

مقاله پژوهشی

پیش‌بینی نرخ نفوذ ماشین تونل‌زنی با استفاده از دسته بندی گروهی داده‌های شبکه عصبی

آلان شوکتی<sup>۱\*</sup>، بهمن احمدی<sup>۲</sup>، کیارش نصری<sup>۳</sup>

۱. استادیار گروه مهندسی معدن، دانشکده مهندسی، دانشگاه کردستان، سنندج، a.showkati@uok.ac.ir

۲. استادیار گروه مهندسی مکانیک، دانشکده مهندسی، دانشگاه کردستان، سنندج، b.ahmadi@uok.ac.ir

۳. دانشجوی کارشناسی ارشد مکانیک سنگ، دانشکده مهندسی معدن، دانشگاه فنی، دانشگاه تهران، kiarash.nasri@ut.ac.ir

دریافت: ۱۴۰۱/۰۸/۱۲ - پذیرش: ۱۴۰۲/۰۱/۱۴

چکیده

پیش‌بینی نرخ نفوذ ماشین حفر تونل (TBM) در سنگ‌های سخت از مهم‌ترین عوامل تاثیرگذار در برآورد هزینه و زمان اتمام حفاری تونل است. در این پژوهش از شبکه عصبی دسته‌بندی گروهی داده‌ها (GMDH) برای پیش‌بینی نرخ نفوذ ماشین حفاری در قطعه جنوبی تونل انتقال آب کرمان استفاده شده است. پس از تشکیل پایگاه داده با استفاده از اطلاعات ژئومکانیکی توده‌سنگ و داده‌های عملکرد واقعی ماشین حفاری، ابتدا با انجام رگرسیون چندمتغیره خطی و غیرخطی همبستگی بین ده پارامتر مختلف بررسی شده و روابط تجربی برای پیش‌بینی نرخ نفوذ ماشین توسعه داده شد. برای طراحی بهینه ساختار شبکه عصبی از الگوریتم ژنتیک چند هدفی در قالب بهینه‌سازی دو هدفی استفاده شد به طوری که داده‌های ورودی به دو دسته آموزش (۷۰ درصد داده‌ها) و پیش‌بینی (۳۰ درصد داده‌ها) تقسیم و خطای آموزش و خطای پیش‌بینی نیز به عنوان دو تابع هدف انتخاب شد. پس از تعیین ساختار بهینه شبکه، تابع نرخ نفوذ ماشین حفاری به صورت چند جمله‌ای‌های چند لایه بر حسب چهار پارامتر با قویترین همبستگی با نرخ نفوذ یعنی مقاومت فشاری توده‌سنگ، محتوای کوارتز، زاویه صفحات ناپیوستگی با راستای تونل و نیروی قائم‌اعمالی بر هر تیغه برش ارائه شد. در این مقاله از پارامتر ترکیبی مقاومت فشاری توده‌سنگ استفاده شد که ضمن کاهش تعداد پارامترهای دخیل در مدل، منجر به ساده‌تر شدن آن شد. مقایسه مقادیر خروجی مدل پیش‌بینی نرخ نفوذ با مقادیر اندازه‌گیری شده ضریب همبستگی بالایی برابر ۰/۸۱ بدست می‌دهد (ضریب ضریب همبستگی در مدل رگرسیون غیرخطی ۰/۶ است) که نشان‌دهنده قابلیت پیش‌بینی بسیار خوب این شبکه است. بر خلاف سایر شبکه‌های عصبی که خروجی آن‌ها اغلب به صورت جعبه سیاه است، در مدل پیشنهادی خروجی نهایی به صورت تابع بازگشتی صریح بین ورودی‌ها و خروجی ارائه شد. این ویژگی منحصر به فرد شبکه عصبی GMDH امکان استفاده مستقیم از روابط ارائه شده در سایر پروژه‌ها و یا تحقیقات آینده را فراهم می‌سازد.

کلمات کلیدی

دسته‌بندی گروهی داده‌ها، نرخ نفوذ، مدل پیش‌بینی، شبکه عصبی، تونل انتقال آب کرمان

## ۱- مقدمه

TBM محسوب می‌شوند که در دو دهه اخیر به طور گسترده‌ای مورد توجه قرار گرفته‌اند [۱۱، ۱۵-۲۳]. در این مدل‌ها، روش‌های متنوع محاسبات نرم<sup>۲</sup> از جمله شبکه عصبی مصنوعی (ANN) [۱۶-۱۷]، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) [۱۱، ۱۵]، منطق فازی (FL) [۷، ۱۸، ۲۴]، بهینه‌سازی ازدحام ذرات (PSO) [۲۵]، الگوریتم تکامل تفاضلی (DE) [۲۰] و ماشین بردار پشتیبان (SVM) [۱۱، ۱۹] به طور موفقیت‌آمیزی برای پیش‌بینی عملکرد TBM به کار رفته‌اند. نتایج حاصل از این مطالعات اغلب برنامه‌هایی به صورت "جعبه سیاه" است که درجه همبستگی بالایی بین مقادیر پیش‌بینی شده و واقعی عملکرد ماشین حفاری نشان می‌دهد. به عبارت دیگر، در این روش‌ها هیچگونه تابع صریحی بین ورودی و خروجی ارائه نمی‌شود که این ویژگی باعث عدم امکان استفاده از آن‌ها در پروژه‌های دیگر می‌شود.

در سال‌های اخیر، الگوریتم‌های یادگیری عمیق<sup>۳</sup> مبتنی بر ادغام روش‌های شبکه عصبی مصنوعی و الگوریتم‌های تکاملی<sup>۴</sup>، منجر به ایجاد محیطی جذاب و موثر در مدلسازی و پیش‌بینی سیستم‌های پیچیده مبتنی بر داده شده است [۳۰-۲۶]. روش دسته‌بندی گروهی داده‌ها<sup>۵</sup> یا GMDH یک فناوری آموزش آماری شبکه‌ای است که حاصل تحقیقات سیبرنیتیکی شامل سیستم‌های خودسامانده، نظریه اطلاعات و علم کامپیوتر است [۳۱]. الگوریتم GMDH برای مدلسازی سیستم‌های پیچیده، انجام پیش‌بینی، شناسایی الگو، تشخیص و خوشه‌بندی داده‌ها کاربرد‌های فراوانی دارد [۳۲]. شبکه‌های عصبی GMDH، جلوه‌ای از الگوریتم GMDH است که به فرم و سبک ساختار شبکه‌ای بیان شده‌اند. استفاده از شبکه‌های عصبی در پیاده‌سازی الگوریتم GMDH باعث انعطاف‌پذیری و بهینه‌سازی آن، به واسطه به وجود آمدن ساختارهای شبکه‌ای متفاوت و همچنین زمینه‌ای برای سهولت در ایجاد نرم‌افزار کامپیوتری شده است [۳۳].

در سایر شبکه‌های عصبی رابطه بین ورودی و خروجی معمولاً به صورت یک جعبه سیاه است که به هیچ وجه قابلیت ارزیابی صریح را فراهم نمی‌کند. ویژگی اصلی بسیار مهم شبکه عصبی GMDH که آن را از سایر روش‌های فرامکاشف‌های<sup>۶</sup> متمایز می‌سازد توانایی ارائه یک تابع بازگشتی صریح به صورت چند جمله‌ای‌های چند لایه است که قابلیت گزارش و استفاده

تونل‌سازی مکانیزه در سنگ‌های سخت به دلیل نرخ بالای پیشروی و سابقه ایمنی خوبی که در چند دهه اخیر کسب کرده است، به طور گسترده‌ای در سراسر جهان در اجرای پروژه‌های مختلف مورد استفاده قرار می‌گیرد. هزینه کلی اجرای چنین پروژه‌هایی به طور قابل توجهی تحت تاثیر زمان اتمام حفاری و ساخت تونل قرار دارد. بنابراین، پیش‌بینی عملکرد ماشین حفار TBM از مهم‌ترین چالش‌های پیش‌رو در مراحل آغازین یک پروژه تونلسازی است که در آن علاوه بر برنامه‌ریزی زمانی و برآورد هزینه، امکان‌سنجی بکارگیری حفاری مکانیزه نیز مورد ارزیابی قرار می‌گیرد. از این رو، روش‌های پیش‌بینی متعددی همچون مدل‌های نیمه‌نظری [۱-۴]، مدل‌های تجربی [۵-۱۴] و مدل‌های مبتنی بر کامپیوتر یا هوش مصنوعی<sup>۱</sup> [۱۵-۲۳] در این خصوص توسعه پیدا کرده‌اند.

روش‌های نیمه‌نظری با تحلیل نیروهای وارد بر تیغه برش و بهره‌گیری از نتایج آزمون‌های آزمایشگاهی سعی در یافتن روابط تعادل نیرو در حین برش سنگ را دارند [۱۱]. ضعف اصلی روش‌های نظری معرف نبودن شرایط آزمایشگاه با شرایط واقعی توده‌سنگ است که همین امر کاربرد این روش‌ها را تا حد زیادی محدود کرده است. همچنین، در برخی از این روش‌ها همانند روش [۲NTNU، ۴] پارامترهایی به کار رفته که تعیین آن‌ها فقط در چند آزمایشگاه خاص امکانپذیر است. در مدل‌های تجربی از همبستگی داده‌های اندازه‌گیری شده سنگ (همانند مقاومت فشاری تک محوره، مقاومت کششی، محتوای کوارتز، درجه شکستگی و نظایر آن) [۸، ۱۱-۱۳] و همچنین سیستم‌های طبقه‌بندی توده‌سنگ همانند RMR، Q و GSI [۵-۷، ۹-۱۰، ۱۲، ۱۴] با پارامترهای عملکرد واقعی ماشین حفار که در پروژه‌های مختلف تونلسازی ثبت شده‌اند، استفاده می‌شود. تحلیل‌های رگرسیون یک یا چندمتغیره خطی و غیرخطی [۶، ۸، ۱۱-۱۲] از جمله روش‌های متداول در توسعه مدل‌های تجربی است. با وجود تطابق خوب پیش‌بینی مدل‌های تجربی با واقعیت، همبستگی نتایج آن‌ها به شدت محدود به پروژه مورد مطالعه است و به ندرت می‌توان از این مدل‌ها برای دیگر پروژه‌های با شرایط زمین‌شناسی متفاوت استفاده کرد [۱۲].

روش‌های هوش مصنوعی که انعطاف‌پذیری ذاتی بالایی برای تخمین و حل مسایل پیچیده و غیرخطی مهندسی دارند، ابزارهای قدرتمندی در زمینه پیش‌بینی عملکرد ماشین حفاری

<sup>۱</sup> Artificial Intelligence (AI)

<sup>۲</sup> Soft computing methods

<sup>۳</sup> Deep learning

<sup>۴</sup> Evolutionary algorithms

<sup>۵</sup> Group method of data handing

<sup>۶</sup> Meta-heuristics

مجدد در تحقیقات آینده را فراهم می‌کند.

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (4)$$

مبنای ریاضی الگوریتم GMDH بر اساس تجزیه سری توابع ولترا به چند جمله‌ای‌های دو متغیره درجه دوم پایه‌ریزی شده است (رابطه ۵) [۳۱].

$$\bar{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (5)$$

در این تجزیه، سری ولترا به مجموعه‌ای از روابط بازگشتی زنجیره‌ای به صورت رابطه ۵ تبدیل می‌شود، به گونه‌ای که مجدد با جای‌گذاری جبری هر یک از روابط بازگشتی در یکدیگر و با هدف ارضا رابطه ۳، این رابطه (سری ولترا) برقرار می‌شود. برای کمینه‌سازی اختلاف بین خروجی‌های تقریب‌زده شده  $\bar{y}$  و خروجی‌های واقعی  $y$ ، لازم است از روش‌های رگرسیون برای محاسبه ضرایب  $a_i$  در رابطه ۵ استفاده شود. به عبارت دیگر، ضرایب هر یک از روابط درجه دو  $G_i$  به گونه‌ای تعیین می‌شوند که خطای خروجی تقریب زده شده به ازای تمام نمونه داده‌های ورودی-خروجی کمینه شود (رابطه ۶) [۳۳]:

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \quad (6)$$

در الگوریتم اصلی GMDH، برای ساخت چند جمله‌ای رابطه ۵ که بتواند بهینگی مجموع حداقل مربعات را به ازای نمونه‌ها  $\{y_i, (i = 1, 2, \dots, M)\}$  تضمین کند، تمام انتخاب‌های ممکن دو متغیر ورودی از مجموع  $n$  متغیر ورودی در نظر گرفته می‌شود. در نتیجه، تعداد  $\binom{n}{2}$  نرون در اولین لایه پنهان شبکه عصبی از نمونه‌های  $\{y_i, x_{ip}, x_{iq}; (i = 1, 2, \dots, M)\}$  که  $p, q \in \{1, 2, \dots, n\}$  تولید می‌شود. تعداد  $M$  دسته داده سه‌تایی  $\{y_i, x_{ip}, x_{iq}; (i = 1, 2, \dots, M)\}$  از بین تمام نمونه‌ها  $p, q \in \{1, 2, \dots, n\}$  به شکل رابطه ۷ ایجاد می‌شود:

$$A = \begin{bmatrix} x_{1p} & x_{1q} & \vdots & y_1 \\ x_{2p} & x_{2q} & \vdots & y_2 \\ \dots & \dots & \vdots & \dots \\ x_{Mp} & x_{Mq} & \vdots & y_M \end{bmatrix} \quad (7)$$

با استفاده از چند جمله‌ای درجه دوم رابطه ۵ به ازای هر ردیف از  $M$  دسته داده سه‌تایی، می‌توان رابطه ماتریسی به صورت رابطه ۸ بدست آورد:

در تحقیق حاضر، با طراحی شبکه عصبی و پیاده‌سازی الگوریتم GMDH، نرخ نفوذ ماشین حفاری TBM در قطعه جنوبی تونل انتقال آب کرمان به طول ۵ کیلومتر (به عنوان مطالعه موردی) پیش‌بینی شده است. برای طراحی بهینه ساختار شبکه عصبی از الگوریتم ژنتیک (GA) چند هدفی<sup>۱</sup> در قالب بهینه‌سازی دوهدفی استفاده شده است. در نهایت پس از تعیین ساختار بهینه شبکه GMDH، تابع نرخ نفوذ ماشین حفاری ارایه شده است. همچنین، برای ارزیابی کارایی شبکه عصبی GMDH در پیش‌بینی نرخ نفوذ، نتایج حاصل با روش‌های تحلیل رگرسیون خطی و غیرخطی مقایسه شده است. از ویژگی‌های بارز این پژوهش ارایه تابع صریح نرخ نفوذ ماشین به صورت چند جمله‌ای‌های چند لایه است که امکان استفاده مجدد از آن را در پروژه‌های با شرایط زمین‌شناسی و ژئومکانیکی مشابه و نیز تحقیقات آینده فراهم می‌سازد.

## ۲- ساختار شبکه عصبی GMDH

ساختار کلی مساله رگرسیون در شبکه عصبی به صورت یافتن تابع  $\bar{f}$  به عنوان جایگزینی برای تابع  $f$  تعریف می‌شود، با این هدف که خروجی  $\bar{y}$  را به صورت تابعی از متغیرهای ورودی  $X = (x_1, x_2, \dots, x_n)$  پیش‌بینی کند که تا حد ممکن به خروجی واقعی  $y$  نزدیک باشد. با فرض داشتن  $M$  نمونه شامل چند متغیر ورودی و یک متغیر خروجی به صورت رابطه ۱

$$y = f(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (1)$$

می‌توان یک شبکه عصبی GMDH آموزش داد به طوری که مقادیر خروجی  $\bar{y}$  را به ازای هر مجموعه ورودی  $X = (x_{i1}, x_{i2}, \dots, x_{in})$  تقریب بزند (رابطه ۲):

$$\bar{y}_i = \bar{f}(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (2)$$

در این حالت، هدف ساختن یک مدل شبکه عصبی GMDH است که در آن مربع خطا بین مقادیر خروجی تقریب زده شده و مقادیر خروجی واقعی کمینه شود (رابطه ۳):

$$\sum_{i=1}^M |\bar{f}(x_{i1}, x_{i2}, \dots, x_{in}) - y_i|^2 \rightarrow \min \quad (3)$$

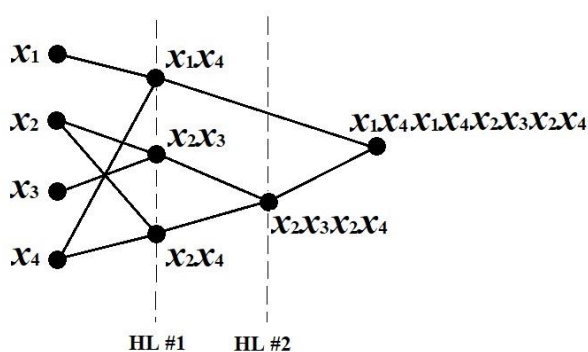
بطور کلی، ارتباط بین متغیرهای ورودی و مقادیر خروجی را می‌توان به صورت یک نمایش پیچیده از سری‌های تابعی ولترا<sup>۲</sup> به شکل رابطه ۴ بیان کرد:

<sup>1</sup> Multi-objective

<sup>2</sup> Volterra functional series

می‌یابد. برای ساخت و بهینه‌سازی شبکه عصبی GS-GMDH در این تحقیق، از روش کدگذاری کروموزوم پیشنهاد شده در مرجع [۳۳] استفاده شده است.


در شکل ۱، نرون  $x_1x_4$  در اولین لایه پنهان با جهش از روی لایه پنهان دوم، به طور مستقیم به خروجی متصل می‌شود. بنابراین مشاهده می‌شود که نرون  $x_1x_4$  دو بار در نامگذاری خروجی شبکه  $x_1x_4x_1x_4x_2x_3x_2x_4$  ظاهر می‌شود. در حقیقت، نرون مجازی  $x_1x_4$  در لایه پنهان دوم ساخته شده و پس از ترکیب با نرون  $x_2x_3x_2x_4$  در همان لایه، نرون خروجی ترکیب  $x_1x_4x_1x_4x_2x_3x_2x_4$  را می‌سازد. به طور کلی، چنین عملیاتی هر بار که یک نرون از روی یک لایه پنهان جهش می‌کند در ترکیب با نرون موجود در لایه پنهان بعدی، اتفاق می‌افتد.



شکل ۱- ساختار کروموزوم شبکه عصبی از نوع GS-GMDH

### ۳- تونل مورد مطالعه

تونل انتقال آب کرمان با طول حدود ۳۸ کیلومتر یکی از پروژه‌های بسیار مهم انتقال آب در ایران است که از جنوب روستای گنجان در شمال غربی حوزه آبریز جازموریان آغاز و تا غرب روستای گلزار در نواحی جنوبی شهر کرمان ادامه می‌یابد. این تونل به قطر ۵/۲۸ متر و با امتداد تقریبی شمالی- جنوبی برای انتقال آب شرب با شدت جریان حدود ۲۲ مترمکعب در ثانیه از سد صفارود به شهر کرمان طراحی شده است. ارتفاع متوسط منطقه از سطح دریا ۱۷۶۰ متر و حداکثر روباره تونل ۹۴۰ متر است که در بخش‌های مرکزی مسیر تونل واقع شده است [۳۴].



شکل ۲- نیمرخ طولی زمین‌شناسی قطعه جنوبی مسیر تونل انتقال آب کرمان [۳۴]

$$Aa = Y \quad (8)$$

که در آن  $a = \{a_0, a_1, a_2, a_3, a_4, a_5\}$ ، بیانگر بردار ضرایب مجهول در رابطه ۵ و  $Y = \{y_1, y_2, \dots, y_M\}^T$  بردار مقادیر خروجی واقعی است. بنابراین رابطه ماتریسی ۸ را می‌توان به صورت رابطه ۹ بازنویسی کرد:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (9)$$

برای تعیین بردار ضرایب بهینه در رابطه ۵ مربوط به تمامی  $M$  دسته داده سه‌تایی، می‌توان از روش حداقل مربعات در تحلیل رگرسیون چندگانه (رابطه ۱۰) استفاده کرد:

$$a = (A^T A)^{-1} A^T Y \quad (10)$$

متناظر با ساختار و هم‌بندی شبکه، روند فوق برای هر نرون در لایه پنهان بعدی تکرار می‌شود. در نهایت، روش تجزیه مقادیر منفرد (SVD) در ترکیب با الگوریتم ژنتیک چند هدفی برای طراحی بهینه همزمان هم‌بندی شبکه عصبی GMDH و ضرایب چند جمله‌ای‌های درجه دوم موجود در آن اعمال می‌شود. تجزیه مقادیر منفرد روشی است برای حل مسایل کمترین مربعات که در آن‌ها احتمال بروز تکنیکی وجود دارد. به کار بردن روش تجزیه مقادیر منفرد در ساختار الگوریتم GMDH کار جدیدی است که در این روش پایه‌ریزی شده و نیز عاملی برای بهینه‌سازی این الگوریتم به شمار می‌آید [۳۲].

در این پژوهش، از شبکه‌های عصبی GMDH با ساختار عمومی (GS-GMDH) برای تخمین و پیش‌بینی سیستم داده‌های ورودی- خروجی استفاده شده است. بر خلاف شبکه‌های عصبی GMDH با ساختار مرسوم (CS-GMDH) که در آن برای ساخت نرون‌ها در لایه جدید تنها از نرون‌های لایه مجاور استفاده می‌کند، در شبکه‌های عصبی با ساختار عمومی برای ساخت نرون در لایه جدید از نرون‌ها در تمامی لایه‌های قبلی استفاده می‌کنند. با توجه به ساختار تعمیم‌یافته شبکه عصبی GS-GMDH، کارایی این نوع شبکه‌ها در مدلسازی سیستم‌های پیچیده واقعی به طور قابل ملاحظه‌ای بهبود

جدول ۱- مشخصات ژئومکانیکی واحدهای سنگی مسیر تونل [۳۴]

| ABDI | q (%) | GSI   | RQD (%) | $\sigma_t$ (MPa) | $\sigma_{ci}$ (MPa) | کیلومتر از      | واحد سنگی |
|------|-------|-------|---------|------------------|---------------------|-----------------|-----------|
| ۲۵۰  | ۰     | ۴۵-۵۵ | ۵۰-۷۰   | ۲-۸              | ۱۰۰-۵۰              | (۰۰۰+۰)-(۲۷۰+۰) | RT1'      |
| ۱۳۴۰ | ۲۰    | ۶۰    | ۷۰-۹۰   | ۱۲-۱۶            | ۱۸۰-۱۵۰             | (۲۷۰+۰)-(۶۲۵+۰) | RT2'      |
| ۱۱۸۰ | ۲۰    | ۶۰    | ۵۰-۷۰   | ۱۱-۱۷            | ۱۶۰-۱۴۰             | (۶۲۵+۰)-(۴۱۰+۱) | RT3'      |
| ۱۰۸۰ | ۳۰    | ۵۵-۶۰ | ۵۰-۷۰   | ۸/۵-۱۵/۵         | ۱۴۰-۱۳۰             | (۴۱۰+۱)-(۶۵۶+۱) | RT4'      |
| ۹۹۰  | ۲۵    | ۶۰    | ۷۰-۹۰   | ۱۱-۱۷            | ۱۳۰-۱۱۰             | (۸۳۱+۱)-(۱۰۴+۲) | RT5'      |
| ۱۷۲۵ | ۳۵    | ۶۵    | ۶۰-۸۰   | ۱۷-۲۳            | ۲۲۰-۱۸۰             | (۱۰۴+۲)-(۹۹۶+۴) | RT6'      |

$\sigma_{ci}$ : مقاومت فشاری تک محوری سنگ بکر،  $\sigma_t$ : مقاومت کششی سنگ بکر، RQD: شاخص کیفیت سنگ، GSI: شاخص مقاومت زمین‌شناسی q: محتوای کوارتز، ABI: شاخص سایش

سطح درزه زبر و بازشدگی عمدتاً کمتر از ۲/۵ میلی‌متر است. این شرایط در سنگ‌های واحد RT5' نیز مشاهده شده با این تفاوت که میزان شیب اکثر درزه‌ها در محدوده ۶۰ تا ۹۰ درجه است.

### ۳-۲- مشخصات ماشین حفاری TBM

ماشین حفاری TBM مورد استفاده در قطعه جنوبی تونل انتقال آب کرمان از نوع سپر دوتایی ساخت شرکت هرنکنشت آلمان است که قابلیت اعمال نیروی پیشران حداکثر ۲۰۰۰۰ کیلو نیوتن را دارد و برای کار در شرایط سنگ سخت طراحی شده است [۳۵]. این ماشین دارای ۳۷ تیغه برشی به قطر هر تیغه ۴۳۲ میلی‌متر (۱۷ اینچ) است که در فواصل میانگین ۷۲ میلی‌متر قرار گرفته‌اند.

### ۳-۳- ایجاد پایگاه داده‌های عملکرد TBM

واحدهای زمین‌شناسی مهندسی در مسیر تونل انتقال آب کرمان بر اساس ویژگی‌های فیزیکی و مکانیکی واحدهای سنگ‌شناسی و چینه‌شناسی معرفی شده در مطالعات زمین‌شناسی تفکیک شدند [۳۴]. برای ویژگی‌سنجی توده‌سنگ در هر یک از واحدهای زمین‌شناسی از روش‌های مختلفی از جمله بازدیدهای صحرایی، مطالعات درزه‌نگاری و نیز برداشت نمونه‌های سطحی و مغزه‌گیری (حفر گمانه‌ها) برای انجام آزمایش‌های مکانیک سنگی، زمین‌شناسی مهندسی و هیدروژئولوژیکی مورد نیاز استفاده شده است. در جدول ۱ مشخصات ژئومکانیکی واحدهای مختلف سنگی در قطعه جنوبی تونل برگرفته از مرجع [۳۴] آورده شده است.

برای تحلیل عملکرد و توسعه روابط به منظور پیش‌بینی نرخ نفوذ ماشین حفاری (ROP) که به صورت میزان نفوذ تیغه برش در سنگ در هر دور چرخش کله حفاری تعریف

برای کاهش زمان ساخت، تونل یاد شده به دو قطعه شمالی و جنوبی با طول تقریباً مساوی تقسیم شده که با استفاده از دو ماشین TBM در حال حفاری است. در تجزیه و تحلیل‌های این پژوهش تنها از داده‌های مربوط به ۵۰۰۰ متر ابتدایی قطعه جنوبی که در دسترس بوده استفاده می‌شود.

### ۳-۱- واحدهای زمین‌شناسی مسیر تونل

ساختگاه تونل از دیدگاه تقسیمات زمین‌شناسی در فلات ایران مرکزی و در کمربند ماگمایی ارومیه-دختر واقع شده است. به دلیل فعالیت‌های آتشفشانی دوران ائوسن، مجموعه‌ای از سنگ‌های رسوبی تا آذرین در این ناحیه قابل مشاهده است. واحدهای سنگی قطعه جنوبی مسیر تونل که در این تحقیق مورد بررسی قرار می‌گیرد، عمدتاً از نوع آهک، ماسه و کنگلومرای آهکی (RT1')، آندزیت لیتیک توف (RT2')، آندزیت پیروکلاستیک (RT3')، آندزیت بازالت (RT4')، لاوا پیروکلاست (RT5') و دیوریت (RT6') است که با گسل‌های اغلب دارای روند شرقی-غربی، شمال غرب-جنوب شرق و شمال شرق-جنوب غرب قطع شده‌اند. جزییات بیشتر زمین‌شناسی مسیر تونل در نیمرخ طولی شکل ۲ آورده شده است [۳۴]. ملاحظه می‌شود که از واحد RT1' که از نوع رسوبی است، جنس سایر واحدهای سنگی مسیر تونل از نوع آذرین سخت است و همگی دارای مقاومت فشاری تک محوری بیش از ۱۰۰ و تا بیش از ۲۰۰ مگاپاسکال در برخی واحدها (RT6') است (جدول ۱).

همچنین، شرایط درزه‌داری توده‌سنگ به گونه‌ای است که واحدهای سنگی بر اساس اندیس مقاومت زمین‌شناسی (GSI) به دو دسته بلوکی (RT2' تا RT6') و بسیار بلوکی (RT1') تقسیم‌بندی می‌شوند. در واحدهای RT1' و RT3' غالب درزه‌ها به شکل صفحه‌ای با شیب غالب ۳۰ تا ۶۰ درجه با

می‌شود، علاوه بر شرایط زمین‌شناسی و ویژگی‌های ژئومکانیکی توده‌سنگ، دست‌یابی به پارامترهای واقعی ماشین و عملکرد آن ضروری است. از این رو، پایگاه داده‌های جامعی شامل اطلاعات زمین‌شناسی مهندسی و مکانیکی توده‌سنگ واحدهای مسیر تونل و پارامترهای عملیاتی ماشین همچون میزان نفوذ و زمان حفاری، مقدار نیروی پیشران، تعداد چرخش کله حفاری در دقیقه، گشتاور و توان ماشین تهیه شد. برای ایجاد پایگاه داده‌ها پس از استخراج و محاسبه مقادیر پارامترهای زمین‌شناسی مهندسی و مکانیک سنگی برای هر واحد سنگ‌شناسی در مسیر تونل، پارامترهای راهبردی واقعی ماشین بر مبنای داده‌های ثبت شده در مقاطع مختلف محاسبه شد، سپس برای هر داده ثبت شده از عملکرد ماشین در مسیر تونل، اطلاعات زمین‌شناسی مهندسی و ژئومکانیکی توده‌سنگ مربوط به آن مقطع تخصیص داده شده و در صفحه گسترده Excel تنظیم شد. در این پایگاه ایجاد شده صرفاً از اطلاعات مقطعی از مسیر تونل با شرایط عادی زمین‌شناسی [۱۴] استفاده شد و داده‌های مربوط به مقاطع گسلی، شرایط هجوم آب و خراب شدن ماشین از پایگاه داده‌ها حذف شد.

$$\sigma_{cm} = \sigma_{ci} \cdot s^a \quad (11)$$

$$s = \exp[(GSI - 100)/9] \quad (12)$$

$$a = a + 1/6(e^{-GSI/15} - e^{-20/3}) \quad (13)$$

پرواضح است که برخی از این پارامترها به یکدیگر وابسته‌اند و حتی بیانگر یک خاصیت مشترک توده‌سنگ‌اند؛ به طور مثال  $RQD$  و  $GSI$  منعکس‌کننده شرایط درزه‌داری و شکستگی‌های سنگ و  $\sigma_{cm}$  و  $\sigma_{ci}$  نیز بیان‌کننده مقاومت آن است. در نهایت باید از ۱۰ پارامتر یاد شده تاثیرگذارترین آن‌ها انتخاب و در مدل پیش‌بینی پیشنهادی آورده شود.

#### ۴- ارایه مدل پیش‌بینی نرخ نفوذ بر مبنای رگرسیون چند متغیره

از آنجا که استفاده از روش‌های آماری برای توسعه روابط و پیش‌بینی عملکرد ماشین TBM به طور گسترده‌ای در مهندسی سنگ مورد استفاده قرار می‌گیرد، در این مقاله ابتدا با استفاده از پایگاه داده ایجاد شده و با کمک تحلیل‌های رگرسیون چند متغیره خطی و غیرخطی همبستگی بین پارامترهای ده‌گانه بخش قبل و تاثیر آن‌ها بر نرخ نفوذ ماشین  $ROP$  بررسی شده و سپس پارامترهای با بیشترین تطابق انتخاب خواهند شد. در این میان، وجود هرگونه رابطه هم‌خطی چندگانه<sup>۱</sup> بین پارامترهای مستقل نیز با بکارگیری فاکتور اتساع واریانس VIF شناسایی شده و از تحلیل‌های بعدی حذف خواهد شد. در گام بعد، با انجام تحلیل‌های رگرسیون چند متغیره (خطی و غیرخطی) با استفاده از نرم‌افزار SPSS روابطی تجربی برای تخمین  $ROP$  (به عنوان پارامتر وابسته) بر حسب تاثیرگذارترین پارامترهای توده‌سنگ و عملکرد واقعی ماشین (به عنوان پارامترهای مستقل) بدست آمد که نتایج آن‌ها در ادامه ارایه شده است.

به طور کلی اطلاعات زمین‌شناسی مهندسی و مکانیک سنگ توده‌سنگ به چهار گروه شامل داده‌های مربوط به سختی و ساینده‌گی سنگ (محتوای کوارتز (درصد)  $q$  و شاخص سایش  $ABI$ )، شرایط درزه‌داری سنگ و جهت‌داری ناپیوستگی‌ها (شاخص کیفیت سنگ  $RQD$  شاخص مقاومت زمین‌شناسی  $GSI$  و زاویه صفحات ناپیوستگی با راستای تونل  $\alpha$  (بر مبنای رابطه NTNU [۳۶])، ویژگی‌های مقاومتی سنگ بکر (مقاومت فشاری تک محوری  $\sigma_{ci}$  (MPa) و مقاومت کششی  $\sigma_t$  (MPa) و فشار روباره ( $p$  (MPa) تقسیم‌بندی شد. همچنین، نیروی قائم اعمالی بر هر تیغه برشی  $F_n$  (kN/cutter) که به عنوان اصلی‌ترین پارامتر مستقل ماشین حفاری نیز شناخته می‌شود، از میان داده‌های ثبت شده برای عملکرد واقعی ماشین انتخاب شد. مقدار خالص این نیرو از رابطه  $F_n = (T_h - T_f) / N_{TBM}$  [۳۷] محاسبه شد که در آن  $T_h$  نیروی پیشران کل ماشین (kN)  $T_f$  نیروی اصطکاک بین ماشین و جداره تونل (kN) و  $N_{TBM}$  تعداد تیغه‌های برشی نصب شده روی کله حفاری است. مطالعات مختلف نشان می‌دهد که مقدار  $T_f$  برای ماشین‌های با سپر دوتایی در زمین‌های غیر مچاله‌شونده برابر ۲۰ درصد وزن ماشین است [۳۷].

علاوه بر پارامترهای فوق که مقادیر آن‌ها را می‌توان

<sup>۱</sup> Multicollinearity

## ۴-۱- رگرسیون چندمتغیره خطی

در این بخش برای یافتن رابطه تجربی به منظور پیش‌بینی نرخ نفوذ ماشین بر اساس داده‌های موجود از رگرسیون خطی چندمتغیره استفاده شده است. نتایج تحلیل‌ها نشان از وجود رابطه هم‌خطی چندگانه شدید بین برخی از پارامترهای ده‌گانه دارد که منجر به غیرواقعی شدن ضریب همبستگی ( $R^2$ ) می‌شود. با بکارگیری فاکتور اتساع واریانس VIF این پارامترها شناسایی (متغیرهای با  $VIF > 10$ ) و به همراه پارامترهای با تطابق پایین از تحلیل‌ها حذف شد.

تحلیل‌ها نشان داد که از بین پارامترهای مقاومتی سنگ بکر ( $\sigma_{ci}$  و  $\sigma_t$ ) و مقاومت فشاری توده سنگ  $\sigma_{cm}$ ، پارامتر ترکیبی  $\sigma_{cm}$  دارای بیشترین تطابق و همبستگی با  $ROP$  است. از طرف دیگر، وجود رابطه غیرمستقیم بین  $GSI$  و  $\sigma_{cm}$  (روابط ۱۱ تا ۱۳) باعث افزایش مقدار VIF شد که با حذف  $GSI$  وجود رابطه هم‌خطی چندگانه بین پارامترهای باقیمانده نیز از بین رفت. همچنین، از آنجا که شدت درزه‌داری توده‌سنگ از طریق  $GSI$  در محاسبه پارامتر ترکیبی  $\sigma_{cm}$  مستتر است، در نتیجه وجود همزمان  $\sigma_{cm}$  و  $RQD$  نیز منجر به افزایش VIF شد که با حذف  $RQD$  مشکل یاد شده رفع شد. پارامترهای شاخص سایش  $ABI$  و فشار روپاره  $p$  نیز کم اثر تشخیص داده شده و از پارامترهای ورودی مدل حذف شد. در نهایت، نرخ نفوذ ماشین بر حسب (mm/rev) بر مبنای مدل خطی زیر با ضریب تعیین  $R^2 = 0.455$  بدست آمد (رابطه ۱۴):

$$ROP = 0.13q - 0.117\sigma_{cm} + 0.023\alpha - 0.027F_n + 11.232 \quad (14)$$

طبق رابطه ۱۴، پارامترهای محتوای کوارتز  $q$ ، مقاومت فشاری توده‌سنگ  $\sigma_{cm}$ ، زاویه صفحات ناپیوستگی با راستای تونل  $\alpha$  و نیروی اعمالی بر تیغه برش  $F_n$  قوی‌ترین تاثیر و همبستگی را با نرخ نفوذ ماشین حفاری دارند. محققان مختلف نیز همبستگی‌های نسبتاً مشابهی بین نرخ نفوذ و پارامترهای  $q$  [۱۲]،  $\alpha$  [۲۰] و  $F_n$  [۹] بدست آورده‌اند با این تفاوت که در کنار آن‌ها، پارامترهای مقاومتی سنگ بکر ( $\sigma_t$  و  $\sigma_{ci}$ ) و نیز شاخص‌های شدت درزه‌داری سنگ همچون  $GSI$  و  $RQD$  نیز وجود دارد [۹]. این درحالی است که در این تحقیق، هر دو گروه پارامترهای مقاومتی سنگ بکر و شدت درزه‌داری در یک پارامتر ترکیبی ( $\sigma_{cm}$ ) گنجانده شده است.

## ۴-۲- رگرسیون چندمتغیره غیرخطی

با در نظر گرفتن ماهیت پیچیده و به شدت غیرخطی پیش‌بینی عملکرد TBM، استفاده از رگرسیون خطی دقت


مطلوب را ندارد و با خطا توأم است، بنابراین در این بخش با استفاده از روش رگرسیون غیرخطی سعی شده است که دقت مدل تجربی پیش‌بینی نرخ نفوذ تا حدی بهبود یابد. بدین منظور، در گام اول همبستگی و میزان تطابق دو به دوی هر یک از پارامترهای ده‌گانه بخش ۳-۳ با نرخ نفوذ  $ROP$  تعیین شد و آنگاه بر اساس نوع همبستگی (درجه دو، درجه سه، نمایی، لگاریتمی و نظایر آن) رابطه کلی غیرخطی ۱۵ را می‌توان بدست آورد:

$$ROP = aq^2 + b\sigma_{cm}^2 + c\sigma_{cm} + d\ln\alpha + eF_n^2 + fF_n + g \quad (15)$$

که در آن  $a$ ،  $b$ ،  $c$ ،  $d$ ،  $e$ ،  $f$  و  $g$  ضرایب ثابتی است که باید در فرآیند رگرسیون غیرخطی محاسبه شود. ملاحظه می‌شود که نوع رابطه غیرخطی  $ROP$  با پارامترهای  $q$ ،  $\sigma_{cm}$  و  $F_n$  درجه دو بوده درحالی که برای  $\alpha$  به صورت لگاریتمی است. با استفاده از پایگاه داده‌های تونل انتقال آب کرمان و با انجام رگرسیون غیرخطی بر مبنای رابطه ۱۵، رابطه ۱۶ برای پیش‌بینی  $ROP$  با سطح اعتماد ۹۵ درصد و ضریب تعیین  $R^2 = 0.60$  بدست آمد:

$$ROP = 0.003q^2 - 0.005\sigma_{cm}^2 + 0.246\sigma_{cm} + 0.797\ln\alpha - 0.00025F_n^2 + 0.078F_n - 6.023 \quad (16)$$

در شکل ۳ مقایسه نتایج نرخ نفوذ حاصل از مدل پیش‌بینی رابطه ۱۶ با مقادیر واقعی ثبت شده در تونل انتقال آب کرمان نشان داده شده است. ملاحظه می‌شود که دقت و ضریب تعیین در مدل غیرخطی به طور چشمگیری (۰/۱۴۵) نسبت به مدل خطی افزایش یافته که خود نشانگر کارایی بسیار بهتر مدل رگرسیون غیرخطی است.



شکل ۳- مقایسه نتایج مدل رگرسیون غیرخطی  $ROP$  با مقادیر واقعی آن‌ها

## ۵- ارایه مدل جدید GMDH برای پیش‌بینی نرخ نفوذ

## ۵-۱- روش بهینه‌سازی ساختار مدل GMDH

پس از معرفی ساختار شبکه عصبی GMDH در بخش ۲، در این بخش به بحث طراحی ساختار شبکه که یکی از مسایل بسیار مهم مطرح در شبکه‌های عصبی مصنوعی چند لایه است پرداخته می‌شود. در این طراحی تعداد لایه‌ها، هم‌بندی و نیز ساختار درونی از قبیل تعداد وزن‌ها و مقادیر آن‌ها و همچنین تابع تحریک هر نرون به صورت مناسب انتخاب شده تا یک نگاشت مناسب و ایده‌آل میان داده‌های ورودی و خروجی برقرار شود. از آنجا که از معدود روش‌های یافتن نقاط بهینه سراسری در فضای جستجوی مشتق‌ناپذیر استفاده از روش‌های تکاملی همانند الگوریتم ژنتیک است، این روش‌ها در طراحی پارامترهای مختلف شبکه‌های عصبی کاربرد گسترده‌ای دارند. عموماً این قبیل روش‌های تصادفی برای آموزش شبکه‌های عصبی در بهینه‌سازی وزن‌ها یا ضرایب، نسبت به روش‌های کلاسیک گرادینت بهتر عمل می‌کنند.

در این روش برای اجرای فرآیند بهینه‌سازی، ابتدا داده‌های ورودی به دو دسته آموزش و پیش‌بینی تقسیم و خطای آموزش<sup>۱</sup> و خطای پیش‌بینی<sup>۲</sup> به عنوان دو تابع هدف انتخاب می‌شود. بدین ترتیب متناظر با داده‌های ورودی، الگوریتم ژنتیک به محاسبه توابع هدف یاد شده می‌پردازد و ساختار بهینه شبکه GMDH را به صورت نقاط پارتو<sup>۳</sup> (غیربرتر) ارایه می‌دهد. در نهایت طراح با برقراری مصالحه<sup>۴</sup> بین توابع هدف، یک نقطه پارتو را انتخاب و بدین ترتیب ساختار شبکه GMDH تعیین می‌شود.

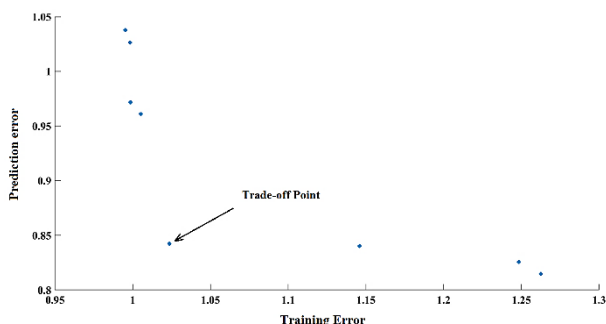
## ۵-۲- نتایج و عملکرد مدل پیش‌بینی GMDH

در این بخش، برای ساخت مدل شبکه عصبی GMDH، نتایج تحلیل‌های رگرسیون انجام شده در بخش قبل مبنای تعیین مجموعه متغیرهای ورودی- خروجی شبکه قرار گرفت. به بیان دیگر، در مدل پیش‌بینی GMDH متغیرهای  $(X_1)$   $q$ ،  $(X_2)$   $\sigma_{cm}$ ،  $(X_3)$   $\alpha$  و  $(X_4)$   $F_n$  به عنوان ورودی‌های  $X_i$  ( $i=1,2,3,4$ ) و نرخ نفوذ  $ROP$  به عنوان خروجی  $Y$  در نظر گرفته می‌شود.

برای نشان دادن توانایی پیش‌بینی شبکه GMDH جفت داده‌های ورودی- خروجی به دو دسته آموزش و پیش‌بینی تقسیم می‌شوند به طوری که ۷۰ درصد از نمونه‌ها (از تعداد

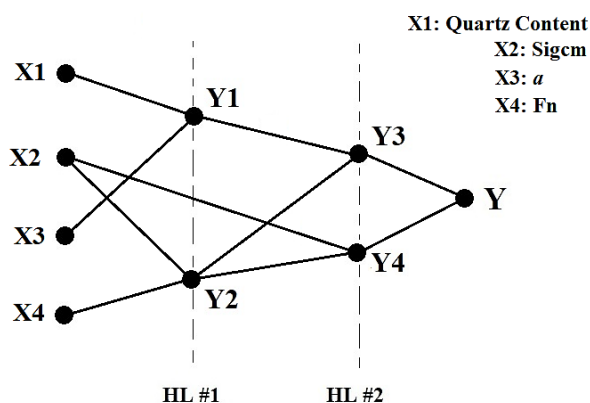
۲۹۰ دسته داده ورودی) در قسمت آموزش و ۳۰ درصد باقیمانده از آن‌ها در قسمت پیش‌بینی به کار می‌رود.

ساختار شبکه که به صورت یک مدل خروجی چندجمله‌ای است که با یک فرآیند بهینه‌سازی دو هدفه به دست می‌آید. الگوریتم ژنتیک دو هدفی، با تعداد جمعیت اولیه ۸۰، احتمال پیوند ۰/۹۵، احتمال جهش ۰/۰۲ و تعداد نسل ۳۰۰ نسبت به ۲۹۰ دسته‌داده ورودی موجود، ساختار بهینه شبکه را به صورت دو لایه پنهان معرفی می‌کند. از فرآیند بهینه‌سازی دو هدفی، تعداد ۸ نقطه بهینه پارتو حاصل شد که در شکل ۴ نمایش داده شده است. همه این را نقاط می‌توان به عنوان یک شبکه عصبی بهینه انتخاب کرد. در این شکل، نقطه Trade-off را می‌توان به عنوان شبکه‌ای که بین توابع هدف، خطای آموزش و خطای پیش‌بینی مصالحه ایجاد می‌کند، در نظر گرفت. بر این اساس، نقطه Trade-off نشان داده شده در شکل ۴ به عنوان شبکه GMDH پیشنهادی برای داده‌های مورد استفاده در این پژوهش معرفی می‌شود.



شکل ۴- نقاط پارتو بدست آمده از بهینه‌سازی دو هدفی مدل شبکه

## عصبی GMDH



شکل ۵- ساختار بهینه مدل شبکه عصبی GMDH برای خروجی  $ROP$  (HL لایه پنهان)

ساختار بهینه شبکه با دو لایه پنهان بدست آمده برای  $ROP$  در شکل ۵ نشان داده شده است. در این ساختار تابع

<sup>1</sup> Training Error (TE)

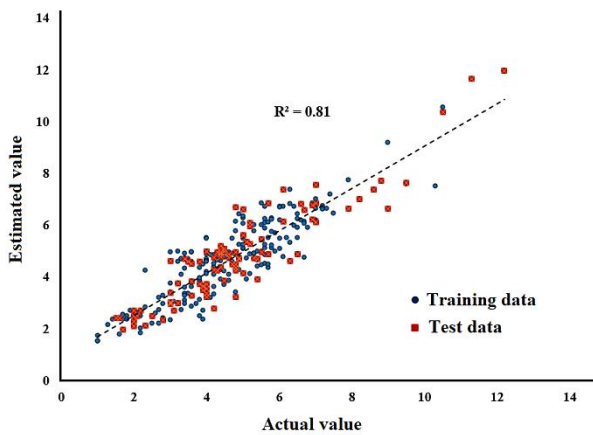
<sup>2</sup> Prediction Error (PE)

<sup>3</sup> Pareto points

<sup>4</sup> Trade-off



آموزش دیده و همچنین قابلیت پیش‌بینی بسیار خوبی را نیز بدست می‌دهد.



شکل ۶- نمودار همبستگی داده‌های واقعی نرخ نفوذ  $ROP$  با مقادیر تخمین زده شده

#### ۶- نتیجه‌گیری

هدف از این تحقیق ارایه مدلی جدید برای پیش‌بینی نرخ نفوذ ماشین حفاری  $ROP$  بر مبنای روش دسته‌بندی گروهی داده‌ها (GMDH) بوده است. بدین منظور، با استفاده از داده‌های موجود در قطعه جنوبی پروژه تونل انتقال آب کرمان پایگاهی از داده‌های ژئومکانیکی توده‌سنگ و عملکرد واقعی ماشین حفاری تهیه و در قالب ۱۰ پارامتر مستقل و یک پارامتر وابسته ( $ROP$ ) مسیر تونل تقسیم‌بندی شد.

$ROP$  (Y) به طور مستقیم به نرون  $Y3$  و  $Y4$  در لایه پنهان دوم و نرون  $Y3$  نیز به نرون  $Y1$  و  $Y2$  در لایه پنهان اول متصل‌اند. از طرف دیگر مشاهده می‌شود که نرون  $Y4$  به نرون  $Y2$  در لایه پنهان اول وصل است اما همزمان با پرش از این لایه، مستقیماً به ورودی  $X2$  متصل می‌شود که نشان‌دهنده اهمیت پارامتر  $X2$  یا  $\sigma_{cm}$  در خروجی نهایی است. همچنین در لایه پنهان اول نیز نرون  $Y1$  به  $X1$  و  $X3$  و نرون  $Y2$  مستقیماً به نرون‌های  $X2$  و  $X4$  در ورودی‌ها متصل می‌شود.

در نهایت ارتباط بین نرون‌ها در لایه‌های مختلف را می‌توان بصورت روابط چندجمله‌ای نوشت که بیان‌کننده مدل  $ROP$  بر حسب ورودی‌های  $X_i$  ( $i=1,2,3,4$ ) است. این روابط بصورت بازگشتی از (الف) تا (ث) در جدول ۲ ارایه شده است. همین ارایه رابطه صریح بین ورودی‌ها و خروجی مدل مزیت اصلی استفاده از مدل شبکه GMDH است که شبکه را از حالت جعبه سیاه خارج می‌کند و امکان استفاده مستقیم از آن در پروژه‌های مشابه را از طریق روابط جدول ۲ فراهم می‌سازد.

برای ارزیابی عملکرد شبکه عصبی، مقادیر خروجی  $ROP$  در مدل ساخته شده در مقابل مقادیر خروجی واقعی (اندازه‌گیری شده) در شکل ۶ آورده شده است. مدل شبکه GMDH پیشنهاد شده مقادیر ضریب تعیین بالایی  $R^2 = 0.81$  در مقایسه با مدل‌های رگرسیونی بدست می‌دهد. با توجه به این نتایج، واضح است که شبکه عصبی ساخته شده به خوبی

جدول ۲- روابط بازگشتی خروجی مدل GMDH برای پیش‌بینی نرخ نفوذ  $ROP$  (Y) بر حسب ورودی‌های  $X_i$  ( $i=1,2,3,4$ )

|  |       |
|--|-------|
| $Y_1 = 7.34879640467803 + 0.10292914083784 X_1 - 0.17924560457558 X_3 - 0.004778353272596 X_1^2 + 0.0016293175610 X_3^2 + 0.0026805475046 X_1 X_3$   | (الف) |
| $Y_2 = 10.30668534703427 + 0.50438960184867 X_2 + 0.09146311833608 X_4 - 0.00362590156147 X_2^2 - 0.0001728745676 X_4^2 - 0.00113880009408 X_2 X_4$  | (ب)   |
| $Y_3 = -10.97532649233386 + 5.05825064647859 Y_1 + 0.5700062716492 Y_2 - 0.64237499686139 Y_1^2 - 0.08542450014687 Y_2^2 + 0.25710473936305 Y_1 Y_2$ | (پ)   |
| $Y_4 = -2.42435832440358 + 0.01618586810409 X_2 + 1.79783553447453 Y_2 + 0.00036877233980 X_2^2 - 0.04596299631025 Y_2^2 - 0.00823689029071 X_2 Y_2$ | (ت)   |
| $Y = 0.2083451241842 - 0.16035060447482 Y_3 + 1.0343319813832 Y_4 + 0.83754426785573 Y_3^2 + 0.34476988622865 Y_4^2 - 1.17034988372264 Y_3 Y_4$      | (ث)   |

مزیت دیگر استفاده از  $\sigma_{cm}$  ترکیب اثر مقاومت فشاری سنگ بکر ( $\sigma_{ci}$ ) و شرایط درزه‌داری و ناپیوستگی‌های توده‌سنگ ( $GSI$ ) در قالب یک پارامتر است که با حذف اثر پارامترهای مختلف در مدل‌های پیش‌بینی و در نتیجه ساده‌تر شدن آن‌ها می‌شود. بر مبنای تحلیل‌های رگرسیونی چندگانه، چهار پارامتر  $q$ ،  $\sigma_{cm}$ ،  $\alpha$  و  $F_n$  قوی‌ترین همبستگی را با نرخ نفوذ ماشین داشته به طوری که مدل غیرخطی با ضریب تعیین ( $R^2=0/60$ ) عملکرد بهتری در مقایسه با مدل خطی ( $R^2=0/455$ ) بدست

ابتدا با استفاده از رگرسیون چندمتغیره خطی و غیرخطی همبستگی بین پارامترهای مستقل ده‌گانه و  $ROP$  بررسی شده و پارامترهای با رابطه هم‌خطی چندگانه نیز از تحلیل‌ها کنار گذاشته شدند. در این پژوهش از پارامتر ترکیبی مقاومت فشاری توده‌سنگ  $\sigma_{cm}$  در کنار پارامترهای مقاومت فشاری و کششی سنگ بکر در تحلیل‌ها استفاده شد و نتایج تحلیل‌ها نشان داد که  $\sigma_{cm}$  در مقایسه با پارامترهای مقاومتی سنگ بکر دارای بیشترین تطابق و همبستگی با  $ROP$  است. علاوه بر این،

7. J. Khademi Hamidi; K. Shahriar; B. Rezai, J. Rostami, 2010; "Performance prediction of hard rock TBM using rock mass rating (RMR) system", Tunn. Undergr. Space Technol., vol. 25(4), pp. 333–345.
8. E. Farrokh; J. Rostami; C. Laughton, 2012; "Study of various models for estimation of penetration rate of hard rock TBMs", Tunn. Undergr. Space Technol., vol. 30, pp.110–123.
9. A. Benato; P. Oreste, 2015; "Prediction of penetration per revolution in TBM tunneling as a function of intact rock and rock mass characteristics", Int. J. Rock Mech. Min. Sci., vol. 74, pp. 119–127.
10. O. Frough; S.R. Torabi; S. Yagiz, 2015; "Application of RMR for estimating rock-mass-related TBM utilization and performance parameters: a case study", Rock Mech. Rock Eng., vol. 48 (3), pp. 1305–1312.
11. A. Salimi; J. Rostami; C. Moormann; A. Delisio, 2016; "Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs", Tunn. Undergr. Space Technol., vol. 58, pp. 236–246.
12. G. Armettia; M.R. Migliazzab; F. Ferraric; A. Bertid; P. Padovesed, 2018; "Geological and mechanical rock mass conditions for TBM performance prediction. The case of "La Maddalena" exploratory tunnel", Tunn. Undergr. Space Technol., vol. 77, pp. 115–126.
13. M. Entacher; J. Rostami, 2019; "TBM performance prediction model with a linear base function and adjustment factors obtained from rock cutting and indentation tests", Tunnell. Undergr. Space Technol., vol. 93, no.103085.
14. H. Xu; Q. Gong ; J. Lu; L. Yin; F. Yang, 2021; "Setting up simple estimating equations of TBM penetration rate using rock mass classification parameters", Tunnell. Undergr. Space Technol., vol. 115, no. 104065
15. M. Alvarez Grima; P.A. Bruines; P.N.W. Verhoef, 2000; "Modeling tunnel boring machine performance by neuro-fuzzy methods", Tunnell. Undergr. Space Technol., vol. 15 (3), pp. 259–269.
16. A.G. Benardos; D.C. Kaliampakos, 2004; "Modelling TBM performance with artificial neural networks", Tunnell. Undergr. Space Technol., vol. 19, pp. 597–605.
17. S. Yagiz; C. Gokceoglu; E. Sezer; S. Iplikci, 2009; "Application of two nonlinear prediction tools to the estimation of tunnel boring machine performance", Eng. Appl. Artif. Intell., vol. 22, pp. 808–814.
18. E. Ghasemi E; S. Yagiz; M. Ataei, 2014; "Predicting penetration rate of hard rock tunnel

داد. همچنین، پارامترهای  $q$ ،  $\sigma_{cm}$  و  $F_n$  به صورت تابع درجه دو و  $\alpha$  نیز به صورت لگاریتمی در مدل غیرخطی ظاهر شدند.

پس از انجام تحلیل‌های آماری فوق، با استفاده از شبکه عصبی GMDH و پس از تقسیم داده‌های ورودی به دو دسته آموزش (۷۰ درصد) و پیش‌بینی (۳۰ درصد)، مقادیر دو تابع خطای آموزش (TE) و خطای پیش‌بینی (PE) با استفاده از الگوریتم ژنتیک دو هدفی محاسبه و در نهایت ساختار بهینه شبکه به صورت دو لایه پنهان تعیین شد. در مدل پیش‌بینی GMDH متغیرهای  $q$  (X1)،  $\sigma_{cm}$  (X2)،  $\alpha$  (X3) و  $F_n$  (X4) به عنوان ورودی و نرخ نفوذ ROP به عنوان خروجی Y در نظر گرفته شد. از آنجا که در مدل GMDH ارتباط بین نرون‌ها در لایه‌های مختلف را می‌توان به صورت روابط چندجمله‌ای نوشت، خروجی نهایی مدل به صورت روابطی بازگشتی بین نرخ نفوذ ROP و ورودی‌های  $X_i$  ( $i=1,2,3,4$ ) تهیه شد. این رابطه صریح بین ورودی‌ها و خروجی مدل از مزیت‌های اصلی استفاده از مدل GMDH است که شبکه را از حالت جعبه سیاه خارج می‌کند و امکان استفاده مستقیم از روابط ارائه شده را در سایر پروژه‌ها فراهم می‌سازد. مقایسه مقادیر خروجی ROP در مدل شبکه عصبی با مقادیر اندازه‌گیری شده نیز ضریب تعیین بالایی  $R^2 = 0.81$  در مقایسه با مدل‌های رگرسیونی بدست می‌دهد که نمایانگر قابلیت پیش‌بینی بسیار خوب این شبکه است.

#### منابع

1. H.P. Sanio, 1985; "Prediction of the performance of disc cutters in anisotropic rock", Int. J. Rock Mech. Min. Sci. Geomech. Abstr., vol. 22 (3), pp. 153–161.
2. O.T. Blindheim, 1979; "Boreability predictions for tunneling Ph.D. Thesis", Department of Geological Engineering. The Norwegian Institute of Technology.
3. J. Rostami, 1997; "Development of a force estimation model for rock fragmentation with disc cutters through theoretical modeling and physical measurement of crushed zone pressure Ph.D. thesis", Colorado School of Mines, Golden, Colorado, USA.
4. A. Bruland, 1998; "Hard rock tunnel boring Ph.D. Thesis", Norwegian University of Science and Technology, Trondheim.
5. N. Barton, 2000; "TBM Tunnelling in Jointed and Faulted Rock", Balkema, Rotterdam.
6. J. Hassanpour; J. Rostami; M. Khamehchiyan, A. Bruland, H.R. Tavakoli, 2010; "TBM performance analysis in pyroclastic rocks: a case history of karaj water conveyance tunnel", Rock Mech. Rock Eng., vol. 43 (4), pp. 427–445.

29. B. Ahmadi; N. Nariman-zadeh; A. Jamali, 2017; "Path synthesis of four-bar mechanisms using synergy of polynomial neural network and Stackelberg game theory", Engineering Optimization, vol. 49(6), pp. 932-947.
30. M. Parsa; E.J.M. Carranza, B. Ahmadi, 2022; "Deep GMDH Neural Networks for Predictive Mapping of Mineral Prospectivity in Terrains Hosting Few but Large Mineral Deposits", Natural Resources Research, vol. 31(1), pp. 37-50.
31. S.J. Farlow, 1984; "The GMDH algorithm", Self-organizing methods in modeling" GMDH type algorithms, vol. 54, p. 350.
32. N. Nariman-Zadeh, et al., 2005; "Evolutionary design of generalized polynomial neural networks for modelling and prediction of explosive forming process", Journal of Materials Processing Technology, vol. 164-165, pp. 1561-1571.
33. N. Nariman-Zadeh; A. Darvizeh; G. Ahmad-Zadeh, 2003; "Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modelling and prediction of the explosive cutting process" Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, vol. 217(6): pp. 779-790.
۳۴. مهندسان مشاور ساحل امید ایرانیان - زیستاب. ۱۳۹۶. گزارش زمین‌شناسی مهندسی تونل انتقال آب کرمان.
۳۵. پورهاشمی، سیدمهدی؛ آهنگری، کاوه؛ حسن‌پور، جعفر، افتخاری، سید مصلح؛ ۱۴۰۰؛ «تحلیل نرخ نفوذ ماشین حفار تمام مقطع در شرایط سنگسایبی»، نشریه علمی مهندسی معدن، دوره ۱۶، شماره ۵۲، صفحه ۷۸ تا ۸۸.
36. A. Bruland, 1999; "Hard Rock Tunnel Boring: Advance Rate and Cutter Wear", Trondheim, Norway: Norwegian Institute of Technology (NTNU).
37. A. Salimi; J. Rostami; C. Moormann; A. Delisio, 2019; "Application of rock mass classification systems for performance estimation of rock TBMs using regression tree and artificial intelligence algorithms", Tunn. Undergr. Space Technol., vol. 92, 103046.
38. E. Hoek; E.T. Brown, 2019; "The Hoek-Brown failure criterion and GSI-2018 edition", J. Rock Mech. Geotech. Eng., vol. 11(3), pp. 445-463.
- boring machine using fuzzy logic", Bull. Eng. Geol. Environ., vol. 73, pp. 23-35.
19. S. Mahdevari S; K. Shahriar; S. Yagiz; M.A. Shirazi, 2014; "A support vector regression model for predicting tunnel boring machine penetration rates", Int. J. Rock Mech. Min. Sci., vol. 72, pp. 214-229.
20. S. Yagiz ; H. Karahan, 2015; "Application of various optimization techniques and comparison of their performances for predicting TBM penetration rate in rock mass", Int. J. Rock Mech. Min. Sci., vol. 80, pp. 308-315.
21. D.J. Armaghani; E.T. Mohamad; M.S. Narayanasamy et al., 2017; "Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition", Tunn. Undergr. Sp. Technol., vol. 63, pp. 29-43.
22. J. Zhou; B. Yazdani Bejarbaneh; D.J. Armaghani; M.M. Tahir, 2020; "Forecasting of TBM advance rate in hard rock condition based on artificial neural network and genetic programming techniques", Bull. Eng. Geol. Environ., vol. 79, pp. 2069-2084.
23. F. Shangxina; C. Zuyub; L. Huac et al., 2021; "Tunnel boring machines (TBM) performance prediction: A case study using big data and deep learning", Tunn. Undergr. Sp. Technol., vol. 110, no. 103636.
24. V.T. Minh; D. Katushin; M. Antonov; R. Veinthal, 2017; "Regression models and fuzzy logic prediction of TBM penetration rate", Open Eng., vol. 7 (1), pp. 60-68.
25. S. Yagiz; H. Karahan, 2011; "Prediction of hard rock TBM penetration rate using particle swarm optimization", Int. J. Rock Mech. Min. Sci., vol. 48, pp. 427-433.
26. E. Sfidari et al., 2018; "Prediction of pore facies using GMDH-type neural networks: a case study from the South Pars gas field, Persian Gulf basin", Geopersia, vol. 8(1), pp. 43-60.
27. A. Jamali et al., 2015; "Reliability-based optimal controller design for systems with probabilistic uncertain parameters using fuzzy limit state function", Journal of Vibration and Control, vol. 21(7), pp. 1413-1429.
28. A. Jamali et al., 2013; "Probability of failure for uncertain control systems using neural networks and multi-objective uniform-diversity genetic algorithms (MUGA)", Engineering Applications of Artificial Intelligence, vol. 26(2), pp. 714-723.