

بررسی تاثیر پارامترهای اجرایی ماشین TBM بر نرخ نفوذ آن با استفاده از روش شبکه‌های عصبی مصنوعی - مطالعه‌ی موردی تونل بلند زاگرس

سید مصلح افتخاری^{۱*}؛ علیرضا باغبانان^۲؛ راحب باقرپور^۳

۱- دانشجوی دکترای تخصصی؛ رشته‌ی مهندسی معدن؛ گرایش مکانیک سنگ؛ دانشکده‌ی مهندسی معدن؛ دانشگاه صنعتی اصفهان

۲ و ۳- استادیار؛ دانشکده‌ی مهندسی معدن؛ دانشگاه صنعتی اصفهان

دریافت دست‌نوشته: ۱۳۹۱/۰۸/۰۲؛ پذیرش مقاله: ۱۳۹۱/۱۰/۲۷

واژگان کلیدی

ماشین حفر تونل (TBM)
نرخ نفوذ
شبکه‌های عصبی مصنوعی
نیروی محوری پیشران
گشتاور

چکیده

نرخ نفوذ یکی از پارامترهای مهم در تعیین مدت زمان حفاری در عملیات تونلسازی است. از آنجا که عملیات حفاری اندرکنش میان زمین و ماشین است؛ بنابراین دو دسته‌ی کلی پارامتر موثر بر نرخ نفوذ وجود دارد. از طرفی در شرایط یکسان زمین، به دلیل پارامترهای اجرایی متفاوت ماشین، مقدار نرخ نفوذ متفاوت است. بنابراین در این مقاله به بررسی اثر پارامترهای ماشین بر نرخ نفوذ با استفاده از روش شبکه‌های عصبی مصنوعی پرداخته شده است. پس از انتخاب پارامترهای موثر بر نرخ نفوذ و ایجاد شبکه‌ی عصبی بهینه، تحلیل حساسیت بر روی پارامتر نیروی محوری پیشران و گشتاور انجام شده است. نتایج تحلیل‌ها نشان می‌دهد که نیروی محوری پیشران و گشتاور در یک محدوده‌ی بهینه، سبب افزایش نرخ نفوذ می‌شود و به منظور دستیابی به نرخ نفوذ حداکثر می‌توان از زوج نیروی محوری پیشران و گشتاور بهینه استفاده نمود.

۱- مقدمه

یکی از عوامل تعیین‌کننده‌ی انتخاب روش حفاری تونل (مکانیزه یا سنتی)، مدت زمان حفر آن است. در روش‌های سنتی، زمان حفر تونل، تابع پیشروی در یک مرحله‌ی آتشکاری است و در حفاری مکانیزه مدت زمان حفر تونل را نرخ پیشروی (AR: Advance Rate) ماشین تعیین می‌کند. نرخ نفوذ (PR: Penetration Rate)، یکی از مهم‌ترین فاکتورهای تاثیرگذار بر سرعت حفاری یا نرخ پیشروی TBM است. نرخ نفوذ، نسبت فاصله‌ی حفاری شده به زمان انجام آن در طول حفاری پیوسته یا به عبارتی برابر با نرخ پیشروی آنی ماشین است و معمولاً بر حسب میلی‌متر بر دور تاج حفر یا متر بر ساعت بیان می‌شود. در صورت پیش‌بینی قابل قبول از نرخ نفوذ و به تبع آن از نرخ پیشروی، تخمین

قابل اطمینانی از زمان و بودجه‌ی لازم جهت انجام پروژه می‌تواند صورت پذیرد.

با توجه به اهمیت پیش‌بینی نرخ نفوذ در عملیات تونلسازی، هم‌زمان با ساخت TBM همواره محققانی به دنبال یافتن روشی برای پیش‌بینی مقدار آن بوده‌اند و تا کنون روش‌های متعدد تئوری و تجربی نیز ارائه شده است. در روش‌های تئوری محققانی از جمله رگسبروگ و فیلیپس (Roxborough & Phillips)، سانئو (Sanio) و بوید (Boyd) با توجه به ارتباط تئوری میان پارامترهای ماشین و نفوذ دیسک و همچنین در برخی موارد پارامترهایی از سنگ به پیش‌بینی نرخ نفوذ پرداخته‌اند [1] و [2]. همچنین، انیستیتو مهندسی حفاری معدن کلرادو برای پیش‌بینی کارایی TBM بر مبنای ۲۰ سال مطالعات تئوریک،

* اصفهان؛ دانشگاه صنعتی اصفهان؛ دانشکده‌ی مهندسی معدن؛ کدپستی: ۸۴۱۵۶۸۳۱۱۱؛ شماره‌ی تلفن: ۰۳۱۱-۳۹۱۵۱۴۸؛ رایانامه: eftekhari_mosleh@yahoo.com & s.eftekhari@mi.iut.ac.ir

و عملکرد موازی آن به وجود آمده است و به مدل‌های ریاضی محض نیازی ندارد؛ بلکه همانند انسان تجربه کسب کرده و سپس نتیجه‌ی این تجربیات را تعمیم می‌دهد. در مواردی که رابطه‌ی مشخصی میان پارامترهای ورودی و خروجی وجود نداشته و ارتباط میان آن‌ها توسط روش‌های مرسوم قابل شناسایی نیست، استفاده از روش شبکه‌های عصبی مصنوعی به سبب عدم نیاز به فرمول‌بندی و پویا بودن شبکه و همچنین امکان لحاظ کردن اثر پارامترهای موثرتر، ایده‌ی خوبی برای تخمین و مدل‌سازی به شمار می‌رود. در واقع شبکه‌ی عصبی با توجه به قابلیت‌هایش، می‌تواند راه‌های ساده‌تر و کم هزینه‌تر و نتایج دقیق‌تری را پیش روی مهندسين، قرار دهد.

به منظور پیش‌بینی یک پارامتر با استفاده از شبکه‌ی عصبی نیاز به سابقه‌ای از آن پارامتر و پارامترهای موثر بر آن است تا بتوان پس از ساخت شبکه‌ای مناسب، از آن به منظور پیش‌بینی کمیت مورد نظر بهره گرفت [۱۴]. گریمما و همکارانش (*Grima, et al.*) تصمیم به پیش‌بینی نرخ نفوذ با توجه به سه مجموعه‌ی کلی موثر بر نرخ نفوذ از قبیل مشخصات سنگ بکر، ناپیوستگی‌ها و مشخصات ماشین گرفتند. این محققین پارامترهای مقاومت فشاری تک محوری (*UCS*) به عنوان مشخصه‌ی سنگ بکر، فراوانی شکستگی مغزه (*CFF: Core Fracture Frequency*) به عنوان مشخصه‌ی ناپیوستگی، سرعت چرخش تاج حفار (*RPM*)، قطر دیسک و نیروی محوری پیشران در هر دیسک به عنوان مشخصات ماشین را در لایه‌ی ورودی و نرخ نفوذ را در لایه خروجی جای داده‌اند [۱۵].

مهدوری و یآوری پارامترهای نوع سنگ، مقاومت فشاری تک محوره، درصد کوارتز، قطر دیسک، نیروی نفوذ در هر دیسک و *RQD* را به عنوان پارامترهای ورودی و نرخ نفوذ را به عنوان خروجی شبکه در نظر گرفته‌اند [۱۶]. همچنین، یاگیز و همکارانش (*Yagiza, et al.*) چهار پارامتر مقاومت فشاری تک محوری، اندیس تردی، فاصله‌ی صفحات ضعف و زاویه‌ی بین این صفحات و محور تونل را به عنوان ورودی شبکه عصبی در نظر گرفته‌اند و شبکه‌ای با چهار ورودی و یک خروجی ایجاد کرده‌اند. همچنین آن‌ها با استفاده از داده‌های مورد استفاده در شبکه‌ی عصبی به پیش‌بینی نرخ نفوذ به کمک رگرسیون‌گیری چند متغیره‌ی

آزمون‌های آزمایشگاهی و ارزیابی داده‌های حاصل از برداشت‌های صحرائی، مدلی با عنوان *CSM (Colorado School of Mines)* ارائه کرده است [3]. فلسفه‌ی این روش تعیین نیروهای وارد بر دیسک برای یک مقدار معین نفوذ و متعاقباً تعیین نیروی پیشروی، گشتاور و توان لازم برای کله‌ی حفار بر مبنای این نیروها است.

روش تجربی بر مبنای ارتباط عملی و مشاهداتی بین پارامترهای زمین و ماشین برقرار است و به واسطه‌ی برآزش بین خصوصیات سنگ و پارامترهای ماشین با نرخ نفوذ به دست آمده است. تعدادی از محققان از جمله تارکی (*Tarkoy*)، گراهام (*Graham*)، فارمر و گلوپ (*Farmer & Glossop*) و نلسون (*Nelson*) تنها با توجه به یک پارامتر از سنگ و یا ترکیب آن با یک پارامتر ماشین به پیش‌بینی نرخ نفوذ پرداخته‌اند [4]، [5]، [6] و [7]. محققانی از جمله کاسینلی (*Cassineli*)، ایناراتو (*Innaurato*)، پارک (*Park*) و حسن‌پور نخ نفوذ را تابعی از سیستم‌های طبقه‌بندی سنگ از قبیل *RMR*، *RSR*، *RQD* و *Q* معرفی کرده‌اند [8]، [9]، [10] و [11] همچنین، روش *NTH* بر مبنای روابط تجربی بین پارامترهای مکانیکی، زمین‌شناسی سنگ و بهره‌وری ماشین با میزان پیشرفت واقعی تونل پایه‌گذاری شده است [12]. روش *QTBM* را بارتن (*Barton*) با اصلاحاتی بر سیستم *Q* از جمله میزان ساینده‌ی سنگ، درصد کانی‌های ساینده، متوسط بار دیسک، مقاومت توده‌سنگ و سطح تنش سنگ ارائه کرده است [13].

دو روش *NTH* و *QTBM* پارامترهای موثرتر را نسبت به سایر روش‌های تجربی در نظر گرفته و از میان روش‌های تجربی، بیش‌تر مورد استفاده قرار می‌گیرند. مزیت روش‌های تجربی این است که به طور طبیعی تمام تاثیرات ناشی از زمین و ماشین را در نظر می‌گیرند؛ اما با این حال، رشد فناوری و ارائه‌ی ماشین‌هایی با قابلیت‌های متفاوت، استفاده از این روش‌ها را محدود می‌سازد. با این وجود، به دلیل اینکه مدل‌های ارائه شده در یک حالت خاص از شرایط زمین پیشنهاد شده‌اند، قابل تعمیم به تمام شرایط نیستند.

در سال‌های اخیر از روش شبکه‌های عصبی مصنوعی به عنوان ابزاری جدید جهت پیش‌بینی نرخ نفوذ استفاده شده است. شبکه‌های عصبی مصنوعی با الهام از ساختار مغز

نظر گرفت. در ادامه پس از توضیح مختصری در ارتباط با منطقه‌ی مورد مطالعه و مبانی شبکه‌های عصبی مصنوعی به ایجاد شبکه‌ی عصبی مصنوعی بهینه جهت پیش‌بینی نرخ نفوذ با در نظر گرفتن پارامترهای موثر پرداخته شده است. پس از آن به منظور بررسی اثر پارامترهای اجرایی ماشین، تحلیل حساسیت بر این پارامترها به کمک شبکه‌ی عصبی بهینه صورت گرفته است.

۲- منطقه‌ی مورد مطالعه

منطقه‌ی مورد مطالعه، بخشی از قطعه‌ی دوم تونل بلند زاگرس واقع در غرب کشور است. قطعه‌ی دوم این تونل به طول ۲۶ کیلومتر و به قطر ۶٫۷۳ متر بوسیله‌ی ماشین حفاری تونل (TBM) با دو سپر در حال اجرا است. حداکثر عمق تونل ۱۰۰۰ متر و میانگین عمق آن ۴۰۰ متر است. مشخصات مربوط به تونل و ماشین TBM در جدول ۱ آورده شده است.

جدول ۱- مشخصات مربوط به تونل و TBM دو سپره [20]

مشخصات	اندازه
طول تونل (KM)	۲۶
قطر حفاری (m)	۶٫۷۳
تعداد دیسک	۴۲
فاصله‌ی دیسک‌ها (mm)	۹۰
قطر دیسک (mm)	۴۳۲
سرعت چرخش (l/min)	۰-۹٫۰۵

شکل ۱، برش زمین‌شناسی مسیر تونل را نشان می‌دهد. واحدهای زمین‌شناسی مهندسی در برش با علائمی متشکل از حروف آغازین لیتولوژی آن مجموعه مشخص شده است. این علائم شامل: LI به عنوان نشانه‌ی آهک، SH نشانه‌ی شیل، MA نشانه‌ی مارن، ML نشانه‌ی آهک مارنی و LS نشانه‌ی شیل آهکی است. مرز واحدهای زمین‌شناسی مهندسی عملاً بر مرز واحدهای زمین‌شناسی منطبق است. با توجه به مطالعات زمین‌شناسی و زمین‌شناسی مهندسی صورت گرفته و با در نظر گرفتن تکرار واحدها در قسمت‌های گوناگون، در مجموع در محدوده‌ی مورد مطالعه، ۲۱ واحد زمین‌شناسی مهندسی قابل تفکیک است [۲۱]. به


غیرخطی پرداخته‌اند [17]. از مقایسه‌ی مقادیر پیش‌بینی شده با استفاده از شبکه‌ی عصبی و رگرسیون چندمتغیره‌ی غیرخطی با مقادیر واقعی نرخ نفوذ، این نتیجه حاصل شده است که نتایج شبکه‌ی عصبی نسبت به رگرسیون غیرخطی به واقعیت نزدیک‌تر است [17]. غلام‌نژاد با استفاده از روش شبکه‌های عصبی مصنوعی به پیش‌بینی نرخ نفوذ با استفاده از پارامترهای مقاومت فشاری تک محوری، فاصله‌ی بین صفحات ضعف در توده سنگ و RQD پرداخته است [18]. ترابی و همکارانش نیز به کمک شبکه‌های عصبی به بررسی اثر پارامترهای ژئوتکنیکی بر نرخ نفوذ پرداخته و عنوان کرده‌اند که شبکه‌ی عصبی نسبت به روش آماری نتایج قابل اطمینان‌تری دارد [19].

در تحقیقات گذشته برای پیش‌بینی نرخ نفوذ با شبکه‌های عصبی مصنوعی، بانک اطلاعاتی داده‌های ورودی و خروجی از چندین پروژه‌ی تونلسازی جمع‌آوری شده و برای هر مقطع سنگی تنها یک مقدار نرخ نفوذ در نظر گرفته شده‌است؛ اما از آنجا که در یک مقطع زمین‌شناسی، نرخ نفوذ در هر سیکل حفاری به دلیل پارامترهای اجرایی ماشین متفاوت، می‌تواند متغیر باشد؛ بنابراین انتخاب تنها یک مقدار مشخص برای نرخ نفوذ در یک نوع سنگ خاص چندان نزدیک به واقعیت نیست. در عین حال نتایج پیش‌بینی شبکه‌های عصبی مصنوعی محققان پیشین، بیانگر این موضوع است که روش شبکه‌های عصبی مصنوعی می‌تواند ابزاری مناسب به منظور پیش‌بینی نرخ نفوذ باشد. بنابراین با توجه به اهمیت تاثیر پارامترهای اجرایی ماشین بر نرخ نفوذ، در مطالعه‌ی حاضر به بررسی اثر این پارامترها بر نرخ نفوذ با استفاده از روش شبکه‌های عصبی مصنوعی پرداخته شده‌است. دشواری یافتن رابطه‌ای میان پارامترهای اجرایی ماشین و نرخ نفوذ، قابلیت‌های شبکه‌های عصبی مصنوعی در حل چنین مسائلی و امکان انجام تحلیل حساسیت پارامترهای موثر در نرخ نفوذ پس از ساخت شبکه‌ی عصبی بهینه از دیگر دلایل بکارگیری این روش برای پیش‌بینی نرخ نفوذ در این پژوهش است.

در تحقیق حاضر بانک اطلاعاتی تنها از تونل بلند زاگرس جمع‌آوری شده‌است تا بتوان به ازای هر سیکل حفاری مقدار نرخ نفوذ آن را لحاظ کرده و در نتیجه اثر پارامترهای اجرایی بر نرخ نفوذ در یک مقطع سنگی را در

بررسی تاثیر پارامترهای اجرایی ماشین TBM بر نرخ نفوذ آن با استفاده از روش شبکه‌های عصبی مصنوعی - تونل بلند زاگرس: ص ۲۹-۴۲

منظور ایجاد شبکه‌ی عصبی مصنوعی به سابقه‌ی حفاری نیاز است و از آنجا که در زمان انجام این پژوهش، ۱۰ کیلومتر از تونل حفر شده بود؛ بنابراین داده‌های مربوط به این کیلومتر از مورد استفاده قرار گرفته است (جدول ۲).



شکل ۱- برش زمین‌شناسی مسیر تونل [20]

مورد نظر برای پیش‌بینی.

۲- لایه‌ی خروجی شامل پارامتر یا پارامترهایی که قرار است توسط شبکه‌ی عصبی پیش‌بینی شود.

۳- لایه یا لایه‌های میانی (پنهان) به عنوان رابط بین لایه‌های ورودی و خروجی.

۳- مبانی شبکه‌های عصبی مصنوعی

یک نرون (کوچک‌ترین واحد پردازشگر اطلاعات)، اساس عملکرد شبکه‌های عصبی مصنوعی را تشکیل می‌دهد. ساختار یک شبکه شامل لایه‌های ذیل است (شکل ۲).

۱- لایه‌ی ورودی شامل پارامترهای موثر بر کمیت


جدول ۲- مشخصات واحدهای موجود در ۱۰ کیلومتر اول تونل زاگرس [۲۱]

واحد زمین‌شناسی مهندسی	مقاومت فشاری تک محوری (MPa)	مقاومت کششی (MPa)	RQD (%)	RMR	دانسیته‌ی خشک (gr/cm ³)	تخلخل (%)
SH-ML 1	۱۰-۳۰	۱-۳	۶۸-۷۵	۴۸	۲٫۴-۲٫۵	۱۰-۱۵
SH-ML 2	۱۵-۳۰	۱-۳	۵۲-۶۰	۴۴	۲٫۳-۲٫۵	۱۰-۱۵
SH-ML 3	۱۰-۲۰	۱-۳	۵۰-۶۵	۴۴	۲٫۳-۲٫۵	۵-۱۵
ML-SH 1	۵۰-۱۰۰	۵	۸۵-۷۲	۶۲	۲٫۵-۲٫۶	۲-۵
ML-SH 2	۱۵-۳۰	۱-۳	۷۰-۶۰	۴۸	۲٫۲-۲٫۵	۵-۱۰
ML-SH 3	۲۵-۵۰	۲-۴	۶۵-۵۰	۴۶	۲٫۰۵-۲٫۵	۵-۱۵
ML-SH 4	۱۵-۳۰	۲-۴	۷۵-۶۵	۵۰	۲٫۲-۲٫۵	۵-۱۰
ML-SH 5	۵۰-۱۰۰	۵	۸۵-۷۵	۴۹	۲٫۳-۲٫۶	۳-۵
SH-LS 1	۱۵-۳۰	۱-۳	۷۰-۶۰	۴۴	۲٫۴-۲٫۵	۳-۱۵
SH-LS 2	۳۰-۵۰	۲-۴	۸۰-۷۵	۵۰	۲٫۳-۲٫۶	۳-۱۰
SH-LS 3	۱۵-۳۰	۱-۳	۷۵-۶۵	۴۴	۲٫۳-۲٫۵	۵-۱۵
SH-LS 4	۱۵-۳۰	۲-۵	۷۵-۷۰	۴۸	۲٫۳-۲٫۶	۵-۱۰
LI 2	۱۰۰-۱۵۰	۲٫۵-۶	۹۰-۸۰	۵۷	۲٫۵-۲٫۶	۲٫۵-۶

طراحی شده است را اجرا می‌گویند. در طی مرحله‌ی آموزش، وزن‌های داخلی شبکه‌ی عصبی که بر روی ورودی‌ها اعمال می‌شود آنقدر تغییر می‌کند تا به وضعیت مناسب برسد. پس از اتمام آموزش، داده‌های مجموعه‌ی اعتبارسنجی به شبکه داده می‌شود و پاسخ‌های شبکه با مقادیر واقعی کمیت مورد تخمین، مقایسه می‌شود. هر چه این دو سری داده (واقعی و تخمینی) بیش‌تر به هم شبیه باشند، قدرت تعمیم شبکه بیش‌تر خواهد بود [۱۴]، [۲۳]، [۲۴] و [22].

معمولاً از دو آماره، ضریب همبستگی و میانگین قدرمطلق خطا، برای ارزیابی اختلاف دو سری داده استفاده می‌شود. کاربرد دیگر مجموعه‌ی اعتبارسنجی در قطع زودهنگام آموزش است. بدین ترتیب که تا قبل از این‌که آموزش تا آخرین مرحله ادامه یابد، در مرحله‌ای که خطای مجموعه‌ی اعتبارسنجی به حداقل می‌رسد آموزش متوقف می‌شود [22].

یکی از پرکاربردترین شبکه‌های مورد استفاده برای تخمین و پیش‌بینی، شبکه‌های پیشرو با قانون پس انتشار خطا (*Feed Forward Back Propagation*) است. چنین شبکه‌هایی از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت موسوم است که در این مسیر، بردار ورودی به شبکه اعمال می‌شود و تاثیراتش از راه لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه‌ی خروجی، پاسخ واقعی شبکه است. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شوند. مسیر دوم به مسیر برگشت موسوم است. در این مسیر، برعکس مسیر رفت، پارامترهای شبکه تغییر و تنظیم می‌شوند. این تنظیم مطابق با قانون اصلاح خطا انجام می‌شود. سیگنال خطا، در لایه‌ی خروجی شبکه تشکیل می‌شود. بردار خطا برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه است. مقدار خطا پس از محاسبه در مسیر برگشت، از لایه‌ی خروجی و از طریق لایه‌های شبکه در کل شبکه توزیع می‌شود. چون توزیع اخیر، در خلاف مسیر ارتباطات وزنی صورت می‌پذیرد، واژه‌ی پس انتشار خطا برای توضیح اصلاح رفتاری شبکه انتخاب شده است. پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی شبکه هر چه بیش‌تر، به پاسخ مطلوب نزدیک‌تر شود [۱۴] و [۲۳].



لایه‌ی خروجی لایه‌های میانی لایه‌ی ورودی
شکل ۲- ساختار لایه‌ای شبکه‌ی عصبی مصنوعی

پیش از پرداختن به عملیات شبیه‌سازی پیشنهاد شده است که داده‌ها در دامنه‌ی صفر و یک تغییر مقیاس داده شوند. یکی از دلایل تاکید بر قرار داشتن داده‌های ورودی در دامنه‌ی صفر تا یک، الزام توابع انتقال (مانند تابع سیگموئید) است که قادر به تمایز بین مقادیر خیلی بزرگ نیستند. هر چه مقدار ورودی این توابع بیش‌تر شود خروجی آن به سمت ۱ یا ۱- نزدیک‌تر می‌شود. مهم‌ترین دلیل تبدیل مقیاس ورودی‌ها به دامنه‌ی صفر تا یک کمک به آموزش شبکه است. از طرف دیگر این کار سبب سادگی بیش‌تر فرآیند می‌شود زیرا خروجی‌ها و ورودی‌های همه‌ی لایه‌های بعدی نیز در دامنه‌ی صفر تا یک قرار می‌گیرد [۱۴]، [۲۳]، [۲۴] و [22]. برای شبیه‌سازی و تخمین مسئله، شبکه‌ی عصبی سه مرحله را طی می‌کند:

۱- آموزش (*Training*)

۲- تعمیم (*Generalization*)

۳- اجرا (*Operation*)

آموزش فرایندی است که طی آن شبکه می‌آموزد تا الگوی موجود در ورودی‌ها را که به صورت مجموعه‌ی داده‌های آموزشی است، بشناسد. برای این منظور هر شبکه‌ی عصبی از مجموعه‌ای از قوانین یادگیری استفاده می‌کند. این قوانین نحوه‌ی یادگیری را تعریف می‌کنند. تعمیم، توانایی شبکه برای ارایه‌ی جواب قابل قبول در قبال ورودی‌هایی که در مجموعه‌ی آموزشی نبوده‌اند، است. استفاده از شبکه برای انجام عملکردی که به آن منظور

۴- پیش‌بینی نرخ نفوذ با شبکه‌های عصبی مصنوعی

به منظور پیش‌بینی نرخ نفوذ با استفاده از شبکه‌های عصبی مصنوعی، ابتدا پارامترهای موثر بر نرخ نفوذ به منظور ایجاد ساختار شبکه انتخاب و سپس به شبیه‌سازی برای دستیابی به شبکه‌ی بهینه پرداخته می‌شود.

۴-۱- ایجاد ساختار شبکه‌ی عصبی مصنوعی

عوامل موثر بر نرخ نفوذ TBM را می‌توان در سه دسته‌ی کلی تقسیم‌بندی نمود که عبارتند از:

- ۱- پارامترهای مربوط به سنگ بکر
- ۲- پارامترهای مربوط به توده‌سنگ
- ۳- پارامترهای اجرایی ماشین

به منظور انتخاب پارامترهای ورودی شبکه تلاش شده است تا اثر این سه دسته عوامل، در پیش‌بینی در نظر گرفته شود. در مجموع برای پیش‌بینی نرخ نفوذ، ۹ پارامتر به عنوان پارامترهای ورودی و موثر بر نرخ نفوذ انتخاب شده است:

- ۱- مقاومت فشاری تک محوری (مگاپاسکال)
- ۲- مقاومت کششی برزیلی (مگاپاسکال)
- ۳- درصد کوارتز (بیانگر قابلیت سایش سنگ)
- ۴- RQD (برای توصیف تعداد درزه‌ها در سنگ)
- ۵- RMR (بیانگر شرایط توده‌سنگ)
- ۶- نوع سنگ با کدگذاری مطابق جدول ۳
- ۷- نیروی محوری پیشران یا تراست (کیلونیوتن)
- ۸- گشتاور (کیلونیوتن متر)
- ۹- سرعت چرخش تاج حفار (دور بر دقیقه)

پارامتر خروجی شبکه‌ی عصبی نیز، نرخ نفوذ (میلی‌متر بر دور تاج حفار) است. این پارامترها به سادگی در مراحل انجام پروژه و بدون نیاز به انجام آزمایش و تکنیک‌های ویژه، قابل جمع‌آوری هستند.

جدول ۳- کدگذاری مربوط به نوع سنگ

کد	نوع سنگ
۱	توده‌ای
۲	متوسط تا ضخیم لایه
۳	نازک تا متوسط لایه
۴	خرد شده

انتخاب پارامترهای ورودی با توجه به سوابق تحقیقات انجام شده که اثر پارامترهای مختلف بر نرخ نفوذ را به طور جداگانه مورد بررسی قرار داده‌اند، صورت گرفته است. به عنوان مثال در تعدادی از تحقیقات تاثیرگذاری مقاومت فشاری تک محوری سنگ بکر بر نرخ نفوذ بررسی و به اثبات رسیده است. در نتیجه این پارامتر به عنوان ورودی شبکه‌ی عصبی انتخاب شده است. همچنین به این سبب که با پارامترهای ماشین متفاوت در شرایط یکسان توده‌سنگ، مقدار نرخ نفوذ می‌تواند متفاوت باشد؛ بنابراین پارامترهای ماشین نیز به عنوان ورودی شبکه در نظر گرفته شده است.

در نگاه اول به نظر می‌رسد که بین برخی از پارامترهای ورودی یک همبستگی درونی وجود دارد (RQD و RMR) که ممکن است سبب خطا در نتایج شود. با این حال، هر پارامتر موضوع مشخصی را شرح می‌دهد و اطلاعات تهیه شده می‌تواند به فهم بیشتر مسئله کمک نماید. به عنوان مثال، در یک مقدار RMR انتظار رفتار یکسانی در موارد مختلف وجود دارد در صورتی‌که تفاوت در مقدار RQD ممکن است منجر به تفاوت در شرایط پایداری شود.

برای ساخت شبکه‌ی مناسب نیاز به زوج‌های ورودی و خروجی از داده‌ها است که از ۱۰ کیلومتر ابتدایی از حفر تونل انتخاب و در یک بانک اطلاعاتی ذخیره شده است [۲۵] و [۲۶]. همان‌طور که در بخش مبانی شبکه‌های عصبی مصنوعی بیان شده است، یک شبکه باید با مجموعه‌ای از زوج‌ها به عنوان زوج آموزش مورد آموزش قرار گرفته و با زوج‌های مجموعه‌ی ارزیابی و آزمون مورد آزمایش قرار گیرد. بنابراین، قبل از عملیات آموزش، مجموعه‌ی بانک اطلاعاتی به طور تصادفی به سه دسته‌ی مجموعه‌ی آموزش، ارزیابی و آزمون افراز می‌شود [۲۲].

تعیین ساختار شبکه‌ی عصبی یکی از مهم‌ترین و مشکل‌ترین مراحل و نیازمند انتخاب تعداد بهینه‌ی لایه‌ها و همچنین تعداد بهینه‌ی نرون‌ها در هر لایه است. روش مشخصی جهت تعیین شبکه‌ی بهینه وجود ندارد. به طور کلی پیشنهاد شده است که با ثابت نگه‌داشتن تعداد لایه، تعداد نرون در هر لایه تعیین شود [۱۴]. شبکه‌ی پیشرو همواره دارای یک لایه‌ی ورودی و یک لایه‌ی خروجی است. تعداد نرون‌ها در لایه‌های ورودی و خروجی به ترتیب با توجه به پارامترهای ورودی و خروجی مدل محدود می‌شوند.

نرون‌های لایه‌های ورودی و خروجی باشد [31]. هیچت-نیلسن (Hecht-Nielsen) و کادیل (Caudill) نیز پیشنهاد کرده‌اند که حد بالایی تعداد نرون در لایه‌ی میانی در یک شبکه با یک لایه‌ی میانی $2I+1$ است که I تعداد ورودی شبکه است [32] و [33].

۴-۲- شبیه‌سازی با شبکه‌های عصبی مصنوعی

با توجه به مطالب مذکور، برای تعیین تعداد نرون‌ها در لایه‌ی میانی، شبکه‌های متعددی با تعداد نرون‌های متفاوت در لایه‌ی میانی مورد آموزش و ارزیابی قرار گرفته و بهترین شبکه انتخاب شده است. در این پژوهش بهترین نتایج با تعداد نرون ۸، ۹، ۱۰ و ۱۱ عدد در لایه‌ی میانی بدست آمده است. مقادیر تخمین زده شده برای نرخ نفوذ توسط شبکه در مقابل مقادیر واقعی نرخ نفوذ برای داده‌های آزمون در یک دستگاه مختصات رسم شده و بهترین خط منطبق بر داده‌ها برازش شده است. مقادیر واقعی در محور افقی و مقادیر تخمین زده شده در محور قائم دستگاه مختصات قرار دارند. در صورتی که خروجی شبکه با مقادیر واقعی نرخ نفوذ برابر باشد، تمامی نقاط بر روی خط $y=x$ قرار می‌گیرند. میزان انحراف نقاط نسبت به این خط، بیانگر میزان تفاوت میان خروجی شبکه و مقادیر واقعی است.

برای ارزیابی شبکه‌ها سه باند (جدول ۴) تعریف شده است. ملاک ارزیابی فراوانی، نقاط در هر یک از این سه باند است. فراوانی داده‌ها در هر باند نشان می‌دهد که شبکه با چه دقت و احتمالی قادر به پیش‌بینی نرخ نفوذ است. فراوانی داده‌ها در هر یک از باندهای ذکر شده برای مجموعه‌ی آزمون شبکه‌های ساخته شده با تعداد نرون‌های ۸، ۹، ۱۰ و ۱۱ در لایه‌ی میانی در جدول ۵ آورده شده است.

جدول ۴- تعریف باندهای خطا

باند	۱	۲	۳
معادله‌ی خطا	$y=x \pm 1$	$y=x \pm 1.5$	$y=x \pm 2$
خطا (mm/rev)	۱	۱,۵	۲

مطابق جدول ۵، تعداد نرون بهینه در لایه‌ی میانی ۸ عدد است. با توجه به جدول ۵ احتمال این‌که خروجی مجموعه‌ی آزمون شبکه‌ی $1 \times 8 \times 9$ با مقدار واقعی نرخ نفوذ کمتر از ۱، ۱,۵ و ۲ میلی‌متر بر دور تاج حفار تفاوت داشته

با وجود این‌که روش معینی برای تعیین تعداد لایه‌ی میانی وجود ندارد؛ اما با این حال تعدادی از محققان عقیده دارند که بسیاری از مسائل با استفاده از یک لایه‌ی میانی قابل حل است [27]، [28]، [29] و [30] و در بسیاری از مطالعات ژئوتکنیکی نیز از یک لایه‌ی میانی استفاده شده است. با این حال به منظور دستیابی به نتایج مناسب، در این مطالعه شبکه‌های زیادی با یک و دو لایه‌ی میانی ساخته شده است. مقایسه‌ی نتایج حاصل از آن‌ها نشان می‌دهد که شبکه‌ی با ساختار یک لایه‌ی میانی در این تحقیق مناسب‌تر است؛ بنابراین در ادامه، شبیه‌سازی و نتایج مربوط به شبکه با یک لایه‌ی میانی ارائه شده است.

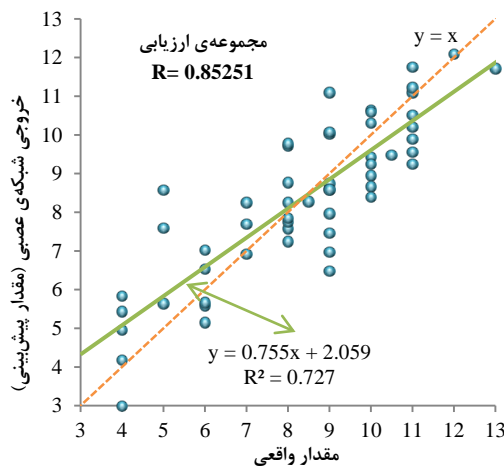
یکی دیگر از پارامترهای مهم در ساخت شبکه‌ای مناسب برای پیش‌بینی، تعداد نرون‌ها در لایه‌ی میانی است. اگر تعداد نرون‌های لایه‌ی میانی کم باشد، شبکه نمی‌تواند نگاشت غیرخطی بین ورودی و خروجی را با دقت لازم منعکس کند. تعداد زیاد نرون‌های لایه‌ی میانی نیز اثر منفی دارد؛ چرا که تعداد عناصر تنظیم شونده‌ی شبکه زیاد شده و شبکه برای یادگیری نیاز به تعداد زیادی مثال در مجموعه‌ی آموزشی دارد تا بتواند اوزان خود را تنظیم کند. همچنین احتمال بیش‌برازشی در شبکه نیز افزایش می‌یابد [۱۴] و [۲۴].

به منظور ایجاد شبکه‌ی بهینه، مقیاس داده‌های ورودی و خروجی شبکه به -1 و $+1$ تغییر داده شده است. برای پیش‌بینی نرخ نفوذ، شبکه‌ای با تغذیه‌ی پیشرو با یک لایه‌ی ورودی، یک لایه‌ی میانی و یک لایه‌ی خروجی ساخته شده است. تابع انتقال در لایه‌ی میانی تابع تانژانت سیگموئید (*Tansig*) و تابع انتقال در لایه‌ی خروجی تابع خطی (*Purelin*) در نظر گرفته شده است. با توجه به سرعت همگرایی الگوریتم لونیگ-مارکوارت (*Levenberg-Marquardt*) در شبکه‌های پیشرو از این الگوریتم برای آموزش شبکه‌ی مورد نظر استفاده شده است. تعداد نرون در لایه‌ی میانی با روش سعی و خطا به گونه‌ای انتخاب می‌شود که بهترین جواب ممکن بدست آید. با این وجود، تعدادی از محققان با توجه به تجربیات خود روش‌ها و محدودیت‌هایی را برای تعداد نرون‌ها در لایه‌ی میانی تعیین کرده‌اند. به عنوان نمونه برکه (*Berke*) پیشنهاد کرده است که تعداد نرون‌ها در لایه‌ی میانی عددی بین میانگین و مجموع


جدول ۵- ارزیابی کارایی شبکه با تغییر تعداد نرون‌های

لایه‌ی میانی				
تعداد نرون	۱۱	۱۰	۹	۸
باند ۱	۱۳	۱۹	۱۶	۱۴
باند ۲	۱۸	۲۲	۲۱	۱۹
باند ۳	۲۰	۲۳	۲۴	۲۶
خطای متوسط	۱٫۳۶	۱٫۱۷	۱٫۲	۱٫۰۷
ضریب همبستگی	۰٫۷۱	۰٫۷۴	۰٫۷۷	۰٫۸۳

باشد به ترتیب برابر با ۵۰، ۶۸ و ۹۳ درصد است. ضریب تطبیق بین مقادیر تخمین زده شده و مقادیر واقعی برای مجموعه‌ی آموزش، ارزیابی و آزمون این شبکه به ترتیب ۹۰، ۸۵ و ۸۳ درصد بدست آمده و به ترتیب در شکل ۳-الف، شکل ۳-ب و شکل ۴-الف آورده شده است. فراوانی داده‌ها در هر یک از سه باند برای مجموعه‌ی آزمون شبکه در شکل ۴-ب نشان داده شده‌است. خطای متوسط بین این مقادیر ۱٫۰۷ میلی‌متر بر دور تاج حفار برآورد شده است.




(ب)

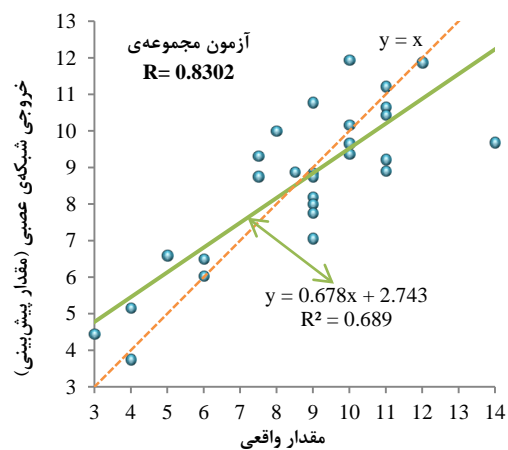


(الف)

شکل ۳- نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده‌ی نرخ نفوذ: الف- برای مجموعه‌ی داده‌های آموزش؛ ب- برای مجموعه‌ی داده‌های ارزیابی




(ب)



(الف)


شکل ۴- نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده‌ی نرخ نفوذ برای مجموعه‌ی داده‌های آزمون الف- بهترین خط برازش شده؛ ب- فراوانی در هر باند

تطبیق بین مقادیر پیش‌بینی شده و مقادیر واقعی برای مجموعه‌ی آزمون جدید این شبکه ۷۹ درصد (شکل ۵-الف) و خطای متوسط بین این مقادیر ۱٫۱۷ میلی‌متر بر دور تاج حفار است. احتمال این‌که خروجی شبکه برای این مجموعه با مقدار واقعی نرخ نفوذ کمتر از ۱، ۱٫۵ و ۲ میلی‌متر بر دور تاج حفار تفاوت داشته باشد، به ترتیب ۵۰، ۷۰ و ۸۸ درصد است. فراوانی داده‌ها در هر یک از سه باند ذکر شده برای این مقادیر در شکل ۵-ب نشان داده شده است.



(ب)

با استفاده از شبکه‌ی بهینه‌ی بدست آمده (۹×۸×۱) به پیش‌بینی نرخ نفوذ در طول ۰٫۵ کیلومتر از تونل (کیلومتراژ ۱۰ تا ۱۰٫۵)، پرداخته شده است. بدین منظور بانک اطلاعاتی شامل ۴۰ زوج ورودی و خروجی از داده‌ها ایجاد شده است. همانند روند قبل مقادیر تخمین زده شده‌ی نرخ نفوذ توسط شبکه در مقابل مقادیر واقعی نرخ نفوذ برای داده‌های جدید آزمون در یک دستگاه مختصات رسم و بهترین خط منطبق بر داده‌ها برازش شده است. ضریب



(الف)

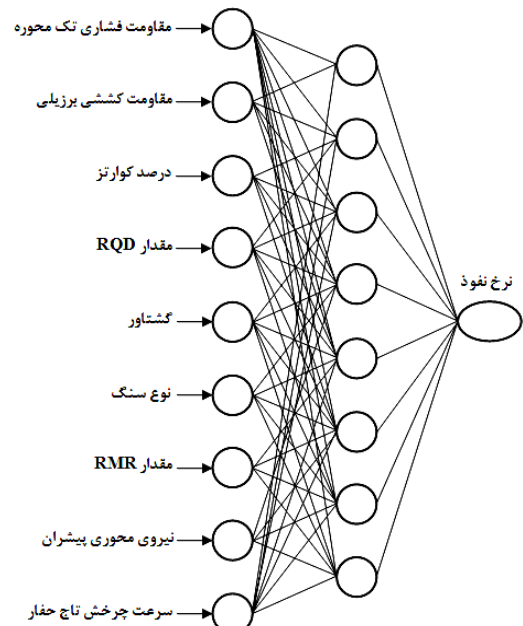
شکل ۵- نمایش مقادیر واقعی در مقابل مقادیر پیش‌بینی شده نرخ نفوذ برای مجموعه‌ی داده‌های آزمون جدید الف- بهترین خط برازش شده ب- فراوانی در هر باند

اجرای ماشین، شامل نیروی محوری پیشران، گشتاور و سرعت چرخش تاج حفار (RPM) هستند. مقدار سرعت چرخش به سبب محدودیت‌های اجرایی پروژه در محدوده‌ی کوچکی تغییر می‌کند؛ به همین دلیل تحلیل حساسیت بر روی نیروی محوری پیشران و گشتاور با مقدار سرعت ثابت صورت گرفته است. تحلیل حساسیت در مقطع سنگی با مشخصات مندرج در جدول ۶ انجام شده است. برای تحلیل حساسیت بر روی پارامتر نیروی محوری پیشران، تمام پارامترها به جز نیروی پیشران ثابت فرض شده و مجموعه‌ای جدید به عنوان ورودی شبکه‌ی بهینه ایجاد و پس از شبیه‌سازی، مقادیر خروجی حاصل به عنوان نرخ نفوذ ثبت شده است.

با توجه به نتایج حاصل از شبیه‌سازی‌ها، می‌توان بیان نمود که شبکه‌ای با ساختار ۹ نرون در لایه‌ی ورودی، ۸ نرون در لایه‌ی میانی و ۱ نرون در لایه‌ی خروجی (۹×۸×۱) شبکه‌ای مناسب و بهینه برای پیش‌بینی نرخ نفوذ در این تونل است (شکل ۶).

پس از اطمینان از شبیه‌سازی، می‌توان با استفاده از شبکه‌ی عصبی مصنوعی بهینه، بر روی پارامترهای ورودی تحلیل حساسیت انجام داد. شرایط زمین در هر مقطع سنگی تقریباً ثابت می‌ماند؛ اما به دلیل تغییر پارامترهای اجرایی ماشین در هر مقطع، نرخ نفوذ می‌تواند مقادیر متفاوتی داشته باشد؛ به همین دلیل تحلیل حساسیت بر روی پارامترهای اجرایی ماشین انجام شده است. پارامترهای

نفوذ کاهش می‌یابد. در نیروی پیشران بیش از مقدار بهینه، احتمال گیرکردن دیسک‌ها و در نتیجه کاهش نرخ نفوذ افزایش می‌یابد. از طرف دیگر مشاهده می‌شود که روند تغییرات در منحنی‌ها یکسان است و با افزایش مقدار گشتاور، مقدار بهینه‌ی نیروی پیشران افزایش می‌یابد. بنابراین برای رسیدن به نرخ نفوذ بیشینه، مقدار گشتاور و نیروی پیشران باید بطور متناسبی انتخاب شود. همچنین در یک نیروی پیشران یکسان در محدوده‌ی کمتر از شرایط بهینه‌ی نرخ نفوذ، گشتاور کمتر سبب نرخ نفوذ بیش‌تری می‌شود. در ناحیه‌ی پس از محدوده‌ی بهینه، گشتاور بیش‌تر، نرخ نفوذ بالاتری را نتیجه می‌دهد.




شکل ۶- ساختار شبکه بهینه ساخته شده

جدول ۶- مشخصات مقطع سنگی در تحلیل حساسیت

مقدار	مشخصات
متوسط تا ضخیم لایه	نوع سنگ
۱۲۵	مقاومت فشاری تک محوری (MPa)
۰,۵	درصد کوارتز
۴,۲۵	مقاومت کششی برزیلی (MPa)
۸۵	RQD (%)
۵۷	RMR

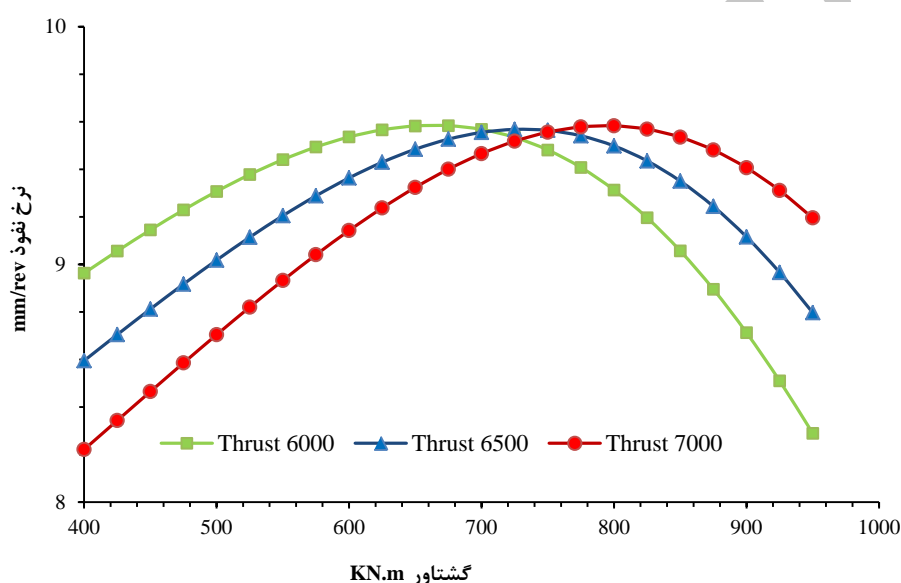
مقادیر نرخ نفوذ بدست آمده از شبکه در مقابل تغییرات نیروی پیشران در شکل ۷ رسم شده است. با توجه به این شکل، مشاهده می‌شود که افزایش نیروی محوری پیشران تا یک حد بهینه، موجب افزایش نرخ نفوذ می‌شود و پس از آن با افزایش نیروی پیشران نرخ



شکل ۷- نرخ نفوذ در مقابل نیروی پیشران حاصل از تحلیل حساسیت

گشتاور یکسان در محدوده‌ی کمتر از شرایط بهینه‌ی نرخ نفوذ، نیروی پیشران کمتر سبب نرخ نفوذ بیش‌تر می‌شود و در ناحیه‌ی پس از محدوده‌ی بهینه، نیروی پیشران بیش‌تر نرخ نفوذ بالاتری را نتیجه می‌دهد. با توجه به تحلیل حساسیت انجام شده، می‌توان نتیجه گرفت که به منظور دستیابی به نرخ نفوذ قابل قبول در این مقطع سنگی، بهتر است از زوج نیروی پیشران و گشتاور بهینه استفاده شود. به عبارت دیگر به منظور دستیابی به نرخ نفوذ مطلوب‌تر باید این دو پارامتر به صورت هماهنگ با یکدیگر تغییر نمایند.

روند یاد شده به منظور تحلیل حساسیت نیروی پیشران، برای پارامتر گشتاور نیز در همان مقطع سنگی تکرار و مقادیر نرخ نفوذ پیش‌بینی شده با شبکه‌ی عصبی در مقابل تغییرات گشتاور در شکل ۸ رسم شده است. با توجه به شکل، مشاهده می‌شود که مقدار گشتاور نیز همانند نیروی پیشران در یک حد بهینه موجب افزایش نرخ نفوذ می‌شود. همچنین مشاهده می‌شود که روند تغییرات در منحنی‌ها یکسان است و با افزایش مقدار نیروی پیشران، مقدار بهینه‌ی گشتاور افزایش می‌یابد. همچنین در یک



شکل ۸ - تحلیل حساسیت نرخ نفوذ در مقابل نیروی پیشران

نظر گرفته شده است؛ در صورتی‌که در هر سیکل حفاری به دلیل پارامترهای متفاوت ماشین، نرخ نفوذ متفاوتی بدست می‌آید.

با توجه توضیحات فوق، در این مقاله به بررسی اثر پارامترهای ماشین بر نرخ نفوذ با استفاده از روش شبکه‌های عصبی مصنوعی پرداخته شده است. به منظور تحلیل با روش شبکه‌های عصبی مصنوعی، شبکه‌های زیادی با ساختارهای متفاوت با در نظر گرفتن یک و دو لایه‌ی میانی و همچنین تعداد نرون‌های متفاوت در لایه‌ها ساخته شده است. در نهایت شبکه‌ای با یک لایه‌ی میانی، ۹ پارامتر ورودی متشکل از پارامترهای مربوط به سنگ بکر،

۵- نتیجه‌گیری

با توجه به اهمیت نرخ نفوذ در عملیات حفاری، محققان مختلفی با روش‌های متعدد تجربی و تئوری به پیش‌بینی این پارامتر پرداخته‌اند. با توجه به پیچیدگی ارتباط بین نرخ نفوذ و پارامترهای موثر آن و همچنین توانایی روش شبکه‌های عصبی مصنوعی در چنین مسائلی، در سال‌های اخیر تلاش‌هایی به منظور پیش‌بینی این پارامتر با استفاده از این روش انجام شده است. مطالعاتی که پیش از این با روش شبکه‌های عصبی مصنوعی صورت گرفته است، نشان‌دهنده‌ی قابلیت این روش در پیش‌بینی نرخ نفوذ است. در این مطالعات، در هر مقطع سنگی تنها یک نرخ نفوذ در

کاهش می‌یابد. در مقادیر نیروی پیشران بیش از حد بهینه، برای دستیابی به نرخ نفوذ بیشتر، گشتاور نیز باید افزایش یابد. تحلیل حساسیت بر روی گشتاور نیز روندی مشابه با نیروی پیشران را نشان می‌دهد. با افزایش مقدار نیروی پیشران، مقدار بهینه‌ی گشتاور افزایش می‌یابد. بنابراین تنها یک زوج نیروی پیشران و گشتاور خاص منجر به نرخ نفوذ حداکثر نمی‌شود؛ بلکه این دو عامل در یک محدوده‌ی بهینه، نرخ نفوذ را افزایش می‌دهند. به منظور دستیابی به نرخ نفوذ حداکثر می‌توان از زوج نیروی محوری پیشران و گشتاور بهینه استفاده نمود.

در این پژوهش برآورد مقدار بهینه‌ی نیروی محوری پیشران و گشتاور TBM با استفاده از روش شبکه‌های عصبی مصنوعی انجام شده است؛ ولی امکان انجام مطالعه‌ی مشابه با استفاده از روش‌های دیگر بهینه‌سازی مانند روش‌های ابتکاری (Heuristic) وجود دارد. انجام این پژوهش، برنامه‌ی آتی مطالعات نویسندگان این مقاله است.

توده‌سنگ و پارامترهای اجرایی ماشین و ۸ نرون در لایه‌ی میانی و پارامتر نرخ نفوذ در لایه‌ی خروجی به عنوان شبکه‌ی بهینه برای پیش‌بینی نرخ نفوذ انتخاب شده است. به منظور اطمینان از انتخاب شبکه‌ی بهینه، بار دیگر این شبکه با استفاده از مجموعه‌ی آزمون جدیدی که در بانک اطلاعاتی مربوط به ساخت شبکه وجود نداشته، مورد بررسی قرار گرفته است. ضریب تطبیق ۷۹ درصد بین مقادیر پیش‌بینی شده و واقعی در این مجموعه نشان‌دهنده‌ی صحت انتخاب شبکه‌ی بهینه است.

پس از ایجاد شبکه‌ی بهینه برای پیش‌بینی، می‌توان به تحلیل حساسیت بر روی پارامترهای ورودی پرداخت. در این مطالعه به کمک شبکه‌ی بهینه به تحلیل حساسیت بر روی پارامترهای نیروی محوری پیشران و گشتاور پرداخته شده است. نتایج تحلیل‌ها نشان می‌دهد که افزایش نیروی محوری پیشران تا یک حد بهینه، سبب افزایش نرخ نفوذ می‌شود. پس از آن با افزایش نیروی پیشران، مقدار نرخ نفوذ

۶- منابع

- [1] Roxborough, F. F., & Phillips, H. R. (1975). Rock Excavation by Disc Cutter. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 12(12), 361-366. [http://dx.doi.org/10.1016/0148-9062\(75\)90547-1](http://dx.doi.org/10.1016/0148-9062(75)90547-1).
- [2] Sanio, H. (1985). Prediction of the Performance of Disc Cutters in Anisotropic Rock. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 22(3), 153-161. [http://dx.doi.org/10.1016/0148-9062\(85\)93229-2](http://dx.doi.org/10.1016/0148-9062(85)93229-2).
- [3] Nilson, B., & Ozdemir, L. (1993). Hard Rock Tunnel Boring Prediction and Field Performance. In L. D. Bowerman & J. E. Monsees (Ed.), *Proceeding of Rapid Excavation and Tunneling Conference* (pp. 833-852). Boston: Society for Mining Metallurgy. ISBN: 9780873351270.
- [4] Tarkoy, P. J. (1974). Prediction TBM Penetration Rate in Selected Rock Types. *Proceeding of the Ninth Canadian Rock Mechanics symposium* (pp. 257-269). Montreal: Mines Branch, Department of Energy, Mines and Resources.
- [5] Graham, P. C. (1976). Rock Exploration for Machine Manufacturers. In Z. T. Bieniawski (Ed.), *Exploration for Rock Engineering: Proceedings of The Symposium on Exploration for Rock Engineering* (pp.173-180). Johannesburg: A A Balkema. ISBN: 9780869610893.
- [6] Farmer, I. W., & Glossop, N. H. (1980). Mechanics of Disc Cutter Penetration. *Tunnels and Tunneling International*, 12, 622-625.
- [7] Nelson, P., O'Rourke, T. D., & Kulhawy, F. H. (1983). Factors Affecting TBM Penetration Rates in Sedimentary Rocks. In C. Christopher (Ed.), *24th U.S. Symposium on Rock Mechanics* (pp. 227-237). Texas: American Rock Mechanics Association.

- [8] Cassinelli, F., Cina, S., Innaurato, N., Mancini, R., & Sampaolo, A. (1982). Power Consumption and Metal Wear in Tunnel-Boring Machines: Analysis of Tunnel-Boring Operation in Hard Rock. In M. J. Jones (Ed.), *Tunnelling* 82 (pp. 73-81). London: Institution of Mining and Metallurgy. ISBN:090048862X.
- [9] Innaurato, N., Mancini, A., Rondena, E., & Zaninetti, A. (1991). Forecasting and Effective TBM Performances in a Rapid Excavation of a Tunnel In Italy. *7th ISRM Congress* (pp. 1009-1014). Aachen: International Society for Rock Mechanics.
- [10] Park, C. W., Park, C., Synn, J. H., Sunwoo, C., & Chung, S. K. (2001). TBM Penetration Rate with Rock Mass Properties in Hard Rock. *AITES-ITA 2001 World Tunnel Congress* (pp. 413-419). Milano. ISBN: 9788855525947.
- [11] Hassanpour, J., Rostami, J., & Zhao, J. (2011). A New Hard Rock TBM Performance Prediction Model for Project Planning. *Tunnelling and Underground Space Technology*, 26(5), 595-603. <http://dx.doi.org/10.1016/j.tust.2011.04.004>.
- [12] Bruland, A. (2000). *Hard Rock Tunnel Boring*. Trondheim: Doctoral thesis, Norwegian University of Science and Technology, Engineering Science and Technology. ISBN:8247102811.
- [13] Barton, N. R. (2000). *TBM Tunnelling in Jointed and Faulted Rock*. Rotterdam: A A Balkema. ISBN:9058093417.
- [۱۴] منهاج، م. ب. (۱۳۹۱). مبانی شبکه‌های عصبی. تهران، ایران: انتشارات دانشگاه صنعتی امیرکبیر. شابک: ۹۷۸۹۶۴۴۶۳۰۸۷۳
- [15] Grima, M. A., Bruines, P. A., & Verhoef, P. W. (2000). Modelling Tunnel Boring Machine Performance by Neuro-Fuzzy Methods. *Tunnelling and Underground Space Technology*, 15 (3), 259-269. [http://dx.doi.org/10.1016/S0886-7798\(00\)00055-9](http://dx.doi.org/10.1016/S0886-7798(00)00055-9).
- [۱۶] یآوری، ش. م. و مهدوری، س. (۱۳۸۵). پیش‌بینی نرخ نفوذ ماشین‌های تونل‌بری با استفاده از شبکه‌ی عصبی. نشریه‌ی دانشکده‌ی فنی، دانشگاه تهران، ۴۰(۱)، ۱۱۵-۱۲۱.
- [17] Yagiza, S., Gokceoglu, C., Sezer, E., & Iplikci, S. (2009). Application of Two Non-Linear Prediction Tools to The Estimation of Tunnel Boring Machine Performance. *Engineering Applications of Artificial Intelligence*, 22 (4-5), 808-814. <http://dx.doi.org/10.1016/j.engappai.2009.03.007>.
- [18] Gholamnejad, J., & Tayarani, N. (2010). Application of Artificial Neural Networks to The Prediction of Tunnel Boring Machine Penetration Rate. *Mining Science and Technology(China)*, 20 (5), 727-733. [http://dx.doi.org/10.1016/S1674-5264\(09\)60271-4](http://dx.doi.org/10.1016/S1674-5264(09)60271-4).
- [19] Torabi, S. R., Shirazi, H., Hajali, H., & Monjezi, M. (2011). Study of The Influence of Geotechnical Parameters on The TBM Performance in Tehran-Shomal Highway Project Using ANN and SPSS. *Arabian Journal of Geosciences*. <http://dx.doi.org/10.1007/s12517-011-0415-3>.
- [20] Khademi Hamidi, J., Shahriar, K., Rezai, B., & Rostami, J. (2010). Performance Prediction of Hard Rock TBM Using Rock Mass Rating (RMR) System. *Tunnelling and Underground Space Technology*, 25 (4), 333-345. <http://dx.doi.org/10.1016/j.tust.2010.01.008>.
- [۲۱] مهندسین مشاور ساحل. (۱۳۸۶). مطالعات زمین‌شناسی مهندسی مسیر تونل. گزارش شماره‌ی ۲۰۲۶.

بررسی تاثیر پارامترهای اجرایی ماشین TBM بر نرخ نفوذ آن با استفاده از روش شبکه‌های عصبی مصنوعی - تونل بلند زاگرس: ص ۲۹-۴۲

[22] Demuth, H., Beale, M., & Hagan, M. (2006). *Neural Network Toolbox for Use with Matlab: User's Guide, 5th*. Natick, Massachusetts, United States of America: The Mathworks, Inc.

[۲۳] مهدوری، س. (۱۳۸۲). پیش‌بینی ضریب بهره‌وری TBM‌های باز. تهران، ایران: پایان‌نامه‌ی کارشناسی ارشد، دانشگاه تهران.

[۲۴] کیا، م. (۱۳۸۹). شبکه‌های عصبی در MATLAB تهران، ایران: خدمات نشر کیان رایانه سبز. شابک: ۹۷۸۶۰۰۵۲۳۷۰۰۹.

[۲۵] افتخاری، س. م. (۱۳۸۹). تحلیل عددی تاثیر پارامترهای هندسی شکستگی‌های منفصل بر نرخ نفوذ دستگاه TBM در توده سنگ شکسته-مطالعه‌ی موردی تونل بلند زاگرس. اصفهان، ایران: پایان‌نامه‌ی کارشناسی ارشد، دانشگاه صنعتی اصفهان.

[26] Eftekhari, M., Baghbanan, A., & Bayati, M. (2010). Predicting Penetration Rate of A Tunnel Boring Machine Using Artificial Neural Network. In K. G. Sharma (Ed.), *ISRM International Symposium-6th Asian Rock Mechanics Symposium-Advances in Rock Engineering*. New Delhi, India: International Society for Rock Mechanics.

[27] Hornik, K. (1989). Multilayer Feed Forward Networks Are Universal Approximators. *Neural Networks*, 2(5), 359-366. [http://dx.doi.org/10.1016/0893-6080\(89\)90020-8](http://dx.doi.org/10.1016/0893-6080(89)90020-8).

[28] Hecht-Nielsen, R. (1989). Theory of The Back-Propagation Neural Network. *International Joint Conference on Neural Networks* (pp. 593-605). Washington, DC, USA: IEEE TAB Neural Network Conference. <http://dx.doi.org/10.1109/IJCNN.1989.118638>.

[29] Cybenko, G. (1989). Approximation by Superpositions of A Sigmoidal Function. *Mathematics of Control, Signals and Systems*, 2 (4), 303-314. <http://dx.doi.org/10.1007/BF02551274>.

[30] Basheer, I. A. (2000). Selection of Methodology for Neural Network Modeling of Constitutive Hysteresis Behavior of Soils. *Computer-Aided Civil and Infrastructure Engineering*, 15(6), 445-463. <http://dx.doi.org/10.1111/0885-9507.00206>.

[31] Berke, L., & Hajela, P. (1991). Application of Neural Networks in Structural Optimization. *NATO-DFG Advanced Study Institute on optimization of large structural systems* (pp. 731-745). Berchtesgaden: Springer. ISBN:0792321294.

[32] Hecht-Nielsen, R. (1987). Kolmogorov's Mapping Neural Network Existence Theorem. In M. Caudill (Ed.), *1st IEEE International Conference on Neural Networks* (pp. 11-14). San Diego. California.

[33] Caudill, M. (1988). Neural Networks Primer, Part III. *AI Expert*, 3 (6), 53-59. ISSN:0888-3785.