

مدل سازی آزمایشگاهی ارتعاشات ناشی از برش سنگ های تزئینی کربناتی و گرانیتی با روش های

آماری و هوش مصنوعی

سجاد محمدی^۱، محمد عطایی*^۲، رضا میکائیل^۳

دریافت مقاله: ۹۹/۰۳/۱۰ پذیرش مقاله: ۹۹/۰۶/۱۶

چکیده

در این پژوهش میزان ارتعاش ناشی از برش سنگ های تزئینی کربناتی و گرانیتی از طریق ساخت یک دستگاه برش در مقیاس آزمایشگاهی مورد مطالعه قرار گرفته است. برای این منظور پارامترهای ۷ نمونه سنگ کربناتی و ۵ نمونه سنگ گرانیتی تعیین شده و ۲۱۱ آزمایش برش صورت گرفته است. مدل های پیش بینی کننده با ترکیب های مختلفی از پارامترهای فیزیکی و مکانیکی سنگ ها با روش های آماری و هوش مصنوعی ساخته و بررسی شده اند. همچنین عملکرد بهترین مدل ها بر اساس چهار معیار برای دو نوع از داده های آزمون شامل داده هایی که جنس سنگ آن ها در ایجاد مدل موجود بوده و دسته ای که نوع سنگ آن ها در ایجاد مدل موجود نبوده ارزیابی شده است. در نهایت بر اساس استراتژی های مختلف اولویت بندی، نتایج معیارهای ارزیابی، سرعت، سهولت و قابلیت اطمینان روش ایجاد مدل، بهترین مدل برای هر خانواده از سنگ ها معرفی شده است. نتایج نشان داده است که بهترین مدل برای هر دو خانواده از سنگ های کربناتی و گرانیتی به صورت مدل رگرسیون چند متغیره غیرخطی است. پارامترهای مشترک ورودی در این دو مدل عمق برش، نرخ برش و فاکتور ساینده گی شیمزاک بوده است. علاوه بر این پارامترها، در سنگ های کربناتی مدول یانگ و در سنگ های گرانیتی مقاومت فشاری تک محوری نیز جزو پارامترهای ورودی بوده اند که مطابق با نتایج تحلیل حساسیت برای تعیین تأثیرگذارترین پارامترها در هر خانواده از سنگ ها بوده است.

کلید واژه ها: سنگ های تزئینی، ارتعاش، مدل سازی آزمایشگاهی، روش های آماری، روش های هوش مصنوعی.

۱. دکتری، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود

۲. استاد، هیات علمی دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود ataei@shahroodut.ac.ir.com

۳. دانشیار، هیات علمی گروه مهندسی معدن و مواد، دانشگاه صنعتی ارومیه

* مسئول مکاتبات

۱. مقدمه

پیشروی در سنگ‌های ساختمانی سخت و نرم ارائه کردند (Mikaeil et al., 2014).

بررسی این مطالعات نشان می‌دهد که هنوز مدلی جامع که دربرگیرنده پارامترهای اساسی ذاتی و عملیاتی برای پیش‌بینی ارتعاش دستگاه در حین برش سنگ‌های تزئینی مختلف باشد ارائه نشده است؛ بنابراین هدف این پژوهش مدل‌سازی میزان ارتعاش ناشی از برش سنگ‌های تزئینی کربناتی و گرانیتی با استفاده از روش‌های آماری و هوشمند است. از این رو، به‌طور کلی مراحل انجام پژوهش را می‌توان به سه بخش جمع‌آوری اطلاعات و تهیه پایگاه داده به همراه آماده‌سازی داده‌ها، ارائه انواع مدل‌های پیش‌بینی کننده آماری و هوشمند و در نهایت ارزیابی و معرفی بهترین مدل به همراه تحلیل حساسیت تقسیم‌بندی کرد.

۲. روش‌ها و مواد

۲-۱. روش‌ها

برای مدل‌سازی ارتعاش ناشی از برش سنگ‌های تزئینی کربناتی و گرانیتی با هدف ایجاد مدل‌های پیش‌بینی کننده میزان ارتعاش، روش‌های آماری و هوشمند مختلف مورد استفاده قرار گرفتند. بر این اساس، روش‌های آماری شامل رگرسیون‌های چند متغیره خطی و غیرخطی و روش‌های هوشمند شامل شبکه عصبی چند لایه پرسپترون بهینه شده با الگوریتم ژنتیک، شبکه عصبی شعاعی و ماشین بردار پشتیبان رگرسیونی بهینه شده با الگوریتم بهینه‌سازی فاخته بوده‌اند.

پرکاربردترین روش‌های آماری به منظور توسعه مدل‌های پیش‌بینی کننده روش تحلیل رگرسیونی است. این روش شامل رگرسیون‌های ساده یا چند متغیره خطی و غیرخطی می‌شود. در این پژوهش از روش‌های رگرسیون چند متغیره خطی و غیرخطی (لگاریتم دو گانه) با استفاده از نرم‌افزار SPSS استفاده شده است.

در این پژوهش به منظور ارائه مدل از روش شبکه عصبی مصنوعی چند لایه پرسپترون با الگوریتم آموزشی باز انتشار خطا استفاده شد. این الگوریتم همواره به مقدار کمینه مطلق

وجود ذخایر بالا (۳/۷ میلیارد تن ذخیره قطعی) سنگ‌های تزئینی در ایران، این کشور را در رده ۱۰ کشور دارنده معادن مرغوب سنگ در جهان قرار می‌دهد (علیپور و همکاران، ۱۳۹۸). از این رو، افزایش کیفیت تولیدات کارخانه‌های سنگ‌بری می‌تواند نقش بسزایی در افزایش صادرات و ارزآوری این صنعت ایفا کند. امروزه استفاده از دستگاه‌های برش دیسکی الماسه در این کارخانه‌ها در دنیا کاربرد گسترده‌ای پیدا کرده است. کیفیت سنگ حاصل از عملیات برش توسط این دستگاه‌ها به فاکتورهای مختلفی بستگی دارد؛ بنابراین، ارزیابی عملکرد دستگاه‌های برش در تخمین هزینه‌ها و طراحی یک کارخانه سنگ‌بری از اهمیت بالایی برخوردار است. شناخت کامل سنگ‌ها و ارزیابی توان اجرایی دستگاه‌های برش، طراحان و برنامه‌ریزان تولید را به سمت بهبود سرعت فرآوری و افزایش تولید سوق می‌دهد.

یکی از اصلی‌ترین شاخص‌های بررسی کیفیت سنگ و همچنین عملکرد دستگاه که به طور مستقیمی بر هزینه‌ها اثر می‌گذارد میزان ارتعاش ایجاد شده در طی فرایند برش است. مقدار این پارامتر علاوه بر تأثیر بر عمر دیسک، کیفیت برش را تعیین می‌کند. در زمینه بررسی، ارزیابی و پیش‌بینی میزان ارتعاش دستگاه برش سنگ‌های ساختمانی در حین فرایند برش تاکنون مطالعات اندکی صورت گرفته است. اوزچلیک و همکاران در سال ۲۰۱۱ به بررسی رابطه بین عمق برش و ارتعاش پرداختند (Ozcelik et al., 2001). میکایل و همکاران در ۲۰۱۱ مدلی رگرسیونی مبتنی بر شاخص قابلیت سایش سنگ‌ها برای پیش‌بینی میزان ارتعاش دستگاه برش سنگ در حین برش سنگ‌های کربناتی (۴ نوع مرمر و ۳ نوع تراورتن) ارائه کردند (Mikaeil et al., 2011). در سال ۲۰۱۱ اوزچلیک و ییلمازکایا تأثیر انیزوتروپی سنگ‌ها در اثر وجود صفحات لایه‌بندی را بر روی ارتعاش ماشین برش مطالعه کردند (Ozcelik and Yilmazkaya, 2011). میکایل و همکاران در ۲۰۱۴ مدل‌های آماری را برای پیش‌بینی ارتعاش دستگاه برش سنگ بر اساس شاخص تردی سنگ، عمق برش و نرخ

بسیار سریع و عمومیت در داشتن تعداد ویژگی است. الگوریتم ماشین بردار پشتیبان یا SVM به دو دسته اصلی به نام‌های رگرسیون بردار پشتیبان یا SVR و دسته‌بندی بردار پشتیبان یا SVC تقسیم می‌شود. SVR برای حل مسائل مربوط به پیش‌بینی و رگرسیون غیرخطی کاربرد دارد، در حالی که SVC در حل مسائل مربوط به طبقه‌بندی به کار می‌رود. استفاده از روش رگرسیون در مسائل غیرخطی موجب به وجود آمدن سه پارامتر میزان جریمه تابع (C)، میزان خطای (E) و پارامتر مربوط به تابع کرنل (در این پژوهش تابع گوسین با پارامتر (σ)) می‌شود که تعیین مقدار بهینه آن‌ها چالش اصلی استفاده از این روش است؛ بنابراین از الگوریتم بهینه‌سازی فاخته برای تعیین مقدار بهینه این پارامترها به صورت روند نمای شکل ۲ استفاده شده است. روش حاصل به صورت COA-SVR نامیده می‌شود.

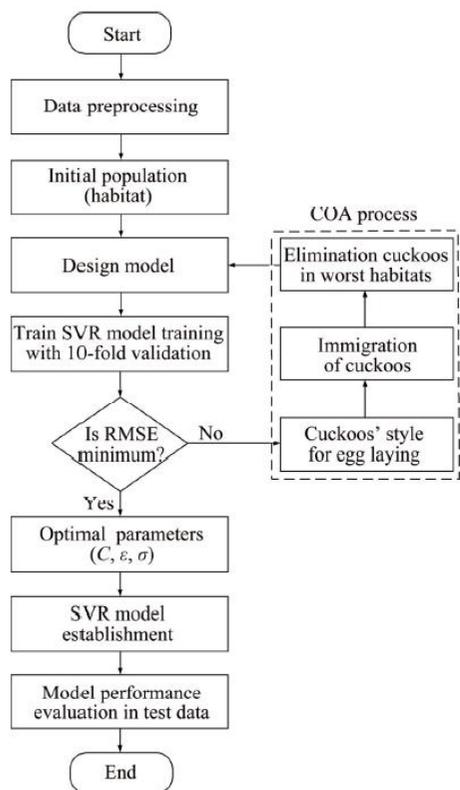
۲-۲. ساخت پایگاه داده

نمونه سنگ‌های مطالعه شده در این پژوهش شامل ۷ نوع سنگ تزئینی کربناتی و ۵ نوع سنگ تزئینی گرانیتی هستند. برای انجام مطالعات آزمایشگاهی و تعیین پارامترهای موردنظر، در مجموع از هر نمونه سنگ، بلوک‌های سنگی تهیه و سپس به آزمایشگاه منتقل شدند. کلیه آزمایش‌ها تحت استانداردهای انجمن بین‌المللی مکانیک سنگ (ISRM, 1981) و با دقت بالا انجام شده است. این آزمایش‌ها در دو بخش تعیین خصوصیات فیزیکی و مکانیکی صورت گرفته که نتایج آن در جدول ۱ آورده شده است. در این جدول EQC کوارتز محتوی، GS اندازه دانه‌ها، MH سختی موس، UCS مقاومت فشاری تک محوری، BTS مقاومت کششی، YM مدول یانگ و SF-a فاکتور سایندگی شیمازک (رابطه (۱)) است.

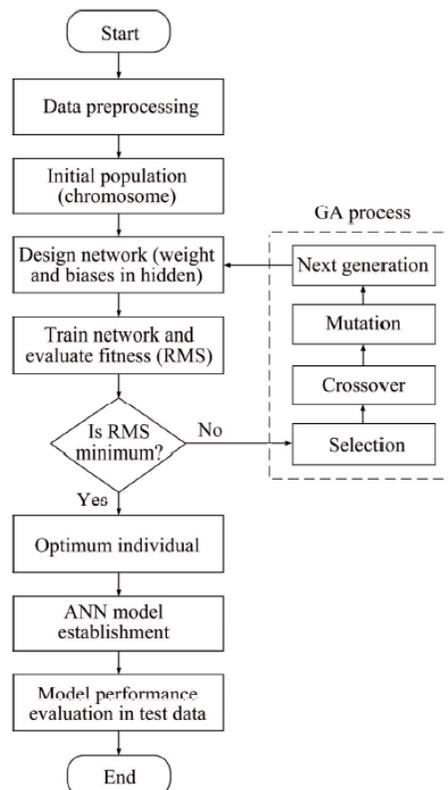
$$SFa = \frac{(Eqc \times Gs \times BTS)}{100} \quad (1)$$

خطا همگرا نمی‌شود و از سویی دیگر دارای نرخ پایین همگرایی است. علاوه بر این امکان گیرکردن ANN در کمینه محلی مقدار خطا آموزش زیاد است. برای این منظور با هدف دستیابی به شبکه‌ای بهینه از الگوریتم بهینه‌سازی ژنتیک به صورت ترکیب با شبکه استفاده شده است. در این پژوهش هدف از بکارگیری این روش بهینه‌سازی، پیدا کردن وزن‌های بهینه شبکه بوده است. الگوریتم به کار رفته برای این ترکیب (GANN-BP) در روند نمای شکل ۱ نمایش داده شده است. یکی از قدرتمندترین شبکه‌های عصبی مورد استفاده در مسایل تخمین توابع، شبکه‌های عصبی پایه شعاعی (RBF) می‌باشند. برخلاف شبکه‌های عصبی پرسپترون که دارای لایه-های متوالی متعدد است، شبکه RBF از سه لایه ثابت تشکیل شده است. لایه ورودی که محل تزریق سیگنال‌های ورودی به شبکه است. لایه میانی یا لایه RBF که شامل توابع RBF می‌شود و لایه خروجی که ترکیبی خطی از کلیه خروجی‌های طبقه RBF را می‌سازد. تعداد نرون‌ها در لایه ورودی و خروجی وابسته به شرایط مسئله است در حالی که تعداد نرون‌های لایه دوم برابر تعداد داده‌های آموزش است. این نوع شبکه‌ها از دو تابع محرک خطی و گوسین در ساختار خود استفاده می‌کنند. در اکثر مواقع از توابع گوسی در لایه RBF استفاده می‌شود که این توابع دارای دو پارامتر مرکز تابع گوسی و واریانس یا میزان گسترده‌گی تابع گوسی است. این مدل به صورت GRNN نامیده می‌شود (سلطانی محمدی و همکاران، ۱۳۹۳).

روش ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است که در حل مسائل پیش‌بینی، دسته‌بندی به صورت خطی و غیرخطی و نیز خوشه‌بندی کاربرد فراوانی در حوزه‌ی فنی و مهندسی دارد. مبنای الگوریتم SVM در سال ۱۹۹۵ توسط وپنیک بر پایه تئوری یادگیری آماری پیشنهاد شد (Vapnik, 1995). الگوریتم SVM برای برطرف کردن ضعف‌های شبکه‌های عصبی مصنوعی ابداع شده است و بنابراین مزایای این روش نسبت به شبکه عصبی توانایی دسته‌بندی به صورت پویا و برخط، سادگی و انجام محاسبات



شکل ۲. روند نمای ارائه مدل با روش COA-SVR



شکل ۱. روند نمای ارائه مدل با روش GANN-BP

(Hoseinian et al., 2017)

روی سنگ‌های مورد مطالعه انجام شد که از این میان ۱۱۰ نمونه آزمایش متعلق به سنگ‌های کربناتی و ۱۰۱ نمونه آزمایش برای نمونه سنگ‌های گرانیتی بوده است. به منظور توسعه مدل‌ها و سپس اعتبار سنجی آن‌ها، به طور تصادفی ۷۵٪ کل داده‌ها به عنوان داده‌های آموزش و ۲۵٪ باقیمانده برای داده‌های آزمون در نظر گرفته شده‌اند. برای بررسی جامعیت و کارایی مدل‌ها به ازای داده‌هایی که نوع سنگ آن‌ها در مرحله آموزش نیست، از هر دو نوع سنگ کربناتی و گرانیتی، داده‌های یک نمونه سنگی به طور کلی از مرحله آموزش حذف شده‌اند (سنگ تراورتن دره بخاری از گروه کربناتی و گرانیت قرمز از گروه سنگ‌های گرانیتی)؛ بنابراین داده‌های آموزش برای سنگ‌های کربناتی شامل داده‌های شش نوع سنگ و برای سنگ‌های گرانیتی شامل ۴ نمونه سنگ بوده است؛ بنابراین دو نوع داده آزمون به صورت نوع الف (نوع سنگ آن‌ها در مرحله آموزش موجود بوده) و نوع ب (نوع

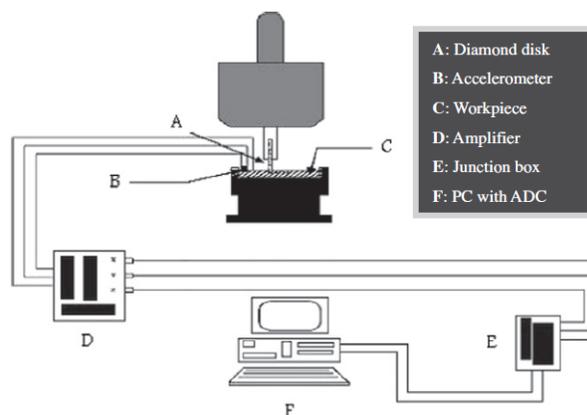
به منظور انجام آزمایش‌های برش در مقیاس آزمایشگاهی، از دستگاه برشی در مقیاس آزمایشگاهی استفاده شد (شکل ۳). مکانیسم این دستگاه بر اساس اصول و قواعد برش دایروی است. در تمامی آزمایش‌ها، برش در حالت موافق (حرکت قطعه کار هم‌راستا با چرخش دیسک) و از آب به عنوان سیال خنک کننده استفاده شد. در طی انجام آزمایش، میزان ارتعاش‌های به وجود آمده در سیستم توسط یک شتاب‌سنج دقیق با کمک تجهیزات جانبی در شرایط مختلف ماشین‌کاری شامل نرخ‌های پیشروی مختلف (۱۰۰، ۲۰۰، ۳۰۰ و ۴۰۰ cm/min) و عمق‌های مختلف برش (۱۵، ۲۲، ۳۰ و ۳۵ mm) ثبت و اندازه‌گیری شد. با توجه به ماهیت سیگنال‌های ارتعاشی و جلوگیری از صفر شدن مقادیر میانگین، در این تحقیق از مقادیر RMS ارتعاش‌های سیستم در تحلیل‌های آماری استفاده شد.

به این ترتیب پس از انجام مطالعات آزمایشگاهی در مجموع ۲۱۱ نمونه آزمایش برش تحت شرایط مختلف ماشین‌کاری بر

سنگ آن‌ها در مرحله آموزش وجود نداشته) در دسترس قرار گرفت.

جدول ۱. مشخصات فیزیکی و مکانیکی سنگ‌های مورد مطالعه

Name	EQC (%)	GS (mm)	MH (n)	UCS (MPa)	BTS (MPa)	YM (GPa)	SF-a (N/mm)
Ghermez Yazd (Granite)	57.65	2.90	6.10	142	8.52	43.60	14.24
Meshki Chayan (Granite)	60.06	0.87	6.60	173	15	48.60	7.60
Sefid Nehbandan (Granite)	64.30	4.10	5.95	145	9.20	35.50	24.25
Shokolati Khoramdareh (Granite)	32.20	3.90	5.65	133	8.30	28.90	10.42
Morvarid Mashhad (Granite)	30.30	3.80	5.60	125	7.40	31.20	8.50
Kerem Hersin (Marble)	3.60	0.55	3.50	71.50	6.80	32.50	0.14
Sourati Anarak (Marble)	3.40	0.45	3.2	74.50	7.10	33.60	0.11
Ghermez Azarshahr (Travertine)	2.80	1.01	2.9	53	4.30	20.70	0.12
Haji Abad (Travertine)	2.60	0.85	2.9	61.50	5.60	21	0.12
Dareh Bokhari (Travertine)	2.70	0.87	2.95	63	5.40	23.50	0.13
Salsali (Marble)	3.20	0.52	3.10	73	6.30	31.60	0.11
Sourati Haftouman (Marble)	4	0.60	3.60	74.50	7.20	35.50	0.17



شکل ۳. نمای شماتیک دستگاه برش در مقیاس آزمایشگاهی

۳. مدل‌سازی ارتعاش

در ارائه مدل‌ها همواره سعی بر این است که تا حد ممکن مدل ساده (دارای پارامتر وردی کمتر) و دارای جامعیت باشد. برای این منظور در اینجا دو پارامتر عملیاتی (نرخ برش F_r و عمق برش D_c) به دلیل اینکه قابل کنترل هستند در تمامی مدل‌ها به عنوان متغیر مستقل وجود خواهند داشت؛ اما از میان پارامترهای ذاتی (سختی موس، مقاومت فشاری تک محوری، مدول یانگ، شاخص شیمازک) باید تعداد متغیرهای مستقل را به گونه‌ای انتخاب کرد که دارای سادگی و عدم همپوشانی باشند. این موضوع از طریق بررسی همبستگی میان هر دو متغیر از متغیرهای ذاتی امکان‌پذیر است. از آنجایی که توزیع آماری متغیرها به صورت نرمال نبوده است، از آزمون شاخص اسپیرمن برای بررسی همبستگی میان پارامترهای

ذاتی استفاده شده است. بر این اساس جدول ۲ ترکیب‌های مجاز پارامترها در توسعه مدل‌های پیش‌بینی‌کننده را با توجه به نتایج بررسی همبستگی نشان می‌دهد.

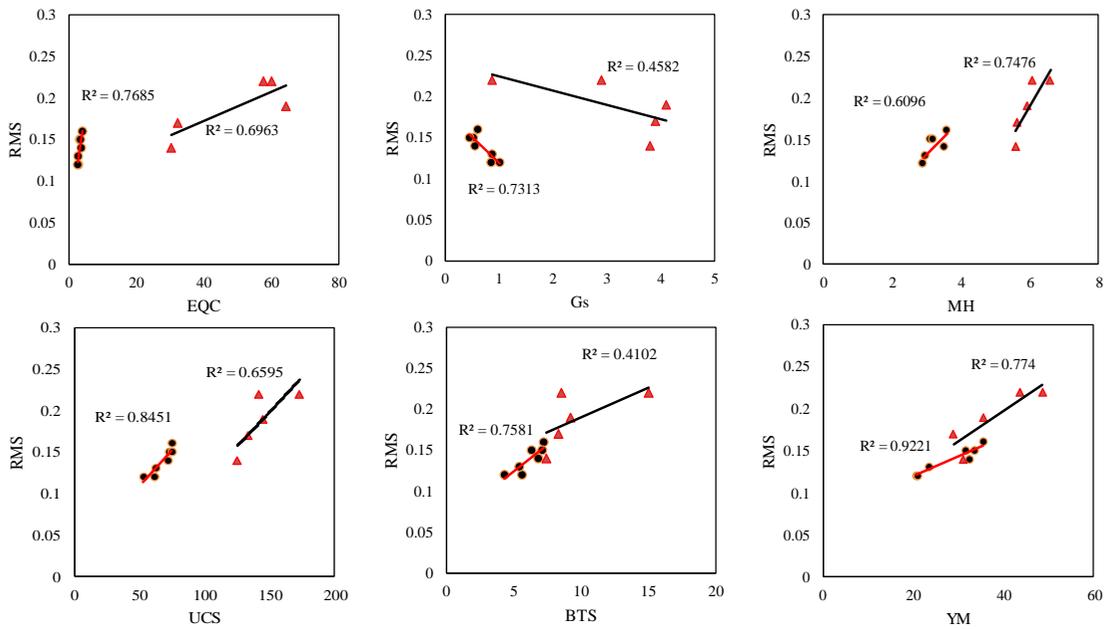
۳-۱. برازش تک متغیره

به منظور تعیین ارتباط میان متغیرهای وابسته با متغیرهای مستقل از رگرسیون تک متغیره استفاده شده است. برای این هدف، مقدار عمق برش و نرخ پیشروی قطعه کار مقادیر ثابت ۳۰ (mm) و ۱۰۰ (mm/s) بوده است. شکل ۴ نتایج برازش تک متغیره کوارتز محتوی، اندازه دانه‌ها، سختی موس، مقاومت فشاری تک محوری، مقاومت کششی و مدول یانگ را در سنگ‌های کربناتی (نقاط دایره‌ای در نمودارها) و گرانیتی (نقاط مثلثی در نمودارها) نشان می‌دهد. در شکل ۴

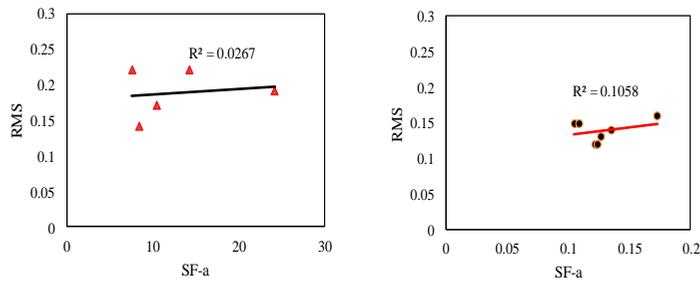
نیز نتایج این برازش برای شاخص شیمازک نمایش داده شده است.

جدول ۲. ترکیب‌های مجاز پارامترهای مستقل در مدل‌سازی ارتعاش

Type Models	Carbonate							Granite								
	1	2	3	4	5	6	7	1	2	3	4	5	6	7	8	9
Independent variables	UCS, D _c , F _r	YM, D _c , F _r	MH, D _c , F _r	SFa, D _c , F _r	UCS, SFa, D _c , F _r	YM, SFa, D _c , F _r	MH, SFa, D _c , F _r	UCS, D _c , F _r	YM, D _c , F _r	MH, D _c , F _r	SFa, D _c , F _r	UCS, SFa, D _c , F _r	YM, SFa, D _c , F _r	MH, SFa, D _c , F _r	UCS, YM, D _c , F _r	UCS, YM, SFa, D _c , F _r

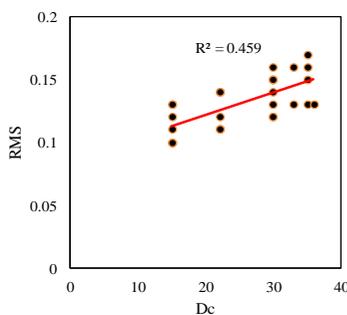
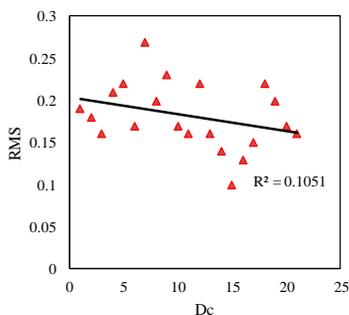


شکل ۴. برازش تک متغیره پارامترهای ذاتی با ارتعاش

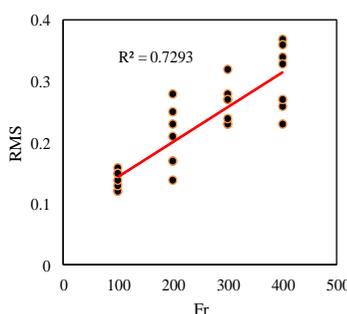
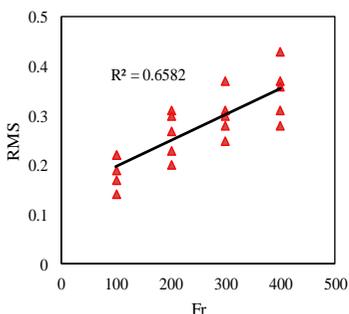


شکل ۵. برازش تک متغیره شاخص شیمازک و ارتعاش

از نمونه‌ها وجود نداشته است. شکل‌های ۶ و ۷ به ترتیب برازش تک متغیره بین عمق برش و نرخ پیشروی با ارتعاش را نمایش می‌دهند.



شکل ۶. برازش تک متغیره عمق برش و ارتعاش



شکل ۷. برازش تک متغیره نرخ پیشروی و ارتعاش

اعتبار سنجی با داده‌های آزمون، معیار خطای مرحله آموزش به صورت جذر میانگین مربعات خطا (RMSE) به صورت رابطه (۲) استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t - y)^2} \quad (2)$$

در این رابطه t مقدار خروجی واقعی (اندازه‌گیری شده)، y مقدار خروجی تخمینی توسط مدل و n تعداد کل داده‌ها است. نتایج حاصل در جدول ۳ درج شده است. همان‌طور که در جدول ۳ مشاهده می‌شود مدل ۶ در سنگ‌های کربناتی و مدل ۵ در سنگ‌های گرانیتی دارای کمترین خطای مرحله آموزش بوده‌اند. این دو مدل به صورت روابط به ترتیب (۳) و (۴) هستند.

در شکل ۴ مشاهده می‌شود که به طور کلی ارتعاش فقط با اندازه دانه‌ها دارای ارتباط غیرمستقیم است و با دیگر متغیرها ارتباط مستقیم دارد. همچنین در شکل ۵ ملاحظه می‌شود که ارتباط مشخصی میان شاخص شیمازک و ارتعاش در هیچ‌یک

در شکل ۶ مشاهده می‌شود که میزان ارتعاش با عمق برش در سنگ‌های کربناتی رابطه مستقیم ضعیفی دارد در حالی که در سنگ‌های گرانیتی دارای رابطه مشخصی نیست. شکل ۷ نشان می‌دهد که میزان ارتعاش با نرخ پیشروی برای هر دو نوع سنگ دارای ارتباط مستقیم است.

۲.۳. مدل‌های رگرسیون خطی

به منظور ایجاد مدل‌های رگرسیونی چند متغیره، شش آزمون معنی‌داری مدل (P-test)، معنی‌داری ضرایب (t-test)، استقلال خطاها، نرمال بودن خطاها، عدم هم خطی و ضرایب منطقی مورد بررسی قرار گرفت. بر این اساس مدل‌های ۱، ۲، ۶ و ۷ در سنگ‌های کربناتی و مدل‌های ۱، ۳، ۵، ۶ و ۷ در سنگ‌های گرانیتی معتبر بودند. به منظور تعیین مدل‌های کاندید برای

جدول ۳. مقدار RMSE مدل‌های معتبر رگرسیون خطی چند متغیره

Type	Carbonate				Granite				
Model	1	2	6	7	1	3	5	6	7
RMSE	0.151	0.139	0.130	0.114	0.043	0.044	0.040	0.042	0.041

$$RMS_C = -0.253 + 0.121 \times MH - 0.891 \times SFa + 0.0023 \times D_c + 0.0006 \times F_r \quad (۳)$$

$$RMS_G = -0.14 + 0.0014 \times UCS - 0.002 \times SFa + 0.0015 \times D_c + 0.0005 \times F_r \quad (۴)$$

جدول ۴. مقدار RMSE مدل‌های معتبر رگرسیون غیرخطی چند متغیره

Type	Carbonate			Granite					
Model	1	6	7	1	2	3	5	6	7
RMSE	0.0239	0.0235	0.029	0.044	0.046	0.045	0.041	0.043	0.042

$$RMS_C = \frac{YM^{0.635} \times D_c^{273} \times F_r^{0.587}}{10^{3.502} \times SFa^{0.16}} \quad (۵)$$

$$RMS_G = \frac{UCS^{0.867} \times SFa^{0.113} \times D_c^{0.156} \times F_r^{0.46}}{10^{3.892}} \quad (۶)$$

ورودی‌ها و تعداد نرون لایه آخر نیز ۱ در نظر گرفته شد. چنین ساختاری برای مقادیر مختلفی از تعداد نرون لایه میانی مورد آزمون قرار گرفت تا بهترین نتیجه حاصل شود. با توجه به خصوصیت تصادفی بودن شبکه و الگوریتم بهینه‌سازی هر ساختار ۵ مرتبه مورد بررسی قرار گرفت. جدول ۵ مقدار RMSE هریک از مدل‌ها را نمایش می‌دهد. در این جدول مشاهده می‌شود که مدل ۵ سنگ‌های کربناتی و مدل ۷ سنگ-های گرانیتی دارای بهترین آموزش (کمترین RMSE) بوده‌اند.

جدول ۵. مدل‌های GRNN

به منظور ارائه بهترین مدل با استفاده از شبکه عصبی مصنوعی رگرسیونی (GRNN) مدل‌های مختلف بر مبنای مقادیر مختلف فاصله اقلیدسی (Euclidean distance) مورد بررسی قرار گرفت. این مقدار که فاصله بین بردار مرکزی نرون با ورودی است، مهم‌ترین پارامتر قابل کنترل در تابع گوسی این نوع از شبکه‌ها است. در اینجا این مقدار از ۰/۱ تا ۱۰۰ با فاصله ۰/۱ تغییر داده شد تا شبکه بهینه بر اساس کمینه میزان RMSE آموزش حاصل شود. نتایج خطای مرحله آموزش مدل‌های GRNN در جدول ۶ درج شده است.

جدول ۵. مقدار RMSE مدل‌های مختلف GANN-BP

Type	Carbonate							Granite								
Model	1	2	3	4	5	6	7	1	2	3	4	5	6	7	8	9
RMSE	0.027	0.029	0.036	0.039	0.026	0.029	0.034	0.043	0.045	0.043	0.049	0.0417	0.0422	0.0416	0.043	0.0420

۳.۳. مدل‌های رگرسیون غیرخطی

در این قسمت نیز آزمون‌های شش‌گانه مطرح شده در مرحله قبل مورد بررسی قرار گرفته و بر این اساس مدل‌های ۱، ۶ و ۷ در سنگ‌های کربناتی و مدل‌های ۱، ۲، ۳، ۵، ۶ و ۷ در سنگ‌های گرانیتی معتبر بوده‌اند. جدول ۴ مقدار RMSE هر یک از این مدل‌ها را نمایش می‌دهد.

۳.۴. مدل‌های GANN-BP

به منظور ایجاد مدل شبکه عصبی MLP بهینه شده با GA (GANN-BP)، تعداد جمعیت اولیه (جوابهای اولیه وزن‌های شبکه) برابر با ۱۵۰ در نظر گرفته شده است که از این میان ۱۵٪ این جمعیت که دارای نتیجه بهتری بوده‌اند برای بقا و قرار گرفتن در نسل بعدی کروموزوم‌ها (تکرار بعدی الگوریتم) انتخاب شده‌اند. همچنین برای دو عملگر تقاطع و جهش به ترتیب ۵۰٪ و ۳۰٪ جمعیت مورد استفاده قرار گرفته‌اند. از سویی دیگر ساختار شبکه همواره به صورت وجود یک لایه میانی یا پنهان بوده است. توابع لایه‌های ورودی، میانی و خروجی به ترتیب به صورت tansig، tansig و purelin که در آن تعداد نرون لایه اول برابر با تعداد

جدول ۶. مقدار RMSE مدل‌های مختلف GRNN

Type	Carbonate							Granite								
Model	1	2	3	4	5	6	7	1	2	3	4	5	6	7	8	9
Euclidean distance	4.9	5.1	9.5	9.5	4.9	5.1	9.5	8.7	9.4	1.2	6.6	11.4	9.4	6.5	9.1	11.4
RMSE	0.02	0.02	0.03	0.03	0.02	0.02	0.03	0.02	0.03	0.03	0.03	0.021	0.02	0.03	0.021	0.02
	2	1	9	9	2	1	9	5	4	2	9	6	7	9	8	5

جدول ۷. مقدار RMSE مدل‌های مختلف COA-SVR

Type	Carbonate							Granite								
Model	1	2	3	4	5	6	7	1	2	3	4	5	6	7	8	9
RMS	0.02	0.02	0.02	0.02	0.02	0.02	0.02	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.04
E	4	5	4	2	4	2	4	1	5	4	8	0	2	3	4	7

۶.۳. مدل‌های COA-SVR

۴. اعتبارسنجی مدل‌ها

به منظور اعتبارسنجی مدل‌های کاندید شده در مرحله قبل (مدل‌های دارای کمترین مقدار RMSE آموزش با استفاده از هریک از روش‌ها) از ۴ معیار ارزیابی RMSE (رابطه (۲))، ضریب تعیین (R^2)، شاخص عملکرد (VAF) و میانگین درصد خطای مطلق (MAPE) استفاده شده است. معادله این معیارها در روابط (۷) تا (۹) ارائه شده است.

$$R^2 = 100 \left[\frac{\left(\sum_{i=1}^n (t - \bar{t})(y - \bar{y}) \right)^2}{\sum_{i=1}^n (t - \bar{t})^2 \sum_{i=1}^n (y - \bar{y})^2} \right] \quad (7)$$

$$VAF = 100 \left[1 - \frac{\text{var}(t - y)}{\text{var}(t)} \right] \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{t - y}{t} \right| \times 100 \quad (9)$$

در این روابط t و y به ترتیب مقادیر اندازه‌گیری شده و پیش‌بینی شده، \bar{t} و \bar{y} میانگین مقادیر اندازه‌گیری شده و پیش‌بینی شده و var بیانگر واریانس مقادیر است.

در این قسمت عملکرد ۱۰ مدل برگزیده (۵ مدل برای سنگ‌های کربناتی و ۵ مدل برای سنگ‌های گرانیتی) بر اساس معیارهای ارزیابی چهارگانه مورد بررسی قرار گرفته است. برای این منظور مقدار پیش‌بینی هریک از مدل‌ها برای داده‌های آزمون نوع الف با مقدار اندازه‌گیری شده مقایسه شده و بر این اساس مقدار معیارهای ارزیابی برای آنها محاسبه و در جدول ۹ درج شده است. جدول ۱۰ نیز نتایج

در این روش به منظور کمینه‌سازی RMSE با الگوریتم بهینه‌سازی فاخته، از روش اعتبارسنجی ضربدری یا گردشی نیز برای حصول اطمینان از عملکرد مناسب مدل استفاده شده است. یکی از انواع این رویکرد، استفاده از روش K-Fold است. در این روش، داده‌های آموزش به K زیرمجموعه افزاز می‌شوند. از این K زیرمجموعه، هر بار K-1 زیرمجموعه برای آموزش و زیرمجموعه باقی‌مانده برای اعتبارسنجی و بکار می‌روند. این روال K بار تکرار می‌شود و همه زیرمجموعه‌ها (K افزاز) دقیقاً یک‌بار برای آموزش و یک‌بار برای اعتبارسنجی بکار می‌روند. در نهایت میانگین نتیجه این K بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود. در این پژوهش مقدار K برابر با ۱۰ در نظر گرفته شد. با توجه به اینکه الگوریتم بهینه‌سازی دارای خاصیت تصادفی است و از سوی دیگر نقطه بهینه به صورت یکتا نیست، لذا برای تعیین بهترین پارامترهای هریک از مدل‌ها، فرایند بهینه‌سازی و تعیین پارامتر ۵ مرتبه صورت گرفت. جدول ۷ نتایج استفاده از این روش را برای مدل‌های مختلف نمایش می‌دهد. در جدول ۷ مشاهده می‌شود که مدل ۶ سنگ‌های کربناتی و مدل ۵ سنگ‌های گرانیتی دارای کمترین RMSE بوده‌اند. پارامترهای بهینه تعیین شده هریک از این مدل‌ها در جدول ۸ درج شده است.

جدول ۸. پارامترهای بهینه شده مدل‌های COA-SVR

Rock Type	Model	Optimal Parameters		
		C	ϵ	σ
Carbonate	6	811.455	0.0949	4.738
Granite	7	2.111	0.0057	4.451

قسمت در ابتدا برای هر نوع سنگ (کربناتی و گرانیتی) اولویت هریک از روش‌ها بر اساس معیارهای ارزیابی چهارگانه مشخص می‌شود. پس از آن با استفاده از دو استراتژی اولویت‌بندی شامل میانگین رتبه‌ها و روش کپلند و در نهایت روش ادغام، اولویت‌بندی مدل‌ها صورت می‌گیرد (برای اطلاع از جزئیات استراتژی‌های اولویت‌بندی به مرجع (عطایی، ۱۳۹۵) رجوع شود). در مرحله آخر نیز با در نظر گرفتن دو جنبه دیگر، بهترین مدل‌ها معرفی می‌شوند.

ارزیابی مدل‌های برگزیده در مرحله آموزش را در اعتبارسنجی با داده‌های آزمون نوع ب ارائه می‌کند.

۵. تعیین بهترین مدل

به منظور تعیین بهترین مدل‌ها برای هر خانواده از سنگ‌ها جنبه‌های مختلف عملکرد مدل‌ها را بر اساس معیارهای ارزیابی چهارگانه، سهولت، زمان دسترسی به جواب و قابلیت اطمینان مدل‌ها باید مدنظر قرار گیرد. بر این اساس در این

جدول ۹. نتایج ارزیابی مدل‌های کاندید در داده‌های آزمون نوع الف

Rock Type	Model	Evaluation Criteria			
		R ²	RMSE	MAPE	VAF
Carbonate (Kerem Hersin, Sourati Anarak, Ghermez Azarshahr, Haji Abad, Salsali, Sourati Haftouman)	Linear Regression	87.46	0.026	8.593	87.350
	Nonlinear Regression	94.53	0.018	5.432	94.453
	GANN-BP	91.96	0.023	6.963	91.496
	GRNN	95.37	0.016	5.867	95.351
	COA-SVR	96.48	0.019	8.349	96.462
Granite (Meshki Chayan, Sefid Nehbandan, Shokolati Khoramdareh, Morvarid Mashhad)	Linear Regression	97.33	0.012	4.380	97.324
	Nonlinear Regression	96.32	0.015	4.726	96.166
	GANN-BP	97.27	0.024	8.762	95.068
	GRNN	90.87	0.023	7.577	90.713
	COA-SVR	95.81	0.032	9.880	86.952

جدول ۱۰. نتایج ارزیابی مدل‌های کاندید در داده‌های آزمون نوع ب

Rock Type	Model	Evaluation Criteria			
		R ²	RMSE	MAPE	VAF
Carbonate (Dareh Bokhari)	Linear Regression	97.40	0.014	6.230	94.179
	Nonlinear Regression	98.76	0.007	3.170	98.699
	GANN-BP	96.93	0.014	4.994	94.665
	GRNN	98.04	0.010	3.725	97.756
	COA-SVR	98.68	0.017	8.924	98.522
Granite (Ghermez)	Linear Regression	88.32	0.059	15.701	82.163
	Nonlinear Regression	89.49	0.054	14.247	85.135
	GANN-BP	89.40	0.043	12.179	76.774
	GRNN	87.36	0.064	16.221	81.213
	COA-SVR	87.59	0.051	13.480	77.326

پارامترهای عملیاتی، مدول یانگ و فاکتور سایندگی شیمازک معرفی می‌شود. نتایج جدول ۱۲ نشان می‌دهد که دو مدل رگرسیونی دارای اولویتی یکسان و بالاتر از دیگر مدل‌ها هستند. این دو به دلیل یکسانی تئوری، قابلیت اطمینانی مشابه یکدیگر در تخمین دارند. از این رو مقایسه از لحاظ سهولت و سرعت می‌تواند تعیین کننده مدل بهتر باشد. به طور واضح یک مدل خطی از یک مدل غیرخطی ساده‌تر و دارای سرعت محاسباتی بیشتر است. از این رو بهترین مدل پیش‌بینی ارتعاش دستگاه حین برش سنگ‌های سخت، مدل رگرسیون خطی

جدول ۱۱ رتبه‌بندی مدل‌ها بر اساس معیارها و جدول ۱۲ ادغام رتبه‌بندی‌ها را نشان می‌دهد.

بر اساس جدول ۱۲ برای سنگ‌های کربناتی مدل رگرسیون غیرخطی دارای بالاترین اولویت بوده است و پس از آن دو مدل GRNN و COA-SVR به ترتیب قرار گرفته‌اند. مقایسه مدل‌ها از دو جنبه دیگر نیز رأی به اولویت بالاتر مدل رگرسیون غیرخطی می‌دهند؛ بنابراین بهترین مدل برای پیش-بینی ارتعاش دستگاه در حین برش سنگ‌های تزئینی کربناتی به صورت رگرسیون غیرخطی و با متغیرهای مستقل

$$R_{ij} = \frac{\sum_{k=1}^m X_{ik} X_{jk}}{\sqrt{\sum_{k=1}^m X_{ik}^2 \sum_{k=1}^m X_{jk}^2}} \quad (10)$$

است که در آن متغیرهای مستقل شامل پارامترهای عملیاتی، مقاومت فشاری تک محوری و فاکتور ساینده‌گی شیمازک است.

۶. تحلیل حساسیت

در این رابطه R_{ij} نشان دهنده میزان تأثیر پارامتر نام بر خروجی مورد نظر، X_{ik} پارامتر مستقل دسته k ام و X_{jk} خروجی متناظر در دسته k ام است.

در این پژوهش از روش دامنه کسینوسی (CAM) برای تحلیل حساسیت طبق رابطه (۱۰) استفاده شده است (Jong and Lee, 2004).

جدول ۱۱. رتبه‌بندی مدل‌های مختلف بر اساس معیارهای چهارگانه

Rock Type	Model	Test data-Type A				Test data-Type B			
		R ²	RMSE	MAPE	VAF	R ²	RMSE	MAPE	VAF
Carbonate	Linear Regression	5	5	5	5	4	3	4	5
	Nonlinear Regression	3	1	1	3	1	1	1	1
	GANN-BP	4	4	3	4	5	4	3	4
	GRNN	2	2	2	2	3	2	2	3
	COA-SVR	1	3	4	1	2	5	5	2
Granite	Linear Regression	1	1	1	1	3	4	4	2
	Nonlinear Regression	3	2	2	2	1	3	3	1
	GANN-BP	2	4	4	3	2	1	1	5
	GRNN	5	3	3	4	5	5	5	3
	COA-SVR	4	5	5	5	4	2	2	4

جدول ۱۲. ادغام رتبه‌بندی‌های مختلف و ارائه رتبه نهایی

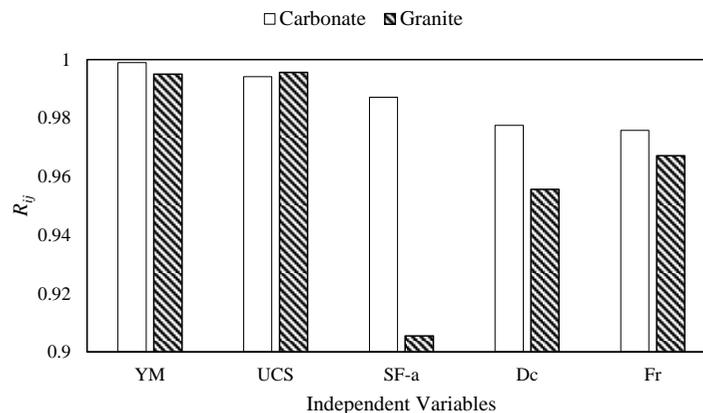
Rock Type	Model	Average rank	Copeland Rank	Ultimate Rank
Carbonate	Linear Regression	4.5	5	4.75
	Nonlinear Regression	1.5	1	1.25
	GANN-BP	3.875	4	3.938
	GRNN	2.25	2	2.125
	COA-SVR	2.875	2	2.438
Granite	Linear Regression	2.125	1	1.563
	Nonlinear Regression	2.125	1	1.563
	GANN-BP	2.75	3	2.875
	GRNN	4.125	5	4.563
	COA-SVR	3.875	5	4.438

در شکل ۸ ملاحظه می‌شود که تمامی پارامترها دارای مقدار بیش از ۰/۹ هستند که بیانگر قرار گرفتن مهم‌ترین پارامترها به عنوان متغیر مستقل یا ورودی مدل‌ها است. مدول یانگ در سنگ‌های کربناتی و مقاومت فشاری تک محوری در سنگ‌های گرانیتی دارای بیشترین تأثیر در خروجی هستند و از این رو مهم‌ترین پارامتر مدل‌ها محسوب می‌شوند؛ بنابراین نیاز است با توجه به نوع سنگ، هریک از این پارامترها با دقت بیشتری اندازه‌گیری شود چرا که تغییرات کوچک در

هرچه میزان تأثیر پارامتر ورودی بر خروجی مورد نظر بیشتر باشد، R_{ij} به یک نزدیک‌تر خواهد بود. در صورت عدم تأثیر پارامتر ورودی بر خروجی نیز، مقدار R_{ij} صفر است. به طور معمول می‌توان گفت که در بررسی R_{ij} ، مقادیر بالای ۰/۹ نشان‌دهنده تأثیر قابل توجه پارامتر مورد نظر بر خروجی و مقادیر کمتر از ۰/۸ بیانگر تأثیر ضعیف آن بر خروجی است (Jong and Lee, 2004). شکل ۸ نتایج تحلیل حساسیت پارامترها را نشان می‌دهد.

مشاهده می‌شود که در سنگ‌های کربناتی نرخ برش نسبت به عمق برش تأثیر بیشتری بر میزان ارتعاش دارد در حالی که این موضوع در سنگ‌های گرانیتی کاملاً برعکس است.

مقدار آن‌ها به تغییرات اساسی در ارتعاش منجر می‌شود. همچنین مقدار شاخص شیمازک در سنگ‌های گرانیتی دارای تأثیر به مراتب کمتری نسبت به سنگ‌های کربناتی است.



شکل ۸. نتایج تحلیل حساسیت پارامترها با روش CAM

۷. نتیجه‌گیری

- بهترین مدل تخمین میزان ارتعاش دستگاه در حین برش سنگ‌های تزئینی کربناتی به صورت مدل رگرسیونی چند متغیره غیرخطی و با متغیرهای مستقل شامل پارامترهای عملیاتی نرخ و عمق برش، مدول یانگ و فاکتور ساینده‌گی شیمازک حاصل شده است.
- بهترین مدل برای پیش‌بینی ارتعاش دستگاه در حین برش سنگ‌های تزئینی گرانیتی به صورت رگرسیون چند متغیره خطی حاصل شده است. در این مدل متغیرهای مستقل شامل پارامترهای عملیاتی نرخ و عمق برش، مقاومت فشاری تک محوری و فاکتور ساینده‌گی شیمازک است.
- نتایج تحلیل حساسیت نشان داد که مدول یانگ و مقاومت فشاری تک محوری به ترتیب تأثیرگذارترین پارامترهای مستقل بر ارتعاش دستگاه در حین برش سنگ‌های تزئینی کربناتی و گرانیتی هستند. همچنین مقدار شاخص شیمازک اگرچه در ارتعاش ناشی از برش سنگ‌های کربناتی دارای تأثیر

میزان ارتعاش دستگاه برش با دیسک الماسی در حین برش سنگ‌های تزئینی کربناتی و گرانیتی از طریق ساخت یک دستگاه برش در مقیاس آزمایشگاهی مورد مطالعه قرار گرفته است. برای این منظور مدل‌های مختلفی بر اساس روش‌های آماری و هوش مصنوعی توسعه یافتند. عملکرد مدل‌ها از طریق چهار معیار ارزیابی R^2 ، RMSE، MAPE و VAF بررسی شده و در نهایت بهترین مدل‌ها معرفی شده‌اند. مهم‌ترین نتایج حاصل از این پژوهش به صورت زیر است:

- نتایج برازش تک متغیره نشان داد به طور کلی ارتعاش با اندازه دانه‌های ارتباط معکوس و با دیگر پارامترها ارتباط مستقیم دارد. همچنین ملاحظه شد که ارتباط مشخصی میان شاخص شیمازک و ارتعاش وجود ندارد. علاوه بر این، مشاهده شد که میزان ارتعاش با عمق برش در سنگ‌های کربناتی رابطه مستقیم ضعیفی دارد در حالی که در سنگ‌های گرانیتی دارای رابطه مشخصی نیست. همچنین نتیجه‌گرفته شد که میزان ارتعاش با نرخ پیشروی برای هر دو نوع سنگ دارای ارتباط مستقیم است.

به‌سزایی است اما این تأثیر در سنگ‌های گرانیتی به مراتب کمتر است. علاوه بر این در سنگ‌های کربناتی نرخ برش نسبت به عمق برش تأثیر بیشتری بر میزان ارتعاش دارد در حالیکه این موضوع در سنگ‌های گرانیتی کاملاً برعکس است.

منابع

- سلطانی محمدی، س.، لک، م.، محمدی، س.، کربلا، م.ا.، ۱۳۹۳. تخمین ارتفاع سطح ایستابی در روزهای مختلف سال با استفاده از شبکه عصبی مصنوعی شعاعی؛ مطالعه موردی: دشت بهبهان. نشریه علمی- ترویجی محاسبات نرم، شماره پنجم، ص ۸۲-۹۳.
- عطایی، م.، ۱۳۹۵. تصمیم‌گیری چند معیاره. چاپ چهارم، انتشارات دانشگاه صنعتی شاهرود.
- علیپور، ع.، مختاریان اصل، م.، میکائیل، ز.، ۱۳۹۸. ارائه رابطه غیرخطی مبتنی بر الگوریتم رقابت استعماری به‌منظور پیش‌بینی قابلیت برش- نرخ تولید سنگ تزئینی با استفاده از دستگاه سیم برش الماسه. مجله انجمن زمین‌شناسی مهندسی ایران، جلد دوازدهم، شماره ۱، ص ۴۲-۳۳.
- Hoseinian, F. S., Abdollahzade, A., Mohamadi, S. S., Hashemzadeh, M., 2017. Recovery prediction of copper oxide ore column leaching by hybrid neural genetic algorithm. Transactions of Nonferrous Metals Society of China, 27(3): 686-693.
- International Society of Rock Mechanics (ISRM). 1981. Rock characterization testing and monitoring. ISRM Suggested methods. Brown ET (ed.).
- Jong, Y. H., and Lee, C. I., 2004. Influence of geological conditions on the powder factor for tunnel blasting. International Journal of Rock Mechanics and Mining Sciences, 41: 533-538.
- Mikaeil, R., Ataei, M., Yousefi, R., 2011. Application of a fuzzy analytical hierarchy process to the prediction of vibration during rock sawing. Mining Science and Technology (China), 21(5): 611-619.
- Mikaeil, R., Ataei, M., Ghadernejad, S., Sadegheslam G., 2014. Predicting the relationship between system vibration with rock brittleness indexes in rock sawing process. Archive of Mining Science, 59 (1): 139-153.
- Ozcelik, Y., Kulaksiz, S., Engin, L. C., Eyuboglu, A. S., 2001. Investigation into Relationship Between Cutting Depth and Vibration in Cutting Process. Presented in 17th International Mining Congress and Exhibition of Turkey.
- Ozcelik, Y., Yilmazkaya, E., 2011. The effect of the rock anisotropy on the efficiency of diamond wire cutting machines. International Journal of Rock Mechanics and Mining Sciences, 48(4): 626-636.
- Vapnik, V N., 1995. The nature of statistical learning theory. Springer-Verlag.