نشریه مکانیک سنگ
Journal of Rock Mechanics
دوره دهم، شماره۲، تابستان۱۴۰۵، صفحه۶۵تا۷۹
https://doi.org/10.22034/IRSRM.2026.601061.1090



پیش‌بینی عملکرد چکش‌های ضربه‌ای هیدرولیکی با استفاده از شبکه عصبی مصنوعی و تحلیل عمق نفوذ با بهینه‌سازی ازدحام ذرات، مطالعه موردی: معدن زغال‌سنگ کوچکعلی شمالی، طبس

محمد راعی عباس آبادی[۱] ، آرش ابراهیم آبادی[۲]، هادی حمیدیان شورمستی[۱]*، طاهره حلاجیان[۱]، محمد تقوائی[۱]

۱- گروه معدن و زمین‌شناسی، واحد قائم‌شهر، دانشگاه آزاد اسلامی، قائم‌شهر، ایران.

۲- گروه مهندسی نفت، معدن و مواد، واحد تهران‌مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.

دریافت : ۱۴۰۵/۰۵/۰۶؛ پذیرش: ۱۴۰۵/۰۶/۳۱

(*نویسنده مسئول: hhamidian@Qaemiau.ac.ir)

چکیده

پیش‌بینی نرخ شکست چکش‌های ضربه‌ای برای برنامه‌ریزی حفاری در معادن زغال‌سنگ اهمیت دارد. در این پژوهش با 30 نمونه‌ی سنگ معدن کوچکعلی شمالی طبس (5 سنگ‌شناسی)، مقاومت فشاری تک‌محوره (UCS) و عمق نفوذ مته ورودی و نرخ شکست آنی (IBR) خروجی بود؛ IBR و عمق نفوذ با روابط نیمه‌تجربی و تحلیلی از UCS برآورد شده‌اند. یک شبکه‌ی عصبی مصنوعی 2-۱-1 (ANN) با اعتبارسنجی 5-fold تکراری ارزیابی شد (R^2 = ± 0.011؛ RMSE = 0.749 ± 0.042 m³/h)، ولی رگرسیون خطی (R^2 = 0.924) و درجه‌دو (R^2 = 0.955) دقیق‌تر بودند؛ بنابراین ANNبرتری پیش‌بینی نشان نداد و در اینجا به‌عنوان مدلی غیرخطی برای تحلیل و بهینه‌سازی به‌کار رفت. سپس الگوریتم ازدحام ذرات (PSO) عمق نفوذ را، با UCS ثابت و سقف انرژی ضربه، روی خروجی مدل جست‌وجو کرد. در سقف 4000 J (با فرض ثابت‌ماندن فرکانس ضربه)، میانگین IBR پیش‌بینی‌شده 9.28 m³/h بود (افزایش پیش‌بینی‌شده‌ی میانگین 35٪ نسبت به پیش‌بینی مدل در عمق فعلی؛ 11٪ تا 52٪ برای سقف‌های 2500 تا 6000 J). این نتایج خروجی مدل‌اند، به‌دلیل همبستگی شدید دو ورودی ($r = -0.93$) اثر مستقل آن‌ها قابل تفکیک نیست و به اعتبارسنجی میدانی نیاز دارند.

واژگان کلیدی

نرخ شکست آنی، چکش ضربه‌ای هیدرولیکی، الگوریتم ازدحام ذرات، شبکه عصبی مصنوعی، معدن زغال‌سنگ، کوچکعلی طبس

۱- مقدمه

عملیات حفاری در معادن زغال‌سنگ به عنوان یکی از مراحل کلیدی در فرآیند استخراج، نیازمند به‌کارگیری تکنیک‌ها و ابزارهای موثر است که بتوانند به حداکثر بهره‌وری و حداقل هزینه دست یابند. چکش‌های ضربه‌ای به دلیل قابلیت‌های بالای خود در شکستن سنگ‌های سخت و سرعت عمل بالا، به یکی از ابزارهای رایج در این صنعت تبدیل شده‌اند. با این حال، عملکرد این نوع چکش‌ها تحت تأثیر عوامل متعددی از جمله نوع سنگ، پارامترهای عملیاتی و شرایط محیطی قرار دارد. پیش‌بینی دقیق نرخ شکست آنی IBR [1]چکش که نشان‌دهنده کارایی چکش ضربه‌ای است، به منظور بهینه‌سازی فرآیندهای حفاری و افزایش بهره‌وری اهمیت فراوانی دارد[۱].

در سال‌های اخیر، تکنیک‌های هوش مصنوعی و الگوریتم‌های بهینه‌سازی به‌عنوان ابزارهایی مؤثر در بهبود مدل‌سازی و پیش‌بینی در حوزه‌های مختلف صنعتی مطرح شده‌اند. یکی از این تکنیک‌ها، استفاده از شبکه‌های عصبی مصنوعی می‌باشد که به دلیل ظرفیت بالای آن‌ها در یادگیری و مدل‌سازی روابط غیرخطی، به طور گسترده در پیش‌بینی‌های مربوط به عملیات حفاری به کار می‌روند. به‌علاوه، الگوریتم بهینه‌سازی ازدحام ذرات (PSO)[2] به دلیل سادگی و کارایی بالای خود، به‌طور مؤثر در بهینه‌سازی پارامترهای مدل‌های شبکه عصبی مصنوعی (ANN)[3] مورد استفاده قرار می‌گیرد[۲, ۳].

در دهه‌های گذشته، تحقیقات متعددی در حوزه پیش‌بینی عملکرد تجهیزات حفاری انجام شده است. در اوایل، مدل‌های ریاضی ساده و تحلیل‌های تجربی برای برآورد IBR و عملکرد چکش‌ها به کار گرفته می‌شدند، اما این رویکردها توانایی مدل‌سازی روابط غیرخطی و تعامل پیچیده عوامل مؤثر را نداشتند. به عنوان مثال، محققانی مانند کهرامان (۱۹۹۹) [۴] با استفاده از تحلیل‌های تجربی و مدل‌های خطی سعی در برآورد میزان بهره‌وری حفاری داشتند، اما نتایج محدود و کمتر قابل اعتماد در شرایط متنوع داشتند.

در سال‌های بعد، با ظهور روش‌های هوشمند و تحلیل‌های داده‌محور، مدل‌های مبتنی بر شبکه‌های عصبی به‌تدریج جایگزین رویکردهای صرفاً تجربی و خطی شدند. برای نمونه، ایفار (۲۰۱۲) با به‌کارگیری ANN و سیستم استنتاج فازی-عصبی تطبیقی(ANFIS)، IBR چکش‌های ضربه‌ای را بر اساس مقادیر بازگشت چکش اشمیت و شاخص کیفیت سنگ پیش‌بینی کرد و نتایج قابل‌قبولی در کاهش خطای پیش‌بینی نسبت به مدل‌های رگرسیونی پیشین ارائه داد[۵]. با این حال، این دسته از رویکردها معمولاً نیازمند تنظیم دستی معماری و پارامترهای شبکه بودند؛ فرآیندی که در آن زمان زمان‌بر و فاقد تضمین دستیابی به حداقل خطا محسوب می‌شد. همین محدودیت، زمینه‌ساز ورود الگوریتم‌های بهینه‌سازی فراابتکاری نظیر PSO به این حوزه گردید، که با خودکارسازی فرآیند تنظیم پارامترها، دقت و پایداری مدل‌های پیش‌بینی را ارتقا بخشیدند[۲, ۳]. حجتی و همکاران (۲۰۲۱) با تلفیق برنامه‌نویسی بیان ژن (GEP) و PSO، یک الگوریتم تکاملی ترکیبی برای پیش‌بینی IBR چکش‌های ضربه‌ای توسعه دادند. این پژوهش بر پایه پایگاه داده‌ای شامل ۸۵ نمونه از دو پروژه تونل مترو در استانبول انجام شد که در آن مقاومت فشاری تک‌محوره(UCS)[4]، شاخص کیفیت سنگ (RQD)، مقدار بازگشت چکش اشمیت (SHRV) و توان دستگاه به‌عنوان ورودی مدل در نظر گرفته شدند. عملکرد مدل پیشنهادی در مقایسه با مدل رگرسیون خطی چندگانه و مدل‌های پیشین بیلگین (۱۹۹۶ و ۲۰۰۲) مورد ارزیابی قرار گرفت و نتایج نشان‌دهنده برتری این رویکرد ترکیبی در دقت پیش‌بینی و کاهش نیاز به فرضیات خطی بود[۶].

لی و همکاران(۲۰۲۴) با استفاده از نظریه موج تنش، یک مدل ریاضی برای فرآیند شکست سنگ توسط چکش‌های ضربه‌ای ارائه دادند که در آن سیستم پیستون- قلم- سنگ به‌صورت یکپارچه مدل‌سازی شد. آن‌ها سپس با به‌کارگیری روش المان گسسته (DEM) این مدل را کالیبره و صحت‌سنجی نمودند و اندازه قطعات حاصل از شکست سنگ را برآورد کردند. نتایج این پژوهش نشان داد که پارامترهای کلیدی چکش (نظیر انرژی ضربه و سرعت پیستون) تأثیر مستقیمی بر راندمان شکست سنگ دارند و می‌توانند در جهت کاهش اتلاف انرژی و بهبود عملکرد عملیاتی چکش

[1] instantaneous breaking rate
[2] Particle Swarm Optimization
[3] artificial neural network
[4] Uniaxial Compressive Strength

هدایت شوند[۷].

ژانگ و همکاران (۲۰۲۵) مکانیزم شکست سنگ توسط چکش‌های دی‌تی‌اچ خوشه‌ای[5] را در روش حفاری «چال کوچک، بزرگ‌سازی سوراخ» مورد بررسی قرار دادند. آن‌ها با انجام آزمون ضربه چکش سقوطی روی نمونه‌های گرانیت و با استفاده از یک مته نه‌دکمه‌ای، ابعاد و حجم گودال ایجادشده، اندازه ذرات خرده‌سنگ و منحنی‌های میکرو-کرنش را برای نسبت‌های مختلف قطر سوراخ بزرگ‌شده به سوراخ راهنما (k) اندازه‌گیری کردند. همچنین یک مدل عددی آسیب دینامیکی برای برهم‌کنش دکمه و سنگ تحت بار ضربه‌ای توسعه دادند که با به‌کارگیری المان‌های چسبنده[6]، فرآیند تصادفی جوانه‌زنی ترک تحت ضربه دکمه را شبیه‌سازی می‌کرد. نتایج نشان داد که مقدارk ، نوع سنگ‌شناسی و زاویه شیب جانبی، تأثیر معناداری بر تعداد و مشخصات ترک‌ها و منحنی‌های برهم‌کنش مته- سنگ دارند[۸].

اسماعیل و همکاران (۲۰۲۱) روش‌شناسی برای پیش‌بینی عملکرد چکش‌های هیدرولیکی در حفاری توده‌سنگ ارائه دادند و آن را در قالب یک مطالعه موردی در شمال غربی مصر پیاده‌سازی کردند. آن‌ها با انجام بررسی‌های میدانی گسترده و استفاده از گمانه‌های اکتشافی، نقشه‌برداری از شاخص کیفیت سنگ (RQD) و UCS را برای پهنه‌بندی توده‌سنگ و گروه‌بندی مناطق با خواص مشابه انجام دادند. سپس برای هر گروه سنگی، نرخ شکست خالص (NBR) بر اساس دو سناریوی به‌کارگیری چکش‌های سبک و متوسط، با در نظر گرفتن محدودیت زمانی پروژه (حدود ۳۰۰ روز کاری در سال)، محاسبه و مقایسه گردید [۹].

اوجاک و همکاران (۲۰۱۸) با گردآوری یک پایگاه داده شامل ۱۲۱ نمونه، چند رویکرد یادگیری ماشین از جمله ANN، k-نزدیک‌ترین همسایه(KNN) ، رگرسیون خطی و رگرسیون چندجمله‌ای را برای پیش‌بینیNBR چکش‌های ضربه‌ای توسعه و مقایسه کردند و عملکرد مدل‌ها را با شاخص‌هایی نظیرR^2 ، MAE و RMSE سنجیدند؛ در این مقایسه، الگوریتم KNN بهترین عملکرد را نشان داد[۱۰].

آکسوی (۲۰۱۴) شاخص ساختار سنگ (RSI) را به‌عنوان یک رتبه‌بندی ترکیبی جدید معرفی کرد که از تلفیق چهار مؤلفه — حداقل انرژی شکست ضربه‌ای، رتبه‌بندی ساختاری توده‌سنگ(SR) ، رتبه‌بندی شرایط سطح ناپیوستگی (SCR) و UCS — به‌دست می‌آید. با استفاده از داده‌های میدانی، رابطه‌ای تجربی میانRSI ، توان دستگاه (P) و IBR ارائه شد که ضریب تعیین آن (R^2)برابر با ۰.۷۰ به‌دست آمد. این پژوهش همچنین نموداری راهنما برای انتخاب چکش هیدرولیکی متناسب با شرایط توده‌سنگ پیشنهاد کرد [۱۱].

در مقایسه با مطالعات پیشین، این پژوهش با تکیه بر داده‌ی معدن زغال‌سنگ کوچکعلی شمالی طبس: (الف)ANN را با رگرسیون خطی و درجه‌دو در پروتکل اعتبارسنجی یکسان مقایسه می‌کند؛ (ب) مدل‌سازی IBR را با جست‌وجوی عمق نفوذ توسط PSO تحت محدودیت انرژی ضربه ترکیب می‌کند ؛ و (پ) سناریوهای بهینه‌سازی را نسبت به سقف انرژی ارائه می‌دهد. برتری ANN بر مدل‌های ساده ادعا نمی‌شود. به‌دلیل حجم کم داده و برآوردی‌بودن IBR و عمق نفوذ، یافته‌های این مقاله جنبه‌ی تحلیلی و راهنما دارد و نیازمند اعتبارسنجی میدانی است.

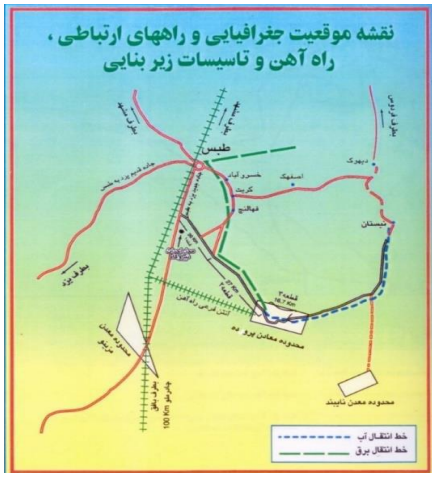
۲- موقعیت و ویژگی های عمومی معدن زغال-سنگ کوچکعلی شمالی طبس

منطقه زغال‌دار کوچکعلی شمالی با وسعتی معادل ۲۴ کیلومتر مربع در جنوب غرب شهرستان طبس و شمال غرب جاده اصلی یزد - طبس قرار گرفته و بر اساس گواهی کشف صادره به شکل پنج ضعلی نامنظمی با مختصات *ABCDE* می‌باشد. جدول (۱) مختصات این پنج ضلعی و شکل (۱) موقعیت جغرافیایی و راه‌های ارتباطی، راه آهن و تأسیسات زیربنایی آورده شده است[۱۲].

جدول ۱: مختصات محدوده معدن زغال‌سنگ کوچکعلی شمالی[۱۲]

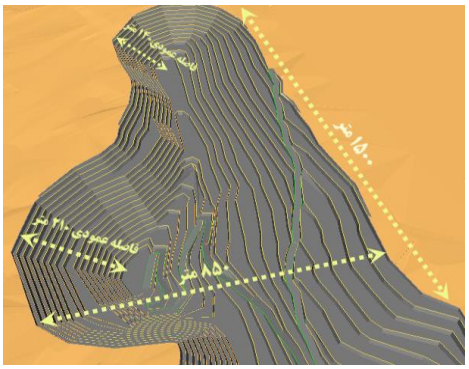
راس	X	Y	منطقه قرارگیری
A	۴۳۵۰۲۷	۳۶۸۹۳۲۶	شمال غربی محدوده
B	۴۳۸۸۲۶	۳۶۸۹۳۲۶	شمال شرقی محدوده
C	۴۳۸۸۲۸	۳۶۸۴۳۲۸	شرق محدوده
D	۴۳۷۷۲۷	۳۶۸۲۸۲۶	جنوب شرقی محدوده
E	۴۳۵۰۲۷	۳۶۸۲۸۲۷	جنوب غربی محدوده

[5] Cluster DTH
[6] cohesive elements

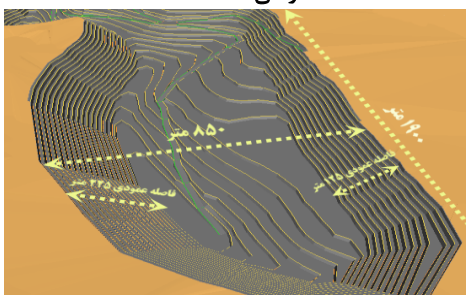


شکل ۱: موقعیت جغرافیایی و راه‌های ارتباطی، راه آهن و تأسیسات زیربنایی[۱۳]

باتوجه به شواهد و بررسی اطلاعات اکتشافی و گزارشات موجود در معدن کوچکعلی شمالی، فاصله این لایه تا لایه‌های قابل کار زیرین آن حدود ۲۰۰ m می‌باشد(مبنای طرحی روباز قرار گرفته است و پارامترهای اقتصادی معدن مورد محاسبه قرار گرفته و نتایج بدست آمده بشرح زیر می‌باشد: میزان زغال‌سنگ قابل استحصال در طرح استخراج معدن برابر با ۲۴۶ هزار تن (برای لایه K32) می‌باشد. ظرفیت استخراج معدن در پنج سال در نظر گرفته شده است. نسبت باطله برداری به ماده معدنی W/O در این معدن برابر با حدود ۱۸ می‌باشد[۱۴]. ارتفاع پله‌ها در معادن مختلف بین ۴ تا ۲۰ m می‌تواند متغیر باشد که معمولاً به جنس سنگ، پارامترهای ژئوتکنیک، نوع ماشین بارگیری، شیب لایه‌ها و پارامترهای موثر ماشین آلات بستگی دارد و در سنگ‌های نرم بین ۴ تا ۶ m ، در سنگ‌های نیمه سخت بین ۶ تا ۸ m و در سنگ‌های سخت بین ۸ تا ۲۰ m تعیین می‌شود. همچنین اندازه انتخاب شده برای ارتفاع پله باید با ارتفاعی که سیستم بارگیری قادر به استخراج است هماهنگی داشته باشد. اگرچه طراحی پله‌های مرتفع موجب کاهش هزینه‌های حفاری و انفجار می‌شوند. اما احتمال حادثه را نیز افزایش می‌دهند و از طرف دیگر ارتفاع کمتر از ۴ m نیز به دلیل افزایش هزینه حفاری و افزایش زمان، کمتر طراحی می‌شوند. غیر از عوامل یاد شده شرایط جوی نیز در انتخاب ارتفاع پله مؤثرند بالاخص مناطق برفگیر که احتمال یخبندان هم زیاد است. در این معدن با توجه به نوع ماشین آلات و ابعاد ارتفاعی مدل بلوکی (ضخامت ۲ m ریزبلوک‌ها که متناسب با ضخامت لایه‌های تعیین شده‌اند)، ارتفاع پله‌ها ۶ m درنظر گرفته شده است. شکل (۲ و ۳) نمایی سه بعدی از پیت بهینه طراحی شده در بخش شمالی و جنوبی را نشان می‌دهد.



شکل ۲: نمای پله‌ها و رمپ‌ها و ابعاد بخش شمالی پیت طراحی شده



شکل ۳: نمای پله‌ها و رمپ‌ها در بخش جنوبی پیت طراحی شده

۳- چکش‌های هیدرولیکی

چکش‌های هیدرولیکی ابزارهای قدرتمندی هستند که در پروژه‌های عمرانی و معدنی برای تخریب بتن، سنگ و سایر مواد سخت به کار می‌روند. عملکرد این چکش‌ها به عوامل متعددی از جمله پارامترهای طراحی چکش، شرایط عملیاتی، و مشخصات ماده هدف بستگی دارد. پیش‌بینی دقیق عملکرد چکش هیدرولیکی، که معمولاً با معیارهایی مانند نرخ شکست ماده، انرژی ضربه، یا عمق نفوذ سنجیده می‌شود، برای بهینه‌سازی فرآیند تخریب، کاهش هزینه‌ها، و افزایش ایمنی عملیات امری حیاتی است. روش‌های سنتی پیش‌بینی اغلب بر اساس مدل‌های تجربی یا روابط تحلیلی ساده بنا شده‌اند که ممکن است در مواجهه با پیچیدگی‌ها و غیرخطی بودن روابط بین پارامترهای ورودی و خروجی، دقت کافی نداشته باشند[۱۵].

۴- نرخ شکست آنی چکش هیدرولیکی (IBR)

IBR یکی از پارامترهای کلیدی در حفاری صخره‌ای و بهره‌برداری از معادن است که نشان‌دهنده مقدار نفوذ لحظه‌ای نوک چکش در سنگ طی یک بازه زمانی می‌باشد. این شاخص معمولاً بر حسب مترمکعب بر ساعت (m3/h) بیان می‌شود. IBR تغییرات لحظه‌ای عملکرد چکش را در هر سیکل ضربه منعکس می‌کند و برای تحلیل دقیق‌تر عملکرد دستگاه و شرایط سنگ مورد استفاده قرار می‌گیرد[۱۶]. در جدول (۲) پارامترهای توده سنگ و ماده سنگ و IBR چکش هیدرولیکی ضربه‌ای سنگ‌های در برگیرنده آورده شده است.

جدول ۲: پارامترهای توده سنگ و ماده سنگ و IBR برآوردی چکش هیدرولیکی ضربه‌ای سنگ‌های در برگیرنده

ردیف	نوع سنگ	تخلخل	UCS	چسبندگی توده سنگ	وزن مخصوص سنگ	عمق نفوذ مته در هر ضربه	تعداد ضربه چکش در هر ثانیه	انرژی هر ضربه	ضریب K	IBR
		درصد	Mpa	Mpa	g/cm^3	m	عدد	J		m^3/hr
۱	ماسه سنگ	۴.۱۳	۷۱.۳۷	۲.۳۳	۲.۷	۰.۰۱۴	۶	۲۰۰۰	۰.۰۱۹	۳.۱۹
۲	ماسه سیلتی	۳.۱۶	۷۳.۹	۲.۳۹	۲.۵	۰.۰۱۴	۶	۲۰۰۰	۰.۰۳	۴.۸۷
۳	آرژیلیت	۱.۹۸	۲۴.۶۹	۰.۷۵	۲.۱	۰.۰۴۱	۶	۲۰۰۰	۰.۰۲	۹.۷۲
۴	سیلت استون	۳.۰۲	۳۹.۳۸	۱.۰۱	۲.۴۲	۰.۰۲۵	۶	۲۰۰۰	۰.۰۲۵	۷.۶۲
۵	شیل	۱.۸۲	۲۱.۲۶	۰.۵۲	۱.۸۶	۰.۰۴۷	۶	۲۰۰۰	۰.۰۱۸	۱۰.۱۶

مقادیر UCS این جدول میانگین سه روش (چکش اشمیت، بار نقطه‌ای، Roclab) است؛ مدل‌سازی با UCS آزمون بار نقطه‌ای هر نمونه انجام شد.

۵- پیش بینی و بهینه سازی عملکرد چکش هیدرولیکی با استفاده از الگوریتم ازدحام ذرات

پیش بینی و بهینه سازی عملکرد تجهیزات حفاری و اندرکنش ابزار سنگ یکی از مهم‌ترین چالش‌های مهندسی معدن و ژئومکانیک است. در فرایند حفاری ضربه‌ای، کارایی چکش هیدرولیکی به پارامترهای متعددی از جمله UCS، ویژگی‌های مکانیکی سنگ، شرایط مته و میزان انرژی ضربه بستگی دارد. از آنجا که روابط حاکم بر رفتار دستگاه و سنگ غالباً پیچیده، غیرخطی و گاهی ناشناخته هستند، استفاده از روش‌های کلاسیک بهینه‌سازی همواره قادر به ارائه پاسخ‌های دقیق و پایدار نیستند. در چنین شرایطی، بهره‌گیری از الگوریتم‌های هوشمند و روش‌های جستجوی فراابتکاری[۷] رویکردی مؤثر برای یافتن نقطه کار بهینه محسوب می‌شود[۶].

یکی از روش‌های رایج فراابتکاری در این حوزه، الگوریتم PSO است. این الگوریتم الهام‌گرفته از رفتار اجتماعی موجودات زنده به‌ویژه حرکت جمعی ماهی‌ها و پرندگان طراحی شده و نخستین‌بار توسط کندی و ایبرهارت ارائه شد. PSO با بهره‌گیری از جمعیتی از «ذرات»، که هر کدام یک راه‌حل ممکن در فضای مسئله را نمایش می‌دهند، می‌تواند بدون نیاز به مشتق‌گیری یا دانستن شکل تابع هدف، بهترین ترکیب پارامترها را بیابد. سادگی، سرعت بالای همگرایی، و توانایی جستجو در توابع غیرخطی و پیچیده، PSO را به ابزاری مناسب برای بهینه‌سازی مسائل

[7] - Metaheuristics

مهندسی تبدیل کرده است[۳].

در این پژوهش، با توجه به اینکه عملکرد چکش هیدرولیکی از طریق مدل‌سازی *ANN* پیش‌بینی شده است، از الگوریتم *PSO* برای بهینه‌سازی ورودی‌های مدل و یافتن بیش‌ترین مقدار *IBR* استفاده شده است. در واقع، *PSO* به جای بهینه‌سازی مستقیم دستگاه، پارامترهای ورودی مدل پیش‌بینی را طوری تنظیم می‌کند که خروجی مدل (*IBR*) بیشینه شود. این روش یک مزیت کلیدی دارد:

از آنجا که مدل *ANN* نقش شبیه‌ساز رفتار دستگاه را بازی می‌کند، *PSO* می‌تواند پیش از آزمایش‌های پرهزینه‌ی میدانی شرایط عملیاتی امیدبخش را پیشنهاد دهد [۱۷, ۱۸]. به این ترتیب: (الف) نقش هر پارامتر در افزایش یا کاهش خروجی مدل مشخص می‌شود؛ (ب) محدوده‌ی مطلوب متغیرهای عملیاتی تعیین می‌گردد؛ (پ) گزینه‌های امیدبخش پیش از آزمون میدانی شناسایی می‌شوند؛ (ت) ابزاری کمکی برای تصمیم‌گیری فراهم می‌شود. بنابراین انتخاب *PSO* به‌دلیل توانایی آن در مواجهه با مدل‌های غیرخطی و عدم وابستگی به مشتق تابع هدف منطقی است. با این حال، چون مدل جایگزین رفتار واقعی دستگاه نیست، نتایج باید با آزمون میدانی تأیید شوند.

۶- پیاده‌سازی مدل و تحلیل نتایج

۶-۱- داده‌ها و پیش‌پردازش

مجموعه‌ی داده شامل ۳۰ نمونه از پنج سنگ‌شناسی (آرژیلیت، ماسه‌سنگ، شیل، سیلت‌استون و ماسه‌سیلتی) است. UCS هر نمونه از آزمون بار نقطه‌ای به دست آمد. عمق نفوذ با رابطه‌ی $h = E/(UCS \cdot A)$ ($E = 2000$ J ، A $= 0.002$ m²) و IBR با رابطه‌ی نیمه‌تجربی $IBR = N = 6)(E \cdot N/UCS) \cdot k$ ضربه بر ثانیه؛ k ضریب تجربی وابسته به سنگ‌شناسی) محاسبه شد. بنابراین عمق نفوذ و IBR اندازه‌گیری مستقیم میدانی نیستند، بلکه برآوردهایی تابع UCS و نوع سنگ‌اند و شبکه‌ی عصبی عملاً این رابطه‌ی از پیش‌شناخته را تقریب می‌زند. در این مقاله «IBR» همواره به معنی IBR برآوردی است.

با توجه به اینکه متغیرهای ورودی دارای واحدها و مقیاس‌های متفاوت هستند، جهت جلوگیری از ایجاد عدم توازن در آموزش *ANN* و نیز افزایش سرعت همگرایی الگوریتم بهینه‌سازی، کلیه داده‌ها پیش از ورود به مدل تحت فرآیند نرمال‌سازی استاندارد[8] قرار گرفتند. در این روش، مقادیر هر متغیر بر اساس میانگین و انحراف معیار همان متغیر تبدیل شده و داده‌ها در بازه‌ای با میانگین صفر و واریانس یک قرار می‌گیرند. پارامترهای نرمال‌سازی شامل میانگین و انحراف معیار مربوط به هر ویژگی در جدول (۳) ارائه شده است.

جدول ۳: پارامترهای نرمال سازی داده‌ها جهت استفاده در الگوریتم

پارامتر	میانگین	انحراف معیار
UCS (MPa)	۴۵.۶۶۵۷	۲۰.۴۲۰۱
عمق نفوذ (m)	۰.۰۲۶۹۰	۰.۰۱۲۲۷
IBR دستگاه (m^3/h)	۷.۱۳۵۷	۲.۴۲۳۳

پیش از مدل‌سازی، به‌منظور اطمینان از عدم تأثیرگذاری نامتناسب نمونه‌های غیرعادی بر فرآیند آموزش شبکه، بررسی داده‌های پرت با استفاده از روش امتیاز استاندارد (Z-score) بر روی هر یک از متغیرهای ورودی (UCS، عمق نفوذ) و خروجی (IBR) انجام شد. با در نظر گرفتن آستانه‌ی استاندارد $|Z|>2.5$ ، هیچ‌یک از ۳۰ نمونه‌ی مجموعه داده به‌عنوان داده‌ی پرت شناسایی نشد (حداکثر مقادیر Z محاسبه‌شده برای UCS، عمق نفوذ و IBR به‌ترتیب برابر با ۱.۳۶، ۲.۲۹ و ۱.۹۸ بود)، که نشان‌دهنده‌ی یکنواختی نسبی و کیفیت مناسب مجموعه داده‌ی تجربی مورد استفاده در این پژوهش است.

برای بررسی هم‌خطی ورودی‌ها، ضریب همبستگی پیرسون و عامل تورم واریانس محاسبه شد: $r = -0.933$ و $VIF = 7.68$. این همبستگی شدید طبیعی است، زیرا عمق نفوذ در داده از رابطه‌ی $h = E/(UCS \cdot A)$ با انرژی ضربه‌ی $E = 2000$ J تولید شده‌اند. حداکثر انرژی ضربه‌ی اسمی چکش برابر ۴۰۰۰ ژول است. اگرچه VIF از آستانه‌ی مرسوم ۱۰

[8] - Standardization

کمتر است، ورودی‌ها عملاً یک متغیر مستقل ندارند و اثر مستقل آن‌ها از داده قابل تفکیک نیست؛ نتایج تحلیل حساسیت و بهینه‌سازی باید با این محدودیت تفسیر شوند.

۶-۲- ساختار مدل و آموزش شبکه

شبکه‌ی عصبی مصنوعی پیش‌خور برای پیش‌بینی *IBR* با ساختار زیر ساخته شد:

لایه ورودی: ۲ نورون (*UCS* و عمق نفوذ (*depth*))

لایه پنهان: ۱ نورون با تابع فعال‌ساز تانژانت هایپربولیک(*tanh*)

لایه خروجی: ۱ نورون (*IBR*) با تابع فعال‌ساز خطی

تابع ریاضی مدل به صورت رابطه (۱) تعریف می‌شود:

$$IBR = 977.5827 \times tanh(-0.0359 \times X1 + 0.0828 \times X2 + 2.6244) - 959.9663 \quad (۱)$$

$$X1 = \frac{UCS - 45.6657}{20.4201} \quad (۲)$$

$$X2 = \frac{depth - 0.02690}{0.01227} \quad (۳)$$

که در آن *IBR* نرخ شکست آنی برآوردی*(m³/h)* ، *UCS* مقاومت فشاری تک‌محوره*(MPa)* ، h عمق نفوذ مته در هر ضربه*(m)*، $X1$ مقاومت فشاری استانداردشده (بدون بعد) و $X2$ عمق نفوذ استانداردشده (بدون بعد) است. مقادیر ۴۵.۶۶۵۷ *MPa* و ۰.۰۲۶۹۰ *m* میانگین و ۲۰.۴۲۰۱ *MPa* و ۰.۰۱۲۲۷ *m* انحراف معیار نمونه‌ها هستند.

شبکه با الگوریتم *Levenberg–Marquardt* روی ورودی و خروجی استانداردشده آموزش داده شد و وزن‌ها و بایاس‌ها ثابت گردید. برای کاهش حساسیت به مقداردهی اولیه، هر آموزش با ۵ مقداردهی اولیه‌ی تصادفی (برای مدل نهایی ۳۰ مقداردهی) تکرار و شبکه‌ی با کمترین خطای آموزش نگه داشته شد؛ در مدل نهایی هر ۳۰ تکرار به خطای یکسان رسیدند.

تعداد نورون‌های پنهان از ۱ تا ۸ با اعتبارسنجی *5-fold* تکراری (۱۰ تکرار؛ یک مقداردهی اولیه در هر فُلد) مقایسه شد (جدول ۴). معماری ۱ نورونی بیشترین *R^2 (0.905)* و کمترین پراکندگی (۰.۰۱۳) را داشت؛ معماری ۲ نورونی میانگین کمتر و پراکندگی بسیار بیشتری نشان داد (۰.۸۳۹ ± ۰.۲۴۳). از ۴ نورون به بعد، تعداد پارامترها (۱۷ تا ۳۳) از تعداد نمونه‌های آموزشی (۲۴ نمونه در هر فُلد) بیشتر شد و مدل واگرا شد *(R^2)* منفی .*(بنابراین ساختار ۱ نورونی انتخاب شد.*

جدول ۴: مقایسه‌ی تعداد نورون‌های لایه‌ی پنهان با اعتبارسنجی *5-fold* تکراری (میانگین ± انحراف معیار)

نورون	پارامتر	R^2	*RMSE (m³/h)*
۱	۵	۰.۰۱۳ ± ۰.۹۰۵	۰.۰۴۸ ± ۰.۷۳۱
۲	۹	۰.۲۴۳ ± ۰.۸۳۹	۰.۴۸۸ ± ۰.۸۳۵
۳	۱۳	۰.۲۱۱ ± ۰.۷۶۴	۰.۴۶۹ ± ۱.۰۶۹
۴	۱۷	$10^{5}\times$-۱.۵ ± $10^{5}\times$۴.۷	۹۲۱.۶ ± ۲۹۲.۹
۵	۲۱	۷۵.۴ ± -۳۶.۶	۱۲.۵۰ ± ۸.۵۳
۶	۲۵	۱۵۰.۵± -۶۷.۲	۱۶.۴۳ ± ۱۲.۰۰
۷	۲۹	۶۹۹.۷ ± -۲۶۶.۲	۳۲.۶۲ ± ۲۳.۶۵
۸	۳۳	۳۲.۶ ± -۴۰.۲	۵.۵۴ ± ۱۴.۳۶

*نکته: این مقایسه با یک مقداردهی اولیه در هر فُلد و با مقیاس‌دهی پیش‌فرض*MATLAB (min–max) *انجام شد؛ ارزیابی نهایی (جدول ۵) با ۵ مقداردهی و ورودی استانداردشده است.*

ساختار ۲-۱-۱ (دو ورودی، یک نورون پنهان، یک خروجی؛ ۵ پارامتر) انتخاب شد، زیرا در مقایسه‌ی ۱ تا ۸ نورون پنهان بیشترین R^2 و کمترین پراکندگی را داشت و با حدود ۲۴ نمونه‌ی آموزشی در هر فولد، ساختارهای بزرگ‌تر (حداقل ۴ نورون؛ ۱۷ پارامتر یا بیشتر) دچار بیش‌برازش و واگرایی شدند.

۶-۳- ارزیابی مدل و مقایسه با رگرسیون

به‌دلیل حجم کم داده (۳۰ نمونه)، تقسیم یک‌باره‌ی آموزش/آزمون پایدار نیست؛ بنابراین دقت مدل با اعتبارسنجی 5-fold تکراری (۱۰ تکرار با تقسیم‌بندی تصادفی متفاوت) سنجیده شد. در هر فُلد، شبکه‌ی عصبی ۲-۱-۱ و دو مدل مرجع (رگرسیون خطی و درجه‌دو) روی همان داده‌های آموزش برازش و روی همان داده‌های آزمون ارزیابی شدند. پیش‌بینی‌های برون‌نمونه‌ی هر ۳۰ نمونه جمع و شاخص‌هایMSE ، MAE، RMSE، MAPE، R^2 و r محاسبه شد و میانگین ± انحراف معیار ۱۰ تکرار در جدول (۵) آمده است. مدل نهایی روی تمام ۳۰ نمونه برازش شد (رابطه‌ی ۱).

شبکه‌ی عصبی به $R^2 = 0.901 \pm 0.011$ و RMSE = 0.749 ± 0.042 m³/h رسید، اما رگرسیون خطی (R^2 =

$R^2 = 0.955$ ؛0.924 RMSE = 0.654) و درجه‌دو ($R^2 = 0.955$ ؛ RMSE = 0.504) در همان فُلدها دقیق‌تر بودند. بنابراین برتری شبکه‌ی عصبی در این داده اثبات نشد و آن را باید مدلی هم‌سطح با مدل‌های ساده دانست. این نتیجه با ماهیت داده سازگار است، زیرا IBR در این مجموعه از رابطه‌ای تقریباً متناسب با عکس مقاومت سنگ محاسبه شده و مدل ساده‌ی چندجمله‌ای آن را به‌خوبی تقریب می‌زند. انحراف معیار گزارش‌شده فقط تغییرات ناشی از تقسیم‌بندی داده را نشان می‌دهد و عدم قطعیت نمونه‌گیری را شامل نمی‌شود. برازش مدل نهایی روی کل داده ($R^2 = 0.943$؛ RMSE = 0.568؛0.452 MAE = 9.36٪ ؛ MAPE =) معیار کیفیت برازش است، نه تعمیم.

بر اساس جدول (۵)، شبکه‌ی عصبی نسبت به رگرسیون خطی و درجه‌دو برتری پیش‌بینی نشان نداد؛ دقیق‌ترین مدل در این داده رگرسیون درجه‌دو بود ($R^2 = 0.955$ در برابر ۰.۹۰۱). بنابراین در این پژوهش شبکه‌ی عصبی نه به‌عنوان روشی برتر برای پیش‌بینی، بلکه به‌عنوان مدلی غیرخطی و هموار برای تحلیل حساسیت و جست‌وجوی عمق نفوذ به‌کار رفته است. دلیل نگه‌داشتن آن در بخش بهینه‌سازی این است که خروجی tanh محدود می‌ماند، درحالی‌که رگرسیون درجه‌دو هنگام برون‌یابی به مقادیر غیرواقع‌بینانه می‌رسد (میانگین ۳۶.۷ مترمکعب بر ساعت در ۴۰۰۰ J). این محدودبودن نشانه‌ی درستی فیزیکی نیست و فقط از شکل تابع ناشی می‌شود.

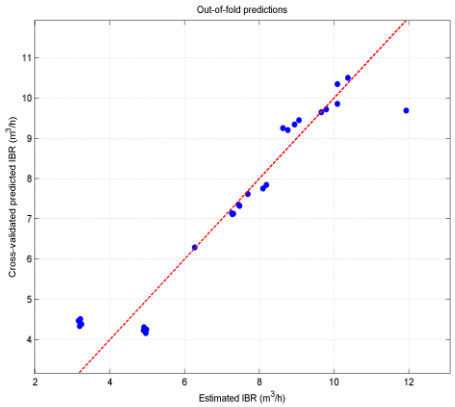
جدول ۵: ارزیابی ANN در مقایسه با رگرسیون خطی و درجه‌دو (اعتبارسنجی ۵ -fold با ۱۰ تکرار)

معیار ارزیابی	ANN (2-1-1)	Linear	Quadratic
MSE	۰.۵۶۲۱± ۰.۰۶۳۲	۰.۴۲۹۲± ۰.۰۴۴۱	۰.۲۵۳۹± ۰.۰۱۹۲
MAE	۰.۵۵۶۴± ۰.۰۳۱۷	۰.۵۰۷۳± ۰.۰۲۱۳	۰.۴۰۹۷± ۰.۰۱۷۷
RMSE	۰.۷۴۸۷± ۰.۰۴۱۹	۰.۶۵۴۳± ۰.۰۳۴۰	۰.۵۰۳۶± ۰.۰۱۹۰
MAPE (%)	۱۰.۷۰± ۰.۷۵	۱۰.۵۶± ۰.۴۷	۷.۴۰± ۰.۴۹
R	۰.۹۴۹۸± ۰.۰۰۵۷	۰.۹۶۱۶± ۰.۰۰۴۰	۰.۹۷۸۳± ۰.۰۰۱۷

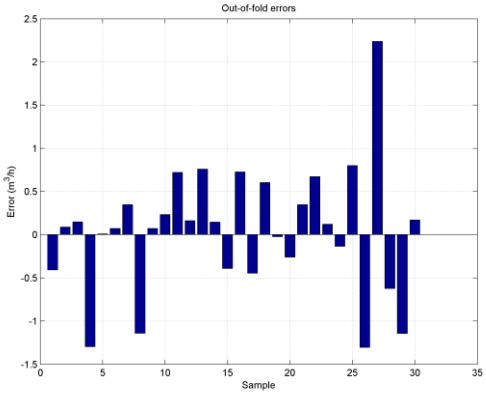
شکل (۴) مقادیر پیش‌بینی‌شده‌ی برون‌نمونه‌ای را در برابر IBR برآوردی نشان می‌دهد و شکل‌های (۵) و (۶) خطای هر نمونه و توزیع خطاها را. ۲۵ نمونه از ۳۰ نمونه خطای مطلق ≤ ۰.۸۰ m^3/h داشتند؛ پنج نمونه‌ی دیگر خطای ۱.۱۴ تا ۲.۲۴ داشتند: نمونه‌ی ۲۷ (شیل؛ کمترین UCS و بیشینه‌ی عمق، یعنی لبه‌ی دامنه‌ی داده) با کم‌برآورد ۲.۲۴ و چهار نمونه‌ی ماسه‌سنگ با بیش‌برآورد ۱.۱۴ تا ۱.۳۰ (خطا IBR = برآوردی − پیش‌بینی مدل؛ مثبت یعنی کم‌برآورد). میانگین باقیمانده به تفکیک سنگ: ماسه‌سنگ ۱.۲۲−، ماسه‌سیلتی ۰.۷۱+، شیل ۰.۶۱+، آرژیلیت ۰.۲۲− و سیلت‌استون ۰.۱۶+. ماسه‌سنگ و ماسه‌سیلتی مقاومت و عمق تقریباً یکسان دارند (۷۰ تا ۷۳ MPa ؛ ۰.۰۱۴ m) ولی IBR آن‌ها متفاوت است (۳.۲ و ۴.۹۵)، چون ضریب تجربی k (۰.۰۱۹ و ۰.۰۳۰) ورودی مدل نیست. مدل این دو سنگ را نمی‌تواند تفکیک کند و مقداری میانی پیش‌بینی می‌کند که خطای سیستماتیک با علامت مخالف ایجاد می‌کند.

۴-۶- تحلیل حساسیت مدل

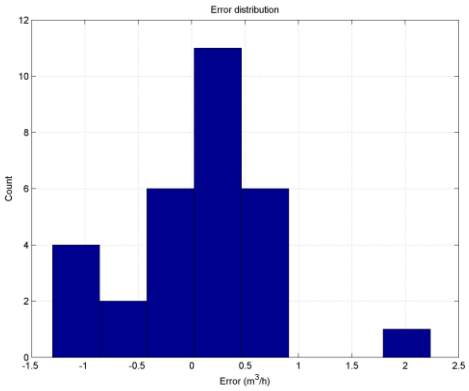
برای سنجش اثر ورودی‌ها، مشتق جزئی خروجی مدل نسبت به هر ورودی در ۳۰ نمونه محاسبه و میانگین مطلق آن در انحراف معیار همان متغیر ضرب شد تا مقایسه مستقل از واحد باشد. میانگین مشتق‌ها ۰.۰۳۷- (m^3/h)/*MPa* برای *UCS* و ۱۴۱ (m^3/h)/*m* برای عمق نفوذ است. پس از نرمال‌سازی، تغییر یک انحراف معیار در *UCS* (۲۰.۴ *MPa*) به‌طور متوسط ۰.۷۵ m^3/h و در عمق نفوذ (۰.۰۱۲۳ *m*) ۱.۷۳ m^3/hr *IBR* پیش‌بینی‌شده را تغییر می‌دهد (نسبت ≈ ۲.۳).



شکل۴: مقایسه‌ی IBR برآوردی با مقدار پیش‌بینی‌شده‌ی برون‌نمونه‌ای (میانگین ۱۰ تکرار اعتبارسنجی 5-fold) برای شبکه‌ی عصبی ۲-۱-۱

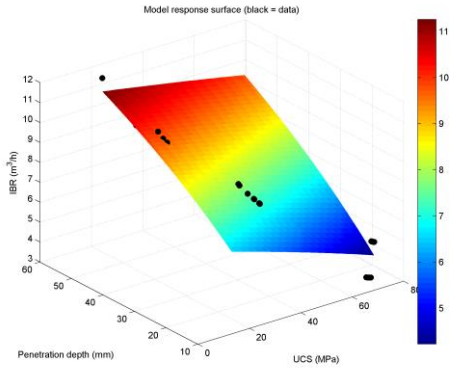


شکل ۵ :خطای پیش‌بینی برون‌نمونه‌ای (IBR برآوردی – پیش‌بینی مدل) به تفکیک شماره‌ی نمونه



شکل ۶: توزیع خطای پیش‌بینی برون‌نمونه‌ای

شکل (۷) سطح پاسخ مدل را نشان می‌دهد. چون مدل یک نورون *tanh* دارد، خروجی با افزایش عمق نفوذ افزایش و با افزایش *UCS* کاهش می‌یابد (رفتار یکنوا). نقاط سیاه نشان می‌دهد داده‌ها در یک نوار باریک قرار دارند (عمق کم برای *UCS* زیاد و برعکس)؛ بخش‌های دور از این نوار برون‌یابی مدل‌اند. به‌دلیل همبستگی شدید ورودی‌ها $(r = -0.93)$ اثر مستقل آن‌ها قابل تفکیک نیست و نسبت ۲.۳ فقط رفتار مدل را توصیف می‌کند.



شکل۷: سطح پاسخ خروجی شبکه‌ی عصبی بر حسب *UCS* و عمق نفوذ (نقاط سیاه: ۳۰ نمونه‌ی داده؛ خروجی مدل برازش‌شده، نه نتیجه‌ی روش *RSM*)

۵-۶- بهینه‌سازی عمق نفوذ با الگوریتم ازدحام ذرات (تحلیل سناریو)

برای یافتن عمق نفوذ بیشینه‌کننده‌ی خروجی مدل، *PSO* (30 ذره، ۱۰۰ تکرار، $w = 0.7$، $c_1 = c_2 = 1.5$) روی شبکه‌ی آموزش‌دیده‌ی ثابت (رابطه‌ی ۱) به‌کار رفت. متغیر تصمیم تنها عمق نفوذ بود و *UCS* هر نمونه، به‌عنوان ویژگی ذاتی سنگ، ثابت ماند. چون طبق $h = E/(UCS \times A)$ افزایش عمق در *UCS* ثابت معادل افزایش انرژی هر ضربه است، بازه‌ی جستجو برابر $\left[min\left(0.055, {E_{max}}/{(UCS \times A)}\right), 0.014\right]$ گرفته شد. برای هر نمونه i با مقاومت فشاری تک‌محوری ثابت UCS_i (MPa)، متغیر تصمیم عمق نفوذ h_i (m) در بازه محدوده فیزیکی و تجربی $h_{min} \le h_i \le h_{max,I}$ جست‌وجو می‌شود:

- حد پایین تجربی: $h_{min} = 0.014\ m$ (کمینه عمق نفوذ مشاهده‌شده در داده‌های تجربی)

- حد بالا: $h_{max,i} = min(0.055, h_{E,i})$ ؛ ۰.۰۵۵ m حد بالای تجربی مجاز (بیشینه عمق مشاهده‌شده در معدن) است؛ $h_{E,i}$ حد ناشی از محدودیت فیزیکی انرژی چکش است که براساس رابطه $h_{E,i} = \frac{E_{max}}{UCS_i \times 10^6 \times A} = \frac{E_{max}}{2000 \times UCS_i}$ محاسبه می‌شود؛ که در آن E_{max} سقف انرژی مجاز هر ضربه چکش (بر حسب J)، $A = 0.002$ m^2 مساحت قلم چکش و UCS_i برحسب MPa است. برای مثال، حداکثرانرژی ضربه‌ی اسمی چکش $E_{max} = 4000$ J است و سقف‌های ۲۵۰۰ تا ۶۰۰۰ ژول برای بررسی حساسیت آمده‌اند و همچنین حد عمق نفوذ انرژی به‌صورت ساده‌شده $h_{E,i} = \frac{2}{UCS_i}$ تعیین می‌گردد.
- **تابع هدف:** بیشینه‌سازی IBR حاصل از رابطه (۱) نسبت به متغیر تصمیم h_i با فرض ثابت بودن UCS_i.

بدون اعمال سقف

فیزیکی انرژی (E_{max}) عمق نفوذ بهینه در تمام نمونه‌ها بدون توجه به سختی سنگ روی حد بالای تجربی (۰.۰۵۵ m) قفل می‌شد و در ۲۰ نمونه از ۳۰ نمونه (به‌ویژه در سازندهای سخت مانند ماسه‌سنگ و ماسه‌سیلتی) انرژی ضربه‌ای بیش از 4000 J (تا حدود 8000 J) نیاز بود که خارج از توان اسمی دستگاه چکش هیدرولیکی موجود است.

بنابراین، با قید فیزیکی $E_{max} = 4000$ J، برای ماسه‌سنگ با $UCS = 71.11$ MPa، عمق نفوذ بهینه در مرز فیزیکی $h_E = \frac{2}{71.11} \approx 0.028$ m (۲۸ mm) به‌صورت ایمن کران‌دار گردید. در سقف ۴۰۰۰ J ، میانگین عمق بهینه ۰.۰۴۴۱ m و میانگین IBR بهینه ۹.۲۸ m^3/h بود؛ میانگین بهبود نسبی نمونه‌ها نسبت به پیش‌بینی همان مدل در عمق فعلی ۳۵٪ شد (جدول ۶). قید عمق برای آرژیلیت و شیل و قید انرژی برای ماسه‌سنگ، ماسه‌سیلتی و سیلت‌استون فعال بود. بهبود بین ۴٪ (شیل) و ۵۳٪ (ماسه‌سنگ) متغیر بود و نمونه‌ی ۲۷ بهبود صفر داشت، چون از قبل در حد بالای عمق بود. جدول (۷) نشان می‌دهد با افزایش سقف از ۲۵۰۰ به ۶۰۰۰ J ، میانگین بهبود از ۱۱٪ به ۵۲٪ می‌رسد؛ بنابراین هیچ عدد واحدی را نمی‌توان به‌عنوان «بهبود بهینه‌سازی» ارائه کرد. شکل (۸) میانگین IBR برآوردی، پیش‌بینی مدل در عمق فعلی و پیش‌بینی مدل در شرایط بهینه را به تفکیک سنگ نشان می‌دهد.

الگوریتم برای هر نمونه در میانگین ۱.۰ و حداکثر ۲ تکرار به مقدار نهایی همگرا شد. این همگرایی سریع نتیجه‌ی یکنوایی مدل نسبت به عمق است و همین بهینه را بدون PSO نیز می‌توان تحلیلی (حد بالای بازه‌ی مجاز) یافت؛ PSO به‌عنوان ابزاری عمومی به‌کار رفته که برای مدل‌های غیریکنوا نیز قابل‌استفاده است.

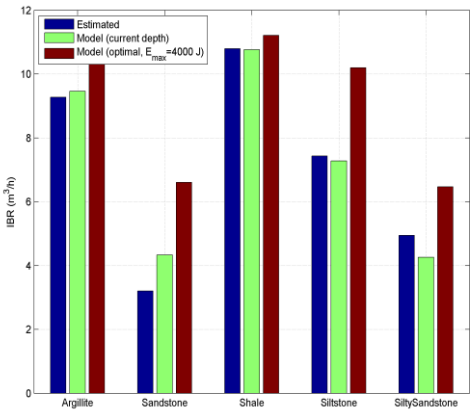
جدول ۶: نتایج بهینه‌سازی عمق نفوذ به تفکیک نوع سنگ در سقف انرژی ۴۰۰۰ J (میانگین نمونه‌های هر سنگ)

نوع سنگ	تعداد نمونه های هر نوع سنگ	عمق نفوذ بهینه	انرژی بهینه	IBR برآوردی	IBR فعلی	IBR بهینه	بهبود
		m	J	m^3/hr	m^3/hr	m^3/hr	%
آرژلیت	۷	۰.۰۵۵۰	۲۸۵۶	۹.۲۸	۹.۴۶	۱۱.۰۸	۱۷.۲
ماسه سنگ	۴	۰.۰۲۸۰	۴۰۰۰	۳.۲۰	۴.۳۳	۶.۶۱	۵۲.۷
شیل	۳	۰.۰۵۵۰	۲۲۱۲	۱۰.۸۰	۱۰.۷۶	۱۱.۲۱	۴.۳
سیلت استون	۱۰	۰.۰۴۹۵	۴۰۰۰	۷.۴۳	۷.۲۷	۱۰.۲۰	۴۰.۳
ماسه سیلتی	۶	۰.۰۲۷۵	۴۰۰۰	۴.۹۵	۴.۲۶	۶.۴۷	۵۱.۸
میانگین کل	۳۰	۰.۰۴۴۱	-	۷.۱۴	-	۹.۲۸	۳۵.۳

نکته: IBR بر حسب m^3/h

جدول ۷: حساسیت نتایج بهینه‌سازی به سقف انرژی ضربه (میانگین ۳۰ نمونه، *UCS* ثابت)

سقف انرژی (*J*)	میانگین *IBR* بهینه (*m³/h*)	میانگین بهبود نسبی (٪)	میانگین عمق بهینه (*m*)
۲۵۰۰	۷.۸۸	۱۱.۲	۰.۰۳۲۹
۳۰۰۰	۸.۴۷	۲۰.۷	۰.۰۳۷۶
۴۰۰۰	۹.۲۸	۳۵.۳	۰.۰۴۴۱
۵۰۰۰	۹.۷۸	۴۵.۳	۰.۰۴۸۱
۶۰۰۰	۱۰.۰۹	۵۲.۴	۰.۰۵۰۵



شکل ۸ :مقایسه‌ی میانگین *IBR* برآوردی، پیش‌بینی مدل در عمق فعلی و پیش‌بینی مدل در شرایط بهینه (*E_{max} = 4000 J*) به تفکیک نوع سنگ

این نتایج برون‌یابی مدل‌اند. در داده، انرژی ضربه ثابت (≈ ۲۰۰۰ *J*) و عمق وابسته به *UCS* است، پس اثر عمق در *UCS* ثابت از داده یاد گرفته نشده است. نتیجه به مدل نیز وابسته است: اگر در همین بهینه‌سازی رگرسیون درجه‌دو جایگزین شبکه شود، مقادیر غیرواقع‌بینانه می‌شوند (میانگین *IBR* ≈ ۳۶.۷ *m³/h* در ۴۰۰۰ *J*). افزون بر آن، طبق *$IBR = (E{\cdot}N/UCS){\cdot}k$*، *IBR* متناسب با توان *E·N* است؛ بهبود فقط وقتی ممکن است که با افزایش انرژی ضربه، فرکانس ثابت بماند (افزایش توان ورودی چکش). این نتایج معادل بهینه‌سازی چکش فعلی نیستند، فقط جهت اثر را نشان می‌دهند و نیازمند آزمون میدانی‌اند.

۶-۶- محدودیت‌های مطالعه

مهم‌ترین محدودیت‌های این مطالعه عبارت‌اند از:

- محدودیت در حجم و تنوع نمونه‌ها: ارزیابی‌ها منحصر به ۳۰ نمونه تجربی برداشت‌شده از یک معدن واحد (معدن زغال‌سنگ کوچکعلی شمالی طبس) و شامل پنج گروه سنگ‌شناسی است؛ به‌طوری‌که برخی گروه‌ها مانند شیل (۳ نمونه) و ماسه‌سنگ (۴ نمونه) دارای تعداد داده‌های محدودی هستند.
- عدم اعتبارسنجی با اندازه‌گیری مستقیم: مقادیرIBR و عمق نفوذ بر اساس روابط تحلیلی و نیمه‌تجربی به‌دست آمده‌اند، نه اندازه‌گیری میدانی مستقیم، و اعتبارسنجی با اندازه‌گیری مستقیم عملکرد چکش انجام نشده است.
- هم‌خطی متغیرها و محدودیت برون‌یابی: در داده‌های مورد مطالعه، انرژی ضربه و فرکانس ثابت فرض شده‌اند و دو متغیر ورودی (UCS و عمق نفوذ) دارای همبستگی منفی شدید (r = -0.93 و VIF = 7.68) هستند. این امر سبب می‌شود که اثر کاملاً مستقل متغیر عمق نفوذ به‌تنهایی تفکیک نگردد و خروجی‌های بهینه‌سازی تا حدی متکی بر برون‌یابی ریاضی مدل در مرزها باشند.
- عدم لحاظ مستقیم ضرایب سنگ‌شناسی: نوع سنگ یا ضریب ساختاری **(k)** به‌صورت یک متغیر مستقل وارد ANN نشده است، که این موضوع می‌تواند باعث ایجاد خطای سیستماتیک در پیش‌بینی IBR برای سازندهای سخت‌تر مانند ماسه‌سنگ و ماسه‌سیلتی شود.
- ارزیابی تطبیقی مدل‌ها: در بخش اعتبارسنجی آماری صرف، ANN برتری معناداری نسبت به مدل‌های رگرسیون درجه‌دو از خود نشان نداد، هرچند به لحاظ کنترل مرزهای فیزیکی خروجی در فاز بهینه‌سازی عملکرد پایدارتری ارائه می‌دهد.
- وابستگی بهبودها به سقف انرژی و توان دستگاه: نرخ بهبودهای پیش‌بینی‌شده (در بازه ۱۱٪ تا

٪۵۲ برای سطوح انرژی ۲۵۰۰ تا ۶۰۰۰ J) به‌شدت تابع سقف انرژی انتخابی (E_{max}) و فرض ثابت‌ماندن فرکانس ضربه چکش است؛ لذا برای چکش‌هایی با توان ثابت، روابط نیمه‌تجربی بهبودی را پیش‌بینی نمی‌کنند و پیاده‌سازی عملیاتی این نتایج نیازمند آزمون‌های میدانی تکمیلی است.

۷- نتیجه‌گیری

در این پژوهش با ۳۰ نمونه از معدن کوچکعلی شمالی طبس، شبکه‌ی عصبی ۱-۱-۲ برای پیش‌بینی *IBR* از *UCS* و عمق نفوذ ساخته شد. در اعتبارسنجی *5-fold* تکراری، شبکه به $R^2 = 0.901 \pm 0.011$ رسید، درحالی‌که رگرسیون خطی (۰.۹۲۴) و درجه‌دو (۰.۹۵۵) دقیق‌تر بودند. بنابراین در این مطالعه *ANN* برتری پیش‌بینی نسبت به مدل‌های مرجع نشان نداد و کاربرد آن صرفاً به‌عنوان مدلی غیرخطی برای تحلیل حساسیت و بهینه‌سازی عمق نفوذ است، نه روشی برتر برای پیش‌بینی. این نتیجه با ساختار داده سازگار است، زیرا *IBR* از مقاومت سنگ به‌صورت تقریباً متناسب با عکس آن برآورد شده است. بزرگ‌ترین خطاها مربوط به ماسه‌سنگ و ماسه‌سیلتی بود که مقاومت یکسان ولی ضریب تجربی k متفاوت دارند و k ورودی مدل نیست. حساسیت نرمال‌شده، اثر عمق نفوذ را حدود ۲.۳ برابر مقاومت نشان داد، ولی به‌دلیل همبستگی شدید دو ورودی *(r = -0.93)* اثر مستقل آن‌ها قابل تفکیک نیست. در بهینه‌سازی با *PSO*، با ثابت‌ماندن مقاومت هر نمونه و اعمال سقف انرژی ضربه، میانگین افزایش پیش‌بینی‌شده *IBR* از ٪۱۱ (سقف ۲۵۰۰ *J*) تا ٪۵۲ (سقف ۶۰۰۰ *J*) متغیر بود(٪۳۵ در ۴۰۰۰ *J*). تفسیر این نتایج با دو محدودیت اصلی مواجه است: تعداد بسیار کم نمونه در برخی سنگ‌ها (شیل ۳ و ماسه‌سنگ ۴ نمونه) و همبستگی شدید مقاومت فشاری و عمق نفوذ *(r = −0.93)*. این نتایج برون‌یابی مدل‌اند و فقط با فرض ثابت‌ماندن فرکانس ضربه (افزایش توان چکش) معنا دارند. برای کاربرد عملی، اندازه‌گیری میدانی مستقل *IBR*، تغییر مستقل انرژی و عمق، افزودن نوع سنگ (ضریب k)به ورودی‌ها و داده‌ی بیشتر لازم است.

۸- منابع

[1] ع. مجتهدزاده, ا. فرامرزی نژاد , ا. محمدی. (۱۴۰۳). بررسی کاربرد و مدیریت ماشین آلات سنگین در پروژه های عمرانی. بیست و چهارمین کنفرانس ملی مهندسی عمران، معماری و شهرسازی ,

[2] Y. Zhao, A. Noorbakhsh, M. Koopialipoor, A. Azizi, and M. Tahir. (2020). A new methodology for optimization and prediction of rate of penetration during drilling operations. Engineering with Computers, 36(2), 587–595.

[3] J. Kennedy and R. Eberhart. (1995). Particle swarm optimization. Proceedings of ICNN'95-international conference on neural networks, 4(1), 1942–1948.

[4] S. Kahraman. (1999). Rotary and percussive drilling prediction using regression analysis. International journal of rock mechanics and mining sciences, 36(7), 981–989.

[5] M. Iphar. (2012). ANN and ANFIS performance prediction models for hydraulic impact hammers. Tunnelling and Underground Space Technology, 27(1), 23–29.

[6] S. Hojjati, D. Tumac, and S. Jeon. (2021). Accurate performance prediction model for impact hammer developed using customized evolutionary algorithm. Tunnelling and Underground Space Technology, 109(1), 103773.

[7] J. Li *et al.* (2024). Theoretical and numerical analysis of the rock breaking process by impact hammer. Powder Technology, 448(1), 120254.

[8] C. Zhang, Y. Zhao, K. Gao, Z. Liu, J. Qin, and X. Lv. (2025). Numerical simulation and experimental study on rock fragmentation and crack propagation characteristics with hole enlargement under impact load. Rock Mechanics and Rock Engineering, 58(3), 3015–3037.

[9] M. Ismael, K. Abdelghafar, M. Sholqamy, and M. Elkarmoty. (2021). Performance prediction of hydraulic breakers in excavation of a rock mass. Rudarsko-geološko-naftni zbornik, 36(4), 69–

80.
[10] I. Ocak, S. E. Seker, and J. Rostami. (2018). Performance prediction of impact hammer using ensemble machine learning techniques. Tunnelling and underground space technology, 80(1), 269–276.
[11] C. Aksoy. (2014). Proposed chart for the selection of impact hammer. International Journal of Rock Mechanics and Mining Sciences, 68(1), 120–127.
[12] شرکت توسعه معادن فلات زرین کیمیا طبس. (۱۳۹۵). طرح اکتشاف معدن کوچکعلی طبس .
[13] شرکت توسعه معادن فلات زرین کیمیا طبس. (۱۴۰۱). طرح بهره برداری معدن کوچکعلی طبس .
[14] شرکت توسعه معادن فلات زرین کیمیا طبس. (۱۴۰۴). معدن کوچکعلی طبس .
[15] ا. جعفری and ع. رهبرفرش بر. (۱۳۸۰). کاربرد چکش های هیدرولیکی در حفاری تونل وبررسی پارامترهای مؤثر بر انتخاب آن. پنجمین کنفرانس تونل ایران ,
[16] آ. م. م. روانشادنیا.(۱۳۹۲) مدیریت ماشین‌آلات عمرانی برای مهندسان و مدیران پروژه .(no. 1100) سیمای دانش، آذر, ۱۳۹۲.362 .p ,
[17] E. Ebrahimi, M. Monjezi, M. R. Khalesi, and D. J. Armaghani. (2016). Prediction and optimization of back-break and rock fragmentation using an artificial neural network and a bee colony algorithm. Bulletin of Engineering Geology and the Environment, 75(1), 27–36.
[18] B. Vergara, M. Torres, V. Aramburu, and C. Raymundo. (2021). Predictive model of rock fragmentation using the neuro-fuzzy inference system (ANFIS) and Particle swarm optimization (PSO) to estimate fragmentation size in open pit mining. International Conference on Applied Human Factors and Ergonomics, 124–131.

Journal of Rock Mechanics
Vol. 10, No. 2, PP. 65-79, (2026)

https://doi.org/10.22034/IRSRM.2026.601061.1090

Predicting the Performance of Hydraulic Impact Hammers Using an Artificial Neural Network and Scenario Analysis of Penetration Depth with Particle Swarm Optimization, Case Study: Koochakali North Coal Mine, Tabas

Mohammad Raei Abbasabadi[1], Arash Ebrahimabadi[2], Hadi Hamidian Shoormasti[1]*. Tahereh Hallajian[1], Mohammad Taghvai[1]

1- Department of Mining and Geology, QaS.C., Islamic Azad University, Qaemshahr, Iran.
2- Department of Petroleum, Mining and Materials Engineering, CT.C., Islamic Azad University, Tehran, Iran.

Received: 28 July 2026 Accepted: 22 September 2026
(*Corresponding author: hhamidian@Qaemiau.ac.ir)

Keywords

Instantaneous breaking rate, hydraulic hammer, particle swarm optimization, artificial neural network, coal mine, Koochakali Tabas

Final English Extended Abstract

Predicting the breaking rate of impact hammers supports drilling planning in coal mines. Using 30 samples from the Koochakali North coal mine (Tabas, Iran; five lithologies), uniaxial compressive strength (UCS) and penetration depth were inputs and the instantaneous breaking rate (IBR) the output; IBR and depth were estimated from UCS using semi-empirical and analytical relations. A 2-1-1 artificial neural network (ANN) evaluated by repeated 5-fold cross-validation gave R^2 = 0.901 ± 0.011 and RMSE = 0.749 ± 0.042 m^3/h, but linear (R^2 = 0.924) and quadratic (R^2 = 0.955) regression were more accurate, so the ANN showed no predictive advantage and served as a nonlinear model for analysis and optimization. Particle swarm optimization (PSO) then searched penetration depth on the model output with UCS fixed and an impact-energy cap. At a 4000 J cap (assuming constant blow frequency) the mean predicted IBR was 9.28 m^3/h (mean predicted increase of 35% over the model prediction at current depth; 11–52% for caps of 2500–6000 J). These are model outputs; the two inputs are strongly correlated (r = −0.93), so their independent effects cannot be separated, and field validation is required.

Summary

This study predicts the instantaneous breaking rate (IBR) of hydraulic impact hammers at the Koochakali North coal mine using a 2-1-1 neural network trained on 30 samples, compares it with linear and quadratic regression, and applies particle swarm optimization (PSO) to penetration depth under impact-energy caps. The ANN (R^2 = 0.901 ± 0.011) did not outperform regression (R^2 = 0.924 and 0.955). Predicted mean gains from PSO ranged from 11% to 52% for caps of 2500–6000 J, but depth and IBR were derived from UCS, so these results are model extrapolations needing field validation.

Introduction

Hydraulic impact hammer performance depends on rock strength and operating parameters. This study builds an ANN to predict IBR from UCS and penetration depth for the Koochakali North mine, compares it with regression baselines, and uses PSO to identify the penetration depth that maximizes predicted IBR under an energy limit. Because the data are few and derived analytically, findings are indicative and require field validation.

Methodology and Approaches

Thirty samples of five lithologies provided UCS (point-load test), penetration depth and IBR; depth and IBR were computed as h = E/(UCS·A) and IBR = (E·N/UCS)·k (E = 2000 J, A = 0.002 m^2, N = 6 blows/s, (UCS in Pa), lithology-dependent k). Inputs and output were standardized. A 2-1-1 feed-forward ANN (tanh hidden neuron, linear output) was trained with Levenberg–Marquardt using multiple random initializations; the hidden-layer size (1–8) was

Journal of Rock Mechanics
Vol. 10, No. 2, PP. 65-79, (2026)

https://doi.org/10.22034/IRSRM.2026.601061.1090



compared by repeated cross-validation. Performance was assessed by 10 repeats of 5-fold cross-validation against linear and quadratic regression on identical folds (MSE, MAE, RMSE, MAPE, R^2, r). PSO (30 particles, 100 iterations, inertia 0.7, $c_1 = c_2 = 1.5$) searched penetration depth between 0.014 m and min(0.055 m, E_max/(UCS·A)) with UCS fixed, for E_max = 2500–6000 J. Standard-deviation-normalized sensitivity, variance inflation factor and z-score outlier checks were also computed in MATLAB.

Results and Conclusions

The ANN gave $R^2 = 0.901 \pm 0.011$, RMSE = 0.749 ± 0.042 m^3/h and MAPE = 10.7%; linear and quadratic regression gave $R^2 = 0.924$ and 0.955 (RMSE = 0.654 and 0.504 m^3/h). Errors were systematic for sandstone (overestimated) and silty sandstone (underestimated) because inputs cannot distinguish lithologies with similar UCS and depth but different empirical coefficients. UCS and depth were strongly correlated ($r = -0.93$, VIF = 7.7); a one-standard-deviation change in depth altered predicted IBR about 2.3 times as much as in UCS, but independent effects cannot be separated. PSO converged within one or two iterations; with UCS fixed, the mean predicted IBR rose from 7.88 to 10.09 m^3/h (mean gain 11–52%) as the energy cap increased from 2500 to 6000 J (9.28 m^3/h and 35% at 4000 J). Using quadratic regression in the same optimization gave implausible values, showing that the optimum reflects extrapolation. Limitations: 30 samples from one mine, analytically derived targets, constant blow frequency assumed and no field validation.