http://tuse.shahroodut.ac.ir/

نشريه‌ي مهندسي تونل و فضاهاي زيرزميني

TUNNELING & UNDERGROUND SPACE ENGINEERING (TUSE)

دوره‌ي 1- شماره‌ي 1/زمستان 1391

بررسي تاثير پارامترهاي اجرايي ماشين TBM بر نرخ نفوذ آن با استفاده از روش شبكه‌هاي عصبي مصنوعي- مطالعه‌ي موردي تونل بلند زاگرس

سيد مصلح افتخاري[1*]؛ عليرضا باغبانان[2]؛ راحب باقرپور[3]

1- دانشجوي دكتراي تخصصي؛ رشته‌ي مهندسي معدن؛ گرايش مكانيك سنگ؛ دانشكده‌ي مهندسي معدن؛ دانشگاه صنعتي اصفهان

2 و 3- استاديار؛ دانشكده‌ي مهندسي معدن؛ دانشگاه صنعتي اصفهان

دريافت دست‌نوشته: 1391/08/02؛ پذيرش مقاله: 1391/10/27

واژگان كليدي

ماشين حفر تونل (TBM)

نرخ نفوذ

شبكه‌هاي عصبي مصنوعي

نيروي محوري پيشران

گشتاور

چكيده

نرخ نفوذ يكي از پارامترهاي مهم در تعيين مدت زمان حفاري در عمليات تونلسازي است. از آنجا كه عمليات حفاري اندركنش ميان زمين و ماشين است؛ بنابراين دو دسته‌ي كلي پارامتر موثر بر نرخ نفوذ وجود دارد. از طرفي در شرايط يكسان زمين، به دليل پارامترهاي اجرايي متفاوت ماشين، مقدار نرخ نفوذ متفاوت است. بنابراين در اين مقاله به بررسي اثر پارامترهاي ماشين بر نرخ نفوذ با استفاده از روش شبكه‌هاي عصبي مصنوعي پرداخته شده است. پس از انتخاب پارامترهاي موثر بر نرخ نفوذ و ايجاد شبكه‌ي عصبي بهينه، تحليل حساسيت بر روي پارامتر نيروي محوري پيشران و گشتاور انجام شده‌است. نتايج تحليل‌ها نشان مي‌دهد كه نيروي محوري پيشران و گشتاور در يك محدوده‌ي بهينه، سبب افزايش نرخ نفوذ مي‌شود و به منظور دستيابي به نرخ نفوذ حداكثر مي‌توان از زوج نيروي محوري پيشران و گشتاور بهينه استفاده نمود.

1- مقدمه

يكي از عوامل تعيين‌كننده‌ي انتخاب روش حفاري تونل (مكانيزه يا سنتي)، مدت زمان حفر آن است. در روش‌هاي سنتي، زمان حفر تونل، تابع پيشروي در يك مرحله‌ي آتشكاري است و در حفاري مكانيزه مدت زمان حفر تونل را نرخ پيشروي (*AR: Advance Rate*) ماشين تعيين مي‌كند. نرخ نفوذ (*PR: Penetration Rate*)، يكي از مهم‌ترين فاكتورهاي تاثيرگذار بر سرعت حفاري يا نرخ پيشروي *TBM* است. نرخ نفوذ، نسبت فاصله‌ي حفاري شده به زمان انجام آن در طول حفاري پيوسته يا به عبارتي برابر با نرخ پيشروي آني ماشين است و معمولاً بر حسب ميلي‌متر بر دور تاج حفار يا متر بر ساعت بيان مي‌شود. در صورت پيش‌بيني قابل قبول از نرخ نفوذ و به تبع آن از نرخ پيشروي، تخمين قابل اطميناني از زمان و بودجه‌ي لازم جهت انجام پروژه مي‌تواند صورت پذيرد.

با توجه به اهميت پيش‌بيني نرخ نفوذ در عمليات تونلسازي، هم زمان با ساخت *TBM* همواره محققاني به دنبال يافتن روشي براي پيش‌بيني مقدار آن بوده‌اند و تا كنون روش‌هاي متعدد تئوري و تجربي نيز ارايه شده است. در روش‌هاي تئوري محققاني از جمله رگسبروگ و فيليپس (*Roxborough & Phillips*)، سانيو (*Sanio*) و بويد (*Boyd*) با توجه به ارتباط تئوري ميان پارامترهاي ماشين و نفوذ ديسك و همچنين در برخي موارد پارامترهايي از سنگ به پيش‌بيني نرخ نفوذ پرداخته‌اند **[1]** و **[2]**. همچنين، انيستيتو مهندسي حفاري معدن كلرادو براي پيش‌بيني كارآيي *TBM* بر مبناي 20 سال مطالعات تئوريك،

* اصفهان؛ دانشگاه صنعتي اصفهان؛ دانشكده‌ي مهندسي معدن؛ كدپستي: 8415683111؛ شماره‌ي تلفن: 0311-3915148؛ رايانامه: *eftekhari_mosleh@yahoo.com* & *s.eftekhari@mi.iut.ac.ir*

آزمون‌هاي آزمايشگاهي و ارزيابي داده‌هاي حاصل از برداشت‌هاي صحرايي، مدلي با عنوان *CSM* (*Colorado School of Mines*) ارايه كرده است **[3]**. فلسفه‌ي اين روش تعيين نيروهاي وارد بر ديسك براي يك مقدار معين نفوذ و متعاقباً تعيين نيروي پيشروي، گشتاور و توان لازم براي كله‌ي حفار بر مبناي اين نيروها است.

روش تجربي بر مبناي ارتباط عملي و مشاهداتي بين پارامترهاي زمين و ماشين برقرار است و به واسطه‌ي برازش بين خصوصيات سنگ و پارامترهاي ماشين با نرخ نفوذ به دست آمده است. تعدادي از محققان از جمله تاركي (*Tarkoy*)، گراهام (*Graham*)، فارمر و گلوسپ (*Farmer & Glossop*) و نلسون (*Nelson*) تنها با توجه به يك پارامتر از سنگ و يا تركيب آن با يك پارامتر ماشين به پيش‌بيني نرخ نفوذ پرداخته‌اند **[4]**، **[5]**، **[6]** و **[7]**. محققاني از جمله كاسينلي (*Cassineli*)، ايناراتو (*Innaurato*)، پارك (*Park*) و حسن‌پور نرخ نفوذ را تابعي از سيستم‌هاي طبقه‌بندي سنگ از قبيل *RMR*، *RSR*، *RQD* و *Q* معرفي كرده‌اند **[8]**، **[9]**، **[10]** و **[11]**. همچنين، روش *NTH*، بر مبناي روابط تجربي بين پارامترهاي مكانيكي، زمين‌شناسي سنگ و بهره‌وري ماشين با ميزان پيشرفت واقعي تونل پايه‌گذاري شده است **[12]**. روش Q_{TBM} را بارتن (*Barton*) با اصلاحاتي بر سيستم *Q* از جمله ميزان ساينده‌گي سنگ، درصد كاني‌هاي ساينده، متوسط بار ديسك، مقاومت توده‌سنگ و سطح تنش سنگ ارايه كرده است **[13]**.

دو روش *NTH* و Q_{TBM} پارامترهاي موثر بيش‌تري را نسبت به ساير روش‌هاي تجربي در نظر گرفته و از ميان روش‌هاي تجربي، بيش‌تر مورد استفاده قرار مي‌گيرند. مزيت روش‌هاي تجربي اين است كه به طور طبيعي تمام تاثيرات ناشي از زمين و ماشين را در نظر مي‌گيرند؛ اما با اين حال، رشد فناوري و ارايه‌ي ماشين‌هايي با قابليت‌هاي متفاوت، استفاده از اين روش‌ها را محدود مي‌سازد. با اين وجود، به دليل اينكه مدل‌هاي ارايه شده در يك حالت خاص از شرايط زمين پيشنهاد شده‌اند، قابل تعميم به تمام شرايط نيستند.

در سال‌هاي اخير از روش شبكه‌هاي عصبي مصنوعي به عنوان ابزاري جديد جهت پيش‌بيني نرخ نفوذ استفاده شده است. شبكه‌هاي عصبي مصنوعي با الهام از ساختار مغز و عملكرد موازي آن به وجود آمده است و به مدل‌هاي رياضي محض نيازي ندارد؛ بلكه همانند انسان تجربه كسب كرده و سپس نتيجه‌ي اين تجربيات را تعميم مي‌دهد. در مواردي كه رابطه‌ي مشخصي ميان پارامترهاي ورودي و خروجي وجود نداشته و ارتباط ميان آن‌ها توسط روش‌هاي مرسوم قابل شناسايي نيست، استفاده از روش شبكه‌هاي عصبي مصنوعي به سبب عدم نياز به فرمول‌بندي و پويا بودن شبكه و همچنين امكان لحاظ كردن اثر پارامترهاي موثر بيش‌تر، ايده‌ي خوبي براي تخمين و مدلسازي به شمار مي‌رود. در واقع شبكه‌ي عصبي با توجه به قابليت‌هايش، مي‌تواند راه‌هاي ساده‌تر و كم هزينه‌تر و نتايج دقيق‌تري را پيش روي مهندسين، قرار دهد.

به منظور پيش‌بيني يك پارامتر با استفاده از شبكه‌ي عصبي نياز به سابقه‌اي از آن پارامتر و پارامترهاي موثر بر آن است تا بتوان پس از ساخت شبكه‌اي مناسب، از آن به منظور پيش‌بيني كميت مورد نظر بهره گرفت [14]. گريما و همكارانش (*Grima, et al.*) تصميم به پيش‌بيني نرخ نفوذ با توجه به سه مجموعه‌ي كلي موثر بر نرخ نفوذ از قبيل مشخصات سنگ بكر، ناپيوستگي‌ها و مشخصات ماشين گرفتند. اين محققين پارامترهاي مقاومت فشاري تك محوري (*UCS*) به عنوان مشخصه‌ي سنگ بكر، فراواني شكستگي مغزه (*CFF: Core Fracture Frequency*) به عنوان مشخصه‌ي ناپيوستگي، سرعت چرخش تاج حفار (*RPM*)، قطر ديسك و نيروي محوري پيشران در هر ديسك به عنوان مشخصات ماشين را در لايه‌ي ورودي و نرخ نفوذ را در لايه خروجي جاي داده‌اند **[15]**.

مهدوري و ياوري پارامترهاي نوع سنگ، مقاومت فشاري تك محوره، درصد كوارتز، قطر ديسك، نيروي نفوذ در هر ديسك و *RQD* را به عنوان پارامترهاي ورودي و نرخ نفوذ را به عنوان خروجي شبكه در نظر گرفته‌اند [16]. همچنين، ياگيز و همكارانش (*Yagiza, et al.*) چهار پارامتر مقاومت فشاري تك محوري، انديس تردي، فاصله‌ي صفحات ضعف و زاويه‌ي بين اين صفحات و محور تونل را به عنوان ورودي شبكه عصبي در نظر گرفته‌اند و شبكه‌اي با چهار ورودي و يك خروجي ايجاد كرده‌اند. همچنين آن‌ها با استفاده از داده‌هاي مورد استفاده در شبكه‌ي عصبي به پيش‌بيني نرخ نفوذ به كمك رگرسيون‌گيري چند متغيره‌ي

غيرخطي پرداخته‌اند **[17]**. از مقايسه‌ي مقادير پيش‌بيني شده با استفاده از شبكه‌ي عصبي و رگرسيون چندمتغيره‌ي غيرخطي با مقادير واقعي نرخ نفوذ، اين نتيجه حاصل شده است كه نتايج شبكه‌ي عصبي نسبت به رگرسيون غيرخطي به واقعيت نزديك‌تر است **[17]**. غلام‌نژاد با استفاده از روش شبكه‌هاي عصبي مصنوعي به پيش‌بيني نرخ نفوذ با استفاده از پارامترهاي مقاومت فشاري تك محوري، فاصله‌ي بين صفحات ضعف در توده سنگ و *RQD* پرداخته است **[18]**. ترابي و همكارانش نيز به كمك شبكه‌هاي عصبي به بررسي اثر پارامترهاي ژئوتكنيكي بر نرخ نفوذ پرداخته و عنوان كرده‌اند كه شبكه‌ي عصبي نسبت به روش آماري نتايج قابل اطمينان‌تري دارد **[19]**.

در تحقيقات گذشته براي پيش‌بيني نرخ نفوذ با شبكه‌هاي عصبي مصنوعي، بانك اطلاعاتي داده‌هاي ورودي و خروجي از چندين پروژه‌ي تونلسازي جمع‌آوري شده و براي هر مقطع سنگي تنها يك مقدار نرخ نفوذ در نظر گرفته شده‌است؛ اما از آنجا كه در يك مقطع زمين‌شناسي، نرخ نفوذ در هر سيكل حفاري به دليل پارامترهاي اجرايي ماشين متفاوت، مي‌تواند متغير باشد؛ بنابراين انتخاب تنها يك مقدار مشخص براي نرخ نفوذ در يك نوع سنگ خاص چندان نزديك به واقعيت نيست. در عين حال نتايج پيش‌بيني شبكه‌هاي عصبي مصنوعي محققان پيشين، بيانگر اين موضوع است كه روش شبكه‌هاي عصبي مصنوعي مي‌تواند ابزاري مناسب به منظور پيش‌بيني نرخ نفوذ باشد. بنابراين با توجه به اهميت تاثير پارامترهاي اجرايي ماشين بر نرخ نفوذ، در مطالعه‌ي حاضر به بررسي اثر اين پارامترها بر نرخ نفوذ با استفاده از روش شبكه‌هاي عصبي مصنوعي پرداخته شده‌است. دشواري يافتن رابطه‌اي ميان پارامترهاي اجرايي ماشين و نرخ نفوذ، قابليت‌هاي شبكه‌هاي عصبي مصنوعي در حل چنين مسائلي و امكان انجام تحليل حساسيت پارامترهاي موثر در نرخ نفوذ پس از ساخت شبكه‌ي عصبي بهينه از ديگر دلايل بكارگيري اين روش براي پيش‌بيني نرخ نفوذ در اين پژوهش است.

در تحقيق حاضر بانك اطلاعاتي تنها از تونل بلند زاگرس جمع آوري شده‌است تا بتوان به ازاي هر سيكل حفاري مقدار نرخ نفوذ آن را لحاظ كرده و در نتيجه اثر پارامترهاي اجرايي بر نرخ نفوذ در يك مقطع سنگي را در نظر گرفت. در ادامه پس از توضيح مختصري در ارتباط با منطقه‌ي مورد مطالعه و مباني شبكه‌هاي عصبي مصنوعي به ايجاد شبكه‌ي عصبي مصنوعي بهينه جهت پيش‌بيني نرخ نفوذ با در نظر گرفتن پارامترهاي موثر پرداخته شده است. پس از آن به منظور بررسي اثر پارامترهاي اجرايي ماشين، تحليل حساسيت بر اين پارامترها به كمك شبكه‌ي عصبي بهينه صورت گرفته است.

2- .منطقه‌ي مورد مطالعه

منطقه‌ي مورد مطالعه، بخشي از قطعه‌ي دوم تونل بلند زاگرس واقع در غرب كشور است. قطعه‌ي دوم اين تونل به طول 26 كيلومتر و به قطر 6/73 متر بوسيله‌ي ماشين حفاري تونل (*TBM*) با دو سپر در حال اجرا است. حداكثر عمق تونل 1000 متر و ميانگين عمق آن 400 متر است. مشخصات مربوط به تونل و ماشين *TBM* در جدول 1 آورده شده است.

جدول 1- مشخصات مربوط به تونل و TBM دو سپره [20]

مشخصات	اندازه
طول تونل (***KM***)	26
قطر حفاري (***m***)	6/73
تعداد ديسك	42
فاصله‌ي ديسك ها (***mm***)	90
قطر ديسك (***mm***)	432
سرعت چرخش (***1/min***)	0-9/05

شكل 1، برش زمين‌شناسي مسير تونل را نشان مي‌دهد. واحدهاي زمين‌شناسي مهندسي در برش با علائمي متشكل از حروف آغازين ليتولوژي آن مجموعه مشخص شده است. اين علائم شامل: *LI* به عنوان نشانه‌ي آهك، *SH* نشانه‌ي شيل، *MA* نشانه‌ي مارن، *ML* نشانه‌ي آهك مارني و *LS* نشانه‌ي شيل آهكي است. مرز واحدهاي زمين‌شناسي مهندسي عملاً بر مرز واحدهاي زمين‌شناسي منطبق است. با توجه به مطالعات زمين‌شناسي و زمين‌شناسي مهندسي صورت گرفته و با در نظر گرفتن تكرار واحدها در قسمت‌هاي گوناگون، در مجموع در محدوده‌ي مورد مطالعه، 21 واحد زمين‌شناسي مهندسي قابل تفكيك است [21]. به

منظور ايجاد شبكه‌ي عصبي مصنوعي به سابقه‌ي حفاري نياز است و از آنجا كه در زمان انجام اين پژوهش، 10 كيلومتر از تونل حفر شده بود؛ بنابراين داده‌هاي مربوط به اين كيلومتراژ مورد استفاده قرار گرفته است (جدول 2).

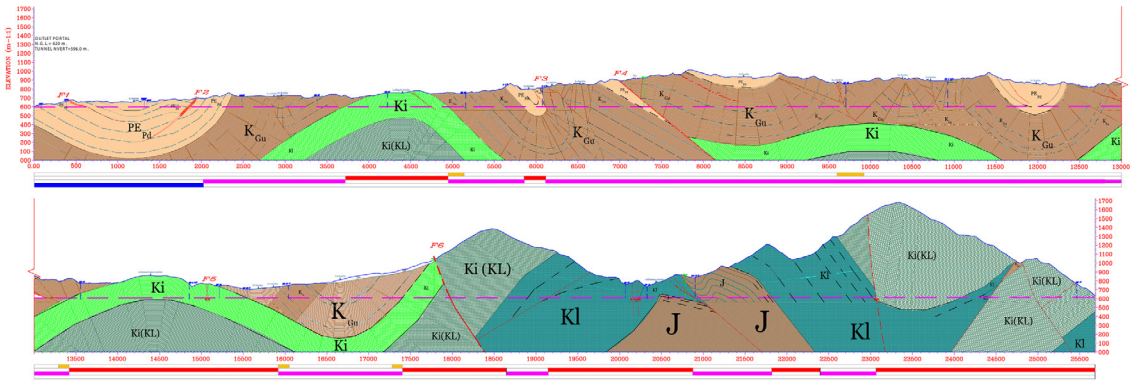

شكل 1- برش زمين‌شناسي مسير تونل **[20]**

3- .مباني شبكه‌هاي عصبي مصنوعي

يك نرون (كوچك‌ترين واحد پردازشگر اطلاعات)، اساس عملكرد شبكه‌هاي عصبي مصنوعي را تشكيل مي‌دهد. ساختار يك شبكه شامل لايه‌هاي ذيل است (شكل 2).

1- لايه‌ي ورودي شامل پارامترهاي موثر بر كميت مورد نظر براي پيش‌بيني.

2- لايه‌ي خروجي شامل پارامتر يا پارامترهايي كه قرار است توسط شبكه‌ي عصبي پيش‌بيني شود.

3- لايه يا لايه‌هاي مياني (پنهان) به عنوان رابط بين لايه‌هاي ورودي و خروجي.

جدول 2- مشخصات واحدهاي موجود در 10 كيلومتر اول تونل زاگرس [21]

واحد زمين‌شناسي مهندسي	مقاومت فشاري تك محوري (*MPa*)	مقاومت كششي (*MPa*)	***RQD*** (%)	***RMR***	دانسيته‌ي خشك (*gr/cm*^{3})	تخلخل (%)
SH-ML 1	10 -30	1 -3	68 -75	48	2/4 -2/5	10 -15
SH-ML 2	15 -30	1 -3	52 -60	44	2/3 -2/5	10 -15
SH-ML 3	10 -20	1 -3	50 -65	44	2/3 -2/5	5 -15
ML-SH 1	50 -100	5	85 -72	62	2/5 -2/6	2 -5
ML-SH 2	15 -30	1 -3	70 -60	48	2/2 -2/5	5 -10
ML-SH 3	25 -50	2 -4	65 -50	46	2/05 -2/5	5 -15
ML-SH 4	15 -30	2 -4	75 -65	50	2/2 -2/5	5 -10
ML-SH 5	50 -100	5	85 -75	49	2/3 -2/6	3 -5
SH-LS 1	15 -30	1 -3	70 -60	44	2/4 -2/5	3 -15
SH-LS 2	30 -50	2 -4	80 -75	50	2/3 -2/6	3 -10
SH-LS 3	15 -30	1 -3	75 -65	44	2/3 -2/5	5 -15
SH-LS 4	15 -30	2 -5	75 -70	48	2/3 -2/6	5 -10
LI 2	100 -150	2/5 -6	90 -80	57	2/5 -2/6	2/5 -6

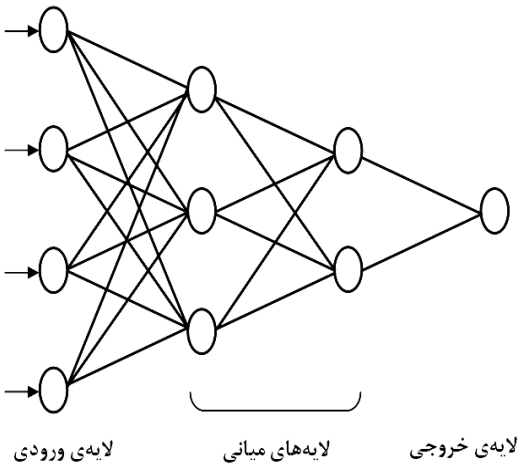

شكل 2- ساختار لايه‌اي شبكه‌ي عصبي مصنوعي

پيش از پرداختن به عمليات شبيه‌سازي پيشنهاد شده است كه داده‌ها در دامنه‌ي صفر و يك تغيير مقياس داده شوند. يكي از دلايل تاكيد بر قرار داشتن داده‌هاي ورودي در دامنه‌ي صفر تا يك، الزام توابع انتقال (مانند تابع سيگموئيد) است كه قادر به تمايز بين مقادير خيلي بزرگ نيستند. هر چه مقدار ورودي اين توابع بيش‌تر شود خروجي آن به سمت 1 يا 1- نزديك‌تر مي‌شود. مهم‌ترين دليل تبديل مقياس ورودي‌ها به دامنه‌ي صفر تا يك كمك به آموزش شبكه است. از طرف ديگر اين كار سبب سادگي بيش‌تر فرآيند مي‌شود زيرا خروجي‌ها و ورودي‌هاي همه‌ي لايه‌هاي بعدي نيز در دامنه‌ي صفر تا يك قرار مي‌گيرد [14]، [23]، [24] و **[22]**. براي شبيه‌سازي و تخمين مسئله، شبكه‌ي عصبي سه مرحله را طي مي‌كند:

1- آموزش (*Training*)
2- تعميم (*Generalization*)
3- اجرا (*Operation*)

آموزش فرايندي است كه طي آن شبكه مي‌آموزد تا الگوي موجود در ورودي‌ها را كه به صورت مجموعه‌ي داده‌هاي آموزشي است، بشناسد. براي اين منظور هر شبكه‌ي عصبي از مجموعه‌اي از قوانين يادگيري استفاده مي‌كند. اين قوانين نحوه‌ي يادگيري را تعريف مي‌كنند. تعميم، توانايي شبكه براي ارايه‌ي جواب قابل قبول در قبال ورودي‌هايي كه در مجموعه‌ي آموزشي نبوده‌اند، است. استفاده از شبكه براي انجام عملكردي كه به آن منظور طراحي شده است را اجرا مي‌گويند. در طي مرحله‌ي آموزش، وزن‌هاي داخلي شبكه‌ي عصبي كه بر روي ورودي‌ها اعمال مي‌شود آنقدر تغيير مي‌كند تا به وضعيت مناسب برسد. پس از اتمام آموزش، داده‌هاي مجموعه‌ي اعتبارسنجي به شبكه داده مي‌شود و پاسخ‌هاي شبكه با مقادير واقعي كميت مورد تخمين، مقايسه مي‌شود. هر چه اين دو سري داده (واقعي و تخميني) بيش‌تر به هم شبيه باشند، قدرت تعميم شبكه بيش‌تر خواهد بود [14]، [23]، [24] و **[22]**.

معمولاً از دو آماره، ضريب همبستگي و ميانگين قدرمطلق خطا، براي ارزيابي اختلاف دو سري داده استفاده مي‌شود. كاربرد ديگر مجموعه‌ي اعتبارسنجي در قطع زودهنگام آموزش است. بدين ترتيب كه تا قبل از اين‌كه آموزش تا آخرين مرحله ادامه يابد، در مرحله‌اي كه خطاي مجموعه‌ي اعتبارسنجي به حداقل مي‌رسد آموزش متوقف مي‌شود **[22]**.

يكي از پركاربردترين شبكه‌هاي مورد استفاده براي تخمين و پيش‌بيني، شبكه‌هاي پيشرو با قانون پس انتشار خطا (*Feed Forward Back Propagation*) است. چنين شبكه‌هايي از دو مسير اصلي تشكيل مي‌شود. مسير اول به مسير رفت موسوم است كه در اين مسير، بردار ورودي به شبكه اعمال مي‌شود و تاثيراتش از راه لايه‌هاي مياني به لايه‌هاي خروجي انتشار مي‌يابد. بردار خروجي تشكيل يافته در لايه‌ي خروجي، پاسخ واقعي شبكه است. در اين مسير پارامترهاي شبكه، ثابت و بدون تغيير در نظر گرفته مي‌شوند. مسير دوم به مسير برگشت موسوم است. در اين مسير، برعكس مسير رفت، پارامترهاي شبكه تغيير و تنظيم مي‌شوند. اين تنظيم مطابق با قانون اصلاح خطا انجام مي‌شود. سيگنال خطا، در لايه‌ي خروجي شبكه تشكيل مي‌شود. بردار خطا برابر با اختلاف بين پاسخ مطلوب و پاسخ واقعي شبكه است. مقدار خطا پس از محاسبه در مسير برگشت، از لايه‌ي خروجي و از طريق لايه‌هاي شبكه در كل شبكه توزيع مي‌شود. چون توزيع اخير، در خلاف مسير ارتباطات وزني صورت مي‌پذيرد، واژه‌ي پس انتشار خطا براي توضيح اصلاح رفتاري شبكه انتخاب شده است. پارامترهاي شبكه طوري تنظيم مي‌شوند كه پاسخ واقعي شبكه هر چه بيش‌تر، به پاسخ مطلوب نزديك‌تر شود [14] و [23].

4- پيش‌بيني نرخ نفوذ با شبكه‌هاي عصبي مصنوعي

به منظور پيش‌بيني نرخ نفوذ با استفاده از شبكه‌هاي عصبي مصنوعي، ابتدا پارامترهاي موثر بر نرخ نفوذ به منظور ايجاد ساختار شبكه انتخاب و سپس به شبيه‌سازي براي دستيابي به شبكه‌ي بهينه پرداخته مي‌شود.

4-1- ايجاد ساختار شبكه‌ي عصبي مصنوعي

عوامل موثر بر نرخ نفوذ *TBM* را مي‌توان در سه دسته‌ي كلي تقسيم‌بندي نمود كه عبارتند از:

1- پارامترهاي مربوط به سنگ بكر
2- پارامترهاي مربوط به توده‌سنگ
3- پارامترهاي اجرايي ماشين

به منظور انتخاب پارامترهاي ورودي شبكه تلاش شده است تا اثر اين سه دسته عوامل، در پيش‌بيني در نظر گرفته شود. در مجموع براي پيش‌بيني نرخ نفوذ، 9 پارامتر به عنوان پارامترهاي ورودي و موثر بر نرخ نفوذ انتخاب شده است:

1- مقاومت فشاري تك محوري (مگاپاسكال)
2- مقاومت كششي برزيلي (مگاپاسكال)
3- درصد كوارتز (بيانگر قابليت سايش سنگ)
4- *RQD* (براي توصيف تعداد درزه‌ها در سنگ)
5- *RMR* (بيانگر شرايط توده‌سنگ)
6- نوع سنگ با كدگذاري مطابق جدول 3
7- نيروي محوري پيشران يا تراست (كيلونيوتن)
8- گشتاور (كيلونيوتن متر)
9- سرعت چرخش تاج حفار (دور بر دقيقه)

پارامتر خروجي شبكه‌ي عصبي نيز، نرخ نفوذ (ميلي‌متر بر دور تاج حفار) است. اين پارامترها به سادگي در مراحل انجام پروژه و بدون نياز به انجام آزمايش و تكنيك‌هاي ويژه، قابل جمع‌آوري هستند.

جدول 3- كدگذاري مربوط به نوع سنگ

نوع سنگ	كد
توده‌اي	1
متوسط تا ضخيم لايه	2
نازك تا متوسط لايه	3
خرد شده	4

انتخاب پارامترهاي ورودي با توجه به سوابق تحقيقات انجام شده كه اثر پارامترهاي مختلف بر نرخ نفوذ را به طور جداگانه مورد بررسي قرار داده‌اند، صورت گرفته است. به عنوان مثال در تعدادي از تحقيقات تاثيرگذاري مقاومت فشاري تك محوري سنگ بكر بر نرخ نفوذ بررسي و به اثبات رسيده است. در نتيجه اين پارامتر به عنوان ورودي شبكه‌ي عصبي انتخاب شده است. همچنين به اين سبب كه با پارامترهاي ماشين متفاوت در شرايط يكسان توده‌سنگ، مقدار نرخ نفوذ مي‌تواند متفاوت باشد؛ بنابراين پارامترهاي ماشين نيز به عنوان ورودي شبكه در نظر گرفته شده است.

در نگاه اول به نظر مي‌رسد كه بين برخي از پارامترهاي ورودي يك همبستگي دروني وجود دارد (*RQD* و *RMR*) كه ممكن است سبب خطا در نتايج شود. با اين حال، هر پارامتر موضوع مشخصي را شرح مي‌دهد و اطلاعات تهيه شده مي‌تواند به فهم بيش‌تر مسئله كمك نمايد. به عنوان مثال، در يك مقدار *RMR*، انتظار رفتار يكساني در موارد مختلف وجود دارد در صورتي‌كه تفاوت در مقدار *RQD*، ممكن است منجر به تفاوت در شرايط پايداري شود.

براي ساخت شبكه‌ي مناسب نياز به زوج‌هاي ورودي و خروجي از داده‌ها است كه از 10 كيلومتر ابتدايي از حفر تونل انتخاب و در يك بانك اطلاعاتي ذخيره شده است [25] و **[26]**. همان‌طور كه در بخش مباني شبكه‌هاي عصبي مصنوعي بيان شده است، يك شبكه بايد با مجموعه‌اي از زوج‌ها به عنوان زوج آموزش مورد آموزش قرار گرفته و با زوج‌هاي مجموعه‌ي ارزيابي و آزمون مورد آزمايش قرار گيرد. بنابراين، قبل از عمليات آموزش، مجموعه‌ي بانك اطلاعاتي به طور تصادفي به سه دسته‌ي مجموعه‌ي آموزش، ارزيابي و آزمون افراز مي‌شود **[22]**.

تعيين ساختار شبكه‌ي عصبي يكي از مهم‌ترين و مشكل‌ترين مراحل و نيازمند انتخاب تعداد بهينه‌ي لايه‌ها و همچنين تعداد بهينه‌ي نرون‌ها در هر لايه است. روش مشخصي جهت تعيين شبكه‌ي بهينه وجود ندارد. به طور كلي پيشنهاد شده است كه با ثابت نگه‌داشتن تعداد لايه، تعداد نرون در هر لايه تعيين شود [14]. شبكه‌ي پيشرو همواره داراي يك لايه‌ي ورودي و يك لايه‌ي خروجي است. تعداد نرون‌ها در لايه‌هاي ورودي و خروجي به ترتيب با توجه به پارامترهاي ورودي و خروجي مدل محدود مي‌شوند.

با وجود اين‌كه روش معيني براي تعيين تعداد لايه‌ي مياني وجود ندارد؛ اما با اين حال تعدادي از محققان عقيده دارند كه بسياري از مسائل با استفاده از يك لايه‌ي مياني قابل حل است **[27]**، **[28]**، **[29]** و **[30]** و در بسياري از مطالعات ژئوتكنيكي نيز از يك لايه‌ي مياني استفاده شده است. با اين حال به منظور دستيابي به نتايج مناسب، در اين مطالعه شبكه‌هاي زيادي با يك و دو لايه‌ي مياني ساخته شده است. مقايسه‌ي نتايج حاصل از آن‌ها نشان مي‌دهد كه شبكه‌ي با ساختار يك لايه‌ي مياني در اين تحقيق مناسب‌تر است؛ بنابراين در ادامه، شبيه‌سازي و نتايج مربوط به شبكه با يك لايه‌ي مياني ارايه شده است.

يكي ديگر از پارامترهاي مهم در ساخت شبكه‌اي مناسب براي پيش‌بيني، تعداد نرون‌ها در لايه‌ي مياني است. اگر تعداد نرون‌هاي لايه‌ي مياني كم باشد، شبكه نمي‌تواند نگاشت غيرخطي بين ورودي و خروجي را با دقت لازم منعكس كند. تعداد زياد نرون‌هاي لايه‌ي مياني نيز اثر منفي دارد؛ چرا كه تعداد عناصر تنظيم شونده‌ي شبكه زياد شده و شبكه براي يادگيري نياز به تعداد زيادي مثال در مجموعه‌ي آموزشي دارد تا بتواند اوزان خود را تنظيم كند. همچنين احتمال بيش‌برازشي در شبكه نيز افزايش مي‌يابد [14] و [24].

به منظور ايجاد شبكه‌ي بهينه، مقياس داده‌هاي ورودي و خروجي شبكه به 1- و 1+ تغيير داده شده است. براي پيش‌بيني نرخ نفوذ، شبكه‌اي با تغذيه‌ي پيشرو با يك لايه‌ي ورودي، يك لايه‌ي مياني و يك لايه‌ي خروجي ساخته شده است. تابع انتقال در لايه‌ي مياني تابع تانژانت سيگموئيد (*Tansig*) و تابع انتقال در لايه‌ي خروجي تابع خطي (*Purelin*) در نظر گرفته شده است. با توجه به سرعت همگرايي الگوريتم لونبرگ-مارکوارت (*Levenberg–Marquardt*) در شبكه‌هاي پيشرو از اين الگوريتم براي آموزش شبكه‌ي مورد نظر استفاده شده است. تعداد نرون در لايه‌ي مياني با روش سعي و خطا به گونه‌اي انتخاب مي‌شود كه بهترين جواب ممكن بدست آيد. با اين وجود، تعدادي از محققان با توجه به تجربيات خود روش‌ها و محدوديت‌هايي را براي تعداد نرون‌ها در لايه‌ي مياني تعيين كرده‌اند. به عنوان نمونه بركه (*Berke*) پيشنهاد كرده است كه تعداد نرون‌ها در لايه‌ي مياني عددي بين ميانگين و مجموع نرون‌هاي لايه‌هاي ورودي و خروجي باشد **[31]**. هيچت-نيلسن (*Hecht-Nielsen*) و كاديل (*Caudill*) نيز پيشنهاد كرده‌اند كه حد بالايي تعداد نرون در لايه‌ي مياني در يك شبكه با يك لايه‌ي مياني 2I+1 است كه I تعداد ورودي شبكه است **[32]** و **[33]**.

4-2- .شبيه‌سازي با شبكه‌هاي عصبي مصنوعي

با توجه به مطالب مذكور، براي تعيين تعداد نرون‌ها در لايه‌ي مياني، شبكه‌هاي متعددي با تعداد نرون‌هاي متفاوت در لايه‌ي مياني مورد آموزش و ارزيابي قرار گرفته و بهترين شبكه انتخاب شده است. در اين پژوهش بهترين نتايج با تعداد نرون 8، 9، 10 و 11 عدد در لايه‌ي مياني بدست آمده است. مقادير تخمين زده شده براي نرخ نفوذ توسط شبكه در مقابل مقادير واقعي نرخ نفوذ براي داده‌هاي آزمون در يك دستگاه مختصات رسم شده و بهترين خط منطبق بر داده‌ها برازش شده است. مقادير واقعي در محور افقي و مقادير تخمين زده شده در محور قائم دستگاه مختصات قرار دارند. در صورتي كه خروجي شبكه با مقادير واقعي نرخ نفوذ برابر باشد، تمامي نقاط بر روي خط $y=x$ قرار مي‌گيرند. ميزان انحراف نقاط نسبت به اين خط، بيانگر ميزان تفاوت ميان خروجي شبكه و مقادير واقعي است.

براي ارزيابي شبكه‌ها سه باند (جدول 4) تعريف شده است. ملاك ارزيابي فراواني، نقاط در هر يك از اين سه باند است. فراواني داده‌ها در هر باند نشان مي‌دهد كه شبكه با چه دقت و احتمالي قادر به پيش‌بيني نرخ نفوذ است. فراواني داده‌ها در هر يك از باندهاي ذكر شده براي مجموعه‌ي آزمون شبكه‌هاي ساخته شده با تعداد نرون‌هاي 8، 9، 10 و 11 در لايه‌ي مياني در جدول 5 آورده شده است.

جدول 4- تعريف باندهاي خطا

باند	1	2	3
معادله‌ي خط	$y=x\pm1$	$y=x\pm1.5$	$y=x\pm2$
خطا (***mm/rev***)	1	1/5	2

مطابق جدول 5، تعداد نرون بهينه در لايه‌ي مياني 8 عدد است. با توجه به جدول 5 احتمال اين‌كه خروجي مجموعه‌ي آزمون شبكه‌ي 1×8×9 با مقدار واقعي نرخ نفوذ كمتر از 1، 1/5 و 2 ميلي‌متر بر دور تاج حفار تفاوت داشته

باشد به ترتيب برابر با 50، 68 و 93 درصد است. ضريب تطبيق بين مقادير تخمين زده شده و مقادير واقعي براي مجموعه‌ي آموزش، ارزيابي و آزمون اين شبكه به ترتيب 90، 85 و 83 درصد بدست آمده و به ترتيب در شكل 3-الف، شكل 3-ب و شكل 4-الف آورده شده است. فراواني داده‌ها در هر يك از سه باند براي مجموعه‌ي آزمون شبكه در شكل 4-ب نشان داده شده‌است. خطاي متوسط بين اين مقادير 1/07 ميلي‌متر بر دور تاج حفار برآورد شده است.

جدول 5- ارزيابي كارايي شبكه با تغيير تعداد نرون‌هاي لايه‌ي مياني

تعداد نرون	8	9	10	11
باند 1	14	16	19	13
باند 2	19	21	22	18
باند 3	26	24	23	20
خطاي متوسط	1/07	1/2	1/17	1/36
ضريب همبستگي	0/83	0/77	0/74	0/71

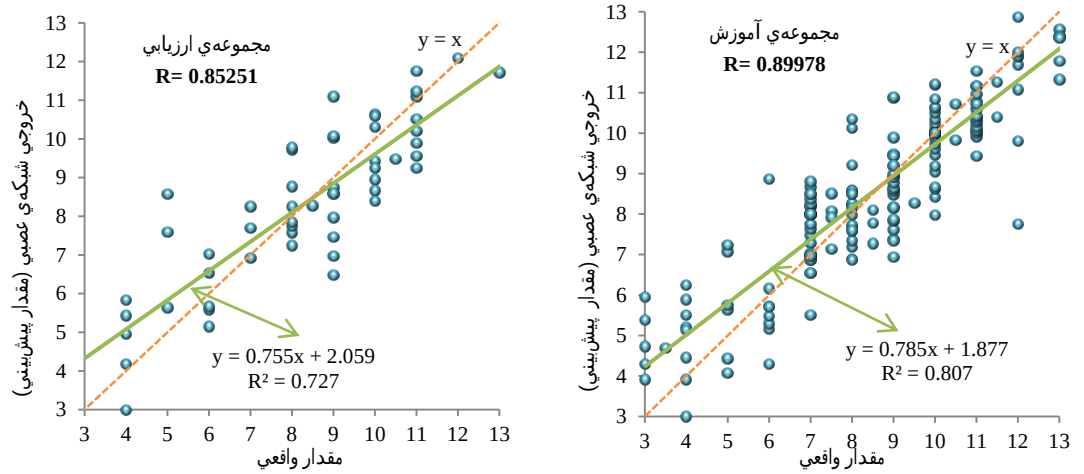

(الف) (ب)

شكل 3- نمايش مقادير واقعي در مقابل مقادير پيش‌بيني شده‌ي نرخ نفوذ: الف- براي مجموعه‌ي داده‌هاي آموزش؛ ب- براي مجموعه‌ي داده‌هاي ارزيابي

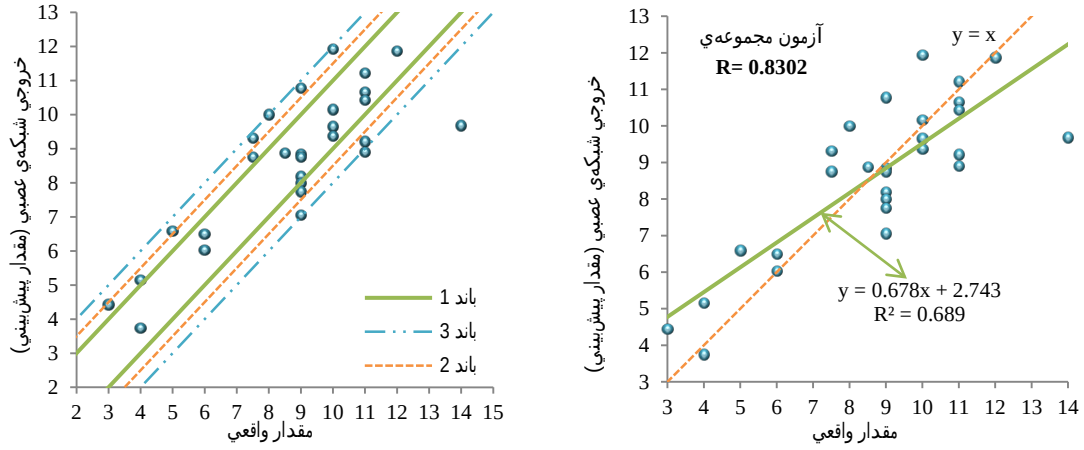

(الف) (ب)

شكل 4- نمايش مقادير واقعي در مقابل مقادير پيش‌بيني شده‌ي نرخ نفوذ براي مجموعه‌ي داده‌هاي آزمون الف- بهترين خط برازش شده؛ ب- فراواني در هر باند

با استفاده از شبكه‌ي بهينه‌ي بدست آمده (9×8×1) به پيش‌بيني نرخ نفوذ در طول 0/5 كيلومتر از تونل (كيلومتراژ 10 تا 10/5)، پرداخته شده است. بدين منظور بانك اطلاعاتي شامل 40 زوج ورودي و خروجي از داده‌ها ايجاد شده است. همانند روند قبل مقادير تخمين زده شده‌ي نرخ نفوذ توسط شبكه در مقابل مقادير واقعي نرخ نفوذ براي داده‌هاي جديد آزمون در يك دستگاه مختصات رسم و بهترين خط منطبق بر داده‌ها برازش شده است. ضريب تطبيق بين مقادير پيش‌بيني شده و مقادير واقعي براي مجموعه‌ي آزمون جديد اين شبكه 79 درصد (شكل 5-الف) و خطاي متوسط بين اين مقادير 1/17 ميلي‌متر بر دور تاج حفار است. احتمال اين‌كه خروجي شبكه براي اين مجموعه با مقدار واقعي نرخ نفوذ كمتر از 1، 1/5 و 2 ميلي‌متر بر دور تاج حفار تفاوت داشته باشد، به ترتيب 50، 70 و 88 درصد است. فراواني داده‌ها در هر يك از سه باند ذكر شده براي اين مقادير در شكل 5-ب نشان داده شده است.

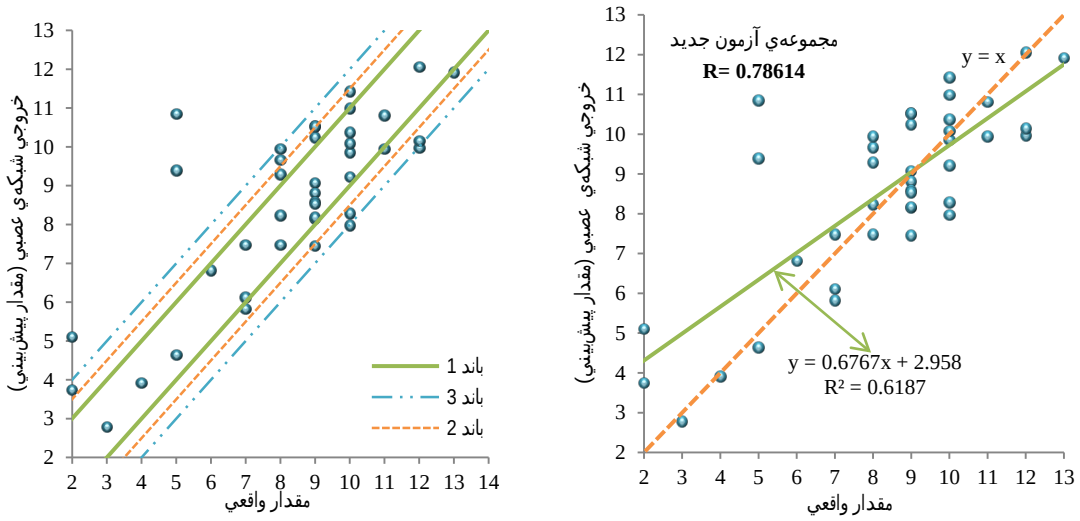

(ب) (الف)

شكل 5- نمايش مقادير واقعي در مقابل مقادير پيش‌بيني شده نرخ نفوذ براي مجموعه‌ي داده‌هاي آزمون جديد الف- بهترين خط برازش شده ب- فراواني در هر باند

با توجه به نتايج حاصل از شبيه‌سازي‌ها، مي‌توان بيان نمود كه شبكه‌اي با ساختار 9 نرون در لايه‌ي ورودي، 8 نرون در لايه‌ي ميانی و 1 نرون در لايه‌ي خروجي (9×8×1) شبكه‌اي مناسب و بهينه براي پيش‌بيني نرخ نفوذ در اين تونل است (شكل 6).

پس از اطمينان از شبيه‌سازي، مي‌توان با استفاده از شبكه‌ي عصبي مصنوعي بهينه، بر روي پارامترهاي ورودي تحليل حساسيت انجام داد. شرايط زمين در هر مقطع سنگي تقريباً ثابت مي‌ماند؛ اما به دليل تغيير پارامترهاي اجرايي ماشين در هر مقطع، نرخ نفوذ مي‌تواند مقادير متفاوتي داشته باشد؛ به همين دليل تحليل حساسيت بر روي پارامترهاي اجرايي ماشين انجام شده است. پارامترهاي اجرايي ماشين، شامل نيروي محوري پيشران، گشتاور و سرعت چرخش تاج حفار (RPM) هستند. مقدار سرعت چرخش به سبب محدوديت‌هاي اجرايي پروژه در محدوده‌ي كوچكي تغيير مي‌كند؛ به همين دليل تحليل حساسيت بر روي نيروي محوري پيشران و گشتاور با مقدار سرعت ثابت صورت گرفته است. تحليل حساسيت در مقطع سنگي با مشخصات مندرج در جدول 6 انجام شده است. براي تحليل حساسيت بر روي پارامتر نيروي محوري پيشران، تمام پارامترها به جز نيروي پيشران ثابت فرض شده و مجموعه‌اي جديد به عنوان ورودي شبكه‌ي بهينه ايجاد و پس از شبيه‌سازي، مقادير خروجي حاصل به عنوان نرخ نفوذ ثبت شده است.

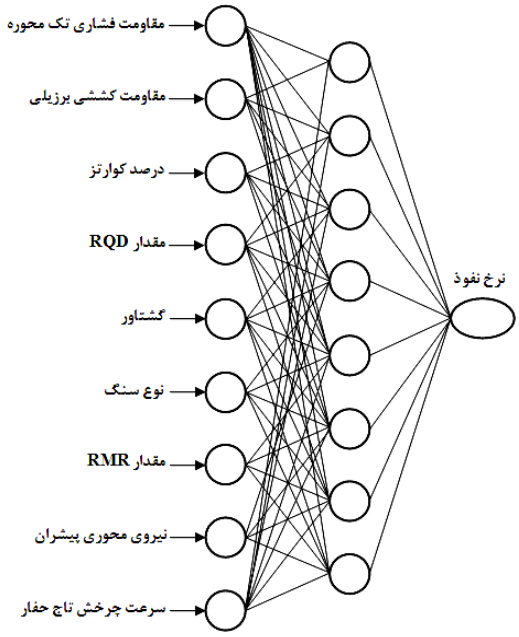

شكل 6- ساختار شبكه بهينه ساخته شده

مقادير نرخ نفوذ بدست آمده از شبكه در مقابل تغييرات نيروي پيشران در شكل 7 رسم شده است. با توجه به اين شكل، مشاهده مي‌شود كه افزايش نيروي محوري پيشران تا يك حد بهينه، موجب افزايش نرخ نفوذ مي‌شود و پس از آن با افزايش نيروي پيشران نرخ نفوذ كاهش مي‌يابد. در نيروي پيشران بيش از مقدار بهينه، احتمال گيركردن ديسك‌ها و در نتيجه كاهش نرخ نفوذ افزايش مي‌يابد. از طرف ديگر مشاهده مي‌شود كه روند تغييرات در منحني‌ها يكسان است و با افزايش مقدار گشتاور، مقدار بهينه‌ي نيروي پيشران افزايش مي‌يابد. بنابراين براي رسيدن به نرخ نفوذ بيشينه، مقدار گشتاور و نيروي پيشران بايد بطور متناسبي انتخاب شود. همچنين در يك نيروي پيشران يكسان در محدوده‌ي كمتر از شرايط بهينه‌ي نرخ نفوذ، گشتاور كمتر سبب نرخ نفوذ بيش‌تري مي‌شود. در ناحيه‌ي پس از محدوده‌ي بهينه، گشتاور بيش‌تر، نرخ نفوذ بالاتري را نتيجه مي‌دهد.

جدول 6- مشخصات مقطع سنگي در تحليل حساسيت

مشخصات	مقدار
نوع سنگ	متوسط تا ضخيم لايه
مقاومت فشاري تك محوري (***MPa***)	125
درصد كوارتز	0/5
مقاومت كششي برزيلي (***MPa***)	4/25
RQD (%)	85
RMR	57

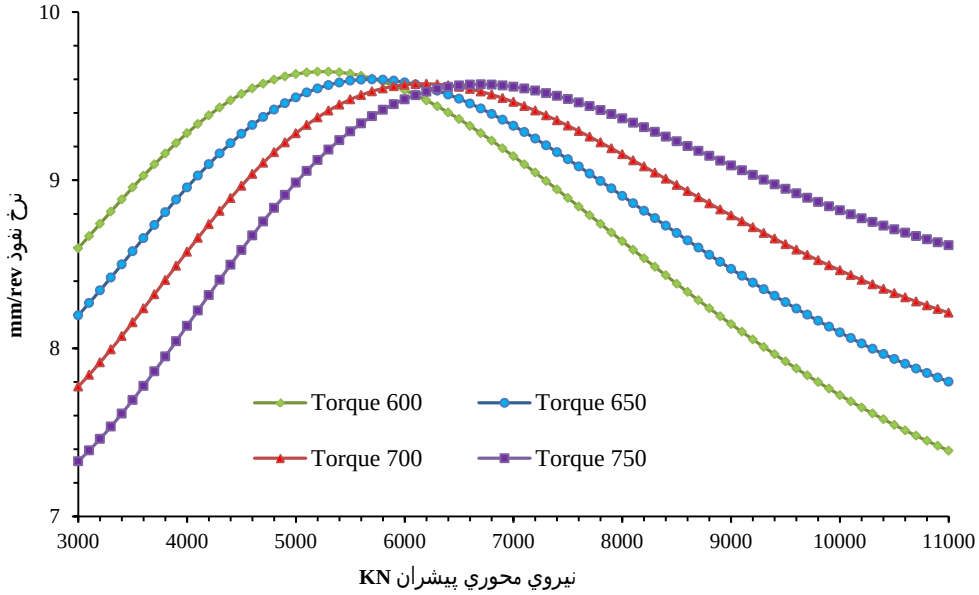

شكل 7- نرخ نفوذ در مقابل نيروي پيشران حاصل از تحليل حساسيت

روند ياد شده به منظور تحليل حساسيت نيروي پيشران، براي پارامتر گشتاور نيز در همان مقطع سنگي تكرار و مقادير نرخ نفوذ پيش‌بيني شده با شبكه‌ي عصبي در مقابل تغييرات گشتاور در شكل 8 رسم شده است. با توجه به شكل، مشاهده مي‌شود كه مقدار گشتاور نيز همانند نيروي پيشران در يك حد بهينه موجب افزايش نرخ نفوذ مي‌شود. همچنين مشاهده مي‌شود كه روند تغييرات در منحني‌ها يكسان است و با افزايش مقدار نيروي پيشران، مقدار بهينه‌ي گشتاور افزايش مي‌يابد. همچنين در يك گشتاور يكسان در محدوده‌ي كمتر از شرايط بهينه‌ي نرخ نفوذ، نيروي پيشران كمتر سبب نرخ نفوذ بيش‌تر مي‌شود و در ناحيه‌ي پس از محدوده‌ي بهينه، نيروي پيشران بيش‌تر نرخ نفوذ بالاتري را نتيجه مي‌دهد. با توجه به تحليل حساسيت انجام شده، مي‌توان نتيجه گرفت كه به منظور دستيابي به نرخ نفوذ قابل قبول در اين مقطع سنگي، بهتر است از زوج نيروي پيشران و گشتاور بهينه استفاده شود. به عبارت ديگر به منظور دستيابي به نرخ نفوذ مطلوب‌تر بايد اين دو پارامتر به صورت هماهنگ با يكديگر تغيير نمايند.

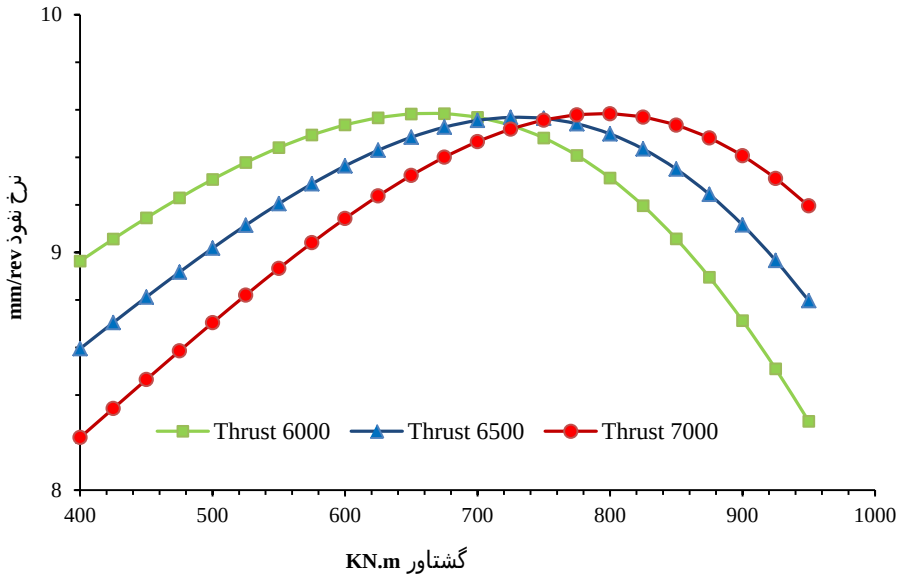

شكل 8 - تحليل حساسيت نرخ نفوذ در مقابل نيروي پيشران

5- نتيجه‌گيري

با توجه به اهميت نرخ نفوذ در عمليات حفاري، محققان مختلفي با روش‌هاي متعدد تجربي و تئوري به پيش‌بيني اين پارامتر پرداخته‌اند. با توجه به پيچيدگي ارتباط بين نرخ نفوذ و پارامترهاي موثر آن و همچنين توانايي روش شبكه‌هاي عصبي مصنوعي در چنين مسائلي، در سال‌هاي اخير تلاش‌هايي به منظور پيش‌بيني اين پارامتر با استفاده از اين روش انجام شده است. مطالعاتي كه پيش از اين با روش شبكه‌هاي عصبي مصنوعي صورت گرفته است، نشان‌دهنده‌ي قابليت اين روش در پيش‌بيني نرخ نفوذ است. در اين مطالعات، در هر مقطع سنگي تنها يك نرخ نفوذ در نظر گرفته شده است؛ در صورتي‌كه در هر سيكل حفاري به دليل پارامترهاي متفاوت ماشين، نرخ نفوذ متفاوتي بدست مي‌آيد.

با توجه توضيحات فوق، در اين مقاله به بررسي اثر پارامترهاي ماشين بر نرخ نفوذ با استفاده از روش شبكه‌هاي عصبي مصنوعي پرداخته شده است. به منظور تحليل با روش شبكه‌هاي عصبي مصنوعي، شبكه‌هاي زيادي با ساختارهاي متفاوت با در نظر گرفتن يك و دو لايه‌ي مياني و همچنين تعداد نرون‌هاي متفاوت در لايه‌ها ساخته شده است. در نهايت شبكه‌اي با يك لايه‌ي مياني، 9 پارامتر ورودي متشكل از پارامترهاي مربوط به سنگ بكر،

توده‌سنگ و پارامترهاي اجرايي ماشين و 8 نرون در لايه‌ي مياني و پارامتر نرخ نفوذ در لايه‌ي خروجي به عنوان شبكه‌ي بهينه براي پيش‌بيني نرخ نفوذ انتخاب شده است.

به منظور اطمينان از انتخاب شبكه‌ي بهينه، بار ديگر اين شبكه با استفاده از مجموعه‌ي آزمون جديدي كه در بانك اطلاعاتي مربوط به ساخت شبكه وجود نداشته، مورد بررسي قرار گرفته است. ضريب تطبيق 79 درصد بين مقادير پيش‌بيني شده و واقعي در اين مجموعه نشان‌دهنده‌ي صحت انتخاب شبكه‌ي بهينه است.

پس از ايجاد شبكه‌ي بهينه براي پيش‌بيني، مي‌توان به تحليل حساسيت بر روي پارامترهاي ورودي پرداخت. در اين مطالعه به كمك شبكه‌ي بهينه به تحليل حساسيت بر روي پارامترهاي نيروي محوري پيشران و گشتاور پرداخته شده است. نتايج تحليل‌ها نشان مي‌دهد كه افزايش نيروي محوري پيشران تا يك حد بهينه، سبب افزايش نرخ نفوذ مي‌شود. پس از آن با افزايش نيروي پيشران، مقدار نرخ نفوذ كاهش مي‌يابد. در مقادير نيروي پيشران بيش از حد بهينه، براي دستيابي به نرخ نفوذ بيش‌تر، گشتاور نيز بايد افزايش يابد. تحليل حساسيت بر روي گشتاور نيز روندي مشابه با نيروي پيشران را نشان مي‌دهد. با افزايش مقدار نيروي پيشران، مقدار بهينه‌ي گشتاور افزايش مي‌يابد. بنابراين تنها يك زوج نيروي پيشران و گشتاور خاص منجر به نرخ نفوذ حداكثر نمي‌شود؛ بلكه اين دو عامل در يك محدوده‌ي بهينه، نرخ نفوذ را افزايش مي‌دهند. به منظور دستيابي به نرخ نفوذ حداكثر مي‌توان از زوج نيروي محوري پيشران و گشتاور بهينه استفاده نمود.

در اين پژوهش برآورد مقدار بهينه‌ي نيروي محوري پيشران و گشتاور *TBM* با استفاده از روش شبكه‌هاي عصبي مصنوعي انجام شده است؛ ولي امكان انجام مطالعه‌ي مشابه با استفاده از روش‌هاي ديگر بهينه‌سازي مانند روش‌هاي ابتكاري (*Heuristic*) وجود دارد. انجام اين پژوهش، برنامه‌ي آتي مطالعات نويسندگان اين مقاله است.

6- منبع‌ها

[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.

[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.

[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.

[14] منهاج، م .ب. (1391). *مباني شبكه‌هاي عصبي*. تهران، ايران: انتشارات دانشگاه صنعتي اميركبير. شابك: 9789644630873.

[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.

[16] ياوري، ش. م.، و مهدوري، س. (1385). پيش‌بيني نرخ نفوذ ماشين‌هاي تونل‌بري با استفاده از شبكه‌ي عصبي. *نشريه‌ي دانشكده‌ي فني، دانشگاه تهران، 40(1)*، 115-121.

[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.

[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.

[21] مهندسين مشاور ساحل. (1386). *مطالعات زمين‌شناسي مهندسي مسير تونل*. گزارش شماره‌ي 2026.

[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.

[23] مهدوري، س. (1382). *پيش‌بيني ضريب بهروري TBMهاي بار*. تهران، ايران: پايان‌نامه‌ي كارشناسي ارشد، دانشگاه تهران.

[24] كيا، م. (1389). *شبكه‌هاي عصبي در MATLAB*. تهران، ايران: خدمات نشر كيان رايانه سبز. شابك: 9786005237009.

[25] افتخاري، س. م. (1389). *تحليل عددي تاثير پارامترهاي هندسي شكستگي‌هاي منفصل بر نرخ نفوذ دستگاه TBM در توده‌سنگ شكسته-مطالعه‌ي موردي تونل بلند زاگرس*. اصفهان، ايران: پايان‌نامه‌ي كارشناسي ارشد، دانشگاه صنعتي 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.

[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 Hystereses 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). Kolmogrov'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.