

تخمین ضریب بهره‌وری ماشین حفر تونل (TBM)

با استفاده از شبکه عصبی مصنوعی

حمیدرضا نجاتی^۱ و مرتضی احمدی^۲

۱. دانشجوی دکتری گروه مهندسی مکانیک سنگ، دانشگاه تربیت مدرس

۲. دانشیار دانشگاه تربیت مدرس

تاریخ دریافت: ۱۳۸۹/۲/۳ تاریخ تصویب: ۱۳۸۹/۷/۲۳

چکیده

پیش بینی سرعت پیشروی ماشین‌های حفر تونل، به منظور تعیین برنامه زمانی و برآورد هزینه‌های اجرایی در پروژه‌های تونل‌سازی با حفر مکانیزه، از اهمیت زیادی برخوردار است. برای این منظور لازم است تا ضریب بهره‌وری ماشین حفر تونل مشخص شده تا براساس آن سرعت پیشروی ماشین تعیین شود. اگر چه روابط تجربی متعددی در این زمینه ارائه شده‌اند ولی این روابط از دقت بالایی برخوردار نیستند. هدف از انجام این مطالعه تعیین ضریب بهره‌وری ماشین TBM باز، با استفاده از شبکه عصبی مصنوعی می باشد. برای این منظور مجموعه‌ای از داده‌های مربوط به تونلسازی با ماشین TBM باز، جمع‌آوری شده و شبکه‌ای با ورودی‌های مقاومت تک محوری فشاری، تنش قائم، فاکتور جهت درزه، نیروی نفوذ تیغه و شاخص کیفیت سنگ بارتن (Q) با خروجی ضریب بهره‌وری ماشین حفر تونل طراحی شده است. از آنجایی که پارامترهای ورودی شبکه، ارتباط بسیار مناسبی با ضریب بهره‌وری ماشین حفر تونل دارند شبکه عصبی طراحی شده قادر است با دقت بسیار بالا ضریب بهره‌وری ماشین حفر تونل را پیش بینی نماید.

واژگان کلیدی: بهره‌وری، شبکه عصبی، جهت درزه، تونل‌سازی، TBM

مقدمه

ماشین حفر تونل تحت تاثیر مدت زمان مفید حفاری و مدت زمان غیر مفید (مدت زمان نصب نگهداری تونل، تعویض تیغه‌های ماشین، تعمیر ماشین و غیره) میباشد. بنابراین برای تعیین سرعت پیشروی ماشین‌های حفر تونل تعیین دقیق ضریب بهره‌وری ماشین‌های حفر تونل از اهمیت زیادی برخوردار است. روابط تجربی متعددی برای تعیین ضریب بهره‌وری TBM ارائه شده‌اند [3,4] اما این روابط، به دلیل پیچیدگی‌های موجود بین میزان بهره‌وری ماشین و

بررسی عملکرد ماشین‌های حفر تونل (TBM) و توسعه مدل‌های مختلف برای ارزیابی و پیش‌بینی عملکرد این ماشین‌ها از اهداف تحقیقات متعددی است که در این زمینه صورت گرفته و یا در حال انجام می‌باشد [1].

تخمین سرعت پیشروی ماشین‌های حفر تونل، به منظور تعیین برنامه زمانی و برآورد هزینه‌های اجرایی در پروژه‌های تونل‌سازی با حفر مکانیزه، از اهمیت زیادی برخوردار است [2]. سرعت پیشروی

می تواند بسیار بالا باشد اما بدون شک این نوع سنگ ها نیاز به نگهداری داشته و در برخی موارد به علت خاصیت فشارندگی زیاد آنها و مشکلات پایداری شدید باعث کاهش فوق العاده ضریب بهره وری به ۱۰-۵ درصد و حتی کمتر هم می رسد [14]. اگر چه در روند کار ماشین TBM، موارد متعددی ممکن است باعث تاخیر در پیشروی ماشین شوند و روی ضریب بهره وری ماشین تاثیر بگذارند ولی ضریب بهره وری TBM به طور عمده به تاخیر ناشی از نصب نگهداری تونل وابسته است [15]. به همین دلیل ضریب بهره وری ماشین حفر تونل ارتباط نزدیکی با شاخص های طبقه بندی مهندسی سنگ دارند. در این مطالعه از شاخص Q به عنوان شاخص طبقه بندی مهندسی سنگها، مقاومت تک محوری فشاری، نیروی نفوذ تیغه، تنش قائم اعمالی بر تونل و فاکتور جهت درزه برای تخمین ضریب بهره وری ماشین حفر تونل استفاده شده است. در جدول ۱ مشخصات آماری ۲۷۵ مجموعه داده های مورد استفاده برای آموزش شبکه عصبی نشان داده شده است. این اطلاعات مربوط به تونل ها و پروژه های متعددی است که در آنها حفاری با TBM باز صورت گرفته است.

شبکه عصبی مصنوعی

شبکه های عصبی با الهام از ساختار مغز و عملکرد موازی آن بوجود آمده اند و تا به حال نتایج شگفت آوری به دنبال داشته اند. این سیستم قادر است روابط بین ورودی و خروجی های شبکه را هر چند پیچیده و غیر خطی باشد به خوبی تعیین نماید.

ساختار شبکه عصبی مصنوعی شامل تعداد واحدهای زیادی به نام نرون می باشد. این نرون ها که همگی با هم ارتباط دارند به واحدهای پردازشگر

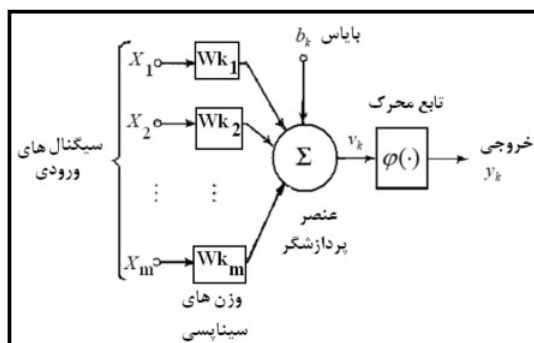
پارامترهای توده سنگ از دقت بالایی برخوردار نیستند. از طرف دیگر، برخی روابط ارائه شده به گونه ای هستند که پارامترهای زیادی در آنها در نظر گرفته شده که تعیین همه این پارامترها برای تعیین ضریب بهره وری ماشین کار ساده ای نمی باشد. به عنوان نمونه تعیین ضریب بهره وری TBM با استفاده از روابط تجربی ارائه شده در روش NTH نسبتاً پیچیده بوده و رابطه ارائه شده از طرف بارتن (Barton) شامل پارامترهای متعددی است [3] که تعیین دقیق آنها به راحتی امکان پذیر نبوده و همچنین این رابطه از دقت بالایی نیز برخوردار نمی باشد [5,6].

هوش مصنوعی به عنوان دانش شبیه سازی هوش انسان با استفاده از کامپیوتر توانایی حل مسائلی از این قبیل را به خوبی داراست. در این میان شبکه های عصبی مصنوعی، به عنوان یکی از شاخه های این علم، با قدرت بسیار بالایی قادر به تشخیص روابط غیرخطی و پیچیده بین پارامترهای مختلف می باشد. بر این اساس شبکه عصبی مصنوعی به طور گسترده در زمینه مهندسی ژئوتکنیک مورد استفاده قرار گرفته است [7-13]. در این مطالعه تلاش می شود تا با استفاده از شبکه عصبی مصنوعی ضریب بهره وری ماشین حفر تونل در سنگ های سخت تعیین شود.

ضریب بهره وری ماشین حفر تونل

طبق تعریف نسبت بخشی از زمان اجرای تونل که در طی آن TBM به کار گرفته می شود به کل زمان اجرای تونل ضریب بهره وری نامیده می شود که این ضریب بسیار به خصوصیات سنگ وابسته است. مقدار ضریب بهره وری در بسیاری از پروژه ها به طور متوسط بین ۳۰-۵۰ درصد می باشد. در سنگ های با کیفیت کم اگر چه نرخ نفوذ ماشین

وزن دار می‌گردد؛ یعنی در ضریب Wk_i ضرب می‌شود.



شکل ۱: مدل پایه یک نرون [17].

این کار، معادل با تاثیر سیناپس بر سیگنال ورودی قبل از ورود به نرون مورد نظر می‌باشد. علاوه بر این، نرون از یک بایاس b_k نیز برخوردار است. نرون برای تعیین خروجی خود از تابع غیر خطی $\varphi(\cdot)$ بهره می‌گیرد و در واقع این تابع غیر خطی، روی سیگنال تولید شده یا سیگنال فعال کننده v_k برای تعیین خروجی y_k عمل می‌کند. در یک شبکه که از m نرون تشکیل شده است خروجی y ورودی نرون‌های دیگر می‌باشد و هر نرون به عنوان یک گره معرفی می‌شود.

عملیات ریاضی انجام شده در عنصر پردازشگر بدین ترتیب است که ابتدا همه ورودی‌های نرون با وزن سیناپسی مربوطه ضرب می‌شود.

$$u_k = \sum_{j=1}^m W_{kj} X_j \quad (1)$$

مقدار فوق با بایاس نرون مربوطه جمع می‌شود.

$$v_k = u_k + b_k \quad (2)$$

مقدار خروجی نرون هم همان خروجی تابع $\varphi(\cdot)$ می‌باشد.

شبکه معروف می‌باشند و دارای مشخصات اساسی چون سیگنال ورودی، قدرت سیناپسی، پیوند های فعال کننده، سیگنال خروجی و آستانه نرون می‌باشند. دینامیک نرون ویژگی های شبکه عصبی را تعیین می‌کند و در واقع نشان می‌دهد که یک شبکه چگونه یاد می‌گیرد، چگونه اطلاعات جدید را با دانش از پیش آموخته خود مقایسه می‌کند، چگونه اطلاعات را طبقه بندی می‌کند، چگونه یک الگوی ذخیره شده را فراخوانی می‌کند و چگونه می‌تواند در صورت نیاز تعداد طبقات طبقه بندی خود را افزایش دهد [16].

در شکل ۱ مدل پایه یک نرون نشان داده شده است.

جدول ۱- مشخصات آماری مجموعه ۲۷۵ داده مورد استفاده

برای آموزش شبکه عصبی

پارامتر	واحد	حداقل مقادیر	حداکثر مقادیر	میانگین مقادیر
Q	-	۰/۱	۵۳۳	۵۵/۸۲
فاکتور جهت درزه (k)	-	۱	۱/۵	۱/۱۲
تنش قائم σ_v	MPa	۰/۲۲	۲۱/۱	۷/۷
مقاومت سنگ σ_c	MPa	۱۰	۲۸۹	۱۰۵
نیروی نفوذ تیغه	KN	۲۰۲۰	۷۸۷۲	۵۴۸۹
ضریب بهره‌وری	(/.)	۴/۸۵	۶۷/۰۸	۳۱/۰۸

با توجه به شکل شکل ۱ ملاحظه می‌گردد که یک نرون معمولی به طور کلی از m ورودی X_j تشکیل شده است که J نشان دهنده نرون مبدا می‌باشد که از ۱ تا m تغییر می‌کند. هر ورودی X_j قبل از اینکه وارد هسته اصلی عنصر پردازشگر شود

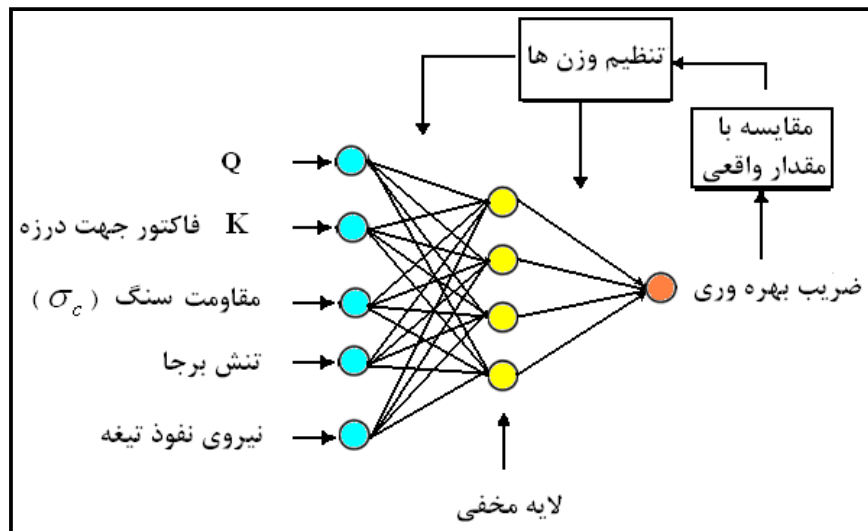
$$y_k = \varphi(v_k) \quad (۳)$$

باید توجه داشت که پارامترهای W و b قابل تنظیم هستند و تابع محرک $\varphi(\cdot)$ نیز توسط طراح تعیین می شود. بر اساس انتخاب $\varphi(\cdot)$ و نوع الگوریتم یادگیری پارامترهای W و b تنظیم می شوند. در واقع یادگیری بدین معنی است که پارامترهای W و b طوری تغییر کنند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید [16].

ساختار شبکه عصبی


نرون ها به صورت طبیعی به روش خاصی به هم اتصال می یابند تا یک شبکه عصبی مصنوعی را تشکیل دهند. به طور کلی در هر لایه می تواند ۱ یا بیش از یک نرون موجود باشد. همچنین نحوه اتصالات نرون ها می تواند به گونه ای باشد که شبکه تک لایه یا چند لایه را بوجود آورد. شبکه های تک لایه از یک طرف الگوی ورودی را دریافت کرده و از طرف دیگر الگوی خروجی را تعیین می کنند در حالی که در شبکه های چند لایه در بین لایه های ورودی و خروجی یک یا چند لایه به عنوان لایه پنهان وجود دارد که وظیفه این لایه ارتباط دادن لایه ورودی و لایه خروجی می باشد. تجربه نشان داده است که شبکه با داشتن حتی یک لایه پنهان قادر است که روابط غیر خطی را از داده های عرضه شده به آن، استخراج نماید [17]. تعداد لایه های مخفی هر شبکه، تعداد نرون های هر لایه، نوع توابع محرک به کار گرفته شده در هر لایه، الگوریتم مورد استفاده برای آموزش شبکه عصبی و همچنین فرآیند یادگیری شبکه تحت عنوان ساختار شبکه عصبی شناخته می شود. این ساختارها معمولاً با سعی و خطا تعیین می شوند. در این مطالعه از یک شبکه پیشخور پس انتشار با یک لایه مخفی که دارای ۴ نرون می باشد

استفاده می شود. در شکل ۲ فرآیند یادگیری پیشخور پس انتشار و نرون های مخفی شبکه عصبی طراحی شده نشان داده شده است. الگوریتم آموزش پس انتشار، یک ابزار ریاضیاتی است که در آن، اجرای معادلات آموزش بر اساس فرآیندهای تکراری است. به طوری که در مرحله آموزش شبکه، یک جفت از الگوهای (X_i, T_i) به شبکه ارائه می شود که X_i یک الگوی ورودی و T_i یک خروجی مطلوب است. الگوی X_i در نرون هر لایه، یک خروجی ایجاد می کند و نهایتاً در لایه خروجی، خروجی Y_i را تولید می نماید که با خروجی مطلوب T_i متفاوت می باشد. مقایسه خروجی Y_i با مقدار واقعی یک سیگنال خطا را به وجود می آورد. این سیگنال خطا وابسته به مقادیر وزن نرون های هر لایه است و با برگشت از لایه آخر به لایه های ابتدایی باعث تعدیل وزن های فرضی اولیه می شود. این فرآیند آنقدر تکرار می شود که میزان خطای محاسبه شده در لایه آخر به حداقل برسد. این خطا معمولاً به صورت میانگین مربعات خطا برای تمامی الگوهای یادگیری در هر سیکل محاسبه می شود. تابع انتقالی که در این شبکه مورد استفاده قرار می گیرد از نوع سیگموئید تانژانت می باشد. تابع آموزش یا الگوریتمی که برای آموزش شبکه مورد استفاده قرار می گیرد الگوریتم لوبنبرگ-مارکودت می باشد که به صورت تابع trainlm معرفی می شود.



شکل ۲- فرآیند یادگیری پیشخور پس انتشار و نرون‌های مخفی شبکه عصبی طراحی شده

بنابراین مجموعه ۲۷۵ داده موجود به ۳ بخش تقسیم می‌شود.



شکل ۳: زمان مناسب توقف آموزش شبکه [18].

بخشی برای آموزش شبکه که شامل ۱۶۵ داده بوده و بخشی برای آزمون که شامل ۵۵ داده بوده و در نهایت ۵۵ داده باقی مانده (۲۰ درصد از کل داده‌ها) برای ارزیابی شبکه مورد استفاده قرار می‌گیرد.

الگوریتم لونیگ-مارکودت می‌تواند بیشتر از ۵۰۰ بار سریعتر از الگوریتم شیب نزولی با تابع traingd که به طور معمول در شبکه‌های پس انتشار کاربرد دارد، به جواب همگرا شود [9]. همچنین تابع یادگیری مورد استفاده برای تعدیل وزن و بایاس شبکه تابع شیب نزولی با ضریب ممتنم می‌باشد. در حالت کلی برای بررسی قدرت تعمیم شبکه مجموعه داده‌ها به دو مجموعه یادگیری و آزمون تقسیم می‌شود؛ سپس داده‌های یادگیری را به دو زیر مجموعه، یکی برای آموزش و دیگری برای ارزیابی عملکرد شبکه به گونه‌ای تقسیم می‌شوند که زیر مجموعه ارزیابی حداکثر ۲۰ درصد از کل مجموعه یادگیری را تشکیل دهد. سپس منحنی نرخ یادگیری را برای داده‌های یادگیری و آزمون رسم می‌شود. در سیکلی که خطای یادگیری داده‌های یادگیری کاهش می‌یابد ولی خطای یادگیری برای داده‌های آزمون افزایش می‌یابد، فرآیند یادگیری متوقف می‌شود. به این روش اصولاً بررسی اعتبار می‌گویند. شکل ۳ زمان مناسب توقف آموزش شبکه را نشان می‌دهد.

پارامترهای ورودی شبکه

همچنین نیروی نفوذ تیغه و تنش قائم از دیگر پارامترهایی هستند که بر روی عملکرد ماشین های حفر تونل تاثیر بسزایی دارند [3,21].

لازم به ذکر است که منظور از تنش قائم، حاصلضرب عمق روباره تونل در وزن مخصوص سنگ روباره می باشد. مجموعه پارامترهای فوق به عنوان ورودی شبکه، برای تخمین تنها خروجی شبکه یعنی ضریب بهره‌وری ماشین حفر تونل مورد استفاده قرار می‌گیرد.

همانطور که اشاره شد تعیین دقیق ضریب بهره‌وری ماشین حفر تونل مشکل می باشد زیرا پارامترهای فرعی متعددی بر روی ضریب بهره‌وری ماشین تاثیر می‌گذارند.

مجموعه داده‌هایی که برای آموزش شبکه در این مطالعه مورد استفاده قرار می‌گیرد، مربوط به بازه‌های زمانی کوتاهی شامل بازه زمانی یک شیف‌ت کاری یا بازه مربوط به ۵ متر حفاری تونل می باشد؛ واضح است که در این بازه‌های کوتاه تاخیرهایی مانند تعویض شیف‌ت‌ها، خرابی دستگاه‌ها، تعویض دیسک‌ها، قطع برق و دیگر تاخیرهای فرعی به طور کلی یا دخیل نبوده و یا اگر هم دخیل باشد در تعداد اندکی از داده‌ها وارد شده‌اند. بنابراین انتظار می‌رود پارامترهای ورودی در نظر گرفته برای شبکه با دقتی بالا خروجی را تعیین کنند. بنابراین برای تعیین ضریب بهره‌وری در بازه‌های بزرگتر لازم است تا تاخیرهای فرعی ذکر شده نیز در نظر گرفته شود. طبیعی است با این روش ضریب بهره‌وری ماشین برای بازه‌های بزرگتر نیز دقیق‌تر محاسبه می‌شود.

همانطور که اشاره شد در این مطالعه برای آموزش شبکه عصبی از پنج ورودی Q (شاخص طبقه بندی مهندسی سنگ)، فاکتور جهت درزه، مقاومت تک محوری فشاری، تنش قائم و نیروی نفوذ تیغه استفاده شده است.

شاخص Q به عنوان یکی از معروفترین شاخص طبقه بندی مهندسی سنگ‌ها همبستگی خوبی با ضریب بهره‌وری ماشین حفر تونل و به طور کلی عملکرد ماشین حفر تونل دارند. به طوری که در هیچ فعالیت دیگری طبقه بندی مهندسی سنگ‌ها به این اندازه داری اهمیت نمی باشد [3].

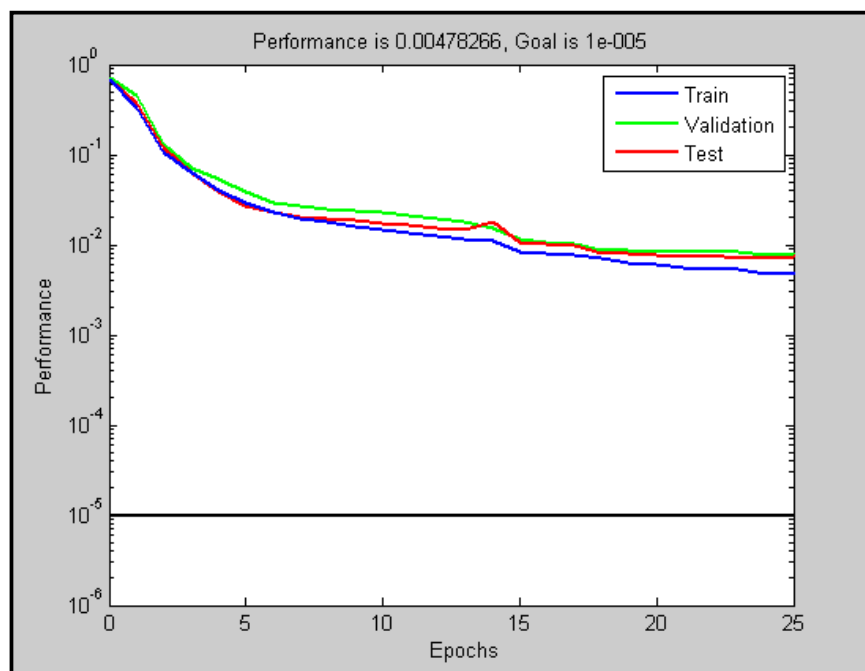
اما نکته قابل توجه این است که در شاخص Q جهت درزه‌ها مورد توجه قرار نمی‌گیرد و این در حالی است که جهت درزه‌ها در عملکرد ماشین های حفر تونل از اهمیت زیادی برخوردار است [19]. در این مطالعه برای در نظر گرفتن این پارامتر از نسبت RMR اصلاح نشده (NRMR) به RMR اصلاح شده ($K = \frac{NRMR}{RMR}$) استفاده می‌شود. در واقع NRMR مقداری از امتیاز توده سنگ در طبقه بندی CSIR می باشد که امتیاز مربوط به جهت داری درزه‌ها که به صورت اعدادی منفی در جداول مربوطه، تعیین شده در نظر گرفته نشده است [20].

در این مطالعه این پارامتر تحت عنوان فاکتور جهت درزه نامگذاری می‌شود. مقاومت تک محوری فشاری نیز از یک طرف بر پایداری فضای زیرزمینی و از طرف دیگر بر سرعت حفاری دستگاه تاثیر می‌گذارد [1].

دقت پیش بینی شبکه

در شکل ۴ منحنی تغییرات میانگین مربع خطای شبکه برحسب تعداد دوره‌های آموزشی برای هر سه مجموعه یادگیری، آزمون و ارزیابی نشان داده شده است.

همانطور که اشاره شد برای ارزیابی عملکرد شبکه بیست درصد از داده‌ها بکار گرفته شده است. برای محاسبه میزان خطای شبکه در هر سیکل، از تابع میانگین مربع خطا استفاده می‌شود.



شکل ۴: منحنی عملکرد شبکه برحسب تعداد دوره‌های آموزشی برای مجموعه داده‌های یادگیری، ارزیابی و آزمون

لازم به ذکر است که آموزش شبکه پس از ۱۰۰ سیکل و براساس روش Cross Validation متوقف می‌شود. همچنین مجموعه داده‌های ورودی و خروجی شبکه قبل از آنکه برای آموزش شبکه مورد استفاده قرار بگیرد به محدوده [۱،-۱] هنجار می‌شوند. این مساله نیز باعث افزایش سرعت همگرایی شبکه می‌شود [9,11].

در نهایت پس از آنکه آموزش شبکه به پایان رسید داده‌های خروجی شبکه دوباره به محدوده واقعی برگردانده می‌شوند.


منظور از عملکرد شبکه میزان کاهش خطای شبکه در هر سیکل آموزش می‌باشد. همانطور که در شکل ۴ نشان داده شده است سرعت همگرایی شبکه بسیار زیاد می‌باشد و این مساله به علت به کارگیری الگوریتم لوبنبرگ-مارکودت می‌باشد، به طوری که پس از ۲۵ سیکل مقدار میانگین مربع خطا (mse) به ۰/۰۰۴۸ رسیده است در صورتی که اگر از الگوریتم شیب نزولی برای آموزش شبکه استفاده شود برای رسیدن به این سطح از خطا به تعداد سیکل‌های آموزشی بسیار بیشتری نیاز است.

نایبوستگی می تواند به عنوان فاکتور جهت درزه مورد استفاده قرار گیرد ولی باید به این نکته توجه شود که میزان گسترش درزه در زاویه صفحه نایبوستگی با محور تونل مشخص نمی شود. به عبارت دیگر اگر زاویه صفحه نایبوستگی با محور تونل را به عنوان فاکتور جهت درزه داری در نظر گرفته شود تفاوتی بین درزه های که به طور فراگیر تمام محیط تونل را در بر گرفته (که اصطلاحاً به آنها joint گفته می شود) با ترک های که شامل درزه های نایبوسته هستند (که اصطلاحاً به آنها fissure گفته می شود) وجود نداشته و اگر زاویه میل آنها یکسان باشد فاکتور جهت درزه آنها کاملاً یکسان خواهد بود [4]. همچنین در این حالت اثر امتداد درزه ها نیز در نظر گرفته نمی شود.

در این مطالعه از فاکتور جدیدی به صورت نسبت RMR اصلاح نشده (NRMR) به RMR اصلاح شده به عنوان فاکتور جهت درزه توده سنگ منطقه استفاده می شود. در این پارامتر علاوه بر اینکه زاویه میل صفحات نایبوستگی با جهت پیشروی مد نظر قرار می گیرد، امتداد صفحات نایبوستگی نیز منظور می شود.

همچنین از آنجایی که گسترش ترک ها و درزه ها بی ارتباط با مقدار شاخص RMR نمی باشد بدون شک مقدار فاکتور جهت درزه برای joint و fissure متفاوت خواهد بود. در این بخش برای بررسی تاثیر فاکتور جهت درزه بر قدرت تخمین شبکه، با حذف این پارامتر از جمع ورودی های شبکه و آموزش مجدد شبکه با چهار ورودی باقی مانده تاثیر فاکتور جهت درزه بر قدرت تخمین شبکه مورد ارزیابی قرار می گیرد.

پس از پایان آموزش شبکه، به منظور بررسی قدرت پیش بینی شبکه عصبی، مقادیر واقعی مجموعه داده های آزمون که شامل ۵۵ داده می باشد با مقادیر پیش بینی شده توسط شبکه مقایسه می شوند. در شکل ۵ مقادیر واقعی و پیش بینی شده توسط شبکه عصبی با هم مقایسه شده اند.



شکل ۵- مقایسه مقادیر واقعی و پیش بینی شده توسط شبکه عصبی

همانطور که در شکل ۵ نشان داده شده است همبستگی بسیار خوبی بین مقادیر پیش بینی شده و مقادیر واقعی وجود دارد. به طوری که ضریب همبستگی خط $y=x$ ، حدود ۰/۹۶ می باشد.

تاثیر فاکتور جهت درزه بر قدرت تخمین شبکه

پارامترهایی که در این مطالعه به عنوان ورودی شبکه برای تخمین ضریب بهره وری ماشین مورد استفاده قرار گرفته اند از جمله پارامترهای شناخته شده در مهندسی سنگ هستند و تاثیر همگی این پارامترها بر عملکرد ماشین های حفر تونل به اثبات رسیده است. یکی از این پارامترها جهت درزه های برخورد کننده با تونل می باشد که تاثیر بسزایی بر عملکرد ماشین های حفر تونل و وضعیت پایداری تونل دارند [4,9,20]. زاویه بین محور تونل و صفحه

شبکه طراحی شده پس از ۱۰۰ سیکل با دقت بسیار مناسبی به جواب همگرا شود.


- از آنجایی که مجموعه داده‌هایی که برای آموزش شبکه مورد استفاده قرار گرفته است مربوط به بازه‌های زمانی کوتاهی می‌باشند و تاخیرهایی مانند تعویض شیفت‌ها، خرابی دستگاه‌ها، تعویض دیسک‌ها، قطع برق و دیگر تاخیرهای معمول وارد نشده‌اند خروجی شبکه با دقتی بالا بوسیله پارامترهای ورودی شبکه پیش بینی می‌شود.

- نسبت RMR اصلاح نشده به RMR اصلاح شده، به عنوان فاکتور جهت درزه‌های محیط، بر روی مقدار ضریب بهره‌وری ماشین تاثیر محسوسی داشته و با حذف این پارامتر از ورودی‌های شبکه قدرت تخمین شبکه کاهش پیدا می‌کند.

منابع

- 1- Benardos A.G. and Kaliampakos D.C. (2004). Modelling TBM performance with artificial neural networks. *Tunnelling and Underground Space Technology* 19:597-605.
- 2- Alber M. (2000). Advance Rates of Hard Rock TBMs and Their Effects on Project: Economics. *Tunneling and Underground Space Technology*. Volume 15: 55-64
- 3- Barton, N. (2000) TBM tunnelling in jointed and faulted rock. Rotterdam: Balkema.
- 4- Bruland, A., Johannessen, B.E., Lislrud, A., Movinkel, T., Myrvold, K. and Johannessen, O., 1988. Hard rock tunnel boring. Project Report 1-88, Norwegian Institute of Technology, Trondheim.
- 5- Sapigni M., Berti M., Bethaz E., Busillo A. and Cardone G. (2002). TBM performance estimation using rock mass classifications. *International Journal of Rock Mechanics & Mining Sciences* 39:771-788.
- 6- Palmstrom A. and Broch E. (2006). Use and misuse of rock mass classification systems with particular reference to the Q-system. *Tunnelling and Underground Space Technology* 21:575-593.

در شکل ۶ مقادیر واقعی و پیش بینی شده توسط شبکه عصبی با چهار ورودی Q، تنش قائم، مقاومت تک محوری و نیروی نفوذ تیغه مقایسه شده است.



شکل ۶- مقایسه مقادیر واقعی و پیش بینی شده توسط شبکه عصبی با چهار ورودی

همانطور که از مقایسه شکل‌های ۵ و ۶ برمی‌آید ضریب همبستگی مقدار پیش بینی شده با مقادیر واقعی ($R^2 = 0.88$) نسبت به ضریب همبستگی شبکه عصبی با پنج ورودی ($R^2 = 0.86$) کاهش پیدا کرده است که این مساله گویای تاثیرپذیری ضریب بهره‌وری ماشین حفر تونل از فاکتور جهت درزه داری می‌باشد.

نتیجه گیری

نتایج مطالعه حاضر را می‌توان در موارد زیر خلاصه نمود:

- بهترین ساختار برای شبکه پیشخور پس انتشاری که در این مطالعه مورد استفاده قرار گرفته است با سعی و خطا تعیین شده و شامل یک لایه مخفی با ۴ نرون می‌باشد که تابع محرک آنها tansig می‌باشد.
- قدرت بالای همگرایی الگوریتم لوببرگ-مارکودت و مناسب بودن پارامترهای ورودی باعث می‌شود که

- 7- Jamialahmadi M, Javadpour F.G. (2000), Relationship of permeability, porosity and depth using an artificial neural network. *Journal of Petroleum Science and Engineering* 26: 235–239.
- 8- Kim C.Y, Bae G.J, Hong S.W, Park C.H. (2001), Neural network based prediction of ground surface settlements due to tunneling. *Computers and Geotechnics* 28: 517–547.
- 9- Meulenkamp F, Alvarez Grima M. (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* 36: 29-39.
- 10- Singh T.N, Sinha S, Singh V.K. (2007) Prediction of thermal conductivity of rock through physico-mechanical properties. *Building and Environment* 42: 146–155.
- 11- Sonmez H, Gokceoglu C, Nefeslioglu H.A, Kayabasi A. (2006), Estimation of rock modulus: For intact rocks with an artificial neural network and for rock masses with a new empirical equation. *International Journal of Rock Mechanics & Mining Sciences* 43:224–235.
- 12- Singh V.K, Singh D, Singh T.N. (2001), Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural networks. *International Journal of Rock Mechanics & Mining Sciences* 38:269–284.
- 13- Huang Y, Wfinstedt S. (1998), The introduction of neural network system and its applications in rock engineering. *Engineering Geology* 49:253-260.
- 14- Barla G, Pelizza S. (2000). TBM tunnelling in difficult ground conditions. *International Conference on Geotechnical and Geological Engineering, Melbourne, Australia.*
- 15- Alber M. (1996). Classifying TBM Contracts. *Tunneling and Underground Space Technology*. December: 41-43.
- 16- Wasserman P.D. *Neural computing theory and practice*. New York: Van Nostrand Reinhold, 1987.
- 17- Haykin S. (1999), *Neural networks a comprehensive foundation*. (second edition). Prentice hall international, Inc.
- 18- Basheer IA and Hajmeer M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *J Microbiol Meth*43:3–31.
- 19- Gong G.M., Zhao J. and Jiao Y.Y. (2005). Numerical modeling of the effects of joint orientation on rock fragmentation by TBM cutters. *Tunnelling and Underground Space Technology* 20:183–191.
- 20- Bieniawski Z.T. (1974). Geomechanical classification of rock masses and its application in tunneling. *Proc. Third International Congress on Rock Mechanics, ISRM, Denver Volume 11A, 1974, Pages 27-32.*
- 21- Gertsch R., Gertsch L. and Rostami J. (2007). Disc cutting tests in Colorado Red Granite: Implications for TBM performance prediction. *International Journal of Rock Mechanics & Mining Sciences* 44:238–246.