

پیش‌بینی پرتاب سنگ ناشی از آتشباری با استفاده از تکنیک درختی M5P

ابراهیم قاسمی*

استادیار، دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان

(دریافت: دی ۱۳۹۵، پذیرش: آذر ۱۳۹۶)

چکیده

پرتاب سنگ یکی از مسائل بحرانی عملیات آتشباری در معادن روباز است که به شدت ایمنی پرسنل و تجهیزات را تحت تأثیر قرار می‌دهد. یکی از راه‌های کاهش ریسک حوادث ناشی از پرتاب سنگ، پیش‌بینی دقیق آن است. طی سالیان گذشته با استفاده از روش‌های هوش مصنوعی، مدل‌های تجربی بسیاری برای پیش‌بینی پرتاب سنگ توسعه داده شده است. اغلب این مدل‌ها شفاف و قابل فهم نبوده و در آنها ارتباط بین پارامترهای ورودی و خروجی به وضوح نشان داده نشده است. هدف از این مقاله ارائه مدلی صریح و قابل فهم برای پیش‌بینی پرتاب سنگ است. برای این منظور از تکنیک M5P استفاده و به کمک آن ساختاری درخت مانند برای تخمین فاصله پرتاب سنگ ارائه شده است. در این مدل پرتاب سنگ بر اساس یک سری معادله‌های خطی پیش‌بینی می‌شود، از این‌رو استفاده از آن بسیار ساده است. به منظور آموزش و آزمایش مدل درختی پیشنهادی، داده‌های آتشباری معدن مس سونگون به کار گرفته شده است. در این مدل فاصله پرتاب سنگ با استفاده از مهم‌ترین پارامترهای قابل کنترل آتشباری یعنی بار سنگ، فاصله‌داری چال‌ها، طول گل‌گذاری، طول چال، قطر چال، خرج ویژه و متوسط خرج در هر چال تخمین زده می‌شود. دقت و کارایی مدل پیشنهادی با استفاده از شاخص‌های آماری R^2 ، VAF و RMSE مورد ارزیابی قرار گرفت. مقدار این شاخص‌ها به ترتیب ۹۲/۱ درصد، ۹۲ درصد و ۳/۹ به دست آمدند. بنابراین می‌توان نتیجه گرفت که تکنیک درختی M5P ابزاری مفید و قدرتمند برای پیش‌بینی پرتاب سنگ است. همچنین، نتایج نشان داد که بار سنگ و قطر چال به ترتیب با اهمیت‌ترین و کم‌اهمیت‌ترین پارامترها در پیش‌بینی پرتاب سنگ هستند.

کلمات کلیدی

معادن روباز، آتشباری، پرتاب سنگ، مدل درختی، تکنیک M5P، معدن مس سونگون

*عهده دار مکاتبات: e_ghasemi@cc.iut.ac.ir

۱- مقدمه

عملیات آتشیاری یکی از مهم‌ترین اجزای چرخه تولید در صنعت معدنکاری خصوصاً معادن روباز محسوب می‌شود که در اغلب موارد هدف اصلی آن، خرد کردن سنگ است. در صنعت معدنکاری سالیانه مقادیر قابل ملاحظه‌ای مواد ناریه مورد استفاده قرار می‌گیرد. مواد ناریه پس از انفجار انرژی بالایی آزاد می‌کنند که تنها ۲۰ تا ۳۰ درصد این انرژی صرف خرد کردن و جابجایی سنگ می‌شود [۱]. باقیمانده این انرژی صرف اثرات جانبی و مضر آتشیاری مانند لرزش زمین و هوا، عقب‌زدگی و پرتاب سنگ می‌شود که پیامدهای زیان‌باری را به همراه دارند. به عبارت دیگر، بیش از ۷۰ درصد انرژی انفجار هدر می‌رود.

همان‌گونه که بیان شد، پرتاب سنگ یکی از پیامدهای مخرب عملیات آتشیاری است که به صورت پرتاب غیرقابل کنترل و ناخواسته قطعات سنگی حاصل از انفجار به بیرون از ناحیه انفجار یا معدن با انرژی و سرعت بالا، تعریف می‌شود [۲]. این قطعات سنگی می‌توانند ابعاد گوناگونی از چند سانتی‌متر تا قطعات بزرگ داشته باشند و از این‌رو برخورد آنها با افراد می‌تواند منجر به جراحات‌های جبران‌ناپذیر و حتی مرگ آنها شود. علاوه بر این برخورد چنین قطعات سنگی با ماشین‌آلات و ساختمان‌ها می‌تواند آسیب‌های جدی به همراه داشته باشد. باجپای و همکاران [۳] و رهاک و همکاران [۴] با بررسی داده‌های آتشیاری کشور آمریکا نتیجه گرفتند که پرتاب سنگ عامل ۳۰ درصد حوادث ناشی از آتشیاری است. این دست آمارها توسط پژوهشگران بسیاری گزارش شده است که تمامی آنها بیانگر اهمیت مسئله پرتاب سنگ است [۵-۹]. بنابراین، پرداختن به این مسئله امری ضروری به نظر می‌رسد.

عموماً پرتاب سنگ در اثر عدم تطابق انرژی انفجار با مقاومت ژئومکانیکی توده‌سنگ اطراف چال ایجاد می‌شود. عوامل گوناگونی باعث ایجاد این عدم تطابق و نهایتاً پرتاب سنگ می‌شود که مهم‌ترین آنها عبارتند از: مقادیر بیش از حد ماده ناریه (تمرکز بالای ماده ناریه یا ماده ناریه قوی)، مقادیر بسیار کم یا بسیار زیاد بار سنگ، گل‌گذاری نامناسب و ناکافی، زمان و الگوی تأخیر نامناسب و وجود ساختارهای ضعیف زمین‌شناسی و ژئوتکنیکی در اطراف چال. به طور کلی پارامترهای اثرگذار بر رخداد و شدت پرتاب سنگ را

می‌توان به دو دسته قابل کنترل و غیر قابل کنترل تقسیم‌بندی کرد [۱۰]. پارامترهای قابل کنترل مانند پارامترهای طراحی انفجار و خصوصیات ماده ناریه، پارامترهایی هستند که توسط آتشیار اجرا می‌شوند و قابل تغییر هستند. بر عکس، پارامترهای غیر قابل کنترل مانند پارامترهای زمین‌شناسی و ژئومکانیکی، پارامترهای طبیعی بوده و توسط زمین اعمال می‌شوند و غیر قابل تغییر هستند. بدون شک، یک راه اساسی برای کنترل پرتاب سنگ، اجرای صحیح و مناسب پارامترهایی است که امکان کنترل آنها وجود دارد.

راه حل دیگر به منظور کاهش خسارت‌های ناشی از پرتاب سنگ، پیش‌بینی دقیق فاصله پرتاب سنگ است تا از این طریق افراد و تجهیزات خارج از محدوده خطر قرار گیرند. طی سالیان گذشته مدل‌های گوناگونی برای پیش‌بینی پرتاب سنگ توسعه یافته است که می‌توان آنها را به دو دسته کلی مدل‌های ریاضی (مکانیکی) و مدل‌های تجربی تقسیم‌بندی کرد [۱۰، ۱۱]. مدل‌های ریاضی دارای پشتوانه علمی قوی هستند و براساس مکانیزم‌های فیزیکی و بررسی رفتار قطعه سنگ پرتاب شده توسعه یافته‌اند، این در حالی است که اغلب مدل‌های تجربی بر اساس تحلیل‌های آماری و توسعه معادله‌ای با بهترین برازش بر داده‌های جمع‌آوری شده از پرتاب سنگ در یک معدن خاص گسترش یافته‌اند. هر یک از این مدل‌ها دارای مزایا و معایبی هستند. به طور مثال، اگر چه مدل‌های ریاضی دارای پشتوانه علمی بسیار قوی هستند اما استفاده از آنها نیازمند پارامترهایی همچون جرم قطعه سنگ، سرعت اولیه پرتاب و زاویه پرتاب است که تعیین آنها کار مشکلی است. استفاده از مدل‌های تجربی بسیار ساده است و اغلب آنها براساس پارامترهای طراحی انفجار که تعیین آنها راحت است، توسعه یافته‌اند. اما ایراد اصلی این مدل‌ها این است که آنها مختص به یک معدن خاص بوده و استفاده مستقیم از آنها در دیگر معادن مجاز نیست و باید براساس شرایط جدید اصلاح شوند. با این وجود، طی سال‌های گذشته مدل‌های تجربی به دلیل راحتی استفاده و ساده بودن برای تخمین پرتاب سنگ ناشی از انفجار در معادن رشد چشم‌گیری داشته‌اند. در ابتدا مدل‌های تجربی با استفاده از روش‌های آماری (رگرسیون ساده یا چند متغیره) توسعه داده می‌شدند اما امروزه روش‌های هوش مصنوعی با کارکردی به مراتب بالاتر، به عنوان یک جایگزین

مناسب برای این روش‌ها معرفی شده‌اند. روش‌های هوش مصنوعی توسط پژوهشگران بسیاری برای تخمین پرتاب سنگ به کار گرفته شده که در جدول ۱ خلاصه‌ای از این

مطالعات ارائه شده است. همه این پژوهشگران نتیجه گرفتند که روش‌های هوش مصنوعی ابزاری مناسب با کارایی بالا برای پیش‌بینی پرتاب سنگ است.

جدول ۱: بعضی از مطالعات انجام شده به منظور پیش‌بینی پرتاب سنگ با استفاده از روش‌های هوش مصنوعی

روش کمکی	روش هوش مصنوعی						سال	پژوهشگران
	DE	GP	SVM	ANFIS	FL	ANN		
GA						●	۲۰۱۰	منجری و همکاران [۱۲]
					●		۲۰۱۱	رضایی و همکاران [۱۳]
						●	۲۰۱۱	منجری و همکاران [۱۴]
			●				۲۰۱۲	امینی و همکاران [۱۵]
			●				۲۰۱۳	خاندوال و منجری [۱۶]
PSO					●	●	۲۰۱۴	قاسمی و همکاران [۱۷]
						●	۲۰۱۴	جاهد ارمغانی و همکاران [۱۸]
						●	۲۰۱۴	مارتو و همکاران [۱۹]
						●	۲۰۱۴	تریودی و همکاران [۲۰]
				●		●	۲۰۱۵	تریودی و همکاران [۲۱]
ICA				●		●	۲۰۱۶	جاهد ارمغانی و همکاران [۲۲]
				●			۲۰۱۶	شیرانی و همکاران [۲۳]
		●				●	۲۰۱۶	باری و همکاران [۲۴]
						●	۲۰۱۶	رینا و مورثی [۲۵]
							۲۰۱۷	دهقانی و شفقی [۲۶]
DA	●							

ANN شبکه عصبی مصنوعی، FL منطق فازی، ANFIS سیستم استنتاج عصبی-فازی تطبیقی، SVM ماشین بردار پشتیبان، GP برنامه‌ریزی ژنتیک، GA الگوریتم ژنتیک، PSO بهینه‌سازی ازدحام ذرات، ICA الگوریتم رقابت استعماری، DE الگوریتم تکامل تفاضلی و DA تحلیل ابعادی.

استفاده از این تکنیک منجر به توسعه مدلی شفاف و قابل فهم می‌شود. لازم به ذکر است که در این مقاله برای توسعه مدل درختی پیش‌بینی کننده پرتاب سنگ، از داده‌های جمع‌آوری شده از عملیات‌های آتشباری در معدن مس سونگون استفاده شده است. در بخش‌های بعدی مقاله پایگاه داده، تکنیک درختی M5P و نحوه توسعه مدل با توضیحات جزئی‌تر شرح داده می‌شوند.

۲- پایگاه داده

همان‌گونه که در مقدمه ذکر شد، در این مقاله قرار است با استفاده از داده‌های آتشباری معدن مس سونگون، مدلی درختی برای تخمین پرتاب سنگ ناشی از آتشباری توسعه داده شود. معدن مس سونگون یکی از بزرگ‌ترین معدن‌های مس پورفیری کشور است که در منطقه‌ای کوهستانی در ۱۳۰ کیلومتری شمال شرقی تبریز بر روی کمر بند متالوژنی سهند-بزمان واقع شده است. متوسط ارتفاع این معدن از سطح دریا ۲۰۰۰ متر است. زمین‌شناسی ذخیره سونگون

عیب اصلی اغلب تکنیک‌های هوش مصنوعی این است که برخلاف روش‌های آماری ارتباط بین پارامترهای ورودی و خروجی را به وضوح نشان نمی‌دهند، از این‌رو این مدل‌ها برای مخاطبان شفاف و قابل فهم نیست. هدف از این پژوهش توسعه مدلی شفاف و قابل درک برای پیش‌بینی پرتاب سنگ است. برای این منظور از تکنیک درختی M5P استفاده می‌شود. با استفاده از این تکنیک یک ساختار درخت مانند با مجموعه‌ای از قوانین (معادلات خطی) برای پیش‌بینی پرتاب سنگ ساخته می‌شود. اگر چه تکنیک M5P طی سال‌های اخیر در حوزه‌های گوناگون علوم با موفقیت برای توسعه مدل‌های پیش‌بینی کننده به کار گرفته شده است اما بررسی پژوهش‌های گذشته نشان می‌دهد که این تکنیک تا کنون در حوزه آتشباری در معدن به کار گرفته نشده است. مهم‌ترین مزایای این تکنیک این است که کارایی آن به مراتب بالاتر از روش‌های مرسوم آماری است و همچنین در آن ارتباط بین پارامترهای ورودی و خروجی به وضوح نشان داده می‌شود یعنی برخلاف اغلب روش‌های هوش مصنوعی،

فاصله‌داری چال‌ها، طول گل‌گذاری، طول چال، قطر چال، خرج ویژه و متوسط خرج در هر چال است. همچنین فاصله پرتاب سنگ به عنوان پارامتر خروجی جمع‌آوری شده است. شایان ذکر است که طول چال در نظر گرفته شده در این پایگاه داده، حاصل جمع ارتفاع پله و اضافه حفاری است. فاصله پرتاب سنگ به صورت بیشینه فاصله افقی بین سینه‌کار تا قطعه سنگ پرتاب شده در نظر گرفته شده و با استفاده از دستگاه GPS دستی اندازه‌گیری شده است. در اندازه‌گیری آن، تنها قطعه سنگ‌هایی که پتانسیل ایجاد آسیب‌های جدی دارند در نظر گرفته شده‌اند. بر اساس تجربه این قطعات سنگی قطری بالاتر از ۱۰ سانتی‌متر دارند و خرده سنگ‌ها با قطر کمتر در نظر گرفته نشده‌اند [۸، ۱۰، ۲۷]. باید ذکر شود که در تمام عملیات‌های آتشفشانی زمان تأخیر بین ردیف‌ها ثابت و برابر با ۱۰۰ میلی‌ثانیه بوده است، از این‌رو این پارامتر به عنوان پارامتر ورودی در نظر گرفته نشده است. خلاصه‌ای از وضعیت آماری پایگاه داده جمع‌آوری شده در معدن مس سونگون در جدول ۲ ارائه شده است.

جدول ۲: توصیف آماری پارامترهای جمع‌آوری شده در معدن مس سونگون

پارامتر	نماد	واحد	کمینه	متوسط	بیشینه	انحراف استاندارد
بار سنگ	B	متر	۲/۵	۴/۱۷	۵	۰/۴۱
فاصله‌داری چال‌ها	S	متر	۳	۴/۸۹	۶	۰/۵۴
طول گل‌گذاری	T	متر	۲	۳/۸۵	۴/۵	۰/۳۴
طول چال	L	متر	۸	۱۱/۸۲	۱۶	۱/۸۲
قطر چال	D	متر	۰/۰۹	۰/۱۳	۰/۱۵	۰/۰۱
خرج ویژه	P	کیلوگرم بر متر مکعب	۰/۱۵	۰/۴	۱/۱۲	۰/۱۲
متوسط خرج در هر چال	Q	کیلوگرم	۵۰	۸۹/۴۱	۱۳۹/۱۷	۱۶/۲۵
فاصله پرتاب سنگ	F	متر	۳۰	۶۸/۲۳	۹۵	۱۴/۲


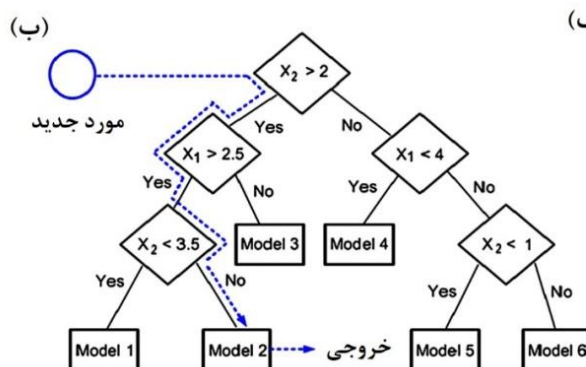
ریشه، گره‌های داخلی و برگ‌ها که توسط شاخه‌ها به یکدیگر وصل شده‌اند، ایجاد می‌کند. بالاترین گره در درخت، گره ریشه نامیده می‌شود. هر گره با یک ویژگی مشخص می‌شود که این ویژگی سؤالی در رابطه با پارامترهای ورودی مطرح می‌کند. بسته به تعداد جواب‌های ممکن به این سؤال حداقل دو شاخه از گره خارج می‌شود. در نهایت هر شاخه به برگ‌ها منتهی می‌شود. معمولاً در ساختار درخت، گره‌ها با دایره، برگ‌ها با مستطیل و شاخه‌ها با خط نمایش داده می‌شوند. برگ‌ها حاوی معادله‌های رگرسیون خطی بر مبنای پارامترهای ورودی هستند که می‌توان با استفاده از آنها پارامتر خروجی را پیش‌بینی کرد. این تکنیک نسبت به

بسیار پیچیده بوده و به طور کلی از سنگ‌های کربناته کرتاسه بالایی، توده مونزونیت سونگون، دایک‌ها و واحدهای آتشفشانی تشکیل شده است. ذخیره زمین‌شناسی این کانسار در حدود ۷۹۶ میلیون تن و ذخیره قابل استخراج آن در حدود ۴۱۰ میلیون تن با عیار متوسط ۰/۶ درصد است. این معدن به روش روباز استخراج می‌شود. متوسط ارتفاع و شیب پله‌های کاری به ترتیب ۱۲/۵ متر و ۶۸ درجه است. شیب نهایی معدن ۳۷ درجه و عرض و شیب راه‌های ارتباطی به ترتیب ۳۰ متر و ۵ درجه است. عمر معدن در حدود ۳۲ سال تخمین زده شده است و نسبت باطله‌برداری کلی در حدود ۱/۷ است. در این معدن به منظور استخراج ماده معدنی، عملیات آتشفشانی انجام می‌شود و ماده منفجره اصلی آنفو است. به منظور توسعه مدل از پایگاه داده‌ای شامل ۱۵۰ عملیات آتشفشانی در این معدن استفاده می‌شود. از آنجایی که یکی از راه‌های کنترل پرتاب سنگ، انتخاب و اجرای صحیح پارامترهای قابل کنترل آتشفشانی است، لذا این پایگاه داده شامل مهم‌ترین پارامترهای قابل کنترل یعنی بار سنگ،

۳- تکنیک درختی M5P

تکنیک درختی M5P در اصل گسترش یافته درخت تصمیم و درخت رگرسیون است که اولین بار در سال ۱۹۹۲ توسط کوئلن معرفی شد و بعدها توسط وانگ و ویتن در سال ۱۹۹۷ شکل اصلاح شده امروزی خود را پیدا کرد [۲۸، ۲۹]. شرح دقیق این تکنیک را می‌توان در کتاب‌ها و مقاله‌های گوناگون یافت اما در ادامه توضیحی اجمالی به منظور آشنایی با آن ارائه می‌شود. همان‌گونه که از اسم این تکنیک نیز مشخص است، این تکنیک برای تخمین پارامتر مورد نظر (خروجی)، ساختاری درخت شکل شامل گره

درون برگ‌های درخت جای می‌گیرند (شکل ۱-الف). سپس در هر برگ، با استفاده از آنالیز رگرسیون خطی چند متغیره، معادله‌ای برای پیش‌بینی پارامتر خروجی بر اساس پارامترهای ورودی توسعه داده می‌شود. در فرآیند استخراج دانش، یک دسته داده ورودی جدید به درون ساختار درختی تغذیه می‌شوند سپس با توجه به شرایط تقسیم به دست آمده از مرحله قبل، این مورد جدید درون یکی از برگ‌های درخت قرار می‌گیرد. حال می‌توان با استفاده از معادله خطی موجود در برگ، مقدار خروجی را پیش‌بینی کرد (شکل ۱-ب).



شکل ۱: فرآیند ساخت درخت با استفاده از تکنیک M5P: (الف) تقسیم فضای ورودی به چندین ناحیه همگن X_1 و X_2 پارامترهای ورودی و Y پارامتر خروجی)، هر مدل بیانگر یک معادله رگرسیون خطی بین پارامترهای ورودی و خروجی است، (ب) نحوه پیش‌بینی یک مورد جدید به کمک درخت [۳۱]

در این بخش با استفاده از پایگاه داده جمع‌آوری شده از ۱۵۰ عملیات آتشباری در معدن مس سونگون، مدلی درختی برای پیش‌بینی پرتاب سنگ توسعه داده می‌شود. این مدل با استفاده از تکنیک M5P در محیط نرم‌افزار WEKA ساخته می‌شود [۳۲]. در ابتدا پیش از ساخت مدل، داده‌ها توسط نرم‌افزار به صورت تصادفی به دو دسته داده‌های آموزش و داده‌های آزمایش تقسیم‌بندی می‌شوند. بر اساس توصیه‌های ذکر شده در متن‌های علمی، ۸۰ درصد داده‌ها (۱۲۰ مورد آتشباری) به عنوان داده آموزش برای توسعه و ساخت مدل درختی و ۲۰ درصد باقی‌مانده (۳۰ مورد آتشباری) به عنوان داده آزمایش برای ارزیابی کارکرد و کارایی مدل توسعه داده شده در نظر گرفته شدند.

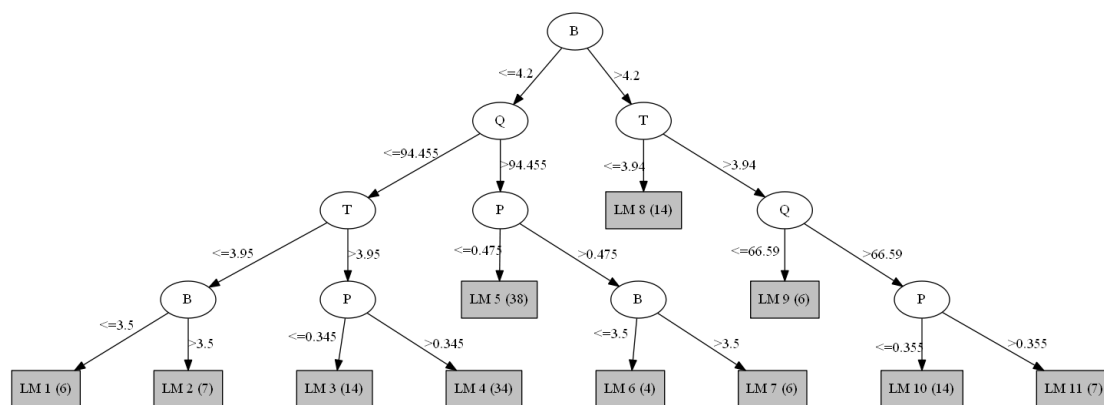
به منظور توسعه مدل از هر دو گزینه هرس کردن و هموارسازی برای ساده کردن ساختار درخت و بهبود نتایج استفاده شد. مدل درختی به دست آمده از نرم‌افزار WEKA به منظور پیش‌بینی پرتاب سنگ بر اساس داده‌های آموزش در شکل ۲ نشان داده شده است. همان‌گونه که ملاحظه

عموماً پس از ساخت درخت، دو فرآیند هرس کردن^۱ و هموارسازی^۲ بر روی آن انجام می‌گیرد. گاهی درخت توسعه داده شده دارای گره‌ها، شاخه‌ها و برگ‌های بسیار زیادی است که منجر به پیچیدگی ساختار آن و بیش یادگیری^۳ مدل می‌شود. به منظور حذف این مشکل، فرآیند هرس کردن انجام می‌گیرد. در این فرآیند با حذف گره‌های داخلی کم اثر، بدون آنکه کاهش چشم‌گیری در دقت مدل رخ دهد، ساختار درخت ساده می‌شود. پس از هرس کردن، به منظور حذف ناپیوستگی‌های به وجود آمده بین معادلات موجود در برگ‌های مجاور، عملیات هموارسازی انجام می‌شود. در این مرحله به منظور بر طرف کردن شکاف ایجاد شده، معادله نهایی موجود در برگ از ترکیب مدل به دست آمده در آن برگ با مدل‌های موجود در مسیر ریشه تا برگ مربوطه به دست می‌آید. عموماً هموارسازی موجب بهبود پیش‌بینی می‌شود.

۴- توسعه مدل درختی

آموزش و هم داده‌های آزمایش). همان‌گونه که پیش از این نیز ذکر شده است، نرم‌افزار بر اساس داده‌های آموزشی که در هر برگ قرار گرفته است با استفاده از تکنیک آنالیز رگرسیون خطی چند متغیره، معادله‌ای خطی برای پیش‌بینی پرتاب سنگ توسعه می‌دهد. معادله‌های خطی موجود در هر برگ در جدول ۳ آورده شده است.

می‌شود، این مدل شامل ۱۰ گره و ۱۱ برگ است. هر گره‌ای حاوی مشخصه‌ای (پارامتر ورودی) بوده و از هر گره بسته به مقادیر پارامتر ورودی، دو شاخه خارج شده است. انتهای تمامی شاخه‌ها یک برگ قرار گرفته است که حاوی یک مدل خطی (LM) است که بر اساس آن می‌توان مقدار پرتاب سنگ را پیش‌بینی کرد. اعداد داخل پرانتز در هر برگ بیانگر تعداد داده‌هایی است که در آن برگ وجود دارد (هم داده‌های



شکل ۲: ساختار مدل درختی M5P برای پیش‌بینی پرتاب سنگ

جدول ۳: معادلات خطی برای پیش‌بینی پرتاب سنگ

شماره مدل	معادله خطی برای پیش‌بینی پرتاب سنگ
LM 1	$F = -11.8659B - 7.1975S + 3.2106T - 0.1421L + 861.4815D - 3.928P + 0.1774Q + 14.8023$
LM 2	$F = -11.5407B - 7.1975S + 3.2106T - 0.1421L + 749.1136D - 3.928P + 0.1774Q + 24.973$
LM 3	$F = -4.7111B - 7.4505S + 3.2106T - 0.1421L + 516.1127D + 5.7471P + 0.1574Q + 35.3642$
LM 4	$F = -4.7111B - 9.5566S + 3.2106T - 0.1421L + 649.0091D + 1.7981P + 0.1824Q + 29.2775$
LM 5	$F = -4.7111B - 6.0576S + 3.2106T - 0.1421L + 448.5732D + 17.7363P + 0.0792Q + 43.3624$
LM 6	$F = -7.5814B - 38.5808S + 10.7305T - 0.1421L + 833.6422D - 3.928P + 0.0792Q + 0.3574$
LM 7	$F = -7.308B - 8.5808S + 3.2106T - 0.1421L + 815.0535D - 3.928P + 0.0792Q + 25.2448$
LM 8	$F = -25.9059B - 3.5494S + 11.6617T + 0.2747L + 222.6576D + 20.5677P + 0.0296Q + 98.7955$
LM 9	$F = -38.9151B - 3.5494S + 10.2526T + 0.8289L + 222.6576D + 45.0385P - 0.023Q + 156.2517$
LM 10	$F = -28.0474B - 3.5494S + 10.2526T + 0.522L + 222.6576D + 37.6822P + 0.0054Q + 110.9697$
LM 11	$F = -28.0474B - 3.5494S + 10.2526T + 0.522L + 222.6576D + 39.7867P + 0.0054Q + 110.9199$

باشد [۳۳، ۱۰]. این مشکل یکی از محدودیت‌های مدل‌های درختی M5P است که ریشه آن تکنیک مورد استفاده برای توسعه معادلات خطی است. با این وجود در مدل‌های درختی می‌توان اهمیت پارامترهای ورودی بر پارامتر خروجی را با تعیین اهمیت نسبی برای هر پارامتر مورد ارزیابی قرار داد. اهمیت نسبی دارای مقداری بین صفر تا یک است که هر چقدر به یک نزدیک‌تر باشد، پارامتر مورد نظر اهمیت بیش‌تری در پیش‌بینی پارامتر خروجی دارد. بر اساس خروجی به دست آمده از مدل، اهمیت نسبی پارامترهای

نکته قابل ذکر در مورد اغلب مدل‌های درختی این است که علامت ضرایب رگرسیون معادلات خطی در هر برگ معیار مناسبی برای ارزیابی تأثیر پارامترهای ورودی (تأثیر مثبت و یا منفی) بر پارامتر خروجی نیست. همان‌گونه که پیش از این ذکر شده است، این معادلات به کمک آنالیز رگرسیون خطی چندگانه توسعه می‌یابند. در این شرایط، در صورت وجود همبستگی بین پارامترهای ورودی پدیده هم‌راستایی چندگانه^۴ رخ می‌دهد و ارزیابی تأثیر پارامترهای ورودی بر مبنای علامت ضرایب رگرسیون می‌تواند گمراه کننده


ارزیابی قرار می‌گیرد. در جدول ۴ داده‌های آزمایش آورده شده است. به منظور پیش‌بینی پرتاب سنگ، هر یک از موارد آزمایش به درون درخت توسعه داده شده در بخش قبل تغذیه می‌شوند (شکل ۲) و با توجه به برگه که در آن قرار می‌گیرند به کمک مدل خطی مربوطه، مقدار پرتاب سنگ پیش‌بینی می‌شود. به طور مثال، اگر پارامترهای مربوط به اولین مورد داده‌های آزمایش وارد درخت شکل ۲ شود، برای پیش‌بینی پرتاب سنگ باید از مدل خطی دهم (LM 10) استفاده کرد. لذا مقدار پرتاب سنگ به صورت رابطه ۱ محاسبه می‌شود:

$$F = (-28.0474 \times 4.5) - (3.5494 \times 5.5) + (10.2526 \times 4.3) + (0.522 \times 9.4) + (222.6576 \times 0.14) + (37.6822 \times 0.34) + (0.0054 \times 78.75) + 110.9697 = 58.6 \text{ m} \quad (1)$$

در جدول ۴، مقادیر واقعی و پیش‌بینی شده پرتاب سنگ برای تمامی داده‌های آزمایش ارائه شده است.

مشخص کردن ضریب تعیین (R^2) بین مقادیر واقعی و پیش‌بینی شده، شاخصی مناسب برای کنترل کردن کارایی هر مدل پیش‌بینی کننده است. هر چه این ضریب به ۱۰۰ درصد نزدیک‌تر باشد، مدل توسعه داده شده کارآمدتر است. شکل ۴ ارتباط بین مقادیر واقعی و پیش‌بینی شده را با بهترین ضریب تعیین نشان می‌دهد. بر اساس این شکل، ضریب تعیین ۹۲/۱ درصد بوده و بیانگر ظرفیت بالای پیش‌بینی مدل است.


ورودی گوناگون در شکل ۳ نشان داده شده است. همان‌گونه که ملاحظه می‌شود، پارامترهای بار سنگ (B)، خرج ویژه (P)، فاصله‌داری چال‌ها (S)، متوسط خرج در هر چال (Q)، طول گل‌گذاری (T)، طول چال (L) و قطر چال (D) به ترتیب اثرگذارترین پارامترها بر پدیده پرتاب سنگ در معدن مس سونگون هستند. در ادامه با استفاده از داده‌های آزمایش، کارایی و دقت مدل مورد ارزیابی قرار می‌گیرد.



شکل ۳: اهمیت نسبی پارامترهای ورودی بر پرتاب سنگ

۵- کارایی و دقت مدل درختی

در این بخش، کارایی مدل درختی ساخته شده با استفاده از داده‌های آزمایش که شامل ۳۰ مورد آتشباری است مورد



شکل ۴: ارتباط بین مقادیر واقعی و پیش‌بینی شده پرتاب سنگ بر اساس مدل درختی MSP

جدول ۴: داده‌های آزمایش به همراه مقادیر واقعی و پیش‌بینی شده پرتاب سنگ

مورد	B (m)	S (m)	T (m)	L (m)	D (m)	P (kg/m ³)	Q (kg)	F (m)	
								واقعی	مدل MSP
۱	۴/۵	۵/۵	۴/۳	۹/۴	۰/۱۴	۰/۳۴	۷۸/۷۵	۵۹	۵۸/۶
۲	۴/۵	۵/۵	۴/۳	۱۳/۳	۰/۱۴	۰/۲۵	۸۳/۳	۵۵	۵۸/۳
۳	۴	۵	۴/۱	۹/۲	۰/۱۴	۰/۳۸	۷۰/۵۹	۸۴	۷۸/۹
۴	۴	۵	۴/۱	۸/۸	۰/۱۴	۰/۵۶	۹۹	۸۵	۸۲/۷
۵	۴/۵	۵	۴/۳	۸/۳	۰/۱۴	۰/۴۲	۷۸/۱۸	۶۴	۶۴/۶
۶	۴	۵	۴/۱	۱۲/۳	۰/۱۴	۰/۴۲	۱۰۴/۱۷	۸۶	۸۴
۷	۴/۵	۵/۵	۴/۳	۹/۸	۰/۱۴	۰/۲۸	۶۷/۳۹	۵۸	۵۷/۱
۸	۴/۵	۵/۵	۴/۳	۱۲/۵	۰/۱۴	۰/۳۶	۱۱۰	۵۹	۶۲/۲
۹	۴/۵	۵/۵	۴/۳	۱۲	۰/۱۴	۰/۳۵	۱۰۳/۵۷	۶۲	۶۰/۸
۱۰	۴	۵	۴/۱	۱۲	۰/۱۴	۰/۴۳	۱۰۲/۱۴	۸۴	۸۳/۷
۱۱	۴	۴/۵	۴/۱	۱۳/۲	۰/۱۳	۰/۲۹	۶۹/۸۱	۷۱	۷۴/۵
۱۲	۴/۵	۵/۵	۴/۳	۹/۸	۰/۱۴	۰/۳۴	۸۱/۳۵	۵۴	۵۸/۹
۱۳	۴	۵	۴/۱	۱۴	۰/۱۴	۰/۴۳	۱۱۹/۶۴	۸۵	۸۵/۲
۱۴	۴	۵	۴/۱	۱۲	۰/۱۴	۰/۳۵	۸۴/۴۴	۸۵	۸۰/۹
۱۵	۴/۵	۵/۵	۴/۳	۱۲/۳	۰/۱۴	۰/۳۲	۹۸/۷۸	۵۷	۶۰/۳
۱۶	۴	۵	۴/۱	۱۲/۴	۰/۱۴	۰/۴۲	۱۰۴/۰۶	۸۴	۸۴
۱۷	۴	۴/۵	۴/۱	۱۳	۰/۱۳	۰/۳۵	۸۲/۲۶	۸۲	۷۸/۴
۱۸	۴	۴/۵	۴/۱	۱۳/۵	۰/۱۳	۰/۵۲	۱۲۷	۸۶	۸۳/۶
۱۹	۴	۴/۵	۴/۱	۱۳	۰/۱۳	۰/۳۸	۹۰	۸۴	۷۹/۸
۲۰	۴	۴/۵	۴/۱	۱۳/۵	۰/۱۳	۰/۳۹	۹۵	۸۴	۸۱/۶
۲۱	۴	۴/۵	۴/۱	۱۳/۵	۰/۱۳	۰/۳۷	۹۰	۸۴	۷۹/۷
۲۲	۴	۵	۴/۱	۱۲/۵	۰/۱۴	۰/۴۲	۱۰۴/۷۱	۸۴	۸۳/۴
۲۳	۴	۵	۴/۱	۱۳/۵	۰/۱۳	۰/۳۵	۹۳/۶۲	۷۴	۷۵/۶
۲۴	۴	۵	۴/۱	۱۲/۶	۰/۱۴	۰/۴۲	۱۰۶/۱۹	۸۲	۸۴/۲
۲۵	۲/۵	۳	۲	۹/۱	۰/۱۴	۱/۱۲	۷۶/۳۲	۹۵	۱۰۴/۸
۲۶	۴/۵	۵/۵	۳/۶	۱۲/۸	۰/۱۴	۰/۳۴	۱۰۸/۳۳	۵۰	۴۹/۷
۲۷	۴	۴/۵	۳/۸	۱۳	۰/۱۳	۰/۲۶	۶۲	۵۴	۶۴/۷
۲۸	۴/۴	۵	۳/۶	۱۰/۶	۰/۱۴	۰/۳۴	۸۰	۵۰	۵۳/۵
۲۹	۴	۵	۴/۱	۱۴	۰/۱۴	۰/۴۱	۱۱۵/۳۸	۸۱	۸۴/۶
۳۰	۴	۵	۴/۱	۱۲/۴	۰/۱۴	۰/۳۱	۷۷/۳۷	۷۲	۷۷/۵

کاهش مقدار آن، کارایی مدل افزایش می‌یابد. زمانی که مقدار RMSE صفر باشد مدل توسعه یافته عالی خواهد بود.


$$VAF = \left[1 - \frac{\text{var}(A_i - P_i)}{\text{var}(A_i)} \right] \times 100 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - P_i)^2} \quad (3)$$

که در این رابطه‌ها var نشان‌دهنده واریانس، A_i مقدار واقعی، P_i مقدار پیش‌بینی شده و N تعداد نمونه‌ها است. شاخص VAF و RMSE به ترتیب ۹۲ درصد و ۳/۹ به دست آمده است و بیانگر این است که مدل توسعه داده شده می‌تواند با خطای قابل قبولی پرتاب سنگ را پیش‌بینی کند.

علاوه بر این، شاخص‌های واریانس خطا^۵ (VAF) و خطای جذر میانگین مربعات^۶ (RMSE) برای ارزیابی ظرفیت پیش‌بینی مدل به ترتیب با استفاده از رابطه‌های ۲ و ۳ محاسبه شده است. شاخص VAF به منظور بررسی اینکه مدل تا چه حدی می‌تواند واریانس در داده‌ها را توضیح دهد، استفاده می‌شود. مقادیر بالای VAF بیانگر کارایی بهتر مدل است. هنگامی که مقدار واقعی و پیش‌بینی شده کاملاً یکسان باشد، مقدار VAF برابر با ۱۰۰ درصد به دست می‌آید. شاخص RMSE بیانگر انحراف در داده‌ها است و با

ساخت مدل استفاده شد. درخت توسعه یافته دارای ۱۱ برگ است که هر برگ حاوی یک معادله خطی برای پیش‌بینی پرتاب سنگ است. برای ارزیابی دقت و کارایی مدل در مرحله آزمایش، شاخص‌های آماری R^2 ، VAF و RMSE محاسبه شدند. این شاخص‌ها به ترتیب ۹۲/۱ درصد، ۹۲ درصد و ۳/۹ به دست آمدند. از این‌رو می‌توان نتیجه گرفت که مدل پیشنهادی روشی مناسب و کاربردی است که می‌تواند به طور مؤثر در پیش‌بینی پرتاب سنگ با خطای قابل قبولی به کار گرفته شود. نتایج آنالیز حساسیت در مرحله توسعه مدل نشان داد که بار سنگ با اهمیت نسبی ۱ و قطر چال با اهمیت نسبی ۰/۱۹ به ترتیب با اهمیت‌ترین و کم‌اهمیت‌ترین پارامترهای اثرگذار بر پرتاب سنگ هستند. از این‌رو طراحی و انتخاب مناسب بار سنگ نقش قابل ملاحظه‌ای در کنترل پرتاب سنگ در معدن مس سونگون دارد. همچنین مقایسه این مدل با رابطه قاسمی و همکاران (رابطه ۴) نشان داد که مدل درختی کارایی بالاتری نسبت به روش‌های آماری کلاسیک دارد.



شکل ۵: مقایسه کارایی مدل درختی پیشنهادی با رابطه قاسمی و همکاران (رابطه ۴) از نظر شاخص‌های آماری گوناگون
این پژوهش نشان داد که تکنیک M5P ابزاری مفید و قدرتمند برای پیش‌بینی پرتاب سنگ است. خروجی به دست آمده از این مدل را می‌توان به عنوان تخمین اولیه‌ای از پرتاب

همچنین به منظور ارزیابی ظرفیت پیش‌بینی مدل درختی توسعه داده شده، این مدل با رابطه قاسمی و همکاران [۱۰] مقایسه شد. قاسمی و همکاران بر اساس داده‌های آتشباری معدن مس سونگون به کمک تکنیک‌های تحلیل ابعادی و رگرسیون غیرخطی (آمار کلاسیک) رابطه ۴ را برای پیش‌بینی پرتاب سنگ توسعه دادند:

$$F = 6946.547[B^{-0.796} \cdot S^{0.783} \cdot T^{1.994} \cdot L^{1.649} \cdot D^{1.766} \cdot (P/Q)^{1.465}] \quad (۴)$$

مقادیر پیش‌بینی شده پرتاب سنگ با استفاده از این رابطه برای داده‌های آزمایش در جدول ۴ آورده شده است. بر اساس داده‌های آزمایش، مقدار خطای پیش‌بینی توسط رابطه ۴ بین ۱۲- تا ۱۸ متر است در حالی که این مقدار برای مدل درختی بین ۱۰/۷- تا ۵/۱ متر است. این بدان معنا است که مقادیر پیش‌بینی شده پرتاب سنگ توسط مدل درختی به مقادیر واقعی آن نزدیک‌تر است. همچنین، ضریب R^2 و شاخص‌های VAF و RMSE برای رابطه ۴ به ترتیب ۷۸/۶ درصد، ۷۶/۶ درصد و ۶/۶ به دست آمده است. در شکل ۵، کارایی معادله ۳ با مدل درختی پیشنهادی از نظر شاخص‌های آماری گوناگون مقایسه شده است. می‌توان نتیجه گرفت که اگر چه رابطه ۴ از دقت نسبتاً قابل قبولی برخوردار است اما کارایی آن به مراتب کمتر از مدل درختی است. به بیان دیگر، مدل درختی در مقایسه با روش‌های آماری کلاسیک قدرت پیش‌بینی بالاتری دارد.

۶- بحث و نتیجه‌گیری

در این مقاله، با استفاده از تکنیک M5P، مدلی درختی برای پیش‌بینی پرتاب سنگ ناشی از عملیات آتشباری توسعه داده شد. در این مدل پرتاب سنگ به عنوان پارامتر خروجی با استفاده از پارامترهایی مانند بار سنگ، فاصله‌داری چال‌ها، طول گل‌گذاری، طول چال، قطر چال، خرج ویژه و متوسط خرج در هر چال به عنوان پارامترهای ورودی مدل، پیش‌بینی می‌شود. مدل پیشنهادی بر اساس پایگاه داده‌ای شامل ۱۵۰ مورد عملیات آتشباری در معدن مس سونگون با استفاده از تکنیک درختی M5P در نرم‌افزار WEKA توسعه یافته است. ۱۲۰ مورد از این داده‌ها برای آموزش مدل و مابقی (۳۰ مورد) برای بررسی و ارزیابی دقت مدل به کار گرفته شده است. به منظور بهبود دقت مدل و ساده کردن ساختار آن، از هر دو گزینه هرس کردن و هموارسازی حین فرآیند

understanding the basics to develop a predictive regime. *Current Science*, 108(4), 660–665.

[6] Mishra, A.K. and Mallick, D.K. (2013). Analysis of blasting related accidents with emphasis on flyrock and its mitigation in surface mines. In: *proceedings of rock fragmentation by blasting, Fragblast 10*, Taylor and Francis, London, pp 555–561.

[7] Kecojevic, V. and Radomsky, M. (2005) Flyrock phenomena and area security in blasting-related accidents. *Saf. Sci.*, 43(9), 739–750.

[8] Little, T.N. (2007). Flyrock risk. In: *proceedings of EXPLO Conference*, Sep. 3-4, Wollongong, pp 35–43.

[9] Verakis, H.C. and Lobb, T.E. (2003). An analysis of blasting accidents in mining operations. In: *proceedings of 29th annual conference explosives and blasting technique, international society of explosives engineers (ISEE)*, Feb. 2-5, Nashville, pp 119–129.

[10] Ghasemi, E., Sari, M. and Ataei, M. (2012). Development of an empirical model for predicting the effects of controllable blasting parameters on flyrock distance in surface mines. *Int. J. Rock Mech. Min. Sci.*, 52, 163–170.

[11] Raina, A.K., Murthy, V.M.S.R. and Soni, A.K. (2014). Flyrock in bench blasting: a comprehensive review. *Bull. Eng. Geol. Environ.*, 73, 1199–1209.

[12] Monjezi, M., Bahrami, A. and Yazdian Varjani, A. (2010). Simultaneous prediction of fragmentation and flyrock in blasting operation using artificial neural networks. *Int. J. Rock Mech. Min. Sci.*, 47(3), 476–480.

[13] Rezaei, M., Monjezi, M. and Yazdian Varjani, A. (2011). Development of a fuzzy model to predict flyrock in surface mining. *Saf. Sci.*, 49(2), 298–305.

[14] Monjezi, M., Amini Khoshalan, H. and Yazdian Varjani, A. (2012). Prediction of flyrock and backbreak in open pit blasting operation: a neuro-genetic approach. *Arab. J. Geosci.*, 5(3), 441–448.

[15] Amini, H., Gholami, R., Monjezi, M., Torabi, S.R. and Zadhesh, J. (2012). Evaluation of flyrock phenomenon due to blasting operation by support vector machine. *Neural Comput. Appl.*, 21(8), 2077–2085.

[16] Khandelwal, K. and Monjezi, M. (2013). Prediction of flyrock in open pit blasting operation using machine learning method. *Int. J. Min. Sci. Technol.*, 23(3), 313–316.

[17] Ghasemi, E., Amini, H., Ataei, M. and Khalokakaei, R. (2014). Application of artificial

سنگ در نظر گرفت که بر اساس آن ریسک خطرات و حوادث احتمالی را می‌توان تا حد قابل قبولی کاهش داد. مهم‌ترین مزیت تکنیک M5P توانایی آن در ایجاد یک ساختار درختی ساده است که هر یک از برگ‌های آن حاوی یک رابطه خطی است و به وضوح ارتباط بین پارامترهای ورودی با پارامتر خروجی را بیان می‌کند. خواننده به راحتی می‌تواند با استفاده از این رابطه‌ها مقدار پرتاب سنگ را برای موارد جدید آتشباری پیش‌بینی کند در حالی که اغلب روش‌های هوش مصنوعی که امروزه به وفور استفاده می‌شود، جعبه سیاه^۷ هستند یعنی در آنها ارتباط بین پارامترهای ورودی با پارامتر خروجی مبهم و غیر شفاف است. بنابراین خوانندگان نمی‌توانند آنها را برای پیش‌بینی پارامتر خروجی به کار گیرند. در آخر باید ذکر شود مدل توسعه داده شده در این مقاله بر اساس شرایط معدن مس سونگون است و استفاده مستقیم آن در سایر معادن توصیه نمی‌شود، بلکه می‌توان برای معدن‌های دیگر با توجه به شرایط موجود در آنها مدل‌های مشابهی را توسعه داد. همچنین باید ذکر شود که با جمع‌آوری داده‌های بیشتر می‌توان این مدل را بهبود بخشید و مدل جامع‌تری توسعه داد.

مراجع

[1] Singh, T.N. and Singh, V. (2005). An intelligent approach to predict and control ground vibration in mines. *Geotech. Geol. Eng.*, 23(3), 249–262.

[2] Institute of Makers of Explosives (IME) (1997). Glossary of commercial explosives industry terms. Safety publication, No. 12, Institute of Makers of Explosives, Washington.

[3] Bajpayee, T.S., Rehak, T.R., Mowrey, G.L. and Ingram, D.K. (2002). A summary of fatal accidents due to flyrock and lack of blast area security in surface mining, 1989 to 1999. In: *proceedings of the 28th annual conference on explosives and blasting technique, international society of explosives engineers (ISEE)*, Feb. 10-13, Las Vegas, pp 105–118.

[4] Rehak, T.R., Bajpayee, T.S., Mowrey, G.L. and Ingram, D.K. (2001). Flyrock issues in blasting. In: *proceedings of the 27th annual conference on explosives and blasting technique, international society of explosives engineers (ISEE)*, Jan. 28-31, Orlando, pp 165–175.

[5] Raina, A.K., Murthy, V.M.S.R. and Soni, A.K. (2015). Flyrock in surface mine blasting:

- [25] Raina, A.K. and Murthy, V.M.S.R. (2016). Importance and sensitivity of variables defining throw and flyrock in surface blasting by artificial neural network method. *Current Science*, 111(9), 1524–1531.
- [26] Dehghani, H. and Shafaghi, M. (2017). Prediction of blast-induced flyrock using differential evolution algorithm. *Eng. Comput.*, 33(1), 149–158.
- [27] Hudaverdi, T. and Akyildiz, O. (2017). A new classification approach for prediction of flyrock throw in surface mines. *Bull. Eng. Geol. Environ.*
- [28] Quinlan, J.R. (1992). Learning with continuous classes. In: *proceedings of the fifth Australian joint conference on artificial intelligence*, world scientific, Singapore, pp 343–348.
- [29] Wang, Y. and Witten, I.H. (1997). Induction of model trees for predicting continuous lasses. In: *proceedings of the poster papers of the European conference on machine learning*, Prague, Czech Republic.
- [30] Ghasemi, E., Kalhori, H., Bagherpour, R. and Yagiz, S. (2018). Model tree approach for predicting uniaxial compressive strength and Young's modulus of carbonate rocks. *Bull. Eng. Geol. Environ.*, 77(1), 331–343.
- [31] Jung, N.-C., Popescu, I., Kelderman, P., Solomatine, D.P. and Price, R.K. (2010). Application of model trees and other machine learning techniques for algal growth prediction in Yongdam Reservoir, Republic of Korea. *J. Hydroinform.*, 123, 262–274.
- [32] WEKA (Waikato Environment for Knowledge Analysis), Version 3.6.12 (2014). The University of Waikato, Hamilton, New Zealand, available at: <http://www.cs.waikato.ac.nz/ml/weka>.
- [33] Montgomery, D.C., Peck, E.A. and Vining, G.G. (2012). *Introduction to linear regression analysis*, 5th edn. Wiley, New Jersey.
- intelligence techniques for predicting the flyrock distance caused by blasting operation. *Arab. J. Geosci.*, 7(1), 193–202.
- [18] Jahed Armaghani, D., Hajihassani, M., Tonnizam Mohamad, E., Marto, A. and Noorani, S.A. (2014). Blasting-induced flyrock and ground vibration prediction through an expert artificial neural network based on particle swarm optimization. *Arab. J. Geosci.*, 7(12), 5383–5396.
- [19] Marto, A., Hajihassani, M., Jahed Armaghani, D., Tonnizam Mohamad, E. and Makhtar, A.M. (2014). A novel approach for blast-induced flyrock prediction based on imperialist competitive algorithm and artificial neural network. *Sci. World J.*, Article ID 643715.
- [20] Trivedi, R., Singh, T.N. and Raina, A.K. (2014). Prediction of blast-induced flyrock in Indian limestone mines using neural networks. *J. Rock Mech. Geotech. Eng.*, 6(5), 447–454.
- [21] Trivedi, R., Singh, T.N. and Gupta, N. (2015). Prediction of blast-induced flyrock in opencast mines using ANN and ANFIS. *Geotech. Eng.*, 33(3), 875–891.
- [22] Jahed Armaghani, D., Tonnizam Mohamad, E., Hajihassani, M., Alavi Nezhad Khalil Abad, S.V., Marto, A. and Moghaddam, M.R. (2016). Evaluation and prediction of flyrock resulting from blasting operations using empirical and computational methods. *Eng. Comput.*, 32(1), 109–121.
- [23] Shirani Faradonbeh, R., Jahed Armaghani, D., Monjezi, M. and Tonnizam Mohamad, E. (2016). Genetic programming and gene expression programming for flyrock assessment due to mine blasting. *Int. J. Rock Mech. Min. Sci.*, 88, 254–264.
- [24] Yari, M., Bagherpour, R., Jamali, S. and Shamsi, R. (2016). Development of a novel flyrock distance prediction model using BPNN for providing blasting operation safety. *Neural Comput. Appl.*, 27(3), 699–706.

⁵ Variance account for⁶ Root mean square error⁷ Black-box¹ Pruning² Smoothing³ Over-fitting⁴ Multicollinearity