیز در تحلیل داده‌ها به‌کارگرفته شده‌اند. لذا با توجه به توضیحات فوق، پارامترهای انتخاب شده برای پیش‌بینی نرخ نفوذ شامل  $UCS$ ,  $RQD$ ,  $RMR$ ,  $TD$ ,  $RPM$  و  $F_n$  می‌باشند.

#### ۵- مدل‌های پیش‌بینی


برای انتخاب بهترین ترکیب پارامترهای ورودی، از حذف و اضافه کردن هرکدام از پارامترها استفاده شده است. بعد از انتخاب پارامترهای ورودی مناسب، برای تحلیل داده‌ها از

از نرم‌افزار SPSS نیز مورد تحلیل قرار گرفته است که در آن معیار  $VIF$  (فاکتور همبستگی بین پارامترهای مستقل) بررسی گردیده است که نتیجه حاصل عدد کمتر از ۵ را نشان داده است؛ لذا مدل نهایی انتخاب شده در این پژوهش مدل شماره ۱۰ و پارامترهای ورودی شامل  $TD$ ،  $UCS$ ،  $RQD$ ،  $RMR$ ،  $RPM$  و  $F_n$  خواهند بود.


ذکر این نکته ضروری به نظر می‌رسد که حضور همزمان  $RQD$  و  $RMR$  نه تنها باعث پایین آمدن کیفیت مدل نشده است بلکه با توجه به نتایج به دست آمده از مدل‌های ده‌گانه بالاترین کیفیت را ارائه داده است. همچنین برای جلوگیری از بیش‌برازش احتمالی در روند آموزش شبکه عصبی، این مدل توسط رگرسیون با استفاده




شکل ۹- ضریب همبستگی مدل ۳




شکل ۸- ضریب همبستگی مدل ۲




شکل ۷- ضریب همبستگی مدل ۱




شکل ۱۲- ضریب همبستگی مدل ۶




شکل ۱۱- ضریب همبستگی مدل ۵




شکل ۱۰- ضریب همبستگی مدل ۴



شکل ۱۵- ضریب همبستگی مدل ۹



شکل ۱۴- ضریب همبستگی مدل ۸




شکل ۱۳- ضریب همبستگی مدل ۷



### ۵-۲- شبکه عصبی

همانطور که قبلاً اشاره شد در شبکه‌های عصبی با در نظر گرفتن تمامی شرایط، اعم از پیچیدگی شرایط یا مدت زمان محاسبه، می‌توان گفت بهترین روشی که در غالب شرایط بهترین نتیجه را به دست می‌دهد، استفاده از شبکه‌های عصبی پس انتشار خطا است لذا از در این مقاله نیز از همین روش با استفاده از نرم‌افزار متلب ورژن ۲۰۱۹ استفاده شده است. از تعداد کل داده‌های موجود، ۷۰٪ برای آموزش، ۱۵٪ برای تست و ۱۵٪ برای اعتبارسنجی مورد استفاده قرار گرفته است. هرکدام از پارامترهای ورودی با ترکیب متفاوتی از تعداد لایه و نورون مورد بررسی قرار گرفته‌اند (حداقل ۳۰ حالت مختلف) و ۶ گزینه انتخاب شده است که در جدول ۳، قابل ملاحظه می‌باشد.



شکل ۱۶- ضریب همبستگی مدل ۱۰

جدول ۳- تعدادی از گزینه‌های شبکه عصبی مورد استفاده

	مشخصات شبکه	R	R <sup>2</sup>	RMSE
شبکه عصبی	گزینه اول	۰/۸۶	۰/۷۴	۰/۵۱
	گزینه دوم	۰/۹۳	۰/۸۶	۰/۴۳
	گزینه سوم	۰/۹۶	۰/۹۲	۰/۳۸
	گزینه چهارم	۰/۹۲	۰/۸۴	۰/۶
	گزینه پنجم	۰/۹۱	۰/۸۲	۰/۷
	گزینه ششم	۰/۹۲	۰/۸۴	۰/۶۱

رگرسیون پیدا کردن خط یا منحنی به گونه‌ای است که نسبت به نقاط موجود، کمترین فاصله ممکن را داشته باشد. به عبارت دیگر، بهترین موقعیت این خط زمانی اتفاق می‌افتد که  $RMSE$  در کمترین حالت خود قرار داشته باشد. برای محاسبه این خط از رابطه ۱ استفاده می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (Y - Y')^2} \quad (1)$$

در این رابطه،  $n$  تعداد داده‌ها،  $Y$  داده‌های اندازه‌گیری شده و  $Y'$  داده‌های پیش‌بینی شده می‌باشند.

با توجه به نتایج جدول ۳، می‌توان گفت که بهترین نتیجه در شبکه‌های عصبی بررسی شده، از شبکه عصبی ۴ لایه به دست آمده است. لذا خروجی‌های مربوط به این خروجی آورده شده است. این جدول همچنین نشان می‌دهد که گزینه اول با حداقل تعداد لایه‌ها (۲ لایه) و تعداد ۵

در جدول ۴، اعداد نشان داده شده در ستون مشخصات شبکه به ترتیب نشان دهنده تعداد پارامترهای ورودی (عدد اول)، لایه‌های میانی (اعداد میانی) و لایه خروجی (عدد آخر) است. ضریب همبستگی یا  $R$ ، یک ابزار آماری است که به واسطه آن نوع رابطه بین دو یا چند متغیر کمی مشخص می‌شود. محدوده تغییر این ضریب بین ۱- تا ۱ است که مثبت یا منفی بودن آن به ترتیب به رابطه مستقیم یا غیر مستقیم پارامترها اشاره دارد. به صورت تجربی می‌توان گفت که هرچه میزان  $R$  به ۱ یا ۱- نزدیک‌تر باشد، پارامترهای مقایسه شده دارای رابطه قوی‌تری هستند. ضریب تعیین یا  $R^2$ ، عددی است بین ۰ و ۱ که از آن برای بیان میزان دقت در پیش‌بینی خروجی‌های آینده استفاده می‌شود که برای محاسبه آن ضریب همبستگی به توان ۲ می‌رسد. خطای مجذور میانگین مربعات یا  $RMSE$ ، خطایی است که از رگرسیون سرچشمه می‌گیرد. کار اصلی



در واقع با پیاده‌سازی شبکه روی داده‌های آزمایش و اعتبارسنجی می‌توان گفت که شبکه آموزش داده شده در استفاده برای داده‌های جدید از توانایی مناسبی برخوردار است و می‌توان شبکه به دست آمده را با دقت مناسب، روی داده‌های جدید اعمال کرد.

همان‌طور که در شکل ۱۷، مشخص است،  $R$  برابر با ۰.۹۶٪ و بنابراین ضریب تعیین  $R^2$  برابر با ۰.۹۲٪ می‌باشد که نشان‌دهنده پیش‌بینی مناسب شبکه است. شکل ۱۸، نشان‌دهنده پراکندگی خطای نهایی مدل پیش‌بینی شده است. در این شکل هرچه پراکندگی ستون‌های خطا کمتر باشد و در مرکز هیستوگرام متمرکزتر باشد، نتیجه بهتری حاصل خواهد شد. در شکل ۱۹، نیز روند طی شده توسط شبکه عصبی برای داده‌ها نشان داده شده است. دایره نشان داده شده در این شکل نشانگر کمترین خطای اتفاق افتاده در شبکه عصبی است که در بیست و یکمین تلاش شبکه عصبی رخ داده است. در واقع شکل ۱۹، نشان می‌دهد که روند آموزش داده‌ها در تکرار بیست و یکم به حالت بهینه رسیده است و از آن مرحله به بعد، بهبودی در شبکه عصبی حاصل نخواهد شد.

### ۵-۳- سیستم فازی-عصبی

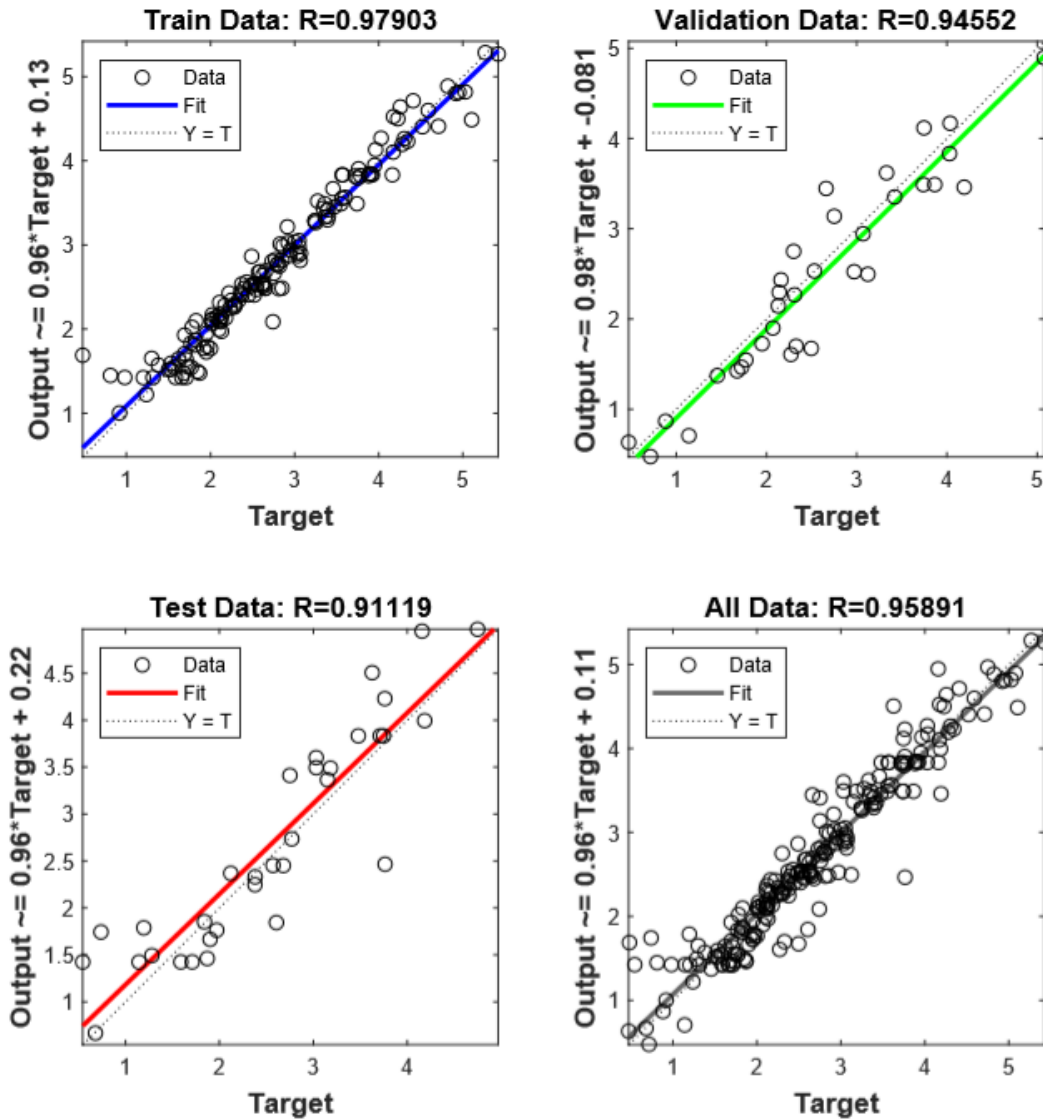
برای پیش‌بینی نرخ نفوذ با استفاده از این نوع از شبکه، از همان داده‌های به کار رفته در شبکه‌های عصبی استفاده شده است، با این تفاوت که در شبکه‌های فازی-عصبی ۱۸۵ دسته داده برای آموزش و ۳۲ دسته برای آزمایش استفاده می‌شود. برای محاسبه و تحلیل با استفاده از شبکه‌های فازی-عصبی از تولباکس نرم‌افزار متلب و همچنین از طریق کدنویسی اقدام شده است. همانطور که اشاره شد در شبکه‌های فازی-عصبی برخلاف روش‌های رگرسیون و شبکه‌های عصبی، امکان دخالت دانش انسانی و به عبارتی امکان بررسی عدم قطعیت‌های موجود در پروژه به علت مفهوم فازی آن، قابل انجام است. این موضوع با استفاده از توابع عضویت در شبکه‌های فازی قابل بیان است. در واقع یک تابع عضویت مقادیر پارامترها را به صورت کمی دریافت می‌کند، آن را به صورت کیفی مورد بررسی قرار می‌دهد و در انتها قبل از رسیدن به خروجی دوباره آن را به شکل کمی ارائه می‌دهد. لذا در این نوع از تحلیل به علت مفهوم فازی و ماهیت کیفی، می‌توان از خطاهای انسانی و ماشینی

نورون در لایه میانی، کمترین مقادیر را برای ضریب همبستگی و ضریب تعیین به همراه دارد. با افزایش تعداد لایه‌ها به ۳ لایه و ۴ لایه، مقادیر ضریب همبستگی و ضریب تعیین افزایش می‌یابد. مقایسه عملکرد گزینه‌های مختلف نشان می‌دهد که افزایش تعداد نورونها در لایه دوم در یک مدل ۲ لایه می‌تواند تا حد زیادی مقادیر ضریب همبستگی و ضریب تعیین را افزایش داده و به مقادیر گزینه‌هایی با تعداد لایه‌های بیشتر نزدیک کند. با افزایش تعداد لایه‌ها بهبودی در نتایج حاصل نشده و در مواردی سبب بدتر شدن نتایج شده است. قابل ذکر است که در غالب مسائل استفاده از تعداد لایه‌های بیشتر از ۳ یا ۴ لایه کاربردی ندارند (Wang, et al., 2020). از این رو در مقایسه گزینه‌های مختلف، بهترین گزینه یک شبکه عصبی ۴ لایه با تعداد ۲۳، ۱۰ و ۵ نورون در لایه‌های میانی به دست آمد که در ادامه خروجی‌های مربوط به این گزینه آورده می‌شود. همانطور که مشاهده می‌شود خطای  $RMSE$  در این گزینه ۰/۳۸ است که واحد این خطا با واحد نرخ نفوذ، یعنی متر بر ساعت، یکسان است. به عبارتی خطای پیش‌بینی شده حداکثر ۰/۳۸ متر بر ساعت با مقدار واقعی اختلاف دارد.


شکل ۱۷، نشان‌دهنده همبستگی بین مقادیر خروجی واقعی و مقادیر پیش‌بینی شده توسط شبکه عصبی است که برای هر کدام از داده‌های آموزش، آزمایش و اعتبارسنجی و همچنین کل داده‌ها انجام گرفته است. در واقع نتایج این شکل، میزان دقت پیش‌بینی توسط شبکه عصبی انتخاب شده را نشان می‌دهد. در این شکل میزان رگرسیون با استفاده از عدد  $R$  قابل مشاهده است. اگر  $R$  برابر ۱ باشد، به آن معناست که بین دو پارامتر مورد نظر رابطه کامل و مستقیم برقرار است. همانطور که پیش‌تر نیز اشاره شد، هرچقدر قدم‌مطلق این ضریب به یک نزدیک‌تر باشد، نشان‌گر آن است که عملکرد رگرسیون بهتر انجام شده است و رابطه قوی‌تری بین پارامترها برقرار است و در نهایت پیش‌بینی نرخ نفوذ با دقت بالاتری را خواهد داشت. در این شکل ضریب همبستگی برای داده‌های آموزش، داده‌های آزمایش و داده‌های اعتبارسنجی نشان داده شده است. در انتها نیز ضریب همبستگی برای تمامی داده‌ها محاسبه شده است. همانطور که مشاهده می‌شود، مقدار  $R$  برای داده‌های آزمایش و اعتبارسنجی نیز به ترتیب برابر ۰.۹۱٪ و ۰.۹۴٪ است.

است. در شکل ۲۰، مشخصات کلی شبکه به کارگرفته شده و روند آموزش و کاهش خطای نهایی در پیش‌بینی نرخ نفوذ، نشان داده شده است.


پروژه که روی مقادیر کمی پارامترها تاثیرگذار بوده‌اند چشم‌پوشی کرد. در ادامه، خروجی‌های مربوط به شبکه‌های فازی-عصبی و کد مورد استفاده برای تحلیل آن آورده شده



شکل ۱۷- همبستگی بین مقادیر خروجی واقعی و مقادیر پیش‌بینی شده توسط شبکه عصبی

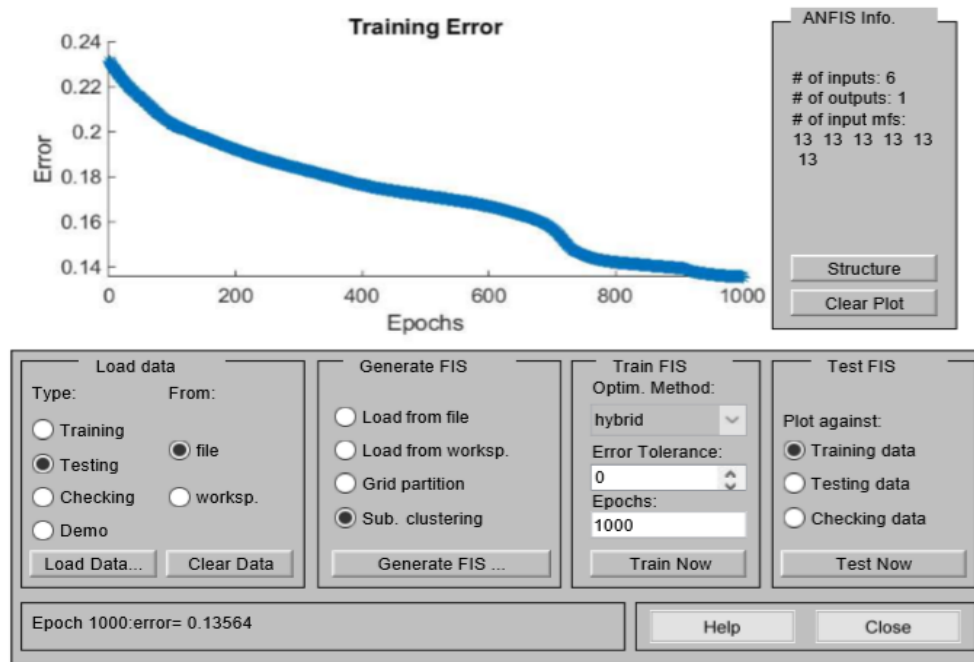


شکل ۱۸- توزیع خطای بین داده‌های واقعی و پیش‌بینی شده



شکل ۱۹- عملکرد شبکه عصبی

پیش‌بینی نرخ نفوذ *TBM* با استفاده از شبکه‌های عصبی و سیستم‌های فازی-عصبی... میلاد عامری و ...، ص ۳۵-۵۶



شکل ۲۰- مشخصات شبکه فازی-عصبی

بود".

شکل ۲۳، نشان دهنده ارتباط بین پارامترهای ورودی و خروجی است که به صورت یک سطح، نشان داده شده است. در این شکل سطح ارتباط بین پارامترهای قطر تونل و مقاومت فشاری تک محوری با نرخ نفوذ نشان داده شده است. بعد از پایان روند آموزش شبکه نیز می‌توان داده‌های واقعی را با داده‌های پیش‌بینی شده توسط سیستم مقایسه کرد. شکل ۲۴ و شکل ۲۵، نشان دهنده مقایسه داده‌های آموزش و داده‌های آزمایش هستند.

در انتها، در شکل ۲۶، می‌توان میزان خطای نهایی و واریانس خطا برای داده‌های آموزش را مشاهده کرد. همانطور که در این شکل ملاحظه می‌شود، میزان خطای حداکثر برابر با  $0.13736$  متر بر ساعت است که در مقایسه با محدوده اعداد نرخ نفوذ واقعی عدد بسیار کمی است. شکل ۲۷، نیز کد نوشته شده در نرم‌افزار متلب را نشان می‌دهد. قابل ذکر است که شکل ۲۶، خروجی به دست آمده از کد نوشته شده در نرم‌افزار متلب است.

همان‌طور که در شکل ۲۰، نشان داده شده است، در این شبکه از کلاس‌بندی کاهشی و روش بهینه‌سازی ترکیبی استفاده شده است. همچنین در این شکل می‌توان تعداد ورودی‌ها و خروجی‌ها و همچنین تعداد توابع عضویت در نظر گرفته شده برای هر ورودی را مشاهده کرد. روند آموزش  $1000$  بار تکرار شده است. در واقع با آزمون و خطا مشخص شده است که با لایردن تعداد تکرار در روند آموزش، تاثیری بر بهبود کیفیت سیستم نخواهد داشت. در شکل ۲۱ تا شکل ۲۶، سایر بخش‌های شبکه‌های فازی-عصبی نشان داده شده است. در شکل ۲۱ و شکل ۲۲، قوانین به کارگرفته شده نشان داده شده است. برای توصیف بهتر قوانین شبکه با توجه به شکل ۶، یکی از خروجی‌ها به صورت زیر مورد بررسی قرار داده می‌شود:

"اگر قطر تونل برابر  $7/2$  متر، مقاومت فشاری تک‌محوری  $152$  مگاپاسکال، مقدار *RMR* برابر  $48/6$ ، مقدار *RQD* برابر  $53/5$ ، نیروی وارد بر هر تیغه برابر  $294$  کیلونیوتن و تعداد دور کاترهد در هر دقیقه برابر  $8/83$  دور باشد، آنگاه مقدار نرخ نفوذ برابر  $3/91$  متر در ساعت خواهد

ter1) and (UCS is in2cluster1) and (Rpm is in3cluster1) and (RMR is in4cluster1) and (RQD is in5cluster1) and (Fn is in6cluster1) then (PR is out1cluster1) (1)  
 ter2) and (UCS is in2cluster2) and (Rpm is in3cluster2) and (RMR is in4cluster2) and (RQD is in5cluster2) and (Fn is in6cluster2) then (PR is out1cluster2) (1)  
 ter3) and (UCS is in2cluster3) and (Rpm is in3cluster3) and (RMR is in4cluster3) and (RQD is in5cluster3) and (Fn is in6cluster3) then (PR is out1cluster3) (1)  
 ter4) and (UCS is in2cluster4) and (Rpm is in3cluster4) and (RMR is in4cluster4) and (RQD is in5cluster4) and (Fn is in6cluster4) then (PR is out1cluster4) (1)  
 ter5) and (UCS is in2cluster5) and (Rpm is in3cluster5) and (RMR is in4cluster5) and (RQD is in5cluster5) and (Fn is in6cluster5) then (PR is out1cluster5) (1)  
 ter6) and (UCS is in2cluster6) and (Rpm is in3cluster6) and (RMR is in4cluster6) and (RQD is in5cluster6) and (Fn is in6cluster6) then (PR is out1cluster6) (1)  
 ter7) and (UCS is in2cluster7) and (Rpm is in3cluster7) and (RMR is in4cluster7) and (RQD is in5cluster7) and (Fn is in6cluster7) then (PR is out1cluster7) (1)  
 ter8) and (UCS is in2cluster8) and (Rpm is in3cluster8) and (RMR is in4cluster8) and (RQD is in5cluster8) and (Fn is in6cluster8) then (PR is out1cluster8) (1)  
 ter9) and (UCS is in2cluster9) and (Rpm is in3cluster9) and (RMR is in4cluster9) and (RQD is in5cluster9) and (Fn is in6cluster9) then (PR is out1cluster9) (1)  
 ster10) and (UCS is in2cluster10) and (Rpm is in3cluster10) and (RMR is in4cluster10) and (RQD is in5cluster10) and (Fn is in6cluster10) then (PR is out1cluster10) (1)  
 ster11) and (UCS is in2cluster11) and (Rpm is in3cluster11) and (RMR is in4cluster11) and (RQD is in5cluster11) and (Fn is in6cluster11) then (PR is out1cluster11) (1)  
 ster12) and (UCS is in2cluster12) and (Rpm is in3cluster12) and (RMR is in4cluster12) and (RQD is in5cluster12) and (Fn is in6cluster12) then (PR is out1cluster12) (1)  
 ster13) and (UCS is in2cluster13) and (Rpm is in3cluster13) and (RMR is in4cluster13) and (RQD is in5cluster13) and (Fn is in6cluster13) then (PR is out1cluster13) (1)

is and UCS is and Rpm is and RMR is and RQD is

in2cluster1  
in2cluster2  
in2cluster3  
in2cluster4  
in2cluster5  
in2cluster6  
in2cluster7  
in2cluster8

in3cluster1  
in3cluster2  
in3cluster3  
in3cluster4  
in3cluster5  
in3cluster6  
in3cluster7  
in3cluster8

in4cluster1  
in4cluster2  
in4cluster3  
in4cluster4  
in4cluster5  
in4cluster6  
in4cluster7  
in4cluster8

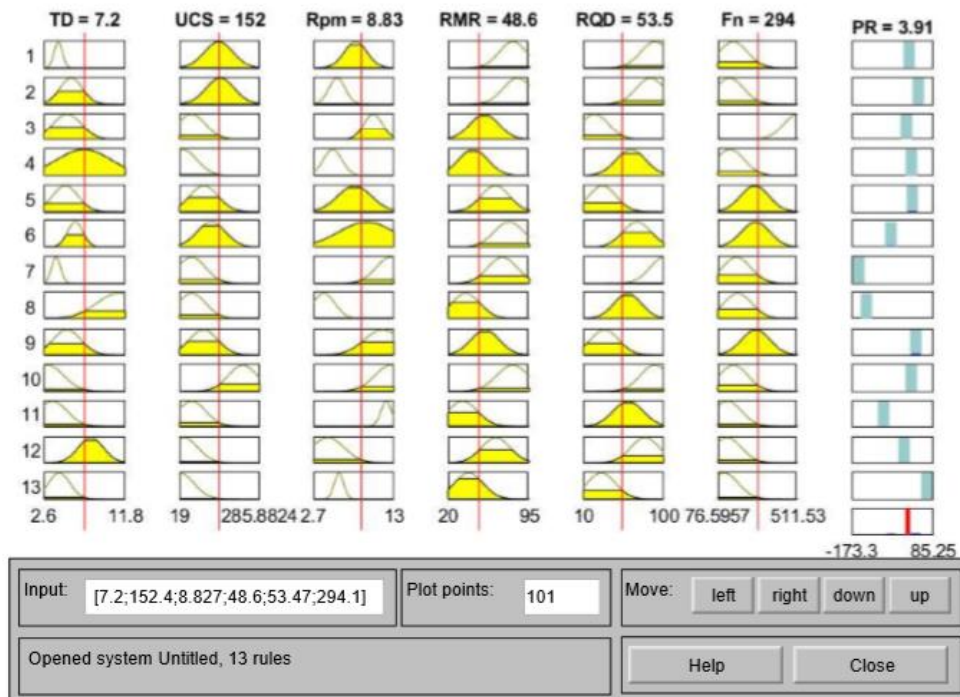
in5cluster1  
in5cluster2  
in5cluster3  
in5cluster4  
in5cluster5  
in5cluster6  
in5cluster7  
in5cluster8

not not not not not

Weight: 1

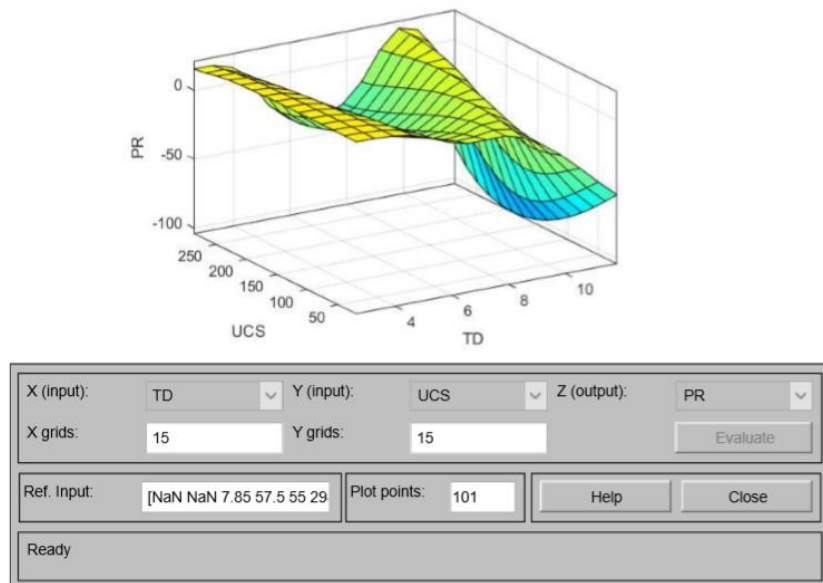
Delete rule Add rule Change rule

شکل ۲۱- قوانین به کار رفته در شبکه

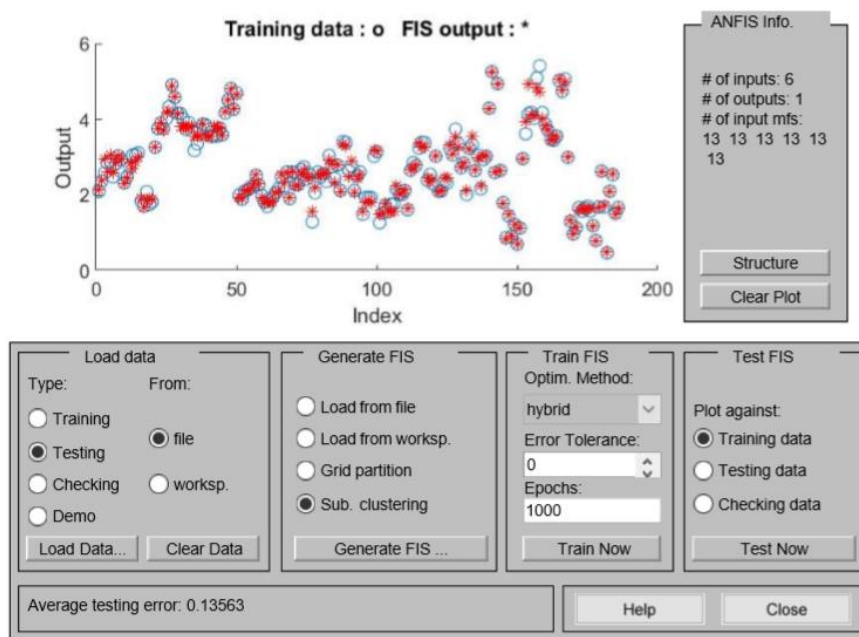


شکل ۲۲- شماتیک قوانین به کار رفته در شبکه

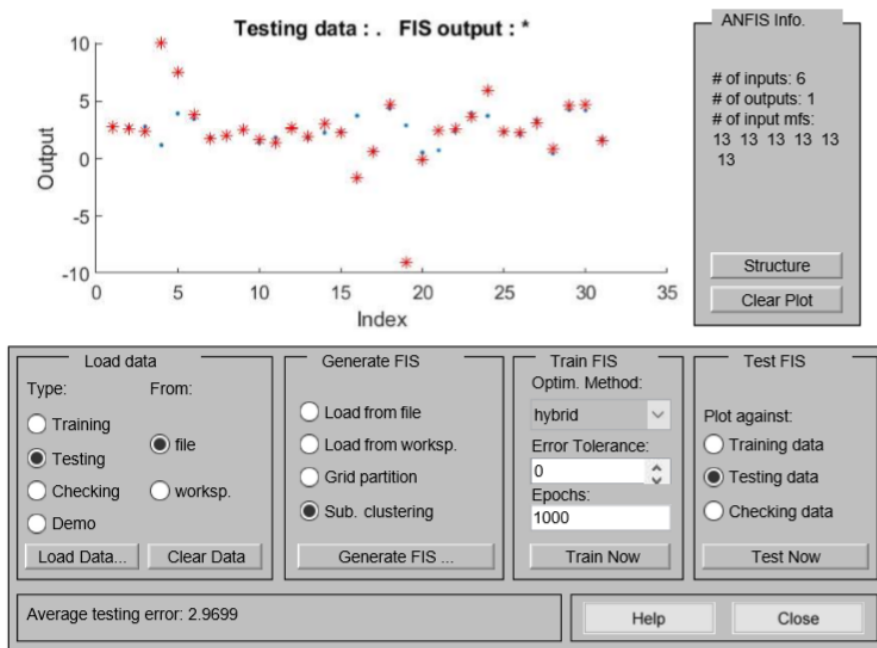
پیش‌بینی نرخ نفوذ *TBM* با استفاده از شبکه‌های عصبی و سیستم‌های فازی-عصبی... میلاد عامری و ...، ص ۳۵-۵۶




شکل ۲۳- رابطه بین قطر تونل، مقاومت فشاری تک محوری و نرخ نفوذ



شکل ۲۴- مقایسه داده‌های واقعی و پیش‌بینی شده در داده‌های آموزش



شکل ۲۵- مقایسه داده‌های واقعی و پیش‌بینی شده در داده‌های آزمایش



شکل ۲۶- خطای نهایی داده‌های آموزش



```
clc;
clear;
close all;

%% Load Data

x=xlsread('in.xlsx');
y=xlsread('out.xlsx');

TrainInputs=x;
TrainTargets=y;
TrainData=[TrainInputs TrainTargets];

m=xlsread('int.xlsx');
n=xlsread('outt.xlsx');

TestInputs=m;
TestTargets=n;
TestData=[TestInputs TestTargets];

Options = genfisOptions('SubtractiveClustering');

%% Design ANFIS

nMFs=3;
InputMF='gaussmf';
OutputMF='linear';

fis=genfis(TrainInputs,TrainTargets,Options);

MaxEpoch=500;
ErrorGoal=0;
InitialStepSize=0.01;
StepSizeDecreaseRate=0.5;
StepSizeIncreaseRate=2;
TrainOptions=[MaxEpoch ...
              ErrorGoal ...
              InitialStepSize ...
              StepSizeDecreaseRate ...
              StepSizeIncreaseRate];
```

شکل ۲۷- کد شبکه عصبی-فازی

## ۶- مقایسه شبکه‌عصبی و سیستم فازی -

### عصبی

همانطور که در بخش‌های قبلی مشاهده گردید، برای پیش‌بینی نرخ نفوذ از ۲ روش برمبنای هوش مصنوعی استفاده شد. در روش شبکه‌های عصبی از یادگیری برای پیش‌بینی استفاده شده است. به عبارتی با استفاده از داده‌های موجود، داده‌های مربوط به پروژه‌های تونلی قبلی، شبکه عصبی آموزش می‌بیند و بعد از آموزش شبکه قادر خواهد بود که از نتایج حاصل شده برای پیش‌بینی استفاده نماید. در روش فازی-عصبی نیز علاوه بر آموزش از فازی کردن داده‌ها استفاده شده است که نتایج مقایسه این دو روش آن در جدول ۴، قابل مشاهده است. با توجه به نتایج جدول ۴، می‌توان گفت که خطای برآورد شبکه فازی-عصبی نسبت به شبکه عصبی کمتر است.

### جدول ۴- مقایسه خطای حاصل شده از شبکه عصبی و

#### شبکه فازی-عصبی

نوع شبکه	خطای $RMSE (m/h)$
شبکه عصبی	۰/۳۸
شبکه عصبی-فازی	۰/۱۳

## ۷- نتیجه‌گیری

مقایسه بین مدل‌های پیش‌بینی نرخ نفوذ قبلی نشان می‌دهد که این مدل‌ها دارای معایبی مانند عدم دقت کافی در پیش‌بینی، عدم به‌کارگیری پارامترهای مناسب، عدم استفاده از بانک داده مناسب و متنوع هستند. از این‌رو تلاش برای معرفی مدل‌های جدید برای پیش‌بینی نرخ نفوذ، همچنان مسئله مهمی در پروژه‌های تونل‌سازی است. امروزه استفاده از مدل‌های جدید و هوشمند به دلیل دقت بالا، امکان حل مسائل پیچیده و غیرخطی و همچنین امکان دخالت دانش انسانی و توصیف عدم قطعیت‌ها، به شدت در حال گسترش است. در این مقاله از دو روش برای پیش‌بینی

نرخ نفوذ استفاده شده است که شامل شبکه‌های عصبی و شبکه‌های فازی-عصبی می‌شوند. در استفاده از شبکه‌های عصبی از ۲۱۷ دسته داده مربوط به ۱۴ تونل استفاده شده است که ۷۰٪ آن‌ها برای آموزش، ۱۵٪ برای تست و ۱۵٪ برای اعتبارسنجی مورد استفاده قرار گرفته‌اند. در شبکه‌های عصبی از بیش از ۳۰ مورد از ترکیب‌های مختلفی در تعداد لایه‌ها و نورون‌ها استفاده شده است. برای انتخاب تعداد لایه‌های شبکه عصبی، از آزمون و خطا استفاده شده است که در آن شبکه‌هایی با تعداد لایه بین ۱ تا ۶ بررسی گردیده‌اند. انتخاب تعداد لایه به عواملی مانند تعداد پارامتر ورودی و نیز پیچیدگی مساله وابسته است، اما با توجه به مطالعات قبلی و همچنین آزمون و خطای صورت گرفته می‌توان نتیجه گرفت که استفاده از شبکه‌های عصبی با ۲ یا ۳ لایه در بیشتر موارد قادر به ارائه نتایج مناسب خواهند بود و استفاده از لایه‌های بیشتر می‌تواند سبب افزایش زمان محاسبات شبکه و حتی کاهش دقت شبکه گردد. در این پژوهش شبکه ۴ لایه بهترین نتیجه را ارائه داده است که خطای  $RMSE$  نهایی این شبکه برابر با ۰/۳۸ متر بر ساعت محاسبه شده است. در روش دوم از شبکه‌های فازی-عصبی استفاده شده که در آن از ۱۸۵ دسته داده برای آموزش و ۳۲ دسته داده برای آزمایش استفاده شده است. این شبکه از نوع ترکیبی بوده و ۱۰۰۰ بار تحت آموزش قرار گرفته است تا خطای آن به پایین‌ترین میزان خود برسد. در این شبکه از روش خوشه‌بندی کاهشی استفاده شده است و برای هرکدام از پارامترهای ورودی از ۱۳ تابع عضویت استفاده شده است. در نهایت پس از پایان روند آموزش، خطای نهایی  $RMSE$  آن برابر ۰/۱۳ متر بر ساعت است که نسبت به روش شبکه عصبی به مراتب عملکرد بهتری را نشان داده است. می‌توان گفت با توجه به اینکه در روش فازی-عصبی، دانش انسانی برای توصیف عدم قطعیت‌ها قابل استفاده است و همچنین عضویت پارامترهای ورودی در محاسبه پارامتر خروجی به صورت دقیق نیست، لذا عملکرد بهتری را نسبت به شبکه عصبی دارد.

## ۸- مراجع

- Adoko, A., & Yagiz, S. (2018). *Fuzzy Inference System-Based for TBM Field Penetration Index Estimation in Rock Mass*. *Geotech Geol Eng.* doi.org/10.1007/s10706-018-0706-5
- Adoko, A., Alipov, A., & Yabukov, K. (2019). *A Comparative Study of TBM Penetration Rate Assessment Rock Mass Properties*. American Rock Mechanics Association. New York.
- Cassinelli, F., Cina, S., Innaurato, N., Mancin, R., & Saopalo, A. (1982). *Power consumption and metal wear in tunnel-boring machines: analysis of tunnel boring operation in hard rock*. *Tunnelling'82, Jones, M.J.Ed., 73-81.*
- Farmer, I., & Glossop, N. (1980). *Mechanics of disc cutter penetration*. *Tunnels Tunnel, 22-25.*
- Farrokh, E. (2020). *Tunnelling and Underground Space Technology*. doi:10.1016/j.tust.2019.103219
- Farrokh, E., Rostami, J., & Laughton, C. (2012). *Study of various models for estimation of penetration rate of hard rock TBMs*. *Tunnelling and Underground Space Technology, 110-123.* doi:10.1016/j.tust.2012.02.012
- Gholami, M., Shahriar, K., Sharifzadeh, M., & Khademi Hamidi, J. (2012). *A comparison of artificial neural networks and multiple regression analysis in TBM performance prediction*. *Asian Rock Mechanics Symposium, (pp. 15-19)*. Seoul.
- Gong, Q., & Zhao, J. (2009). *Development of a rock mass characteristics model for TBM penetration rate prediction*. *International Journal of Rock Mechanics and Mining Sciences, 8-18.*
- Gong, Q., Yin, H., & Zhao, J. (2016). *TBM tunneling under adverse geological conditions: An overview*. *Tunneling and Underground Space Technology, 4-17.*
- Graham, P. (1976). *Rock exploration for machine manufacturers*. Bieniawski ZR *Exploration for rock engineering, (pp. 173-180)*. Balkema.
- Grima, M., Bruines, P., & Verhoef, P. (2000). *Modeling Tunnel Boring Machine Performance by Neuro-Fuzzy Methods*. *Tunnelling and Underground Space Technology, 259-269.*
- Hassanpour, J., Rostami, J., & Zhao, J. (2011). *A new hard rock TBM performance prediction model for project planning*. *Tunnelling and Underground Space Technology, 595-603.*
- Hedayatzadeh, M., Shahriar, K., & Khademi Hamidi, J. (2010). *An Artificial Neural Network Model To Predict The Performance of Hard Rock TBM*. *ISRM International Symposium (pp. 23-27)*. New Delhi: India.
- Innaurato, N., Mancini, R., Rondena, E., & Zaninetti, A. (1991). *Forecasting and effective TBM performances in a rapid excavation of a tunnel in Italy*. *7th international congress ISRM. Aachen.*
- Khademi Hamidi, J., Shahriar, K., Rezai, B., & Rostami, J. (2011). *Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system*. *Tunnelling and Underground Space Technology, 333-345.*

- Koopialipoor, M., Tootoonchi, H., Jahed Armaghani, D., & Tonnizam Mohamad, E. (2019). Application of deep neural networks in predicting the penetration rate of tunnel boring machine. *Bulletin of Engineering Geology and the Environment*. doi:10.1007/s10064-019-01538-7
- Liu, Q., X. Huang, Q. Gong, L. Du, Y. Pan, & J. Liu. (2016). Application and development of hard rock TBM and its prospect in China. *Tunnelling and Underground Space Technology*, 33-46.
- Medel-Morales, R., & Botello-Rionda, S. (2013). Design and Optimization of Tunnel Boring Machines by Simulating the Cutting Rock Process using the Discrete Element Method. *Computacion y Sistemas*, 329-339.
- Mobarra, Y., Hajian, A., & Rahgozar, M. (2013). Application of Artificial Neural Networks to the Prediction of TBM Penetration Rate in TBM-driven Golab Water Transfer Tunnel. *International Conference on Civil Engineering Architecture & Urban Sustainable Development*. Tabriz.
- Mohammadi, S., Torabi-Kaveh, M., & Bayati, M. (2014). Prediction of TBM penetration rate using intact and mass rock properties (case study: Zagros long tunnel, Iran). *Arab J Geosci*.
- Moradi, M., & Farsangi, M. (2014). Application of the Risk Matrix Method for Geotechnical Risk Analysis and Prediction of the Advance Rate in Rock TBM Tunnelling. *Rock Mech Rock Eng*, 1951-1960.
- Ozdemir, L., Miller, R., & Wang, F. (1978). *Mechanical tunnel boring prediction and machine design*. Colorado: Colorado School of Mines.
- Ramezanzadeh, A. (2005). *Performance analysis and development of new models for performance prediction of hard rock TBMs in rock mass*. Lyon: Ph.D. Thesis.
- Report, G. (2020). *Geotechnical Report of Glass Tunnel. Developing of Water Sources of Iran*.
- Rostami, J. (1997). *Development of a force estimation model for rock fragmentation with disc cutters through theoretical modelling and physical measurement of crushed zone pressure*. Colorado School of Mines, Colorado: Ph.D. Thesis.
- Salimi, A., Singh, T., Moormann, C., & Jain, P. (2015). TBM Performance Prediction in Rock Tunneling Using Various Artificial Intelligence Algorithms. *11th Iranian and 2nd Regional Tunnelling Conference*. Tehran.
- Sanio, H. (1985). Prediction of the performance of disc cutters in anisotropic rock. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 153-161.
- Tarkoy, P. (1973). *Predicting TBM penetration rates in selected rock types*. 9th Canadian Rock Mechanics Symposium. Montreal.
- Wang, X., Lu, H., Wei, X., Wei, G., Behbahani, S., & Iseley, T. (2020). Application of Artificial Neural Network in Tunnel Engineering: A Systematic Review. *IEEE Access*. doi:10.1109/ACCESS.2020.3004995
- Yagiz, S. (2002). *Development of rock mass features and toughness in the CSM model basic penetration for hard rock tunneling machine*. Colorado School of Mines, Colorado: Ph.D Thesis.

پیش‌بینی نرخ نفوذ TBM با استفاده از شبکه‌های عصبی و سیستم‌های فازی-عصبی... میلاد عامری و ...، ص ۳۵-۵۶

Yagiz, S. (2008). Utilizing rock mass properties for predicting TBM performance in hard rock condition. *Tunnelling and Underground Space Technology*, 326-339.

Yavari, M., & Mahdevari, S. (2006, April). TBM Penetration Rate Prediction Using Neural Networks. *Journal of The College of Engineering*, pp. 115-121.

Zadeh, L. (1965). Fuzzy Sets. *Information and Control*, 338-353.

## *TBM penetration rate prediction using neural networks and neuro-fuzzy systems*

M. Ameri<sup>\*1</sup>; E. Farrokh<sup>2</sup>; H. Molladavoodi<sup>3</sup>

1- MSc Graduate; Faculty of Mining Engineering, Amirkabir University of Technology, milad.a70@aut.ac.ir

2- Associate Professor; Faculty of Mining Engineering, Amirkabir University of Technology, e.farrokh@aut.ac.ir

3- Assistant Professor; Faculty of Mining Engineering, Amirkabir University of Technology, davoodi@aut.ac.ir

Received: 1 Aug 2021; Accepted: 16 Jan 2022

DOI: 10.22044/tuse.2022.10987.1424

---

### **Keywords**

Penetration rate  
Neural network  
Neuro-fuzzy system  
Tunnel boring machine  
Machine parameters  
Rock mass parameters

---

### **Extended Abstract**

#### **Summary**

TBM penetration rate (PR) prediction is one of the most crucial issues for project cost and time estimation, although this issue has remained an important challenge for engineers and investors. Results of former investigations in this regard show that there are different methods for PR prediction, including theoretical and statistical models as classic methods and neural networks, fuzzy logic systems and neuro-fuzzy models as intelligent and new or modern methods. The modern methods are more capable of analyzing complex and non-linear relationships in comparison with the classic methods. Accordingly, implementation of the modern methods for PR prediction will lead to a more precise outcome. In this paper, a database, including 14 tunnels around the world, has been used. Chosen parameters are a combination of machine and rock mass specifications, including normal mean thrust force ( $F_n$ ), cutterhead revolution per minute (Rpm), tunnel diameter (TD), rock mass rating (RMR), rock quality designation (RQD) and uniaxial compressive strength (UCS). By analyzing and reviewing relevant results, it has been determined that omission or failure to use appropriate parameters causes a significant decline in PR prediction. These results also show that the UCS and RQD are among the most effective parameters. Furthermore, it has been concluded that using neuro-fuzzy networks (RMSE = 0.13 m/h) is more accurate than neural networks (RMSE = 0.38 m/h).

### **Introduction**

TBM penetration rate is one of the most important problems in tunneling projects, and has a significant impact on project cost and time. Hence, an accurate estimation of this parameter can lead to an optimization in project cost and time. In recent years, many studies have been carried out to assess the most important parameters affecting the PR. These studies based on different methods, such as theoretical and statistical models as classic methods, and artificial intelligence models as modern methods. Reviewing publications in this regard shows, for a better PR prediction, machine parameters and rock mass parameters both will be needed. Besides, a good database, which contains various projects, is very helpful for a better prediction.

### **Methodology and Approaches**

A database of 14 tunnel projects around the world has been collected that includes 217 datasets of chosen parameters for PR prediction. In this paper, the chosen parameters for the PR prediction are normal mean thrust force ( $F_n$ ), cutterhead revolution per minute (Rpm), tunnel diameter (TD), RMR, RQD and UCS, which cover both machine parameters and rock mass parameters. The research methodology in this paper is the application of neural network and neuro-fuzzy systems that are coded in MATLAB software. Among these 217 datasets, 70% are used for training, 15% for testing and the remaining 15% for validation. In the applied neural networks, 30 different layer combinations have been tested including networks containing 1 to 6 layers. For the neuro-fuzzy system, used in this study, 185

---

datasets have been used for training and 32 datasets has been used for testing. This neuro-fuzzy network uses hybrid combination, which has been trained more than 1000 times. In this paper, root mean square error (RMSE) has been chosen as a criterion for assessing the accuracy. The results have shown that neural networks method has an RMSE = 0.38 m/h and neuro-fuzzy system has an RMSE= 0.13 m/h, implying that the neuro-fuzzy system is more accurate than the neural networks method.

### **Results and Conclusions**

The results show that PR prediction using artificial intelligence methods are more precise than the classical methods. That is because the artificial intelligence methods have more power to analyze the complex relationships between different parameters. The results have also shown that most effective parameters in the PR prediction are UCS and RQD as two rock mass parameters. Recent studies in the neural networks context show that in most cases, not only using a network with more than 2 or 3 layers has not a positive effect on final results, but makes the network hyper-complex and time consumable although the best result in this paper has been obtained from a 4-layer network. Analyzing the data clearly shows that the more data exist the more precise result will be obtained. As the results show the neuro-fuzzy system with RMSE = 0.13 m/h has a more precise PR prediction in comparison with the neural network having RMSE = 0.38 m/h. This is because in the neuro-fuzzy system describing uncertainties can be implemented by human knowledge.

---