



پیش بینی نرخ نفوذ ماشین حفر تونل تمام مقطع با استفاده از ترکیب شبکه های عصبی مصنوعی و روش مونت کارلو

سید مصطفی افتخاری*، محمد مختاریان، علیرضا باغبانان

دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان، ایران

mosleh.eftekhari@mi.iut.ac.ir

(*عهدده دار مکاتبات

دریافت: ۹۳/۲/۲۵؛ دریافت اصلاح شده: ۹۳/۹/۱۱؛ پذیرش: ۹۳/۱۲/۲؛ قابل دسترس در تارنما: ۹۴/۹/۱۵

چکیده

تحلیل عملکرد و پیش بینی دقیق نرخ نفوذ ماشین حفر تونل تمام مقطع هدف مطالعات محققان بسیاری شده است. پیش بینی عملکرد ماشین حفر تونل تمام مقطع در برنامه زمان بندی پروژه های حفاری و بودجه مورد نیاز ضروری است. در این مطالعه تلاش شده است تا با ترکیبی از روش شبیه سازی مونت کارلو و شبکه های عصبی مصنوعی به پیش بینی نرخ نفوذ پرداخته شود. شبکه های عصبی مصنوعی شکلی از هوش مصنوعی است که تلاش می کند تا از سیستم عصبی و مغز انسان الگو برداری کند. شبکه های عصبی مصنوعی می تواند اثر تمام پارامترهای موثر در پیش بینی یک پدیده را لحاظ کند. شبیه سازی مونت کارلو روشی برای نمونه برداری و تولید تصادفی بر اساس تابع چگالی احتمال است. در این مطالعه داده های ۱۰ کیلومتر از تونل زاگرس به منظور پیش بینی استفاده شده است. در این راستا، مشخصات ماده سنگ، توده سنگ و پارامترهای اجرایی از قبیل نیروی محوری پیش ران و گشتاور مورد نیاز است. نتایج حاصل از شبیه سازی های مختلف نشان می دهد که شبکه ای با ۱۱ نرون در لایه ورودی و ۱۶ نرون در لایه میانی مناسب ترین ساختار شبکه برای پیش بینی در این مطالعه است. ضریب همبستگی بین خروجی شبکه و مقادیر واقعی در مجموعه آزمایش ۸۷٪ است. به منظور ارزیابی شبکه بهینه، مجموعه آزمایش جدیدی که در آن پارامترهای اجرایی ماشین با استفاده از روش مونت کارلو و به طور تصادفی ایجاد شده است، استفاده می شود. نتایج شبکه ساخته شده و مقایسه تابع توزیع نرخ نفوذ داده های واقعی و نرخ نفوذ حاصل از داده های تصادفی نشان می دهد که شبکه عصبی ساخته شده قابلیت پیش بینی قابل قبولی از نرخ نفوذ ماشین حفر تونل تمام مقطع را دارد.

واژه های کلیدی: نرخ نفوذ، ماشین حفر تونل تمام مقطع (Tunnel Boring Machine: TBM)، شبکه های عصبی مصنوعی، روش مونت کارلو

۱- مقدمه

آتش کاری است و در روش حفر مکانیزه مدت زمان حفر تونل را، نرخ

پیشروی ماشین تعیین می کند. نرخ نفوذ حفاری بصورت نسبت

فاصله واقعی به زمان حفر تعریف می شود و معمولاً برحسب میلیمتر

روش حفر تونل یکی از عوامل تعیین کننده در مدت زمان حفر تونل

است. در روش سنتی، زمان حفر تونل تابع پیشروی در یک سیکل

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 نمی‌باشند و می‌توان در شرایط یکسان با تحقیق انجام شده مورد استفاده قرار گیرند (افتخاری و همکاران ۱۳۹۱). شبکه‌های عصبی مصنوعی یکی از روش‌های بدیع و در حال تحولی است که در موضوعات متنوعی از قبیل الگوسازی، شناخت الگو و پیش‌بینی بکار رفته که نتایج مفیدی را داشته است، همچنین این شبکه‌ها به عنوان ابزاری دقیق و مناسب در مسائل مختلف مهندسی بکار گرفته شده‌اند. از جمله کاربرد این شبکه‌ها در مهندسی مکانیک سنگ، استفاده آن در پیش‌بینی نرخ نفوذ TBM می‌باشد. افراد مختلفی در این زمینه به مطالعه پرداخته‌اند. گریم و همکارانش تصمیم به پیش‌بینی نرخ نفوذ با توجه به سه مجموعه‌ی کلی موثر بر نرخ نفوذ از قبیل مشخصات سنگ بکر، توده سنگ (نایبوستگی‌ها) و مشخصات ماشین گرفتند. پارامترهای مقاومت فشاری تک محوری (UCS) به عنوان مشخصه‌ی سنگ بکر، فراوانی شکستگی مغزه (CoreFracture Frequency) به عنوان مشخصه‌ی نایبوستگی، 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 (Grima et al. 2000). یاگیز و همکارانش چهار پارامتر مقاومت فشاری تک محوری، اندیس تردی، فاصله‌ی صفحات ضعف و زاویه 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 (Yagiz et al. 2009). غلام نژاد و طیارانی پیش‌بینی نرخ نفوذ TBM را با استفاده از شبکه‌های عصبی مصنوعی مورد بررسی قرار داده و نتایج قابل قبولی را بدست آورده‌اند (Gholamnejad & Tayaranian 2010). همچنین، افتخاری و همکاران به مطالعه پیش‌بینی نرخ نفوذ TBM با استفاده از شبکه عصبی مصنوعی در تونل زاگرس پرداخته‌اند (Eftekhari et al. 2010). هدایت زاده و همکاران با استفاده از شبکه‌های عصبی به پیش‌بینی نرخ نفوذ TBM در سنگ‌های سخت در ۶/۵ کیلومتر تونل البرزپرداخته‌اند (Hedayatzadeh et al. 2010). در اکثر تحقیقات گذشته پیش‌بینی نرخ نفوذ با شبکه‌های عصبی مصنوعی، بانک اطلاعاتی داده‌های ورودی و خروجی از چندین پروژه تونل‌سازی جمع‌آوری شده و برای هر مقطع سنگی تنها یک

بر دور تاج حفار بیان می‌شود در حالی که سرعت پیشروی به صورت نسبت فاصله حفاری به مجموع زمان صرف شده می‌باشد. نرخ نفوذ، تابعی از ویژگی‌های سنگ و ماشین می‌باشد بنابراین از عوامل تاثیر گذار بر روی نرخ نفوذ حفاری، خواص توده سنگ، ماده سنگ و مشخصات ماشین می‌باشد. برآورد نرخ نفوذ ماشین حفر تونل تمام مقطع (Tunnel Boring Machine: TBM) به عنوان اساسی برای پیش‌بینی میزان پیشروی در حفاری‌ها می‌باشد (افتخاری و همکاران ۱۳۹۱). به همین دلیل روش‌های تجربی متعددی به منظور پیش‌بینی نرخ نفوذ ارائه شده است. روش تجربی اساساً بر مبنای ارتباط عملی و مشاهداتی بین پارامترهای زمین و ماشین برقرار است و به واسطه برازش بین خصوصیات سنگ و پارامترهای ماشین با نرخ نفوذ به دست آمده‌اند، که در ادامه تعدادی از آنها معرفی شده‌اند. گراهام برای سنگ‌هایی که مقاومت فشاری آنها در دامنه ۲۰۰-۱۴۰ مگاپاسکال می‌باشد رابطه (۱) را برای نرخ نفوذ ارائه کرده است (Graham 1976).

$$P_R = \frac{3940F_n}{UCS} \quad \text{رابطه (۱)}$$

که در آن، F_n نیروی برش هر دیسک برحسب کیلونیوتن، UCS مقاومت فشاری تک محوری برحسب کیلو پاسکال، P_R نرخ نفوذ بر حسب میلی متر بر دور تاج حفار می‌باشد.

فارمر و گلوپس رابطه‌ی زیر را برای تخمین نرخ نفوذ با استفاده از نیروی برش متوسط و تنش کششی در سنگ‌های رسوبی ارائه کرده‌اند اما با این حال خواص توده سنگ (نایبوستگی‌ها) در این مدل در نظر گرفته نشده است (Farmer & Glossop 1980).

$$P_R = \frac{624F_n}{\sigma_t} \quad \text{رابطه (۲)}$$

که در آن σ_t مقاومت کششی برزیلی برحسب مگا پاسکال می‌باشد. یاگیز اثرات بعضی از خواص توده سنگ را بر روی عملکرد ماشین در شرایط سخت سنگ شکسته را مورد بررسی قرار داده که بر اساس آن رابطه زیر بدست آمده است (Yagiz 2008).

$$P_R = 1.093 + 0.029.PSI - 0.003UCS + 0.437 \quad \text{رابطه (۳)}$$

که در آن، PSI شاخص حداکثر شیب زاویه آلفا (جهت نایبوستگی نسبت به محور تونل)، DPW فاصله صفحات ضعیف می‌باشد.

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 ارائه ماشین‌هایی با قابلیت‌های متفاوت، استفاده از این روش‌ها را

مقطع سنگی با استفاده از داده‌های تصادفی جدید که از طریق روش مونت کارلو ایجاد شده‌اند مورد ارزیابی قرار گرفته است.

جدول ۱- مشخصات مربوط به تونل زاگرس و ماشین (TBM) افتخاری و

همکاران (۱۳۹۱)

مشخصات	اندازه
طول تونل (KM)	۲۶
قطر حفاری (m)	۶/۷۳
تعداد دیسک	۴۲
فاصله دیسک ها (mm)	۹۰
قطر دیسک (mm)	۴۳۲
سرعت چرخش (1/min)	-۹/۰۵


۲- منطقه مورد مطالعه

منطقه مورد مطالعه بخشی از قطعه دوم تونل بلند زاگرس واقع در غرب کشور می‌باشد. قطعه دوم این تونل به طول ۲۶ کیلومتر و به قطر ۶/۷۳ متر بوسیله ماشین حفاری تونل (TBM) با سپر دویل در حال اجرا می‌باشد. حداکثر عمق تونل ۱۰۰۰ متر و میانگین عمق آن ۴۰۰ متر می‌باشد (افتخاری و همکاران ۱۳۹۱). مشخصات مربوط به تونل و ماشین TBM در جدول ۱ آمده است. تصویر ۱ مقطع زمین شناسی مسیر تونل را نشان می‌دهد.

۳- شبکه‌های عصبی مصنوعی

کوچک‌ترین واحد شبکه عصبی مصنوعی، نرون است. هر شبکه از تعدادی پارامتر ورودی و یک لایه خروجی و یک یا چند لایه میانی تشکیل شده است. نرون‌های هر لایه به وسیله وزن‌هایی به نرون‌های لایه بعدی متصل می‌شود. طی فرآیند آموزش شبکه، این وزن‌ها و

مقدار نرخ نفوذ در نظر گرفته شده است، اما از آنجا که در یک مقطع زمین شناسی، 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 و از طرف دیگر، مشخصات و پارامترهای مرتبط با سنگ در یک مقطع سنگی نیز یکسان و ثابت نمی‌باشد و در یک محدوده‌ی خاص تغییر می‌کنند. اما 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 پیش‌بینی نرخ نفوذ، در مطالعه‌ی حاضر پیش‌بینی این پارامتر با استفاده از روش شبکه‌های عصبی مصنوعی با در نظر گرفتن تغییرات پارامترهای ماشین و سنگ پرداخته شده است. به منظور در نظر گرفتن تغییرات پارامترهای سنگ در یک مقطع سنگی در پیش‌بینی با شبکه عصبی مصنوعی از روش شبیه‌سازی مونت کارلو استفاده شده است که با توجه به محدوده‌ی تغییرات پارامترها و میانگین آنها که در گزارشات زمین شناسی منطقه موجود می‌باشد، به تعداد سیکل‌های حفاری در مقطع مورد نظر، مقادیر تصادفی از پارامترهای سنگ ایجاد شده است. در تحقیق حاضر بانک اطلاعاتی تنها از تونل بلند زاگرس جمع‌آوری شده است تا بتوان به ازای هر سیکل حفاری مقدار نرخ نفوذ آن را لحاظ کرد. در ادامه پس از توضیح مختصری در ارتباط با منطقه‌ی مورد مطالعه، مبانی شبکه‌های عصبی مصنوعی و همچنین روش مونت کارلو، به ایجاد شبکه‌های عصبی مصنوعی با ساختارهای مختلف جهت انتخاب شبکه بهینه به منظور پیش‌بینی نرخ نفوذ پرداخته شده است و پس از آن شبکه‌ی بهینه ساخته شده در یک



تصویر ۱- مقطع زمین شناسی مسیر تونل (افتخاری و همکاران ۱۳۹۱)

پس انتشار محسوب می شود. الگوریتم لونبرگ-مارکوارت توانایی آموزش شبکه با سرعت ۵۰۰ بار بیشتر نسبت به الگوریتم گرادیان شیب را دارد (Meulenkamp & Grima 1999).

تعیین معماری و ساخت شبکه یکی از مهم ترین و مشکل ترین وظایف در مدل شبکه عصبی مصنوعی است که نیازمند تعداد بهینه ای از لایه ها و نرون ها می باشد. هیچ روش واحد و یکپارچه ای برای تعیین و معماری مطلوب شبکه و همچنین تعیین تعداد نرون های شبکه لایه میانی وجود ندارد، اما به طور تجربی می توان از روش آزمون و خطا در تعیین تعداد نرون ها استفاده کرد (منهاج ۱۳۹۱، Mehrotra et al. 1997).

۴- روش مونت کارلو

اساساً شبیه سازی مونت کارلو شامل ایجاد یک فضای نمونه از متغیرهای تصادفی و تکرار یک تحلیل به صورت مکرر با استفاده از متغیر تصادفی است که در این چرخش، از توزیع متغیرها با استفاده از یک مولد عدد تصادفی، استفاده می شود. شبیه سازی مونت کارلو شامل نمونه گیری و تولید متغیر تصادفی از تابع توزیع احتمال است. بعد از اینکه یک توزیع تئوری تعیین شد، متغیرهای تصادفی باید برای شبیه سازی تولید شوند. تکنیک های زیادی برای تولید متغیرهای تصادفی وجود دارد. یکی از این روش ها، روش تبدیل معکوس است. اگر $U(0,1)$ به صورت یکنواخت در بازه $(0,1)$ توزیع یافته باشد و X که یک متغیر تصادفی دارای تابع توزیع F_X باشد، در این صورت می توان متغیر تصادفی X را بوسیله انجام عملیات با استفاده از تولید عدد تصادفی $U(0,1)$ و تبدیل معکوس F_X^{-1} مطابق با رابطه زیر بدست آورد.

$$\sigma_K = \left[\frac{1}{n-1} \sum (i_K - \mu_K)^2 \right]^{1/2} \quad \text{رابطه (۴)}$$

بنابراین برای تولید یک متغیر تصادفی X الگوریتم زیر را داریم:

۱- تولید متغیر تصادفی از $U(0,1)$. توجه: U تولید کننده ی عدد تصادفی در بازه $(0,1)$ است.


۲- رجوع به $X = F_X^{-1}(U)$

۵- پیش بینی نرخ نفوذ TBM

در این مطالعه خواص مکانیکی توده سنگ و پارامترهای عملیاتی TBM از ۱۰ کیلومتر تونل زاگرس برای پیش بینی نرخ نفوذ با استفاده

مقادیر ثابتی که با آنها جمع می شوند و اصطلاحاً بایاس نامیده می شوند، به طور پی در پی تغییر می کنند تا اینکه مجموع مربعات خطابه حداقل برسد (منهاج ۱۳۹۱، Mehrotra et al. 1997). ساختار شبکه عصبی در تصویر ۲ نشان داده شده است.

از پرکاربردترین شبکه های مورد استفاده در تخمین و پیش بینی استفاده از شبکه های پیشرو با قانون پس انتشار خطا است. چنین شبکه هایی از دو مسیر اصلی تشکیل می شود. مسیر اول به مسیر رفت موسوم است که در این مسیر، بردار ورودی به شبکه اعمال می شود و تأثیراتش از طریق لایه های میانی به لایه های خروجی انتشار می یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه را تشکیل می دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می شوند. مسیر دوم به مسیر برگشت موسوم است. در این مسیر، برعکس مسیر رفت، پارامترهای شبکه تغییر و تنظیم می شوند. این تنظیم مطابق با قانون اصلاح خطا انجام می شود. سیگنال خطا، در



تصویر ۲- ساختار شبکه عصبی مصنوعی (افتخاری و همکاران ۱۳۹۱)

لایه ی خروجی شبکه تشکیل می شود. بردار خطا برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه است. مقدار خطا، پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه های شبکه در کل شبکه توزیع می شود. چون توزیع اخیر، در خلاف مسیر ارتباطات وزنی صورت می پذیرد، کلمه پس انتشار خطا جهت توضیح اصلاح رفتاری شبکه انتخاب شده است. پارامترهای شبکه طوری تنظیم می شوند که پاسخ واقعی شبکه هر چه بیشتر، به سمت پاسخ مطلوب نزدیک تر شود (منهاج ۱۳۹۱). از آنجا که برای آموزش شبکه عصبی بر اساس الگوریتم لونبرگ-مارکوارت محاسبات به صورت موازی انجام می شود، جزء سریع ترین روش ها برای آموزش شبکه عصبی

تخلخل، مقاومت فشاری تک محوره (UCS)، مقاومت کششی برزیلی (BTS)، (RQD) برای توصیف تعداد درزه‌ها در سنگ)، (GSI) اندیس شاخص زمین شناسی، (RMR) بیانگر شرایط توده سنگ)، سرعت تاج حفار (RPM)، نیروی محوری پیشران، گشتاور و قدرت ماشین. مشخصات واحدهای موجود در ۱۰ کیلومتر اول تونل زاگرس در جداول ۲ و ۳ گنجانده شده است. در نگاه اول به نظر می‌رسد که بین برخی از پارامترهای ورودی یک همبستگی درونی وجود دارد (از جمله RQD و RMR) که ممکن است باعث خطا در نتایج شود. با این حال، هر پارامتر موضوع مشخصی را شرح می‌دهد و اطلاعات تهیه شده می‌تواند به فهم بیشتر مسئله کمک کند. به عنوان مثال، در شرایطی که مقدار RMR یکسان در موارد مختلف وجود داشته باشد، انتظار رفتار یکسانی وجود دارد در صورتیکه تفاوت در مقدار RQD آنها، ممکن است منجر به تفاوت در شرایط پایداری به عبارتی شرایط پایدار در یکی و شرایط ناپایدار در دیگری شود.

قبل از پرداختن به پیش بینی نرخ نفوذ و ساخت شبکه عصبی، پیش پردازشی بر روی داده‌ها انجام شده است. داده‌های پراکنندگی بالا از بانک اطلاعاتی ایجاد شده حذف شده‌اند. همچنین قبل از پرداختن به عملیات شبیه سازی، مقیاس داده‌های ورودی شبکه به ۱- و ۱+ تغییر

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

(مهندسی مشاور ساحل ۱۳۸۶)

تخلخل (%)	دانشسته اشباع (gr/cm ³)	دانشسته خشک (gr/cm ³)	مدول الاستیسیته (GPa)	مقاومت کششی (MPa)	مقاومت فشاری تک محوری (MPa)	واحد زمین شناسی مهندسی
۱۰-۱۵	۲/۵-۲/۷	۲/۴-۲/۵	۴-۶	۱-۳	۱۰-۳۰	SH-ML 1
۱۰-۱۵	۲/۴-۲/۷	۲/۳-۲/۵	۴-۶	۱-۳	۱۵-۳۰	SH-ML 2
۵-۱۵	۲/۴۴-۲/۷۳	۲/۳-۲/۵	۴-۶/۵	۱-۳	۱۰-۲۰	SH-ML 3
۲-۵	۲/۶-۲/۷	۲/۵-۲/۶	۵/۵-۷	۳-۵	۵۰-۱۰۰	ML-SH 1
۵-۱۰	۲/۵-۲/۷	۲/۲-۲/۵	۵-۶/۵	۱-۳	۱۵-۳۰	ML-SH 2
۵-۱۵	۲/۳-۲/۸	۲/۰۵-۲/۵	۴-۶/۵	۲-۴	۲۵-۵۰	ML-SH 3
۵-۱۰	۲/۵-۲/۶	۲/۲-۲/۵	۴-۶	۲-۴	۱۵-۳۰	ML-SH 4
۳-۵	۲/۵-۲/۶	۲/۳-۲/۶	۵/۵-۷	۳-۵	۵۰-۱۰۰	ML-SH 5
۳-۱۵	۲/۵-۲/۶	۲/۴-۲/۵	۴-۶	۱-۳	۱۵-۳۰	SH-LS 1
۳۳-۱۰	۲/۵-۲/۶	۲/۳-۲/۶	۵-۶	۲-۴	۳۰-۵۰	SH-LS 2
۵-۱۵	۲/۵-۲/۶	۲/۳-۲/۵	۴-۶	۱-۳	۱۵-۳۰	SH-LS 3
۵-۱۰	۲/۴-۲/۷	۲/۳-۲/۶	۴-۶	۲-۵	۱۵-۳۰	SH-LS 4
۲/۵-۶	۲/۵-۲/۷	۲/۵-۲/۶	۱۵-۳۰	۲/۵-۶	۱۰۰-۱۵۰	LI 2

* SH: شیل، LI: آهک، MA: مارن، ML: آهک ماری و LS: شیل آهکی

از مدل سازی شبکه‌های عصبی مصنوعی، مورد استفاده قرار گرفته است. با توجه به سرعت همگرایی الگوریتم لونیبرگ-مارکووات در شبکه‌های پیشرو از این الگوریتم جهت آموزش شبکه مورد نظر استفاده شده است. به طور کلی ۱۹۰۰ مجموعه داده ورودی به منظور آموزش، ارزیابی و آزمایش شبکه عصبی مصنوعی مورد استفاده قرار گرفته است. تعداد پارامترهای ورودی در این شبکه به دو بخش پارامتر ماشین و پارامترهای توده سنگ تقسیم بندی شده‌اند. برای انتخاب تعداد نرون‌ها در لایه پنهان، از روش آزمون و خطا استفاده شده است. تابع انتقال لایه پنهان، تانژانت سیگموئید و تابع انتقال لایه خروجی، خطی است. اگر تعداد نرون‌ها و لایه‌ها بیش از حد معمول باشد سیستم به جای تجزیه آنها را حفظ می‌کند. برای آموزش شبکه و قبل از اجرای ANN، در ابتدا به صورت تصادفی داده‌ها به سه دسته‌ی آموزش، اعتبارسنجی و آزمایش تقسیم شده است و به این منظور ۷۰٪ داده‌ها برای آموزش شبکه، ۱۵٪ داده‌ها برای اعتبارسنجی و ارزیابی و ۱۵٪ باقیمانده برای آزمایش شبکه عصبی اختصاص داده شده‌است. در صورتی که خروجی شبکه با مقادیر واقعی نرخ نفوذ برابر باشد کلیه 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 (افتخاری و همکاران ۱۳۹۱). از آنجا که پارامترهای ماشین در هر سیکل حفاری متفاوت می‌باشد، بنابراین فرض یک مقدار ثابت پارامترهای سنگ در طول یک مقطع سنگی می‌تواند سبب کم اثر شدن این پارامترهای سنگ در شبیه سازی به کمک شبکه عصبی مصنوعی شود، در صورتی که پارامترهای سنگ نیز در هر مقطع سنگی در یک محدوده تغییر می‌کنند و به ازای سیکل‌های مختلف حفاری همانند پارامترهای ماشین می‌توانند متفاوت باشند. به منظور در نظر گرفتن تغییرات پارامترهای سنگ در یک مقطع سنگی در پیش بینی، از روش شبیه سازی مونت کارلو استفاده شده است که با توجه به محدوده‌ی تغییرات پارامترها و میانگین آنها که در گزارشات زمین شناسی منطقه موجود می‌باشد و با فرض تابع توزیع نرمال برای این پارامترها، به تعداد سیکل‌های حفاری در مقطع مورد نظر، مقادیر تصادفی از پارامترهای سنگ ایجاد شده است.

برای پیش بینی نرخ نفوذ ۱۵ پارامتر به عنوان پارامترهای اولیه ورودی در نظر گرفته شده است. این پارامترها عبارتند از: مدول الاستیسیته، چگالی اشباع، چگالی خشک، فاصله ناپیوستگی‌ها، درصد کوارتز،

جدول ۳- ادامه مشخصات واحدهای موجود در ۱۰ کیلومتر اول تونل زاگرس

(مهندسی مشاور ساحل ۱۳۸۶)

واحد زمین شناسی مهندسی	فاصله ناپیوستگی ها (cm)	درصد کوارتز	RQD (%)	RMR	GSI
SH-ML 1	۱۵-۱۰۰-۲۰۰	۰-۵	۶۸-۷۵	۳۸-۴۸	۳۵-۴۵
SH-ML 2	۱۰-۸۰-۲۵۰	۰-۵	۵۲-۶۰	۳۴-۴۴	۲۸-۳۵
SH-ML 3	۱۰-۴۰-۷۰	۰-۵	۵۰-۶۵	۴۲-۵۰	۴۰-۴۵
ML-SH 1	۲۵-۸۰-۳۰۰	۰-۲	۸۵-۷۲	۵۰-۶۲	۴۰-۵۵
ML-SH 2	۱۰-۳۰-۵۰	۰-۳	۷۰-۶۰	۳۸-۴۸	۴۵-۵۰
ML-SH 3	۱۰-۹۰-۳۰۰	۳-۵	۶۵-۵۰	۳۵-۴۶	۳۵-۴۵
ML-SH 4	۱۵-۶۰-۲۰۰	۰-۵	۷۵-۶۵	۴۰-۵۰	۴۰-۴۵
ML-SH 5	۲۰-۵۰-۳۰۰	۰-۲	۸۵-۷۵	۵۵-۶۳	۴۰-۵۵
SH-LS 1	۱۰-۸۵-۲۰۰	۰-۵	۷۰-۶۰	۳۵-۴۲	۳۵-۴۰
SH-LS 2	۲۰-۳۰-۵۰	۰-۳	۸۰-۷۵	۴۸-۵۳	۴۰-۴۵
SH-LS 3	۱۰-۲۰-۵۰	۰-۵	۷۵-۶۵	۳۷-۴۵	۳۵-۴۰
SH-LS 4	۱۰-۵۰-۱۰۰	۳-۵	۷۵-۷۰	۴۳-۴۸	۴۰-۴۵
LI 2	۱۵-۱۰۰-۲۰۰	۰-۱	۹۰-۸۰	۵۲-۵۷	۵۵-۶۰

جدول ۴- نتایج شبکه عصبی مصنوعی با ورودی های متفاوت

ردیف	تعداد ورودی ها	ساختار شبکه	ضریب همبستگی داده های آموزش	ضریب همبستگی داده های آزمایش	خطای جذر میانگین مربعات (RMSE)
۱	۵	۱۴-۱	۰/۵۱	۰/۴۷	۲/۷۶۱۷
۲	۶	۱۴-۱	۰/۶۲	۰/۵۹	۲/۳۴۴۴
۳	۷	۱۴-۱	۰/۶۶	۰/۵۶	۲/۴۶۵۷
۴	۸	۱۷-۱	۰/۵۸	۰/۴۵	۲/۷۴۸۲
۵	۹	۱۲-۱	۰/۷۰	۰/۶۱	۲/۳۰۷۶
۶	۱۰	۹-۱	۰/۶۱	۰/۶۰	۲/۵۶۵۹
۷	۱۱	۱۵-۱	۰/۶۳	۰/۵۵	۲/۵۶۶۸
۸	۱۲	۱۱-۱	۰/۶۴	۰/۶۶	۲/۰۸۰۱
۹	۱۳	۱۱-۱	۰/۷۰	۰/۶۰	۲/۳۰۷۶
۱۰	۱۴	۱۶-۱	۰/۶۵	۰/۵۵	۲/۲۶۰۴
۱۱	۱۵	۱۲-۱	۰/۶۹	۰/۶۲	۲/۱۶۸۵

با ورودی های مختلف آورده شده است.

در نهایت شبکه ای با ورودی های مقاومت فشاری تک محوره، مقاومت کششی، مدول الاستیسیته، چگالی خشک، فاصله ناپیوستگی ها، RQD, GSI و همچنین نیروی محوری، گشتاور، توان ماشین و RPM به عنوان شبکه ی بهینه پس از ساخت شبکه های متعدد انتخاب شده است. با توجه به مطالب مذکور، برای تعیین تعداد نرون ها در لایه میانی، شبکه های متعددی با تعداد نرون های متفاوت در لایه میانی مورد آزمایش و ارزیابی قرار گرفته و بهترین شبکه انتخاب شده است که نتایج در جدول ۵ آورده شده است.

بهترین معماری شبکه شامل ۱۱ پارامتر ورودی، ۱۶ نرون در لایه میانی (پنهان) و ۱ نرون در لایه خروجی به عنوان شبکه بهینه انتخاب شده و در تصویر ۳ ساختار شبکه ی عصبی بهینه نشان داده شده است. در این مطالعه، ضریب همبستگی بین مقادیر واقعی و پیش بینی شده برای زیر مجموعه آموزش، اعتبار سنجی و آزمایش شبکه بهینه به ترتیب ۰/۹۳، ۰/۸۰، ۰/۸۷ می باشد. مقادیر تخمین زده شده برای نرخ نفوذ توسط شبکه در مقابل مقادیر واقعی برای داده های آزمون در یک دستگاه مختصات رسم شده و بهترین خط منطبق بر داده ها برآزش شده است (تصویر ۴). میانگین مربعات خطا در این مدل ۷۰۹۴۴ می باشد.


داده شده است. یکی از دلایل تأکید بر قرار داشتن داده های ورودی در این دامنه، الزام تابع انتقال است که قادر به تمایز بین مقادیر خیلی بزرگ نیست. هر چه مقدار ورودی این تابع بیشتر شود خروجی آن به سمت ۱ یا ۰ نزدیکتر می شود. مهمترین دلیل تبدیل مقیاس ورودی ها به این دامنه کمک به آموزش شبکه است. از طرف دیگر این کار موجب سادگی بیشتر می شود زیرا خروجی ها و ورودی های لایه های بعدی نیز در این دامنه قرار می گیرد.

۴- تمایل مساسیت جهت تعیین شبکه عصبی بهینه

به منظور دستیابی به شبکه ای با ساختار بهینه از لحاظ تعداد پارامترهای ورودی و تعداد لایه و نرون میانی، شبکه های متعددی با حذف برخی از پارامترهای اولیه و با انجام چندین مرحله آموزش با نرون های مختلف در لایه میانی ساخته شده است و همچنین، چون در فرآیند آموزش، وزن های اولیه به صورت تصادفی مقدار دهی شده و احتمال دارد شبکه در کمینه محلی گرفتار شود، هر شبکه چندین بار مورد آموزش قرار گرفته و بهترین نتیجه مورد استفاده قرار گرفته است و در نهایت با مقایسه نتایج شبکه های ساخته شده شبکه بهینه حاصل می شود. در ادامه به چند نمونه از شبکه های ساخته شده اشاره شده است و در جدول ۴ نتایج کلی از بهترین شبکه های ساخته شده

جدول ۵- ساخت شبکه عصبی با تعداد نرون های مختلف


ردیف	تعداد نرون لایه میانی	معماری شبکه	ضریب همبستگی زیر مجموعه آموزش	ضریب همبستگی زیر مجموعه آزمایش	خطای جذر میانگین مربعات (RMSE)
۱	۳	۳-۱	۰/۵۸	۰/۵۹	۲/۴۵۵۳
۲	۴	۴-۱	۰/۶۰	۰/۵۱	۲/۰۸۱۹
۳	۵	۵-۱	۰/۶۱	۰/۵۷	۲/۲۱۹۶
۴	۶	۶-۱	۰/۵۷	۰/۵۱	۲/۴۱۸۸
۵	۷	۷-۱	۰/۶۱	۰/۴۴	۲/۶۰۰۹
۶	۸	۸-۱	۰/۷۲	۰/۵۴	۲/۲۴۵۸
۷	۹	۹-۱	۰/۶۶	۰/۵۹	۲/۱۸۴۸
۸	۱۰	۱۰-۱	۰/۶۷	۰/۵۱	۲/۳۸۹۹
۹	۱۱	۱۱-۱	۰/۶۰	۰/۴۳	۲/۰۵۰۸
۱۰	۱۲	۱۲-۱	۰/۷۴	۰/۵۲	۲/۸۱۴۴
۱۱	۱۳	۱۳-۱	۰/۸۰	۰/۵۶	۲/۴۲۲۱
۱۲	۱۴	۱۴-۱	۰/۷۶	۰/۶۸	۲/۶۲۷۵
۱۳	۱۵	۱۵-۱	۰/۷۲	۰/۷۱	۲/۳۱۵۱
۱۴	۱۶	۱۶-۱	۰/۹۳	۰/۸۷	۷/۰۹۴۴
۱۵	۱۷	۱۷-۱	۰/۸۴	۰/۵۶	۲/۴۶۷۵
۱۶	۱۸	۱۸-۱	۰/۷۲	۰/۵۱	۲/۵۸۱۵
۱۷	۱۹	۱۹-۱	۰/۷۹	۰/۶۶	۲/۲۳۳۶
۱۸	۲۰	۲۰-۱	۰/۷۰	۰/۶۱	۲/۲۵۰۳




تصویر ۴- نمایش مقادیر واقعی در مقابل مقادیر پیش بینی شده نرخ نفوذ برای مجموعه‌ی داده‌های آزمون

۷- ارزیابی شبکه بهینه

از آنجا که در یک مقطع سنگی پارامترهای سنگ تقریباً ثابت می باشد، بنابراین پارامترهای اجرایی ماشین نقش اصلی در تفاوت نرخ نفوذ در سیکل های حفاری در یک سنگ را ایفا می کنند. بنابراین به منظور نشان دادن قابلیت شبکه ساخته شده در پیش بینی نرخ نفوذ، با استفاده از روش مونت کارلو مقادیر تصادفی از پارامترهای اجرایی ماشین در یک مقطع سنگی، با توجه به تابع توزیع آنها ایجاد شده و با استفاده از شبکه بهینه ساخته شده به پیش بینی نرخ نفوذ در مجموعه جدید پرداخته شده است. بهترین تابع توزیع برازش شده بر پارامترهای اجرایی ماشین از جمله نیروی محوری پیشران، گشتاور، توان ماشین و سرعت تاج حفار در مقطع سنگی مورد بررسی، تابع توزیع نرمال می باشد که در تصویر ۵ نشان داده شده است. در نتیجه با مقایسه تابع توزیع نرخ نفوذ داده‌های واقعی و نرخ نفوذ حاصل از داده‌های تصادفی در این مقطع سنگی می توان به بررسی قابلیت پیش بینی شبکه پرداخت. نرخ نفوذ داده‌های واقعی در مقطع سنگی مورد بررسی، از تابع توزیع نرمال با میانگین ۸۷۶۳ و انحراف معیار ۷۸۷۶ تبعیت می کند در حالی که نرخ نفوذ پیش بینی شده از تابع توزیع نرمال با میانگین ۸۸۸۰ و انحراف معیار ۲/۰۱۶ تبعیت می کند. مقایسه تابع توزیع نرخ نفوذ واقعی و پیش بینی شده در تصویر ۶ آمده است. در واقع این نمودار دوری و نزدیکی نتایج حاصل از شبکه عصبی مصنوعی با مقادیر واقعی را نشان می دهد.



تصویر ۳- ساختار شبکه‌ی عصبی بهینه



تصویر ۶- نمایش تابع توزیع نرخ نفوذ واقعی و پیش بینی شده


یک ضریب آماری بین مقادیر واقعی و پیش بینی شده به منظور تعیین غیر قطعیت و مقایسه ی بین مقادیر واقعی و پیش بینی شده در شرایطی که تعداد آنالیزهای مربوط برای هر دو مجموعه برابر باشد به صورت رابطه (۶) ارائه شده است (Ronold & Bjerager 1992). در این رابطه y مقدار و x مقدار پیش بینی شده است و K ضریب عدم قطعیت است که این ضریب انحراف بین مقدار واقعی و پیش بینی شده را به صورت یک مقدار آماری نشان می دهد که دارای میانگین و انحراف معیار به صورت روابط (۷) و (۸) می باشد که در این روابط n تعداد آنالیز است. اگر مقدار میانگین برابر ۱ باشد یعنی مقادیر بدست آمده کاملاً بر مقادیر واقعی منطبق است و مقدار انحراف معیار صفر است (Ronold & Bjerager 1992).

$$Y = K.X \quad \text{رابطه (۵)}$$

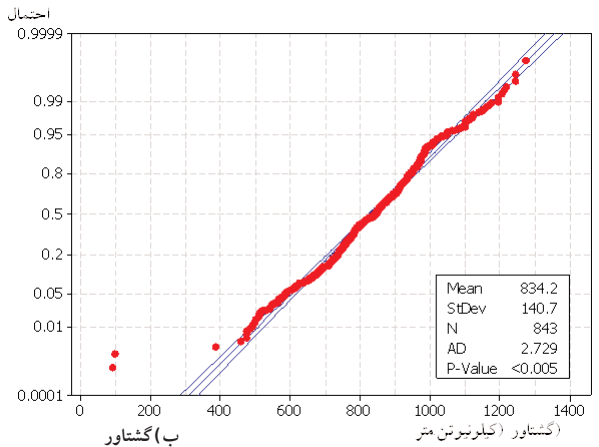
$$\mu_K = \frac{1}{n} \sum_{K=1}^n \frac{y_K}{x_K} \quad \text{رابطه (۶)}$$

$$\sigma_K = \left[\frac{1}{n-1} \sum (i_K - \mu_K)^2 \right]^{1/2} \quad \text{رابطه (۷)}$$

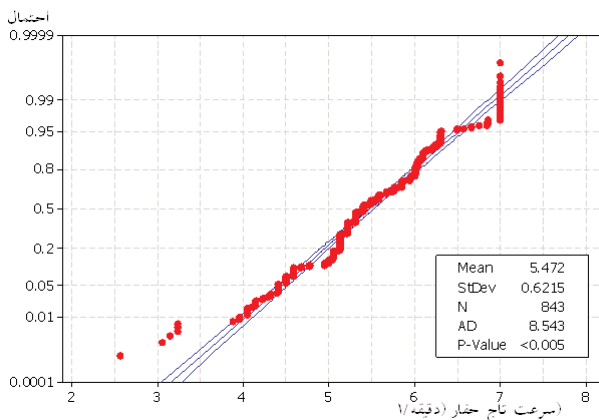
با توجه به روابط ارائه شده مقدار میانگین و انحراف معیار در این مطالعه به ترتیب ۷۰۳ و ۰/۳ بدست آمده است که نشان میدهد، نتایج پیش بینی شده به خوبی بر نتایج واقعی منطبق است و این مهم در تصویر نیز قابل مشاهده است. بنابراین، نتایج شبکه عصبی ساخته شده و همچنین مقایسه نتایج شبکه عصبی با داده های تصادفی با مقادیر واقعی نرخ نفوذ نشان می دهد که شبکه عصبی ساخته شده قابلیت پیش بینی قابل قبولی از نرخ نفوذ TBM را دارد.




الف) نیروی محوری پیشران



ب) گشتاور



ج) سرعت تاج حفار



د) توان ماشین

تصویر ۵- تابع توزیع نرمال برازش شده بر پارامترهای ماشین (نیروی محوری پیشران ب) گشتاور ج) سرعت تاج حفار د) توان ماشین

۸- نتیجه گیری

عملکرد نرخ نفوذ حفاری در TBM ها یک موضوع مهم در استخراج تونل به صورت مکانیزه می باشد. روش شبکه‌های عصبی مصنوعی یک ابزار قوی برای پیش بینی نرخ نفوذ TBM در معادن و تونل ها می باشد. این شبکه می تواند پتانسیل قابل توجهی برای حل وقت گیر مسائل را داشته باشد. در این مدل نیازی به رابطه خاص از جمله پیش بینی به روش های سنتی نمی باشد. شبکه مورد استفاده پیشرو و از الگوریتم پس انتشار خطا برای پیش بینی نرخ نفوذ استفاده گردید. ۱۵ پارامتر اولیه ورودی شامل، نیروی محوری پیشران، گشتاور، توان ماشین، RPM، مقاومت فشاری تک محوری، مقاومت کششی، مدول الاستیسیته، چگالی خشک، چگالی اشباع، درصد کوارتز، تخلخل، فاصله ناپیوستگی ها، RQD, RMR و GSI به عنوان ورودی انتخاب شدند. به این دلیل که داده های ارائه شده مربوط به مقاطع مختلف سنگی مسیر تونل در گزارش های زمین شناسی، به صورت مقادیر حداقل و حداکثر می باشد و در نظر گرفتن مقادیر میانگین آنها برای کل طول مقطع با توجه به طبیعت و ویژگی های زمین چندان نزدیک به واقعیت به نظر نمی رسد، بنابراین در این مطالعه به منظور در نظر گرفتن اثر پارامترهای سنگ و تغییرات آن در مسیر تونل، با توجه به توزیع پارامترهای سنگ و با بهره گیری از روش شبیه سازی مونت کارلو به تعداد سیکل های حفاری، پارامتر سنگ تصادفی متناسب با تابع توزیع و بازه تغییرات آنها در مقاطع سنگی ایجاد شد و شبکه های مختلفی با ترکیبات مختلفی از پارامترهای اولیه مورد بررسی قرار گرفت و در نهایت پس از بررسی های انجام شده شبکه ای با ۱۱ پارامتر ورودی شامل، نیروی محوری پیشران، گشتاور، توان ماشین، RPM، مقاومت فشاری تک محوری، مقاومت کششی، مدول الاستیسیته، چگالی خشک، فاصله ناپیوستگی ها، RQD و GSI به عنوان بهترین شبکه انتخاب شد که این شبکه ی بهینه دارای ۱۶ نرون در لایه پنهان و ۱ نرون در لایه خروجی می باشد و ضریب هبستگی برای زیرمجموعه آزمایش، ۰/۸۷ بدست آمده است. به منظور نشان دادن قابلیت شبکه ساخته شده در پیش بینی نرخ نفوذ، در یک مقطع سنگی که حفاری شده و در آن مقطع مقادیر نرخ نفوذ ثبت شده است، با استفاده از روش مونت کارلو مقادیر تصادفی از پارامترهای اجرایی ماشین با توجه به تابع توزیع و بازه تغییرات آنها ایجاد شد و با استفاده از شبکه بهینه ساخته شده به پیش بینی نرخ نفوذ در مجموعه جدید پرداخته شد. با

مقایسه تابع توزیع نرخ نفوذ داده های واقعی و نرخ نفوذ حاصل از داده های تصادفی در این مقطع سنگی این نتیجه حاصل شد که نتایج پیش بینی شده به خوبی بر نتایج واقعی منطبق است و بنابراین، شبکه عصبی ساخته شده قابلیت پیش بینی قابل قبولی از نرخ نفوذ TBM را دارد. در اینصورت با چنین رویکردی می توان به ازای هر مقطع سنگی توزیعی از مقادیر نرخ نفوذ را ارائه کرد که در آن، مقدار متوسط نرخ نفوذ و بازه تغییرات آن مشخص است.

مراجع

افتخاری، م.، باغبانان، ع.، و باقرپور، ر.، ۱۳۹۱. بررسی تاثیر پارامترهای اجرایی ماشین TBM بر نرخ نفوذ آن با استفاده از روش شبکه های عصبی مصنوعی - مطالعه موردی تونل بلند زاگرس. نشریه ی علمی پژوهشی مهندسی تونل و فضاها ی زیرزمینی، شماره ۱.

منهاج، م. ب.، ۱۳۹۱. مبانی شبکه های عصبی. انتشارات دانشگاه امیر کبیر.

مهندسی مشاور ساحل، ۱۳۸۶. مطالعات زمین شناسی مهندسی مسیر تونل. گزارش. ۲۰۲۶.

Eftekhari, M., Baghbanan, A. & Bayati, M., 2010. Predicting penetration rate of A Tunnel Boring Machine Using Artificial Neural Network. in *ISRM International Symposium-6th Asian Rock Mechanics Symposium, India*.

Farmer, I. & Glossop, N., 1980. Mechanics of disc cutter penetration. *Tunnels and Tunnelling, Vol. 12, pp 22-25*.

Gholamnejad, J. & Tayarani, N., 2010. Application of artificial neural networks to the prediction of tunnel boring machine penetration rate. *Mining Science and Technology (China), Vol. 20, pp 727-733*.

Graham, P., 1976. Rock exploration for machine manufacturers. *Exploration for rock engineering, pp 173-180*.

Grima, M., Bruines, P. & Verhoef, P., 2000. Modeling tunnel boring machine performance by neuro-fuzzy methods. *Tunnelling and underground space technology, Vol. 15, pp 259-269*.

Hedayatzadeh, M., Shahriar, K. & Hamidi, J. K., 2010. An Artificial Neural Network Model to Predict the Performance of Hard Rock TBM. in *ISRM International Symposium-6th Asian Rock Mechanics Symposium, India*.

Mehrotra, K., Mohan, C. K. & Ranka, S., 1997. Elements of artificial neural networks. *the MIT Press*.

Meulenkamp, F. & Grima, M. A., 1999. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. *International Journal of rock mechanics and mining sciences, Vol. 36, pp 29-39*.

Ronold, K. O. & Bjerager, P., 1992. Model uncertainty representation in geotechnical reliability analyses. *Journal of geotechnical engineering, Vol. 118, pp 363-376*

Yagiz, S. 2008. Utilizing rock mass properties for predicting TBM performance in hard rock condition. *Tunnelling*

and Underground Space Technology, Vol. 23, pp 326-339.
Yagiz, 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, Vol. 22, pp 808-814.