

### ارزیابی پدیده ترکیدن خودبخودی سنگ در حفاریات زیرزمینی عمیق با استفاده از روش‌های هوشمند در نرم‌افزار داده‌کاوی WEKA

پژوهشی

هادی فتاحی<sup>۱\*</sup>؛ فاطمه جبرایی<sup>۲</sup>؛ محمد عشوری<sup>۳</sup>

۱- دانشیار؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، h.fattahi@araku.ac.ir

۲- دانشجوی کارشناسی ارشد؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، fatemeh.jiryaee@gmail.com

۳- دانشجوی کارشناسی؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، iron.azar@gmail.com

دریافت دست‌نوشته: ۱۳۹۹/۱۲/۳۰؛ پذیرش دست‌نوشته: ۱۴۰۰/۰۴/۱۶

شماره صفحات: ۳۹۷ تا ۴۱۴

شناسه دیجیتال (DOR): 20.1001.1.23223111.1399.9.4.5.4

#### چکیده

انفجار سنگ در حفاریات زیرزمینی عمیق پدیده‌ای است که به صورت شکست ناگهانی سنگ و آزاد سازی انرژی کرنشی ذخیره شده در معادن زیرزمینی و تونل‌های سنگی، معمولاً در نقاط پر تنش و با عمق زیاد نسبت به سطح زمین مشاهده می‌شود. بر اثر این شکست انفجاری، سنگ به صورت قطعات کوچک و بزرگ به اطراف پرتاب شده و در اثر برخورد به انسان و یا تجهیزات باعث آسیب آن‌ها می‌شود. در تحقیق حاضر به بررسی پدیده ترکیدن خودبخودی سنگ با استفاده از روش‌های هوشمند و مقایسه نتایج آن‌ها با سه روش تجربی (معیار تنش مماسی، معیار تردی و شاخص انرژی الاستیک) پرداخته می‌شود. در این مقاله از روش‌های هوشمند ماشین بردار پشتیبان (SVM)، نزدیک‌ترین همسایگی (KNN)، شبکه‌های بیزین (BNs)، شبکه عصبی مصنوعی (ANN) و مدل درختی CHAID در نرم‌افزار قدرتمند WEKA استفاده شده است. برای ارزیابی دقت مدل‌سازی از شاخص‌های مختلف آماری استفاده شد که نهایتاً نتایج بدست آمده، نشان از برتری روش‌های هوشمند نسبت به روش‌های تجربی دارد. در میان روش‌های هوشمند بکار گرفته شده، مدل ماشین بردار پشتیبان با دقت ۸۰/۸ درصد از توانایی بالایی در ارزیابی پدیده ترکیدن خودبخودی سنگ برخوردار است.

#### واژگان کلیدی

ترکیدن خودبخودی سنگ  
حفاریات زیرزمینی عمیق  
روش‌های هوشمند  
ماشین بردار پشتیبان  
نرم‌افزار WEKA

#### ۱- پیش‌گفتار

سطح و تنش بالا افزایش پیدا می‌کند (Manchao, et al., 2012). انفجار سنگ ممکن است حتی در سنگ‌های نرمتر مانند معادن ذغال سنگ اتفاق افتد. این پدیده یکی از عوامل خیلی مهم در برهم زدن ایمنی حفاریات زیرزمینی نظیر معادن و تونل‌ها است که می‌تواند منجر به مشکلات اقتصادی زیادی مانند تخریب نگهداری، آسیب رساندن به تجهیزات موجود در محل و یا تلفات انسانی شود. با پیشرفت

ترکیدن خود به خودی سنگ پدیده‌ای است که به انفجار شدید یک بلوک و در نتیجه گسیختگی ناگهانی توده‌ی سنگ منجر می‌شود و با آزاد شدن انرژی کرنشی ذخیره شده در سنگ همراه است، به گونه‌ای که انرژی آزاد شده را بتوان به عنوان یک پدیده‌ی لرزه‌ای مشخص تلقی کرد. شدت انفجار سنگ با نزدیک شدن به مناطق با عمق زیاد نسبت به

\*اراک؛ خیابان دانشگاه؛ دانشگاه صنعتی اراک؛ ساختمان شهید زین‌الدین؛ دانشکده مهندسی علوم زمین؛ گروه مهندسی ژئومکانیک؛ شماره تلفن:

جلوگیری از وقوع آن به وسیله‌ی واتر جت پرداختند. نتایج به دست آمده نشان داد که واتر جت می‌تواند اثرات انفجار سنگ را با تحریک آزادسازی تنش و انحلال انرژی ذخیره شده در توده زغال سنگ در نزدیکی شکاف برش کاهش دهد و شکاف‌های حلقوی می‌توانند خطرات ریزش سنگ را از طریق مسدود کردن یا تضعیف تنش و انرژی کاهش دهند (Song, et al., 2014). میفنگ کای در سال ۲۰۱۵ پیش‌بینی و پیشگیری از وقوع انفجار سنگ در معادن فلزی و معدن طلای سان شانداو (Sanshandao) چین را مورد ارزیابی قرار داد (Cai, 2016). لی‌خی هوا و همکاران در سال ۲۰۱۶ پدیده انفجار سنگ در معادن زغال ایسلند و نحوه‌ی پیشگیری از وقوع آن را مورد بررسی قرار دادند (Li et al., 2016). ژو و همکاران در سال ۲۰۱۶ از مدل‌های ابری و آنتروپی وزنی برای پیش‌بینی و کلاس‌بندی انفجار سنگ استفاده کرده و در تحقیق خود مدل آنتروپی-وزنی را با مدل‌های بیزین و نزدیک‌ترین همسایگی مقایسه کردند. نتایج نشان داد که دقت پیش‌بینی مدل آنتروپی-وزنی بالاتر از روش‌های دیگر است (Zhou, et al., 2016). نینگ لی و همکاران در سال ۲۰۱۷ جهت پیش‌بینی انفجار سنگ از شبکه‌های بیزین استفاده کرده و به این نتیجه رسیدند که خطای شبکه‌های بیزین نسبت به روش‌های سنتی پایین‌تر و در بین پارامترهای ورودی ماکزیمم تنش مماسی تاثیرگذارترین پارامتر در وقوع انفجار سنگ است (Li, et al., 2017). جیانگ هی و همکاران در سال ۲۰۱۷ انفجار سنگ را به وسیله‌ی آنالیز تنش‌های استاتیکی و دینامیکی با مانیتور کردن ریز لرزه‌ها ارزیابی و پیش‌بینی کردند (He, et al., 2017).

## ۲- برخی از علل ایجاد پدیده انفجار سنگ

انفجار سنگ یک فاکتور مهم در ایمنی تونل‌ها و همچنین یک فاکتور عملکردی مهم در قراردادهای تونلی است. با افزایش عمق و توسعه تونل‌ها، انفجار سنگ افزایش و موارد بیشتری از وقوع آن در تونل‌ها گزارش شده است؛ همچنین در بعضی موارد شواهد نشان می‌دهد که انفجار سنگ در شرایط یکسان توده‌ی سنگ، در موقع حفاری با ماشین آلات امکان رخداد بیشتری نسبت به حفاری با مته و انفجار دارد. زمانی که یک حفاری داخل سنگ، چه با استفاده از چال

علم و افزایش عمق حفاری جهت دسترسی به مواد معدنی و حفر تونل‌های عمیق، پتانسیل وقوع انفجار سنگ افزایش یافته است (Stacey & Rojas, 2013). پیش‌بینی شرایط انفجار سنگ یک مسئله چند کلاسه است که اخیراً استفاده از روش‌های داده کاوی و روش‌های تجربی مختلف جهت پیش‌بینی این پدیده مرسوم شده است.

هدف از این تحقیق ارزیابی پدیده ترکیدن خودبخودی سنگ با استفاده از روش‌های داده کاوی (هوشمند) تحت نرم‌افزار WEKA و مقایسه و کارایی آن‌ها با نتایج روش‌های تجربی معیار تنش مماسی (SC (Stress Criterion)، معیار تردی (BC (Brittleness Criterion) و شاخص انرژی الاستیک (EEI (Elastic Energy Index) می‌باشد. به این منظور از روش‌های هوشمند نظیر ماشین بردار پشتیبان (SVM (Support Vector Machines)، شبکه عصبی مصنوعی (ANN (Artificial Neural Network)، درخت تصمیم (CHAID (Chi-Squared Automatic Interaction Detection)، الگوریتم نزدیک‌ترین همسایگی (KNN (K-Fold Nearest Neighbor) و الگوریتم شبکه‌ی بیزین (BNs (Bayesian Networks) استفاده شده است.

در سال‌های اخیر پژوهش‌های متعددی در رابطه با پدیده انفجار سنگ و چگونگی پیش‌بینی آن انجام شده که در ادامه به مهمترین آن‌ها اشاره خواهد شد. ژو و همکاران در سال ۲۰۱۲ با ترکیب دو الگوریتم بهینه‌سازی ژنتیک و اجتماع ذرات (PSO (Particle Swarm Optimization) توانستند قابلیت روش ماشین بردار پشتیبان در پیش‌بینی پتانسیل انفجار سنگ را ارتقا دهند (Zhou, et al., 2012). دانگ و همکاران در سال ۲۰۱۲ در مورد موضوع پیش‌بینی کلاس انفجار سنگ در پروژه‌های زیرزمینی به مقایسه‌ی روش (RF (Random Forest) با دو روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی پرداختند. نتایج نشان داد که با استفاده از روش RF می‌توان کلاس انفجار سنگ را به دقت طبقه‌بندی کرد (Dong, et al., 2013). آدوکو و همکاران در سال ۲۰۱۳ با استفاده از روش منطق فازی و سیستم استنتاج عصبی-فازی (ANFIS (Adaptive Neuro Fuzzy Inference System) به پیش‌بینی کلاس انفجار سنگ پرداختند (Adoko, et al., 2013). دژائو سونگ و همکاران در سال ۲۰۱۴ به مدل‌سازی عددی انفجار سنگ و

### ۳-۲- معیار تردی (BC)

تردی سنگ طبق رابطه ۲ با نسبت مقاومت فشاری تک محوره سنگ ( $MPa$ ) به مقاومت کششی تک محوره سنگ ( $MPa$ )، محاسبه می‌شود و شدت انفجار سنگ طبق جدول ۲، تعیین می‌شود (Kwasniewski, et al., 1994).

$$B = \frac{\sigma_c}{\sigma_t} \quad (2)$$

جدول ۲- پدیده ترکیدن خودبخودی سنگ بر اساس معیار تردی


B	شدت انفجار سنگ
$> 40$	بدون انفجار
$26/7 - 40$	ضعیف
$14/5 - 26/7$	متوسط
$< 14/5$	شدید

### ۳-۳- شاخص انرژی الاستیک ( $EI$ )

شاخص انرژی الاستیک متناسب با انرژی کرنشی ذخیره شده در یک چرخه بارگذاری-باربرداری مطابق شکل ۱، است و در سال ۱۹۸۱ توسط کیدی بینسکی طبق رابطه ۳ ارائه شده است (Kidybiński, 1981):

$$Wet = \frac{\Phi_{sp}}{\Phi_{st}} \quad (3)$$

که در آن انرژی کرنشی باقیمانده و  $\Phi_{st}$  انرژی کرنشی اتلافی است و طبقه‌بندی شدت انفجار سنگ بر اساس آن مطابق جدول ۳، است.



شکل ۱- منحنی تنش-کرنش در یک چرخه بارگذاری-باربرداری

زنی و آتشیاری و چه با روش‌های مکانیزه حفر می‌شود، ضرورتاً توده سنگ اطراف دچار آشفته‌گی می‌شود. این آشفته‌گی‌ها می‌تواند به صورت ایجاد ترک‌های جدید، باز و بسته شدن شکستگی‌های موجود و توزیع مجدد تنش باشد. در طول این فرآیندها خصوصیات فیزیکی، هیدرولیکی و مکانیکی توده سنگ اطراف حفاری به طور قابل ملاحظه‌ای تحت تاثیر قرار می‌گیرد. به‌علاوه، انرژی ماده منفجره موجود در یک چال، در سنگ الاستیک نامحدود، با انفجار فوری در تمام طول خرج به سه شکل اصلی آزاد می‌شود: انرژی امواج ضربه، انرژی کرنشی و انرژی گاز. با انفجار ماده منفجره به دلیل تغییر شکل پذیری الاستیک سنگ مقداری از انرژی، به عنوان انرژی کرنشی در سنگ ذخیره می‌شود و در نتیجه با آزاد شدن آن انفجار سنگ رخ می‌دهد (da Gama & Navarro Torres, 2002)

### ۳- روش‌های تجربی ارزیابی پدیده ترکیدن خودبخودی سنگ

#### ۳-۱- معیار تنش مماسی ( $SC$ )

این معیار با نسبت تنش مماسی به مقاومت فشاری تک محوری طبق رابطه ۱ به‌دست می‌آید (Wang & Park, 2001):

$$T_s = \frac{\sigma_\theta}{\sigma_c} \quad (1)$$

که در آن حداکثر تنش مماسی دیواره تونل ( $MPa$ ) و  $\sigma_c$  مقاومت فشاری تک محوره ( $MPa$ ) است و شدت انفجار سنگ طبق جدول ۱، تعیین می‌شود.

جدول ۱- پدیده ترکیدن خودبخودی سنگ بر اساس معیار تنش مماسی

$T_s$	شدت انفجار سنگ
$\leq 0/2$	بدون انفجار
$0/3 - 0/2$	ضعیف
$0/55 - 0/3$	متوسط
$> 0/55$	شدید

جدول ۳- پدیده ترکیدن خودبخودی سنگ بر اساس


Wet	شدت انفجار سنگ
$< 2$	بدون انفجار
$2 - 3/5$	ضعیف
$3/5 - 5$	متوسط
$5 <$	شدید

۴- مختصری از تکنیک‌های داده‌کاوی (روش‌های هوشمند) بکار گرفته شده در این تحقیق برای ارزیابی پدیده ترکیدن خودبخودی سنگ

بهره‌گیری از قدرت فرآیند داده‌کاوی جهت شناسایی الگوها و مدل‌ها و نیز ارتباط عناصر مختلف در پایگاه داده جهت کشف دانش نهفته در داده‌ها و نهایتاً تبدیل داده به اطلاعات، روز به روز ضروری‌تر می‌شود. در سال‌های اخیر کشف سریع و دقیق اطلاعات با ارزش و پنهان از مجموعه داده‌ها، به عنوان علم داده‌کاوی مورد توجه قرار گرفته است که شامل کاربرد ابزارهای مختلف برای تحلیل داده‌ها و کشف یک الگوی ناشناخته معتبر بر روابط بین مجموعه داده‌ها است. در ادامه به توصیف برخی از تکنیک‌های داده‌کاوی (روش‌های هوشمند) بکار گرفته شده در این تحقیق برای ارزیابی پدیده ترکیدن خودبخودی سنگ پرداخته خواهد شد (McCourt, 1999).

۴-۱- روش شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیادی سپرده است. یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی و میانی یا پنهان تشکیل می‌شود. هر لایه شامل گروهی از سلول‌های عصبی یا نرون‌ها هستند که عموماً با کلیه نرون‌های لایه‌های دیگر در ارتباط هستند، مگر اینکه کاربر ارتباط بین نرون‌ها را محدود کند. نرون می‌تواند یک تابع ریاضی غیرخطی باشد، در نتیجه یک شبکه عصبی که از اجتماع این نرون‌ها تشکیل می‌شود می‌تواند یک سامانه کاملاً پیچیده و غیرخطی باشد. یک سلول عصبی از پنج بخش اصلی تشکیل می‌شود که عبارتند از ورودی، وزن‌ها، تابع جمع، تابع فعال سازی و خروجی. ورودی‌ها، اطلاعات یا داده‌های خامی هستند که به شبکه تغذیه شده است. وزن‌ها مقادیری هستند که اثر یک مجموعه ورودی یا یک عنصر ورودی لایه قبلی را در سلول جدید بیان می‌کنند. تابع جمع، تابعی است که اثر ورودی‌ها و وزن‌ها را به طور کامل روی عنصر مورد نظر محاسبه می‌کند. برای استفاده از شبکه عصبی مصنوعی، باید سیستم شبکه ابتدا آموزش ببیند (Fattahi & Bazdar, 2017). پس از اتمام آموزش، معمولاً خطای شبکه به حداقل می‌رسد و خروجی شبکه نیز مشابه با خروجی هدف خواهد شد. شکل ۲، ساختار بخش‌های یک سلول عصبی در یک شبکه عصبی مصنوعی را نشان می‌دهد.



شکل ۲- ساختار بخش‌های یک سلول عصبی

۴-۲- روش ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان اولین بار توسط Vapnik ارائه شد. این روش به عنوان یکی از راه‌ها در یادگیری ماشین و

تشخیص الگو گسترش یافته است. ماشین بردار پشتیبان پیشگویی‌های خود را با استفاده از ترکیبی خطی از تابع Kernel انجام می‌دهد که روی مجموعه‌ای از داده‌های

شود. وجود قید، ضمانت می‌کند که داده‌ای در حاشیه قرار نمی‌گیرد (Fattahi, 2019).

#### ۴-۳- روش درخت تصمیم CHAID

درخت تصمیم یک روش غیر پارامتریک با ساختار سلسله مراتبی داده و یادگیری با نظارت است که با استفاده از استراتژی تقسیم و حل، پیاده‌سازی می‌شود. در این روش، تقسیم بندی داده‌ها با استفاده از ویژگی‌های آن‌ها به صورت یک درخت انجام می‌شود. این روش بر اساس داده‌های آموزش در هر مرحله، یکی از ویژگی‌های داده را انتخاب می‌کند و داده‌های آن مجموعه را به دو یا تعدادی بیشتر تقسیم بندی کرده و این کار را تا زمانی ادامه می‌دهد که تمام داده‌های موجود در یک دسته دارای یک برچسب والد باشند. علت نام گذاری این روش به درخت تصمیم این است که این درخت فرآیند تصمیم‌گیری برای تعیین دسته یک مثال ورودی را نشان می‌دهد. دسته بندی یک نمونه از گره ریشه شروع شده و ویژگی‌های مشخص شده توسط این گره مورد بررسی قرار می‌گیرد و آنگاه حرکت به سمت پایین شاخه درختی که متناظر با آن ویژگی است، صورت می‌گیرد و این فرآیند تا زیردرختی که گره جدید ریشه آن است، ادامه پیدا می‌کند تا به یک گره برگ برسیم و در این حالت گره برگ، ویژگی داده مورد نظر را مشخص می‌کند.

پس از سال ۱۹۷۰ محققان آمار کاربردی، الگوریتم‌هایی را جهت تولید و ساخت درخت تصمیم توسعه دادند که الگوریتم CHAID یکی از این الگوریتم‌ها است. الگوریتم CHAID درختی شبیه درخت تصمیم است که از مجذور مربع استفاده کرده و در ابتدا برای متغیرهای اسمی طراحی شده بود که بعدها برای متغیرهای عددی نیز مورد استفاده قرار گرفت. این الگوریتم با توجه به نوع برچسب کلاس از آزمون‌های مختلف آماری استفاده می‌کند و هرگاه به حداکثر عمق تعریف شده برسد و یا تعداد نمونه‌ها در گره جاری از مقدار تعریف شده‌ای کمتر باشد، متوقف می‌شود. الگوریتم CHAID هیچ گونه روش هرسی را اجرا نمی‌کند و می‌تواند مقادیر ناقص را نیز کنترل کند.

#### ۴-۴- روش نزدیک‌ترین همسایگی (KNN)

در این روش، ابتدا فاصله رکورد جدید از همه رکوردهای آموزشی محاسبه می‌شود. سپس  $K$  نزدیک‌ترین رکوردها را به نمونه جدید بر اساس یک معیار شباهت به‌دست آورده و

آموزشی با نام بردارهای پشتیبان عمل می‌کند. ماشین بردار پشتیبان داده‌های غیرخطی را به فضایی با ابعاد بالاتر می‌برد. سپس از توابع خطی ساده برای ایجاد مرزهای جداکننده خطی در فضای جدید استفاده می‌کند (Fattahi & Babanouri, 2017). در ماشین بردار پشتیبان بر خلاف شبکه‌های عصبی مصنوعی که پارامترهای مدل با کمینه سازی خطا تنظیم می‌شوند، ریسک ناشی از عدم طبقه‌بندی صحیح به عنوان یک تابع هدف تعریف می‌شود و پارامترها نسبت به آن، تنظیم و بهینه‌سازی می‌شوند (Babanouri & Fattahi, 2018). ایده اساسی این طبقه‌بندی کننده، یافتن یک ابرصفحه بهینه به عنوان سطح تصمیم‌گیری به گونه‌ای است که حاشیه بین دو کلاس را حداکثر کند. در صورتی که داده‌ها به صورت خطی جداپذیر نباشد، داده‌ها با کرنلی غیرخطی به فضای با ابعاد بالاتر منتقل می‌شوند و ابر صفحه بهینه در آن فضا تعیین می‌شود. فرض کنید  $I$  داده‌های آموزشی موجود است که هر یک با  $(x_i, y_i)$  نشان داده می‌شود،  $x_i$  بردار ویژگی  $n$  بعدی و  $y_i \in [-1, 1]$  برچسب آن است. هدف یافتن ابر صفحه‌ای است که دو کلاس با برچسب ۱ و -۱ را با بیشترین حاشیه از هم جدا کند. این ابر صفحه را می‌توان با رابطه ۴ بیان کرد (Fattahi, et al., 2014).


$$W^T \phi(x) + b = 0 \quad (4)$$

در این رابطه بردار وزن  $w$  برداری عمود بر ابر صفحه،  $b$  بردار بایاس است که به منظور اندازه‌گیری فاصله ابر صفحه تا مبدا استفاده می‌شود و  $\phi(x)$  کرنلی برای انتقال داده به فضایی با ابعاد بالاتر است. حداکثر حاشیه بین دو کلاس، معادل حداقل کردن اندازه  $W$  است که منجر به حل مساله حداقل سازی رابطه ۵ می‌شود.

$$\begin{aligned} & \min \left( \frac{1}{2} \|W\|^2 + C \sum_{i=1}^k \varepsilon_i \right) \\ & \text{Subject to:} \\ & y_i (w \phi(x_i) + b) > 1 - \varepsilon_i \\ & i=1, 2, \dots, k \end{aligned} \quad (5)$$

پارامتر  $C$ ، پارامتر ظرفیت در ماشین بردار پشتیبان است. به منظور در نظر گرفتن نویز موجود در داده‌ها و تداخل بین داده‌های آموزشی، از متغیر  $\varepsilon > 0$  استفاده می‌

آوری داده‌های کافی برای کاهش عدم قطعیت‌ها وجود ندارد؛ همچنین از این روش در سیستم‌های استفاده می‌شود که ارتباط پیچیده بین متغیرهای مسئله وجود دارد. در این شبکه استفاده از داده‌های کمی و کیفی با استفاده از تعیین احتمال شرطی بین متغیرها وجود دارد. یک شبکه بیزین برای مجموعه‌ای از متغیرها  $X = [X_1, \dots, X_N]$  شامل یک ساختار شبکه  $S$  که استقلال یا وابستگی شرطی متغیرهای  $X$  را بیان می‌کند و یک مجموعه  $P$  از توزیع‌های احتمال محلی است که به هر متغیر اختصاص دارد. مطابق شکل ۳، ساختار شبکه  $S$  یک گراف جهت دار فاقد دور است. گره‌ها در  $S$  در تناظر یک به یک با متغیرهای  $X$  هستند.



شکل ۳- نمونه‌ای از ساختار شبکه بیزین

### ۵- معیارهای ارزیابی مدل

یکی از کاربردی‌ترین ابزارها برای ارزیابی کارایی و دقت مدل‌ها در مسائل طبقه‌بندی، ماتریس کارایی است. نمونه‌ای از این ماتریس برای طبقه‌بندی‌های دو کلاسه در جدول ۴، نشان داده شده است. در این ماتریس  $TP$  تعداد کلاس‌های مثبتی است که کلاس بندی به درستی آن‌ها را پیش‌بینی کرده است،  $FP$  تعداد کلاس‌های منفی است که کلاس بندی به اشتباه مثبت پیش‌بینی کرده است،  $FN$  تعداد کلاس‌های مثبتی است که کلاس بندی به اشتباه منفی پیش‌بینی کرده است و  $TN$  تعداد کلاس‌های منفی است که کلاس بندی به درستی منفی پیش‌بینی کرده است.  $P$  و  $N$  نیز به ترتیب تعداد کلاس‌های مثبت و منفی است. با استفاده از این ماتریس معیارهای آماری گوناگونی مانند دقت، خطا و حساسیت را می‌توان برای ارزیابی کارایی مدل‌ها محاسبه کرد.

دسته‌های این  $K$  همسایه را بررسی می‌کند، در آخر دسته نمونه جدید را برابر با بیش‌ترین دسته در  $K$  همسایه آن قرار می‌دهد. در اینجا باید دو پارامتر مشخص شوند یکی معیار شباهت و دیگری تعداد  $K$  است. تعیین درست  $K$  یکی از چالش‌های این الگوریتم هست که روی نتیجه دسته بندی اثر مهمی دارد. برای محاسبه میزان نزدیکی یا شباهت رکورد جدید با هر یک از رکوردهای آموزشی روش‌های مختلفی وجود دارد. مثلاً برای دو رکورد  $P$  و  $Q$  که تمام ویژگی‌های آن از نوع عددی هستند، می‌توان از معیار معروف فاصله اقلیدسی به صورت رابطه ۶ استفاده کرد.

$$d(p, q) = \sqrt{\sum_{i=1}^k (p_i - q_i)^2} \quad (6)$$

$k$  تعداد فیلدهای هر رکورد است و  $p_i$  و  $q_i$  مقادیر ویژگی  $i$ ام برای رکوردها است. یکی از مشکل الگوریتم  $KNN$  تعیین مقدار  $K$  است و در این عمل این مقدار با آزمایش کردن و روش سعی و خطا به دست می‌آید؛ یعنی حل مساله را با  $K=1$  و یک‌سری داده‌های آزمایشی شروع کرده تا خطای دسته‌بندی به دست آید و این عملیات با افزایش مقدار  $K$  تکرار می‌شود تا بهترین  $K$  پیدا شود. به‌طور کلی عموماً با افزایش رکوردهای آزمایشی مقدار  $K$  هم زیاد می‌شود.

### ۴-۵- روش شبکه‌های بیزین (BNs)

شبکه‌های بیزین در زمینه استدلال احتمالی به‌طور گسترده مورد استفاده قرار می‌گیرند و به درخت متصل روی احتمالات استدلال شده تبدیل می‌شوند. شبکه بیزین یک مدل گرافیکی برای نمایش احتمالات مابین متغیرهای موردنظر است. این شبکه شامل بخش کیفی (مدل ساختاری) است که نمایش بصری از فعل و انفعالات در میان متغیرها و بخش کمی (مجموعه‌ای از مشخصات احتمال محلی) را فراهم می‌کند. شبکه‌های بیزین که به نام‌های متعددی معروف است، سیستمی بر اساس نظریه احتمالات است که توسط توماس بیز ابداع شده است و بر قاعده معروف توماس بیز تأکید دارد. با استفاده از این قاعده می‌توان به مدل کردن روابط علت و معلولی یک فرآیند، آنالیز وضعیت موجود و تخمین وضعیت آینده یک سیستم پرداخت. این روش موثری برای تصمیم‌گیری در مواردی می‌باشند که اطلاعات کامل وجود نداشته و یا امکان جمع

## ۷- تحلیل نتایج

داده‌های مورد استفاده در این تحقیق به تعداد ۱۲۰ داده (جدول ۵)، از چهار مقاله (Zhou et al., 2012) (Dong et al., 2013) (Li et al., 2017) (Adoko et al., 2013) در زمینه معدن و تونل گردآوری شده‌اند که در آن‌ها چهار کلاس‌بندی، عدم وقوع (A)، ضعیف (B)، متوسط (C) و شدید (D) از رخداد‌های واقعی انفجار سنگ در نقاط مختلف دنیا ذکر شده است. پدیده ترکیدن خودبخودی سنگ به عنوان متغیر خروجی در مدل‌ها، پیش‌بینی می‌شود، به طوری که در اطلاعات واقعی جمع‌آوری شده از طبقه‌بندی پدیده ترکیدن خودبخودی سنگ، ۱۷/۵ درصد عدم وقوع، ۳۱/۶ درصد ضعیف، ۳۶ درصد متوسط و ۱۴/۲ درصد شدید گزارش شده است که نمودار ستونی در شکل ۴، فراوانی داده‌ها در هر کلاس انفجار سنگ را نشان می‌دهد. به‌علاوه در این تحقیق از شش متغیر تنش مماسی حداکثر (M<sub>TS</sub>: Maximum Tangential Stress)، مقاومت فشاری تک محوره (UCS: Uniaxial Compressive Strength)، مقاومت کششی تک محوره (UTS: Uniaxial Tensile Strength)، شاخص تردی (BC)، شاخص تنش مماسی (SC) و شاخص انرژی الاستیک (EEI) به‌عنوان متغیرهای ورودی به مدل‌ها استفاده شده است. تنش مماسی حداکثر به‌صورت غیر مستقیم از پارامترهای دیگر و شاخص انرژی الاستیک به‌صورت مستقیم از آزمایشگاه تعیین می‌شود. شکل ۵، نمودار هیستوگرام سه متغیر M<sub>TS</sub>، UCS و UTS را نشان می‌دهد که هر ستون با یک تفکیک رنگی مشخص شده است. هر رنگ مربوط به یک کلاس از متغیر توصیفی است؛ به‌طوری که در هر ستون از هر متغیر فراوانی کلاس‌های واقعی داده‌هایی مشخص شده است که در آن طبقه قرار می‌گیرند.

هدف از این بخش تعیین اهمیت پارامترهای ورودی در انتخاب مدل‌های مناسب است؛ به‌گونه‌ای که مدل‌های انتخاب شده دارای بالاترین میزان دقت برای پیش‌بینی شرایط انفجار سنگ باشند. در نهایت این مدل‌ها با مدل‌های تجربی مقایسه می‌شود. به این منظور از نرم‌افزار WEKA کمک گرفته شده است. پس از آن که این داده‌ها برای نرم‌افزار تعریف شد، قبل از شروع انجام مدل‌سازی‌ها، بایستی ابتدا داده‌ها نرمال‌سازی شوند و حداقل و حداکثر متغیرها

جدول ۴- ماتریس کارایی برای طبقه‌بندی دو کلاس

		کلاس بندی تخمینی			
		-	Yes	No	Total
کلاس بندی واقعی	Yes	TP	FN	P	
	No	FP	TN	N	
Total		p'	N'	P + N	

دقت یک کلاس‌بندی عبارت است از درصدی از کل داده‌های ورودی که کلاس‌بندی به درستی آن‌ها را پیش‌بینی کرده است. می‌توان نرخ دقت و خطا را مطابق معادلات ۷ و ۸ محاسبه کرد.

$$\text{Accuracy} = (TP + TN) / (P + N) \quad (7)$$

$$\text{Error Rate} = (FP + FN) / (P + N) \quad (8)$$

معیار حساسیت به صورت نرخ مثبت واقعی مطرح می‌شود که برابر با نسبت تعداد کلاس‌های مثبتی که کلاس بندی به درستی مثبت پیش‌بینی کرده، به کل داده‌های مثبت است (معادله ۹):

$$\text{Sensitivity} = TP/P \quad (9)$$

## ۶- معرفی اجمالی نرم‌افزار WEKA

نرم‌افزار WEKA مجموعه‌ای از الگوریتم‌های یادگیری ماشینی و ابزارهای پیش‌پردازش داده‌ها است. این نرم‌افزار پشتیبانی‌های ارزشمندی را برای کل فرآیندهای داده کاوی تجربی فراهم می‌کند. نرم‌افزار WEKA نرم‌افزاری Open Source است که توسط دانشگاه وایکاتو در نیوزلند طراحی شده است. بسیاری از تکنیک‌های داده کاوی در نرم‌افزار WEKA پیاده‌سازی شده است از جمله: خوشه‌بندی، رگرسیون، بصری‌سازی، دسته‌بندی یا طبقه‌بندی و انتخاب ویژگی که همگی در این نرم‌افزار قابل اجرا هستند. نرم‌افزار WEKA الگوریتم‌های طبقه‌بندی و پیش‌بینی بسیار متنوعی را پیاده‌سازی می‌کند. طبقه‌بندی روشی است، برای مشخص کردن گروهی که یک نمونه داده در آن قرار می‌گیرد. الگوریتم‌های طبقه‌بندی به *Meta*، *Misc*، *trees* و *Rules* تقسیم می‌شوند.

داده‌ها به ۱۰ لایه عمل اعتبارسنجی انجام شده است. ماتریس همبستگی با یک نمایش کلی از روابط دو به دو بین متغیرها، به شکل زیر محاسبه شده است.

بین ۱- و ۱ قرار بگیرند؛ همچنین در این تحقیق از روش اعتبارسنجی متقابل (*Cross Validation*) برای ارزیابی مدل‌ها کمک گرفته شده است؛ به طوری که با افزاز مجموعه

$$\begin{bmatrix} 1 & 0.04 & 0.13 & 0.39 & 0.1 & 0.19 \\ 0.04 & 1 & 0.62 & -0.18 & 0.02 & 0.44 \\ 0.13 & 0.62 & 1 & -0.15 & -0.31 & 0.1 \\ 0.39 & -0.18 & -0.15 & 1 & 0.26 & -0.11 \\ 0.1 & 0.02 & -0.31 & 0.26 & 1 & -0.01 \\ 0.19 & 0.44 & 0.1 & -0.11 & -0.01 & 1 \end{bmatrix}$$

جدول ۵- داده‌های چهار متغیر اصلی مورد استفاده در روش‌های تجربی و مدل‌های داده کاوی (Zhou, et al., 2012)، (Dong, et al., 2013)، (Adoko, et al., 2013) و (Li, et al., 2017)

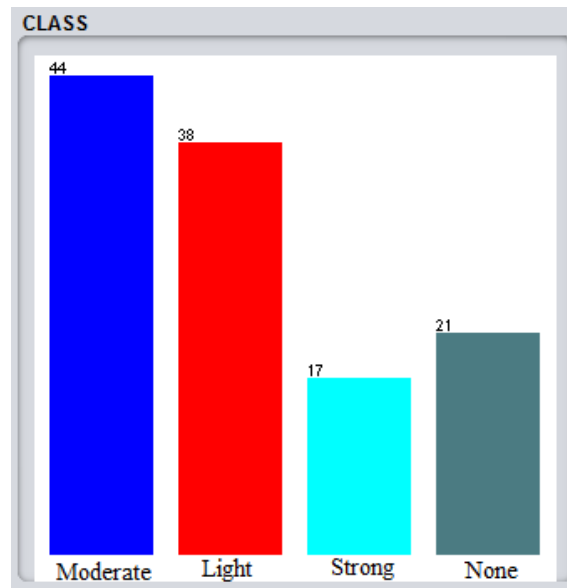
No	$\sigma_{\theta}$	$\sigma_c$	$\sigma_t$	CLASS	No	$\sigma_{\theta}$	$\sigma_c$	$\sigma_t$	CLASS
۱	۹۰	۱۷۰	۱۱/۳	C	۶۱	۱۱/۳	۹۰	۴/۸	A
۲	۹۰	۲۲۰	۷/۴	B	۶۲	۹۲	۲۶۳	۱۰/۷	B
۳	۶۲/۶	۱۶۵	۹/۴	B	۶۳	۶۲/۴	۲۳۵	۹/۵	D
۴	۵۵/۴	۱۷۶	۷/۳	C	۶۴	۴۳/۴	۱۳۶	۷/۲	D
۵	۳۰	۸۸/۷	۳/۷	C	۶۵	۱۱	۱۰۵	۴/۹	A
۶	۴۸/۷۵	۱۸۰	۸/۳	C	۶۶	۴۶/۴	۱۰۰	۴/۹	B
۷	۸۰	۱۸۰	۶/۷	B	۶۷	۲۳	۸۰	۳	B
۸	۸۹	۲۳۶	۸/۳	C	۶۸	۴۶/۲	۱۰۵	۵/۳	B
۹	۹۸/۶	۱۲۰	۶/۵	C	۶۹	۱۳/۹	۱۲۴	۴/۲۲	A
۱۰	۱۰۸/۴	۱۴۰	۸	D	۷۰	۱۷/۴	۱۶۱	۳/۹۸	B
۱۱	۵۷	۱۸۰	۸/۳	C	۷۱	۱۹	۱۵۳	۴/۴۸	B
۱۲	۵۰	۱۳۰	۶	C	۷۲	۱۹/۷	۱۴۲	۴/۵۵	B
۱۳	۶۲/۵	۱۷۵	۷/۲۵	C	۷۳	۱۸/۷	۸۲	۱۰/۹	A
۱۴	۷۵	۱۸۰	۸/۳	C	۷۴	۲۸/۶	۱۲۲	۱۲	C
۱۵	۱۱	۱۱۵	۵	A	۷۵	۲۹/۸	۱۳۲	۱۱/۵	C
۱۶	۴۳/۴	۱۲۳	۶	C	۷۶	۳۳/۶	۱۵۶	۱۰/۸	C
۱۷	۱۸/۸	۱۷۸	۵/۷	A	۷۷	۲۶/۹	۹۲/۸	۹/۴۷	C
۱۸	۳۴	۱۵۰	۵/۴	A	۷۸	۵۵/۹	۱۲۸	۶/۲۹	D
۱۹	۵۶/۱	۱۳۱/۹۹	۹/۴۴	C	۷۹	۵۹/۹	۹۶/۶	۱۱/۷	B
۲۰	۵۴/۲	۱۳۴	۹/۱	C	۸۰	۶۸	۱۰۷	۶/۱	D
۲۱	۷۰/۳	۱۲۸/۳	۸/۷	C	۸۱	۱۰۵/۵	۱۸۷	۱۹/۲	C
۲۲	۶۰/۷	۱۱۱/۵	۷/۸۶	D	۸۲	۱۰۵/۵	۱۷۰	۱۲/۱	B
۲۳	۵۴/۲	۱۳۴	۹/۰۹	C	۸۳	۱۰۵/۵	۱۹۰	۱۷/۱	B
۲۴	۷۰/۳	۱۲۹	۸/۷۳	C	۸۴	۴۷/۵۶	۵۸/۵	۳/۵	B
۲۵	۳۵	۱۳۳/۴	۹/۳	B	۸۵	۴۳/۶۲	۷۸/۱	۳/۲	B



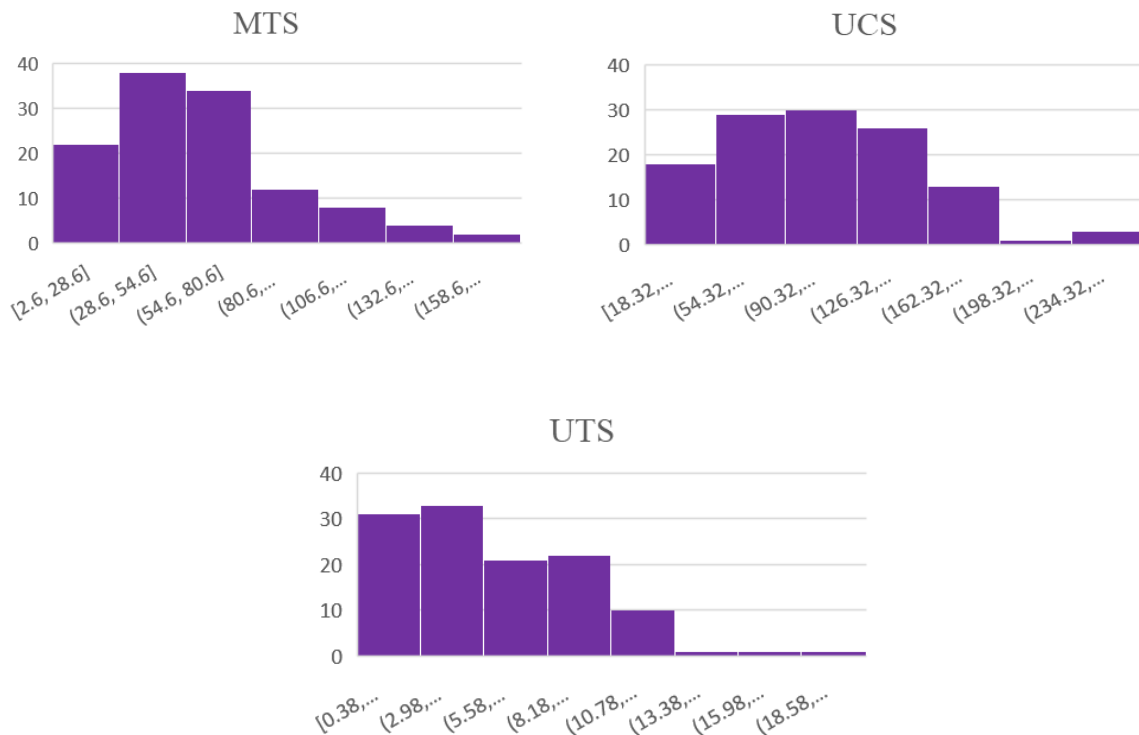
ادامه جدول ۵- داده‌های چهار متغیر اصلی مورد استفاده در روش‌های تجربی و مدل‌های داده کاوی (Zhou, et al., 2012).  
(Li, et al., 2017) و (Adoko, et al., 2013). (Dong, et al., 2013)

No	$\sigma_{\theta}$	$\sigma_c$	$\sigma_t$	CLASS	No	$\sigma_{\theta}$	$\sigma_c$	$\sigma_t$	CLASS
۲۶	۱۵۷/۳	۹۱/۲۳	۶/۹۲	D	۸۶	۲۵/۷	۵۹/۷	۱/۳	A
۲۷	۱۴۸/۴	۶۶/۷۷	۳/۸۱	B	۸۷	۲۶/۹	۶۲/۸	۲/۱	B
۲۸	۱۳۲/۱	۵۱/۵	۲/۴۷	C	۸۸	۴۰/۴	۷۲/۱	۲/۱	B
۲۹	۱۲۷/۹	۳۵/۸۲	۱/۲۴	B	۸۹	۳۹/۴	۶۵/۲	۲/۳	C
۳۰	۱۰۷/۵	۲۱/۵	۰/۶	A	۹۰	۳۸/۲	۷۱/۴	۳/۴	C
۳۱	۹۶/۴۱	۱۸/۳۲	۰/۳۸	A	۹۱	۴۵/۷	۶۹/۱	۳/۲	C
۳۲	۱۶۷/۲	۱۱۰/۳	۸/۳۶	D	۹۲	۳۵/۸	۶۷/۸	۳/۸	C
۳۳	۱۱۸/۵	۲۶/۰۶	۰/۷۷	B	۹۳	۳۹/۴	۶۹/۲	۲/۷	C
۳۴	۳۴/۱۵	۵۴/۲	۱۲/۱	B	۹۴	۴۰/۶	۶۶/۶	۲/۶	C
۳۵	۶۰	۱۳۵	۱۵/۰۴	B	۹۵	۳۹	۷۰/۱	۲/۴	C
۳۶	۶۰	۶۶/۴۹	۹/۷۲	B	۹۶	۵۷/۲	۸۰/۶	۲/۵	D
۳۷	۶۰	۱۰۶/۳۸	۱۱/۲	B	۹۷	۵۵/۶	۱۱۴	۲/۳	C
۳۸	۶۰	۸۶/۰۳	۷/۱۴	B	۹۸	۵۶/۹	۱۲۳	۲/۷	C
۳۹	۶۰	۱۴۹/۱۹	۹/۳	B	۹۹	۶۲/۱	۱۳۲	۲/۴	C
۴۰	۶۰	۱۳۶/۷۹	۱۰/۴۲	B	۱۰۰	۲۹/۷	۱۱۶	۲/۷	B
۴۱	۶۳/۸	۱۱۰	۴/۵	C	۱۰۱	۲۹/۱	۹۴	۲/۶	B
۴۲	۲/۶	۲۰	۳	A	۱۰۲	۲۷/۸	۹۰	۲/۱	A
۴۳	۴۴/۴	۱۲۰	۵	B	۱۰۳	۳۰/۳	۸۸	۳/۱	B
۴۴	۱۳/۵	۳۰	۲/۶۷	B	۱۰۴	۵۵/۶	۱۱۴	۲/۳	C
۴۵	۷۰/۴	۱۱۰	۴/۵	C	۱۰۵	۴۱/۶	۶۷/۶	۲/۷	C
۴۶	۳/۸	۲۰	۳	A	۱۰۶	۴۰/۱	۷۲/۱	۲/۳	C
۴۷	۵۷/۶	۱۲۰	۵	C	۱۰۷	۵۸/۲	۸۳/۶	۲/۶	D
۴۸	۱۹/۵	۳۰	۲/۶۷	C	۱۰۸	۵۶/۸	۱۱۲	۲/۲	C
۴۹	۸۱/۴	۱۱۰	۴/۵	D	۱۰۹	۳۴	۱۵۰	۵/۴	A
۵۰	۴/۶	۲۰	۳	A	۱۱۰	۶۰/۷	۱۱۱/۵	۷/۸۶	D
۵۱	۷۳/۲	۱۲۰	۵	C	۱۱۱	۵۴/۲	۱۳۴	۹/۰۹	C
۵۲	۲۰	۳۰	۲/۶۷	D	۱۱۲	۷۰/۳	۱۲۹	۸/۷۳	C
۵۳	۱۵/۲	۵۳/۸	۵/۵۶	A	۱۱۳	۳۵	۱۳۳/۴	۹/۳	B
۵۴	۸۸/۹	۱۴۲	۱۳/۲	D	۱۱۴	۱۵۷/۳	۹۱/۲۳	۶/۹۲	D
۵۵	۵۹/۸۲	۸۵/۸	۷/۳۱	C	۱۱۵	۱۴۸/۴	۶۶/۷۷	۳/۸۱	B
۵۶	۳۲/۳	۶۷/۴	۶/۷	A	۱۱۶	۱۳۲/۱	۵۱/۵	۲/۴۷	B
۵۷	۳۰/۱	۸۸/۷	۳/۷	D	۱۱۷	۱۲۷/۹	۳۵/۸۲	۱/۲۴	B
۵۸	۱۸/۸	۱۷۱/۵	۶/۳	A	۱۱۸	۱۰۷/۵	۲۱/۵	۰/۶	A
۵۹	۳۴	۱۴۹	۵/۹	B	۱۱۹	۹۶/۴۱	۱۸/۳۲	۰/۳۸	A
۶۰	۳۸/۲	۵۳	۳/۹	A	۱۲۰	۱۶۷/۲	۱۱۰/۳	۸/۳۶	D

ارزیابی پدیده ترکیدن خودبخودی سنگ در حفريات زیرزمینی عمیق با استفاده از... هادی فتاحی و ...، ص ۳۹۷-۴۱۴



شکل ۴- نمودار ستونی متغیر توصیفی کلاس انفجار سنگ



شکل ۵- نمودار هیستوگرام سه متغیر  $\sigma_i$ ،  $\sigma_c$  و  $\sigma_\theta$

پیش‌بینی شده به تعداد کل نمونه‌ها که نسبت حساسیت نیز نامیده می‌شود،  $FP Rate$  نسبت نمونه‌های به اشتباه پیش‌بینی شده به تعداد کل نمونه‌ها،  $Precision$  نسبت نمونه‌های مثبت صحیح به تعداد نمونه‌هایی است که مثبت پیش‌بینی شده‌اند،  $Recall$  نسبت نمونه‌های مثبت صحیح به تعداد نمونه‌هایی که در واقعیت مثبت بوده‌اند. این شاخص‌ها از طریق ماتریس کارایی محاسبه می‌شوند.

جدول ۶- مقدار شاخص‌های ارزیابی برای مدل ماشین بردار پشتیبان در نرم‌افزار WEKA

مقدار	شاخص ارزیابی
۸۰/۸۳%	نمونه‌هایی که درست طبقه‌بندی شده‌اند
۱۹/۱۷%	نمونه‌هایی که درست طبقه‌بندی نشده‌اند
۰/۷۲۷	Kappa
۰/۲۷۴	MAE
۰/۳۴۸	RMSE
۸۲/۶۱%	RRSE

جدول ۷- ماتریس کارایی مدل ماشین بردار پشتیبان

Classified as →	a	b	c	d
a=C	۴۲	۴	۰	۱
b=B	۳	۲۸	۰	۴
c=D	۳	۴	۹	۱
d=A	۰	۳	۰	۱۸

جدول ۸- مقدار پارامترهای به‌دست آمده از ماتریس کارایی برای مدل ماشین بردار پشتیبان

Class	TP Rate	FP Rate	Precision	Recall	ROC Area
C	۰/۸۹۴	۰/۰۸۲	۰/۸۷۵	۰/۸۹۴	۰/۹۴۴
B	۰/۸	۰/۱۲۹	۰/۷۱۸	۰/۸	۰/۸۱۱
D	۰/۵۲۹	۰/۰۱	۰/۹	۰/۵۲۹	۰/۸۲۳
E	۰/۸۵۷	۰/۰۵۱	۰/۷۸۳	۰/۸۵۷	۰/۹۵۹
Weighted Avg	۰/۸۰۸	۰/۰۸	۰/۸۱۷	۰/۸۰۸	۰/۸۹۱

مدل‌ها نشان داده شده است. مقدار  $RMSE$  محاسبه شده برای مدل‌ها تقریباً نزدیک به هم است، اما در مدل‌های  $ANN$  و  $CHAID$  این معیار با اختلاف اندکی پایین‌تر از سایر مدل‌ها است که نشان‌دهنده خطای نسبتاً پایین آن‌ها است. بعلاوه درصد دقت مدل‌ها به معنی نسبت تعداد

یکی از مدل‌های استفاده شده، روش ماشین‌بردار پشتیبان ( $SVM$ ) است که نتایج به‌دست آمده از این مدل در نرم‌افزار  $WEKA$  در قالب جداولی مانند جداول ۶، ۷ و ۸ در صفحه نشان داده شده است. همانطور که مشخص است، دقت این روش با معیارهای مختلف نظیر  $Kappa$ ،  $MAE$ ،  $RMSE$  (Root Mean Squared Error)،  $RRSE$  (Root Relative Squared Error) و  $Error$  مطابق جدول ۶، سنجیده شده است. دقت این مدل از نظر درصد داده‌هایی که درست پیش‌بینی شده به کل داده‌ها، ۸۰/۸۳ درصد است. در آخرین بخش از خروجی نرم‌افزار، مطابق جدول ۷، ماتریس کارایی مدل قرار می‌گیرد. در این ماتریس در ردیف اول ۴۲ عدد شدت انفجار متوسط را به درستی پیش‌بینی کرده است، ۴ عدد شدت انفجار ضعیف را به اشتباه پیش‌بینی کرده است و ۱ عدد شدت انفجار شدید را نیز به اشتباه پیش‌بینی کرده است که می‌بایست همه را شدت انفجار متوسط پیش‌بینی می‌کرد.


همچنین در جدول ۸، اطلاعات دیگری با عنوان  $Detailed Accuracy By Class$  را در اختیار می‌گذارد. در این جدول برای مدل‌های طبقه‌بندی مقدار شاخص‌ها مختلفی محاسبه شده است و براساس آن‌ها می‌توان به مقایسه‌ی عملکرد مدل‌ها پرداخت. در این جدول،  $ROC Area$  (مساحت زیر منحنی  $ROC$  (Receiver Operating Characteristic)) نسبت نمونه‌های درست

## ۷-۱- ارزیابی دقت

علاوه بر روش ماشین بردار پشتیبان روش‌های دیگری چون  $ANN$ ،  $BNs$  و  $CHAID$  با استفاده از داده‌ها مدل‌سازی شده و خروجی‌هایی مانند خروجی روش اول ارائه می‌دهند. در نمودار شکل ۶، درصد دقت و  $RMSE$  این

بهبتری نسبت به سایر مدل‌ها است. از طرفی روش *BNs* در این مقایسه‌ها از دقت پایینی برخوردار است.

داده‌های درست پیش‌بینی شده به کل داده‌ها، در شکل نمایش داده شده است. از این منظر نیز دقت بالای روش ماشین بردار پشتیبان تایید شده است و نشان دهنده مدل



شکل ۶- درصد دقت و *RMSE* در مدل‌سازی‌های انجام شده

نظر است. به عبارتی هرچه پیش‌بینی‌های صحیح مدل در یک کلاس بیشتر باشد، به اصطلاح، مدل به کلاس مورد نظر حساسیت بیشتری نشان داده است. در Error! Reference source not found. حساسیت هر مدل‌سازی نسبت به کلاس‌های مختلف آورده شده است؛ همچنین شکل ۷، این واقعیت را به صورت نمودار نشان می‌دهد.

#### ۲-۷- ارزیابی حساسیت

همان‌طور که در بخش‌های قبل ذکر شد، حساسیت یک مدل نسبت به مقادیر کیفی متغیر کلاس‌بندی شده، برابر با نسبت کلاس‌های مثبت صحیح به کل کلاس‌های مثبت است. مقدار حساسیت از صفر تا یک است. هرچه این مقدار به یک نزدیک‌تر باشد، نشان دهنده توانایی بالای مدل در پیش‌بینی پدیده ترکیدن خودبخودی سنگ در کلاس مورد

جدول ۹- ارزیابی حساسیت مدل‌ها در کلاس‌بندی‌های مختلف

داده‌های مربوط به آزمون	درصد حساسیت مدل‌ها				
	<i>SVM</i>	<i>ANN</i>	<i>KNN</i>	<i>CHAID</i>	<i>BNs</i>
کلاس بندی					
عدم وقوع	۰/۸۶	۰/۴۸	۰/۶۷	۰/۷۶	۰/۶۶
ضعیف	۰/۸۰	۰/۶۰	۰/۶۳	۰/۴۶	۰/۳۷
متوسط	۰/۸۹	۰/۹۲	۰/۸۳	۰/۸۷	۰/۸۳
شدید	۰/۵۳	۰/۵۹	۰/۴۷	۰/۴۱	۰/۱۰

بردار پشتیبان در پیش‌بینی انفجار سنگ در کلاس‌های متوسط و ضعیف از بالاترین حساسیت برخوردار هستند، اما در کل مدل ماشین بردار پشتیبان از حساسیت بیشتری

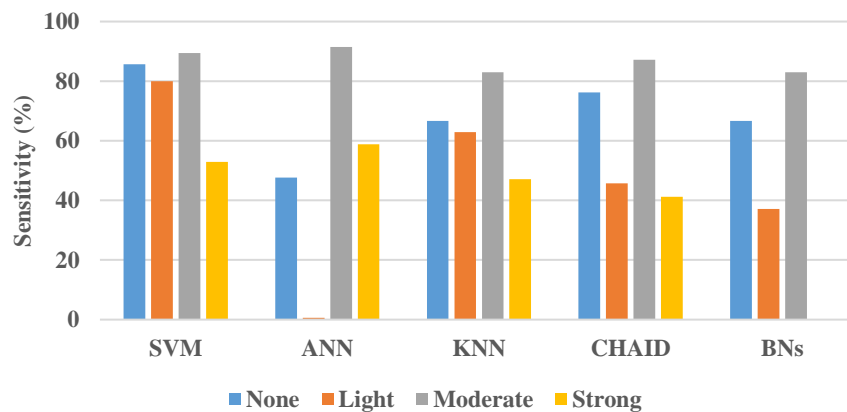
با توجه به این ارزیابی حساسیت روش‌های هوشمند نسبت به کلاس‌های مختلف انفجار عدم وقوع، متوسط، ضعیف و شدید، می‌توان دریافت مدل *ANN* در پیش‌بینی انفجار سنگ در کلاس‌های متوسط و شدید و مدل ماشین

شکل ۸، دقت و خطای معیارهای تجربی در کنار مدل‌های داده‌کاوی (هوشمند) را نشان می‌دهد که بر اساس آن می‌توان گفت، مدل‌های داده‌کاوی ماشین بردار پشتیبان و شبکه عصبی مصنوعی از دقت بالایی نسبت به روش‌های تجربی برخوردار هستند؛ لذا استفاده از آن‌ها در مراحل اولیه پیش‌بینی انفجار سنگ توصیه می‌شود. البته دقت روش شاخص انرژی الاستیک نیز به دلیل بالاتر بودن دقت آن از دو روش دیگر تجربی نیز حائز اهمیت است. همانطور که از شکل استنباط می‌شود، بالاترین دقت مربوط به مدل ماشین بردار پشتیبان و کمترین دقت مربوط به روش معیار تنش مماسی است.


نسبت به سایر روش‌های هوشمند در کلاس‌های مختلف انفجار سنگ برخوردار است.

### ۷-۳- مقایسه روش‌های هوشمند با روش‌های تجربی مرسوم

در این بخش به مقایسه روش‌های هوشمند با روش‌های مرسوم تجربی شاخص انرژی الاستیک *EI*، شاخص تردی *BC* و معیار تنش مماسی *SC* پرداخته می‌شود. هدف از این کار سنجیدن کارایی روش‌های هوشمند نسبت به روش‌های تجربی رایج است که برای پیش‌بینی پدیده انفجار سنگ در حفاریات زیرزمینی اعم از تونل‌ها و معادن استفاده شده‌اند.



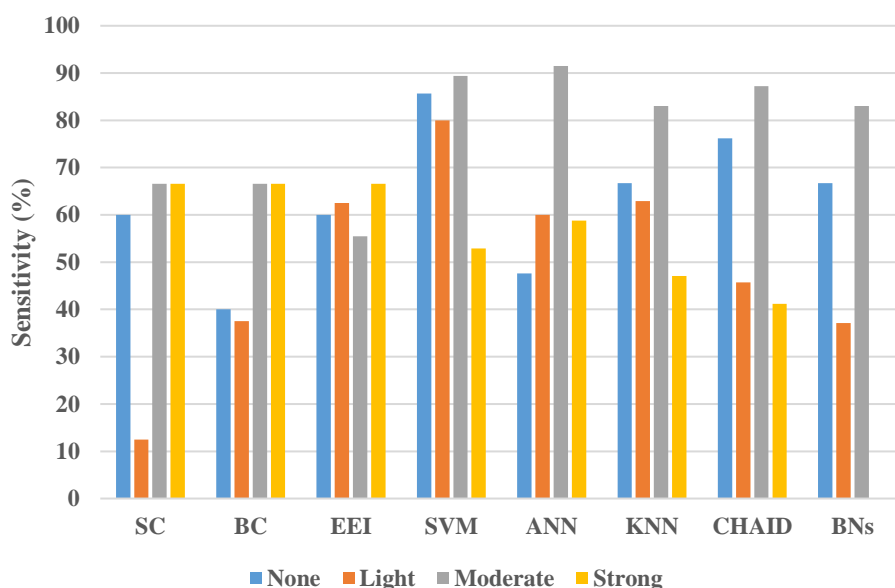
شکل ۷- نمودار ستونی حساسیت مدل‌ها در در کلاس‌های مختلف پدیده ترک‌یدن خودبخودی سنگ



شکل ۸- مقایسه دقت و خطای روش‌های هوشمند با روش‌های تجربی

کلاس شدید انفجار سنگ، صادق است؛ اما به طور کلی می‌توان گفت، مدل ماشین‌بردار پشتیبان و مدل شبکه عصبی مصنوعی شبکه عصبی مصنوعی از بیشترین درصد حساسیت در کلاس‌های مختلف انفجار برخوردار هستند.

در شکل ۹، حساسیت روش‌های تجربی و روش‌های هوشمند با یکدیگر مقایسه شده‌اند. در این مقایسه همانطور که از شکل مشخص است، روش‌های هوشمند بیشتر روی کلاس متوسط انفجار سنگ حساسیت نشان می‌دهند و همچنین این موضوع در مورد معیارهای تجربی در رابطه با



شکل ۹- مقایسه‌ی حساسیت روش‌های تجربی و روش‌های هوشمند

### ۳-۷- بررسی اهمیت متغیرها

با توجه به تحلیلی که در نرم‌افزار WEKA انجام گرفت، دو متغیر *MTS* و *EEI* به عنوان مؤثرترین متغیرها معرفی شده است. بررسی اهمیت متغیرها را همچنین می‌توان با حذف متغیر مورد نظر بررسی کرد. در روند ساخت مدل ماشین بردار پشتیبان، با حذف متغیر *MTS*، درصد پیش‌بینی‌های صحیح به ۷۲/۵ درصد و با حذف *EEI* مقدار آن به ۷۶/۶۶ درصد کاهش پیدا می‌کند؛ اما با حذف سایر متغیرها اختلاف زیادی در مقدار آن ایجاد نمی‌شود. این بررسی نشان می‌دهد، دو متغیر تنش مماسی ماکزیمم و شاخص انرژی الاستیک اهمیت بالاتری در مدل‌های پیش‌بینی دارند.

### ۸- نتیجه‌گیری

انفجار سنگ به‌عنوان یک معضل در صنعت حفاری در این پژوهش مورد بررسی قرار گرفت. به این منظور اطلاعات و

داده‌های شش پارامتر ورودی تأثیرگذار از جمله، تنش مماسی ماکزیمم، مقاومت فشاری تک محوره، مقاومت کششی تک محوره، معیار تنش مماسی، شاخص تردی و شاخص انرژی الاستیک و پارامتر خروجی با عنوان شدت انفجار سنگ با چهار کلاس عدم وقوع، ضعیف، متوسط و شدید با کمک گرفتن از چهار مقاله جمع‌آوری شد. سپس با هدف پیش‌بینی پدیده ترکیدن خودبخودی سنگ چند مورد از روش‌های هوشمند تحت نرم‌افزار WEKA به کار گرفته شد و در نهایت نتایج آن با روش‌های تجربی مقایسه گردید. مدل‌های استفاده شده در این تحقیق عبارتند از: الگوریتم ماشین بردار پشتیبان *SVM*، الگوریتم شبکه عصبی مصنوعی *ANN*، الگوریتم درخت تصمیم *CHAID*، الگوریتم نزدیکترین همسایه *KNN* و الگوریتم شبکه بیزین *BNs* و همچنین روش‌های تجربی که استفاده شد، عبارتند از:

۰/۳۳۷ است که در مقایسه با سایر مدل‌ها مقدار کمتری دارد و در نتیجه از دقت بالاتری برخوردار است. بعلاوه از مقایسه دقت روش‌های تجربی می‌توان دریافت که شاخص انرژی الاستیک در بین آن‌ها دارای دقت بالاتری است. در مورد ارزیابی حساسیت روش‌های هوشمند و روش‌های تجربی می‌توان گفت که درصد حساسیت در مدل ماشین بردار پشتیبان در حالت‌های شدت انفجار عدم وقوع و ضعیف و درصد حساسیت در مدل شبکه عصبی مصنوعی در حالت شدت انفجار متوسط از دیگر مدل‌ها و درصد حساسیت در روش‌های تجربی در حالت شدت انفجار شدید از دیگر روش‌ها و روش‌های هوشمند بالاتر است. به‌علاوه بررسی اهمیت متغیرهای ورودی به مدل‌ها، نشان داد، دو متغیر تنش مماسی ماکزیمم و شاخص انرژی الاستیک، از تأثیرگذاری بالاتری در پیش‌بینی صحیح کلاس‌ها برخوردار هستند.

شاخص انرژی الاستیک  $EEl$ ، شاخص تردی  $BC$  و معیار تنش مماسی  $SC$ . نتایج نشان داد: به‌طور کلی دقت روش‌های هوشمند نسبت به روش‌های تجربی در پیش‌بینی نوع کلاس شدت انفجار سنگ، بالاتر بوده است. البته روش  $BNs$  از این نتیجه‌گیری مستثنی است؛ بنابراین مدل‌های داده‌کاوی قابلیت پیش‌بینی در موضوع انفجار سنگ را دارند و می‌توان با کمک گرفتن از آن‌ها مراحل اولیه پیش‌بینی و طراحی را پشت سر گذاشت. دقت در مدل‌های داده‌کاوی ماشین بردار پشتیبان،  $ANN$  و  $KNN$ ، با تعریف درصدی از کل داده‌های ورودی که کلاس بندی، به درستی این داده‌ها را در کلاس مربوطه جای داده است، به ترتیب ۸۰/۸، ۷۰ و ۶۹/۱۶ است؛ همچنین در مورد ارزیابی  $RMSE$  در روش‌های هوشمند می‌توان به این نکته اشاره کرد که بهترین مقدار  $RMSE$  در میان روش‌های هوشمند، مربوط به مدل شبکه عصبی مصنوعی با مقدار

## ۹- منابع

- Adoko, A. C., Gokceoglu, C., Wu, L., & Zuo, Q. J. (2013). Knowledge-based and data-driven fuzzy modeling for rockburst prediction. *International Journal of Rock Mechanics and Mining Sciences*, 61, 86-95 .
- Babanouri, N., & Fattahi, H. (2018). Constitutive modeling of rock fractures by improved support vector regression. *Environmental Earth Sciences*, 77(6), 243 .
- Cai, M. (2016). Prediction and prevention of rockburst in metal mines—A case study of Sanshandao gold mine. *Journal of Rock Mechanics and Geotechnical Engineering*, 8(2), 204-211 .
- da Gama, C. D., & Navarro Torres, V. D. (2002, November 2002). *Prediction of EDZ (excavation damaged zone) from explosive detonation in underground openings* ISRM International Symposium-EUROCK 2002, Funchal .
- Dong, L.-j., Li, X.-b., & Kang, P. (2013). Prediction of rockburst classification using Random Forest. *Transactions of Nonferrous Metals Society of China*, 23(2), 472-477 .
- Fattahi, H. (2019). Tunnel boring machine penetration rate prediction based on relevance vector regression. *International Journal of Optimization in Civil Engineering*, 9(2), 343-353 .
- Fattahi, H., & Babanouri, N. (2017). Applying optimized support vector regression models for prediction of tunnel boring machine performance. *Geotechnical and Geological Engineering*, 35(5), 2205-2217 .

- Fattahi, H., & Bazdar, H. (2017). Applying improved artificial neural network models to evaluate drilling rate index. *Tunnelling and Underground Space Technology*, 70, 114-124 .
- Fattahi, H., Gholami, A., Amiribakhtiar, M .S., & Moradi, S. (2014). Estimation of asphaltene precipitation from titration data: a hybrid support vector regression with harmony search. *Neural Computing and Applications*, 26, 789-798 .
- He, J., Dou, L., Gong, S., Li, J., & Ma, Z. (2017). Rock burst assessment and prediction by dynamic and static stress analysis based on micro-seismic monitoring. *International Journal of Rock Mechanics and Mining Sciences*, 100(93), 46-53 .
- Kidybiński, A. (1981). Bursting liability indices of coal. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts*, 18(4), 295-304 .
- Kwasniewski, M., Szutkowski, I., & Wang, J. (1994). Study of ability of coal from seam 510 for storing elastic energy in the aspect of assessment of hazard in Porabka-Klimontow Colliery. *Sci. Rept. Silesian Technical University* .
- Li, N., Feng, X., & Jimenez, R. (2017). Predicting rock burst hazard with incomplete data using Bayesian networks. *Tunnelling and Underground Space Technology*, 61, 61-70 .
- Li, X., Pan, F., Li, H., Zhao, M., Ding, L., & Zhang, W. (2016). Prediction of rock-burst-threatened areas in an island coal face and its prevention: a case study. *International Journal of Mining Science and Technology*, 26(6), 1125-1133 .
- Manchao, H., Xuena, J., Peixoto, A., Sousa, L., Sousa, R. L., & Miranda, T. F. (2012). Prediction of rockburst based on experimental systems and artificial intelligence techniques .
- McCourt, T. (1999). *Conflicting communication interests in America: The case of national public radio*. Greenwood Publishing Group .
- Song, D., Wang, E., Liu, Z., Liu, X., & Shen, R. (2014). Numerical simulation of rock-burst relief and prevention by water-jet cutting. *International Journal of Rock Mechanics and Mining Sciences*, 70, 318-331 .
- Stacey, T., & Rojas, E. (2013). A potential method of containing rockburst damage and enhancing safety using a sacrificial layer. *Journal of the Southern African Institute of Mining and Metallurgy*, 113(7), 565-573 .
- Wang, J.-A., & Park, H. (2001). Comprehensive prediction of rockburst based on analysis of strain energy in rocks. *Tunnelling and Underground Space Technology*, 16(1), 49-57 .
- Zhou, J., Li, X., & Shi, X. (2012). Long-term prediction model of rockburst in underground openings using heuristic algorithms and support vector machines. *Safety Science*, 50(4), 629-644 .
- Zhou, K.-p., Yun, L., Deng, H.-w., Li, J.-l., & Liu, C.-j. (2016). Prediction of rock burst classification using cloud model with entropy weight. *Transactions of Nonferrous Metals Society of China*, 26(7), 1995-2002 .



## Evaluation of rock burst potential in deep underground excavations using artificial intelligence methods in WEKA data mining software

H. Fattahi<sup>1</sup>; F. Jiryae<sup>2</sup>; M. Ashori<sup>3</sup>

1- Associate Professor; Faculty of Earth Sciences Engineering, Arak University of Technology, h.fattahi@arakut.ac.ir

2- Master Student; Faculty of Earth Sciences Engineering, Arak University of Technology,

fatemeh.jiryae@gmail.com

3- Undergraduate Student; Faculty of Earth Sciences Engineering, Arak University of Technology,

iron.azar@gmail.com

Received: 20 Mar 2021; Accepted: 7 Jul 2021

DOR: 20.1001.1.23223111.1399.9.4.5.4

---

### Keywords

Rock burst potential  
Experimental methods  
Artificial intelligence methods  
Support vector machine  
WEKA software

---

### Extended Abstract

#### Summary

A rock burst in deep underground excavations is a sudden and violent expulsion of rock from the surrounding rock mass. Due to the complex features of rock burst hazard assessment systems, this study employs data mining techniques such as support vector machine (SVM), k-nearest neighbor (KNN), Bayesian networks (BNs), artificial neural network (ANN) and

CHAID tree model for the determination of classification of rock burst and compares their results with three experimental methods. For this purpose, WEKA data mining software have been used. The results show that among data mining algorithms, the SVM model has the highest accuracy, namely the accuracy of 80.8%. However, measuring the accuracy of the models using RMSE shows that the ANN model is the best model value with the RMSE = 0.337.

### Introduction

Rock burst is considered a dynamic instability phenomenon of surrounding rock mass of underground space in high geostatic stress and is caused by the violent release of strain energy stored in rock mass. Rock burst occurs during excavating underground space in the form of stripe of rock slices or rock fall or throwing rock fragments, sometimes accompanied by crack sound. Because it occurs suddenly and intensely, rock burst usually causes injury including death to workers, damage to equipment, and even substantial disruption and economic loss of underground space excavation. Therefore, there is a need for the development of suitable computational methods to predict and control the rock bursts particularly in a safe and economical underground excavation in burst-prone grounds.

### Methodology and Approaches

In order to predict the classification of rock burst, data mining models such as, SVM, ANN, CHAID decision tree, KNN and BNs were used. The WEKA software was used to build these models. Moreover, the results of data mining methods were compared with the performance of experimental methods of tangential stress criterion (SC), brittleness criterion (BC) and elastic energy index (EEI).

### Results and Conclusions

In general, the accuracy of intelligent methods has been higher than experimental methods in prediction of the type of

rock burst intensity class. The accuracy of SVM, ANN and KNN data mining models has been obtained as 80.8%, 70% and 69.16%. Furthermore, the best value of RMSE among these models is related to the ANN model with RMSE value of 0.337. In addition, the study of the importance of input variables to the models has shown that the two variables of maximum tangential stress and elastic energy index, compared to other variables, have higher effects on the correct prediction of the classes.

---