


بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشگاه صنعتی شاهرود

عنوان مقاله

پیش‌بینی استحکام ستون در معادن زیرزمینی با استفاده از تکنیک افزایش گرادیان تصادفی

تهیه کننده

محسن زمانی ثمرین

دانشجو دکتری مهندسی معدن گرایش استخراج مواد معدنی

40200685

آذر ماه 1402

چکیده:

پیش‌بینی استحکام ستون اهمیت زیادی دارد چرا که شکست ستون می‌تواند منجر به حوادث بزرگ شود. در این مقاله، یک مدل افزایش گرادیان تصادفی (SGB) برای طبقه‌بندی استحکام ستون به کار گرفته شد. پنج عامل پتانسیلی مرتبط، از جمله عرض ستون، ارتفاع ستون، نسبت عرض ستون به ارتفاع ستون، مقاومت فشاری یک محدوده صخره و استرس ستون، برای ایجاد سیستم ارزیابی انتخاب شد. 205 نمونه ستون جمع‌آوری شدند و یک مدل SGB با آموزش 80٪ از داده‌های اصلی (165 نمونه) ایجاد شد و مقادیر بهینه پارامترهای مدل با روش 10-fold cross-validation به دست آمدند. مجموعه آزمایش خارجی (با 40 نمونه) برای اعتبارسنجی امکانات مدل SGB استفاده شد. دقت و تحلیل کاپا، همراه با سه معیار داخلی طبقه‌بندی (precision، recall، و F-measure) و منحنی مشخصات عملکرد به منظور ارزیابی عملکرد مدل بهینه SGB، رندوم فارست (RF)، ماشین بردار پشتیبان (SVM)، و مدل MLPNN استفاده شدند. نتایج نشان دادند که مدل SGB اعتبار بالاتری نسبت به مدل‌های RF، SVM و MLPNN دارد. حساسیت پارامترها بر اساس اهمیت متغیر نسبی بررسی شد و استرس ستون و نسبت عرض ستون به ارتفاع ستون به عنوان متغیرهای اصلی تأثیرگذار بر استحکام ستون شناخته شدند.

کلمات کلیدی:

استحکام ستون

(SGB) افزایش گرادیان تصادفی

(آزمایش 10 برابر) 10-fold cross-validation

(ROC curve) منحنی مشخصات عملکرد

اهمیت نسبی متغیر

1) مقدمه:

در معدن کاری زیرزمینی بلندمدت و بزرگ مقیاس، وجود تعداد زیادی از غارها یکی از مهمترین عواملی است که امنیت تولید معدن را به خطر می‌اندازد و ستون‌ها سازه‌ای اصلی هستند که بر استحکام غارها تأثیر می‌گذارند. عدم پایداری یک ستون منجر به فروپاشی سقف در منطقه غار می‌شود که منجر به تعداد زیادی کشته و خسارات جدی در وجدان مالکیتی می‌شود [1] - [3]. بنابراین، افزایش استحکام ستون‌های معدن مهم است تا استخراج زیرزمینی به صورت کارآمد و ایمن انجام شود.

با توجه به اهمیت استحکام ستون، تعداد زیادی از مقالات در مورد ابعاد مختلف استحکام ستون منتشر شده‌اند و در دهه‌های گذشته تعداد زیادی از روش‌های ارزشمند توسط محققان برای درک و پیش‌بینی شکست ستون‌ها به کار گرفته شده‌اند. به طور کلی، این روش‌ها را می‌توان به دو دسته تقسیم کرد: روش‌های تجربی [4]، [5] و شبیه‌سازی عددی [6] - [8]. روش‌های تجربی معمولاً برای ارزیابی قدرت استون بر اساس فرمول‌های تجربی استفاده می‌شوند [9] - [11]. چرا که مشخص کردن استرس واقعی ستون‌ها در معادن زیرزمینی مشکل است، یک ضریب ایمنی (FS) برای ستون تعریف شده است که نسبت میانگین قدرت به میانگین استرس ستون است و برای ارزیابی استحکام ستون به کار می‌رود [6]، [12]. به طور کلی، یک ستون با $FS > 1.0$ پایدار است، در حالی که $FS < 1.0$ به معنای ناپایدار بودن ستون است [6]، [12] - [14]. با ظهور نرم‌افزارهای شبیه‌سازی عددی، فناوری شبیه‌سازی عددی به تجزیه و تحلیل استحکام ستون‌ها کاربرد پیدا کرده‌است. به عنوان مثال، دنگ و همکاران [6] با استفاده از تعدادی از روش‌های ترکیبی برای تجزیه و تحلیل استحکام ستون‌ها ارائه شده‌اند. به عنوان مثال، Shnorhokian و همکاران [15] با استفاده از نرم‌افزار FLAC3D، یک مدل محاسباتی عددی برای تحلیل ایمنی اندازه‌های مختلف ستون‌ها تحت توقف‌های مختلف ایجاد کردند Mortazavi و همکاران [7] فرآیند تغییر شکل و شکست ستون‌های معدن در شرایط طبیعی را به دست آوردند و تأثیر هندسه ستون‌ها و پارامترهای مکانیکی کمینه سنگ معدن را بر اساس نرم‌افزار UDEC تحلیل کردند. این مطالعات به درک ما از استحکام ستون‌ها کمک زیادی کرده‌اند، اما هنوز از حل کامل این مشکل دور هستند به دلیل مشکلات زیر:

(a) استحکام یک ستون تحت تأثیر بسیاری از پارامترها قرار دارد و برای این دو روش سخت است تا تأثیر عدم قطعیت‌ها را در نظر بگیرند.

(b) مرزهای ضریب ایمنی مشخص و واضح نیستند. در تئوری، یک ستون با $FS > 1.0$ پایدار است. با این حال، در سناریوهای مهندسی واقعی پیش‌آمده است که ستون‌های با $FS > 1.0$ شکست خورده‌اند [6]، [12].

(c) به دلیل رفتار غیرخطی ستون‌ها با استرس بالا در معادن عمیق، مکانیسم شکست ستون که در روش‌های موجود استفاده می‌شود، مناسب نیست.

در سال‌های اخیر، تکنیک‌های داده‌کاوی و مدل‌های ارزیابی هوشمند با توفیق برای تجزیه و تحلیل استحکام ستون‌ها به کار گرفته شده‌اند و با افزایش دسترسی به پارامترهای ستون، نتایج قابل توجهی به دست آورده‌اند. Cauvin و همکاران [16] یک مدل احتمالاتی برای پیش‌بینی استحکام ستون‌ها بر اساس عدم قطعیت داده و مدل پیشنهاد دادند Tawadrous و [17] Katsabanis از شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی استحکام ستون‌های تاج باقی‌مانده در اندازه‌های بزرگ استفاده کردند و نتیجه نشان داد که مدل ابر یک روش قابل قبول و قابل اعتماد برای ارزیابی جامع استحکام ستون‌هاست [14] Wattimena و Wattimena و همکاران [18] از رگرسیون لجستیک برای محاسبه احتمال شکست ستون استفاده کردند و این نویسندگان متوجه شدند که این ابزار مفیدی برای تحلیل استحکام ستون‌هاست. Griffiths و همکاران [19] یک مدل برای پیش‌بینی استحکام ستون‌ها با ترکیب نظریه میدان تصادفی و روش مونت‌کارلو پیشنهاد دادند. Zhou و همکاران [20] از روش‌های یادگیری نظارت‌شده مانند تحلیل تمایز Fisher، ماشین‌های بردار پشتیبان (SVM)، جنگل تصادفی (RF)، تحلیل تمایز خطی (LDA) و شبکه‌های عصبی متعدد لایه (MLPNN) برای پیش‌بینی استحکام ستون استفاده کردند و سپس عملکرد الگوریتم‌ها را با مقایسه نتایج پیش‌بینی مورد تجزیه و تحلیل قرار دادند. تمام مدل‌های هوشمند فوق می‌توانند به ما در درک شکست ستون‌ها کمک زیادی کنند، اما هر کدام از آن‌ها مزایا و معایب خود را دارند [20] - [22] و هیچ‌کدام برای هر مهندسی قابل استفاده نیستند. به علاوه، تمرکز هر شاخص ارزیابی متفاوت است. به عنوان مثال، Kappa و منحنی ROC برای داده‌های ناپرتیت استفاده‌مندتر هستند. برای پیش‌بینی استحکام ستون، مهم است که افترا به درستی پیش‌بینی حالت‌های شکست و ناپایدار باشد، که نیاز به معرفی معیارهایی جهت مقایسه و تجزیه و تحلیل عملکرد مدل‌ها برای حالت‌های مختلف است. این دو نیاز را باید با معرفی روش‌ها و معیارهای ارزیابی بیشتر برای پیش‌بینی استحکام ستون‌ها در معادن زیرزمینی برطرف کرد.

الگوریتم افزایش گرادیان تصادفی (SGB) یک الگوریتم یادگیری ماشین بهبود یافته است که توسط فریدمن [23]، [24] برای مطالعات رگرسیون و طبقه‌بندی ارائه شده است. الگوریتم SGB توانایی مدل‌سازی روابط غیرخطی را دارد و در عدم وجود داده‌ها و داده‌های ناپایدار قوی باقی می‌ماند و به‌ویژه برای پردازش داده‌های بالابُعدی مناسب است [25]. به علاوه، لازم نیست متغیرهای پیش‌بینی را قبلی انتخاب یا تغییر شکل داد [26] و دقت پیش‌بینی می‌تواند بر اساس یک قسمت از داده‌های آموزش افزایش یابد که همچنین به جلوگیری از

بیش‌برازش داده کمک می‌کند. الگوریتم SGB با موفقیت در بسیاری از زمینه‌ها مورد استفاده قرار گرفته است، مانند مطالعات در مورد انفجارهای سنگ [27]، رانش زمین [28]، خسارت سازه‌های مسکونی [29]، تصویربرداری دیجیتال [26]، پیش‌بینی داده‌های سری زمانی [30] و گونه‌های درخت [31]. بنابراین، جلب توجه و الهام برانگیز است که از مدل SGB برای پیش‌بینی استحکام ستون‌ها استفاده شود. هدف این مطالعه تأیید امکان و اعتبار الگوریتم SGB در پیش‌بینی استحکام ستون‌ها است، مقایسه عملکرد الگوریتم SGB با سه مدل دیگر با استفاده از شاخص‌های ارزیابی بیشتر، و بررسی اهمیت نسبی متغیرهای تأثیرگذار است. امیدوار است که نتایج بتوانند هشدار زودهنگام به مدیریت معدن ارائه دهند تا اقدامات مناسبی برای کاهش خسارت و حفظ جان‌ها انجام شود.

در این مقاله، پیش‌بینی استحکام ستون‌ها با استفاده از مدل SGB انجام می‌شود. با توجه به ابهام و عدم قطعیت شاخص‌های ارزیابی، برخی از شاخص‌های نماینده تیپیکال برای تشکیل سیستم شاخص انتخاب شده‌اند و روش fold CV-10 برای بهینه‌سازی پارامترهای مدل معرفی شده است. عملکرد با مقایسه دو شاخص کلی دسته‌بندی (دقت دسته‌بندی و ضریب Kappa کوهن)، سه شاخص دسته‌بندی داخل دسته (بازیابی، دقت و اندازه F) و منحنی ROC مدل‌های SGB، RF، SVM و MLPNN ارزیابی می‌شود. حساسیت عوامل نیز با محاسبه اهمیت متغیرهای نسبی مورد بررسی قرار می‌گیرد.

(2) پایگاه داده و پارامترها

(A) مکانیسم‌های شکست ستون‌ها

پاسخ کلی یک ستون به بارگذاری ناشی از معدنکاری بستگی به اندازه ستون، ساختار زمین‌شناسی کلیه سنگ، و محدودیت‌های سطحی که سنگ محیطی بر ستون اعمال می‌کند، دارد [4]، [5]. انواع شکست ستون‌ها می‌توانند به سه نوع تقسیم شوند [32]: شکست فشاری-کشنده، شکست کششی و شکست برشی در امتداد سطح ضعیف. شکست فشاری-کشنده به علت یک شکست خطی ستون در امتداد شکاف مشترک تحت عمل استرس برشی ایجاد می‌شود و داخل ستون ادامه می‌یابد، باعث کاهش تدریجی منطقه تحمل ستون می‌شود و در نهایت ستون را نابود می‌کند. شکست کششی رخ می‌دهد زمانی که ستون‌ها با شکاف‌های مشترک طولی تحت تأثیر استرس کششی عرضی ترک می‌خورند. شکست کششی به شکاف‌های مشترک طولی ستون‌ها تحت تأثیر استرس کششی عرضی اشاره دارد. شکست برشی در امتداد سطح ضعیف نیز شکست ستون‌ها با لایه‌های ضعیف را نشان می‌دهد که توسط استرس برشی عرضی ایجاد می‌شود و تحت تأثیر استرس محوری به وجود می‌آید. به طور کلی، پایداری ستون وابسته به موارد ذکر شده است و این عوامل نقش مهمی در شکست ستون‌ها ایفا می‌کنند.

پایداری ستون با ساختارهای هندسی و زمین‌شناسی به‌طور مستقیم وابسته است و به علت فعالیت‌های معدن کاری، توزیع دوباره استرس ستون را تحت تأثیر قرار می‌دهد.

(B) تجزیه و تحلیل پارامترها

برای ایجاد مدل‌های طبقه‌بندی، باید از برخی پارامترهای ستون استفاده شود. در عین حال، برای جلوگیری از بیش‌برازش مدل، باید به سه اصل در انتخاب پارامترها اعتماد کرد [33]. اولاً، باید از پارامترهای حساس و پایدار که ویژگی‌های پایداری ستون را منعکس می‌کنند، به عنوان نشانگرهای تمیزکاری استفاده شود. ثانیاً، پارامترها باید به‌طور فیزیکی مستقل از یکدیگر باشند. و سوماً، داده‌های پارامترها باید به‌راحتی به‌دست آمده یا در دسترس باشند. پایداری یک ستون تحت تأثیر عوامل متعددی قرار می‌گیرد و عوامل تأثیرگذار اصلی به شرح زیر هستند: (1) بارگذاری ستون، (2) اندازه ستون، (3) ساختار زمین‌شناسی و مقاومت بدنه معدن خود. به طور کلی، عرض ستون، ارتفاع ستون و نسبت عرض به ارتفاع می‌توانند اندازه یک ستون را منعکس کنند، به‌ویژه نسبت عرض به ارتفاع ستون تأثیر قابل توجهی بر احتمال شکست و یولنت ستون‌ها دارد [34] و این نسبت نشانگر اصلی برای طراحی و ارزیابی قدرت ستون‌ها در معادن زیرزمینی است. استرس ستون می‌تواند با وضعیت استرس ستون مرتبط شود و مقاومت بدنه معدن می‌تواند با مقاومت فشاری یک جهتی سنگ تعیین شود. در عین حال، همه یا بخشی از این پارامترها به کار رفته‌اند تا پایداری و قدرت ستون پیش‌بینی شود. به عنوان مثال، عرض و عمق ستون توسط Esterhuizen و همکاران [35] برای تحلیل پایداری ستون انتخاب شد. مطالعه Song و همکاران [36] نشان داد که عرض ستون، عمق معدن و عرض اتاق بیشترین تأثیر معنی‌دار را بر پایداری ستون دارند. Wattimena [14] و Wattimena و همکاران [18] پایداری ستون را با توسعه مدل خود با استفاده از نسبت عرض به ارتفاع ستون و نسبت قدرت ستون به استرس پیش‌بینی کردند. Ghasemi و همکاران [37] مدل خود را با استفاده از پارامترهای شامل عمق، عرض ستون، طول ستون و شرایط بارگذاری توسعه دادند. Zhou و همکاران [12] از پنج پارامتر ستون استفاده کردند، از جمله عرض ستون، ارتفاع ستون، نسبت عرض به ارتفاع ستون، مقاومت فشاری یک جهتی سنگ و استرس ستون. بر اساس تمام تجزیه و تحلیل‌های فوق، پنج پارامتر، شامل عرض ستون (X_1)، ارتفاع ستون (X_2)، نسبت عرض به ارتفاع ستون (X_3)، مقاومت فشاری یک جهتی سنگ (X_4) و استرس ستون (X_5)، در این مطالعه انتخاب شدند زیرا به طور گسترده در وظایف پیش‌بینی پایداری ستون با نتایج خوب استفاده شده‌اند و داده‌ها به‌راحتی قابل دسترس هستند. توجه داشته باشید که پایداری ستون همچنین تحت تأثیر عوامل دیگری مانند سیگنال‌های مانیتورینگ میکروسیسمیک و ویژگی‌های اختلالات دینامیک است. اما داده‌های دو شاخص دشوار به دست آمده و مشاهده می‌شود که پایداری ستون حتی بدون این دو شاخص می‌تواند

بهتر پیش‌بینی شود بر اساس نتایج [13]، [14]، [18]، [19] و [37]. بنابراین، سیگنال‌های مانیتورینگ میکروسیسمیک و ویژگی‌های اختلالات دینامیک به عنوان شاخص‌های ارزیابی در این مطالعه به کار نگرفته شدند.

جدول 1: آمار توصیفی پنج شاخص برای مدل SGB.

Indicators	X_1 / m	X_2 / m	X_3	X_4 / MPa	X_5 / MPa
Maximum	45.00	53.00	4.57	316.00	127.60
Minimum	1.90	1.80	0.31	19.00	1.10
Mean	9.93	10.14	1.35	144.11	46.81
Standard deviation	8.01	11.50	0.77	71.26	29.93

C) داده‌های موردی و تجزیه و تحلیل اولیه

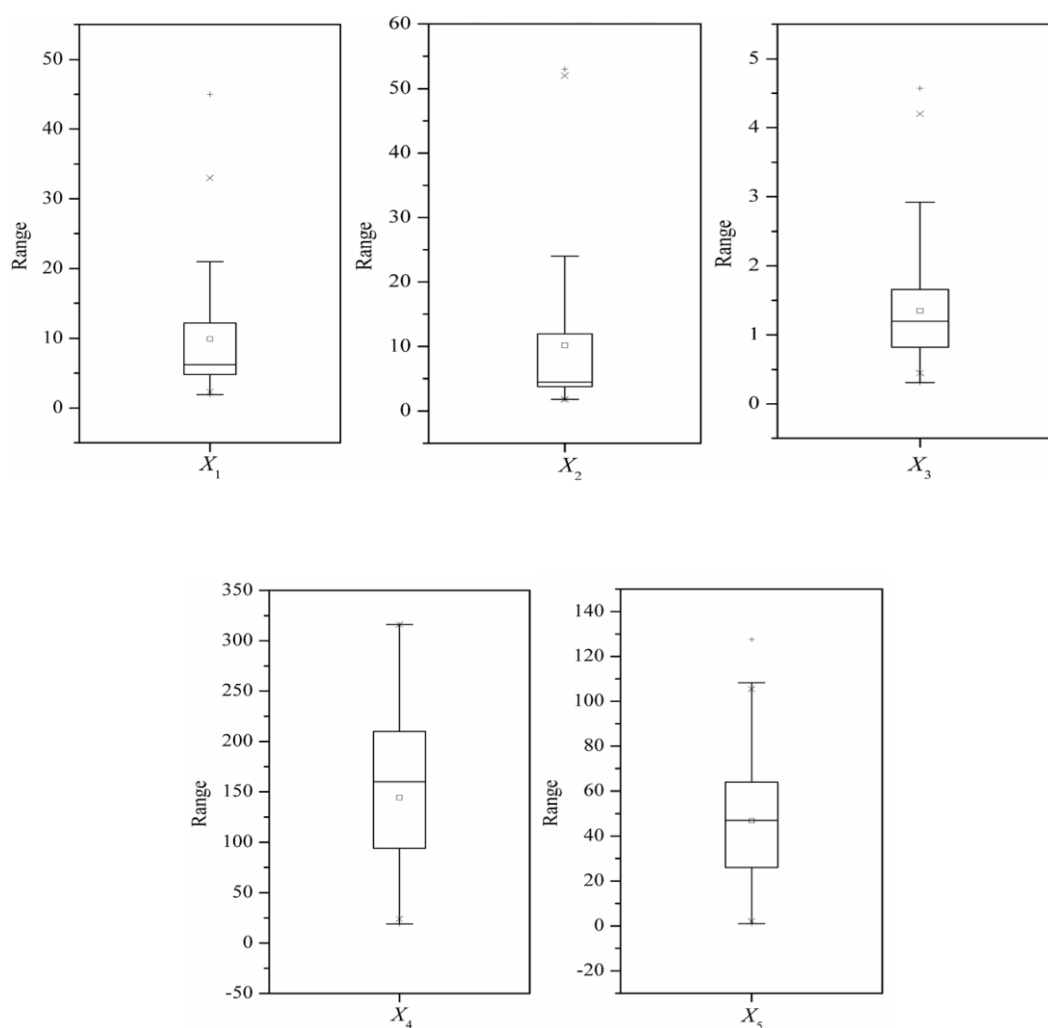
برای اندازه‌گیری و مقایسه عملکرد مدل SGB، 205 مورد ستون (در دسترس در جدول S1) از معادن زیرزمینی به صورت مستقیم از برخی مقالات جمع‌آوری شده است در بازه زمانی 1972-2017. داده‌های موارد ستون از هشت معدن مختلف سنگی جمع‌آوری شده‌اند که عبارتند از: معدن فسفات Wengfu در چین [32]؛ معدن سنگ در ایالات متحده [12]، [35]؛ معدن H-W شرکت Westmin Resources Ltd در کانادا [5]؛ معدن Zinkgruvan در سوئد [38]؛ معدن باز در کانادا [39]؛ معدن Selebi-Phikwe در آفریقای جنوبی [40]؛ معدن اورانیوم Elliot Lake در کانادا [41]. تمام داده‌ها از این ادبیات جمع‌آوری شده‌اند و منابع معتبر بدون هیچ‌گونه پردازشی هستند.

یک نمودار جعبه‌ای از تمام موارد در شکل 1 نشان داده شده است. به جز نسبت عرض به ارتفاع ستون (X_3)، میانه بیشتر پارامترها در وسط جعبه‌ها نیستند، که نشان‌دهنده توزیع نامتقارن این پارامترها است. در همین حالت، چند نقطه پرت با ارزش‌های بسیار بزرگ یا بسیار کوچک برای تمام پارامترها به جز مقاومت فشاری یک محوره سنگ (X_4) وجود دارد. ویژگی‌های آماری (حداکثر، حداقل، میانگین و انحراف معیار) مجموعه داده کاهش یافته در جدول 1 نشان داده شده‌اند.

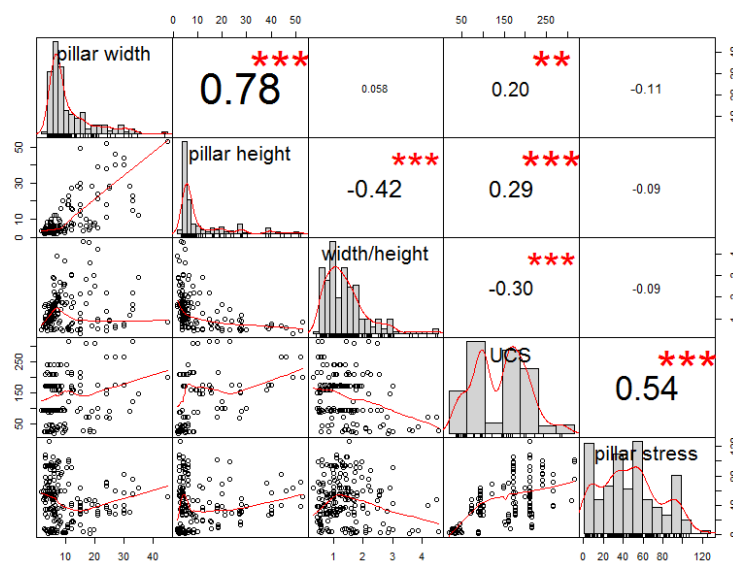
سه نوع پایداری برای مجموعه داده وجود دارد: پایدار (S، 73 مورد)، ناپایدار (U، 37 مورد) و شکسته (F، 95 مورد). شکل 2 ماتریس نقاط پراکندگی مجموعه داده را نشان می‌دهد. توزیع هر پارامتر در روی قطر نشان داده شده است و اعداد در بخش‌های بالایی نمایش‌دهنده همبستگی دو پارامتر هستند. از شکل 2، مشخص است که بیشتر پارامترها با یکدیگر همبستگی نسبتاً ضعیفی دارند ($R < 0.5$) [22]. همچنین می‌توان دید که عرض

ستون به طور قابل توجهی با ارتفاع ستون و استحکام فشاری یک محوره با استرس ستون همبستگی متوسطی دارد. به علاوه، مشخص است که مجموعه داده به طور گسترده منتشر شده است و توزیع اکثر متغیرهای تأثیرگذار نامتقارن است.

نمودار طبقه‌بندی پایداری ستون نسبت به هر شاخص خاص در شکل 3 نشان داده شده است. ایده‌آل، برای طبقه‌بندی آسان و روشن، مقادیر تمام شاخص‌ها باید فقط یک مقدار برچسب کلاس در شکل داشته باشند. ظاهر است که مقادیر برخی از شاخص‌ها برای یک ستون پایداری خاص در برخی از رویدادها بیش از یک مقدار متناظر دارند. این ممکن است به دلیل این باشد که مقادیر شاخص در میان کلاس‌های پایداری ستون حدود واضحی ندارند. همچنین می‌توان از شکل 3 استنباط کرد که هیچ‌کدام از پارامترها نمی‌توانند پایداری ستون را به خوبی تمایز دهند.



شکل 1. نمودار جعبه‌ای از هر متغیر برای موارد شکست سنگ.



شکل 2. ماتریس پراکندگی پنج پارامتر پایداری ستون.

3) روش شناسی

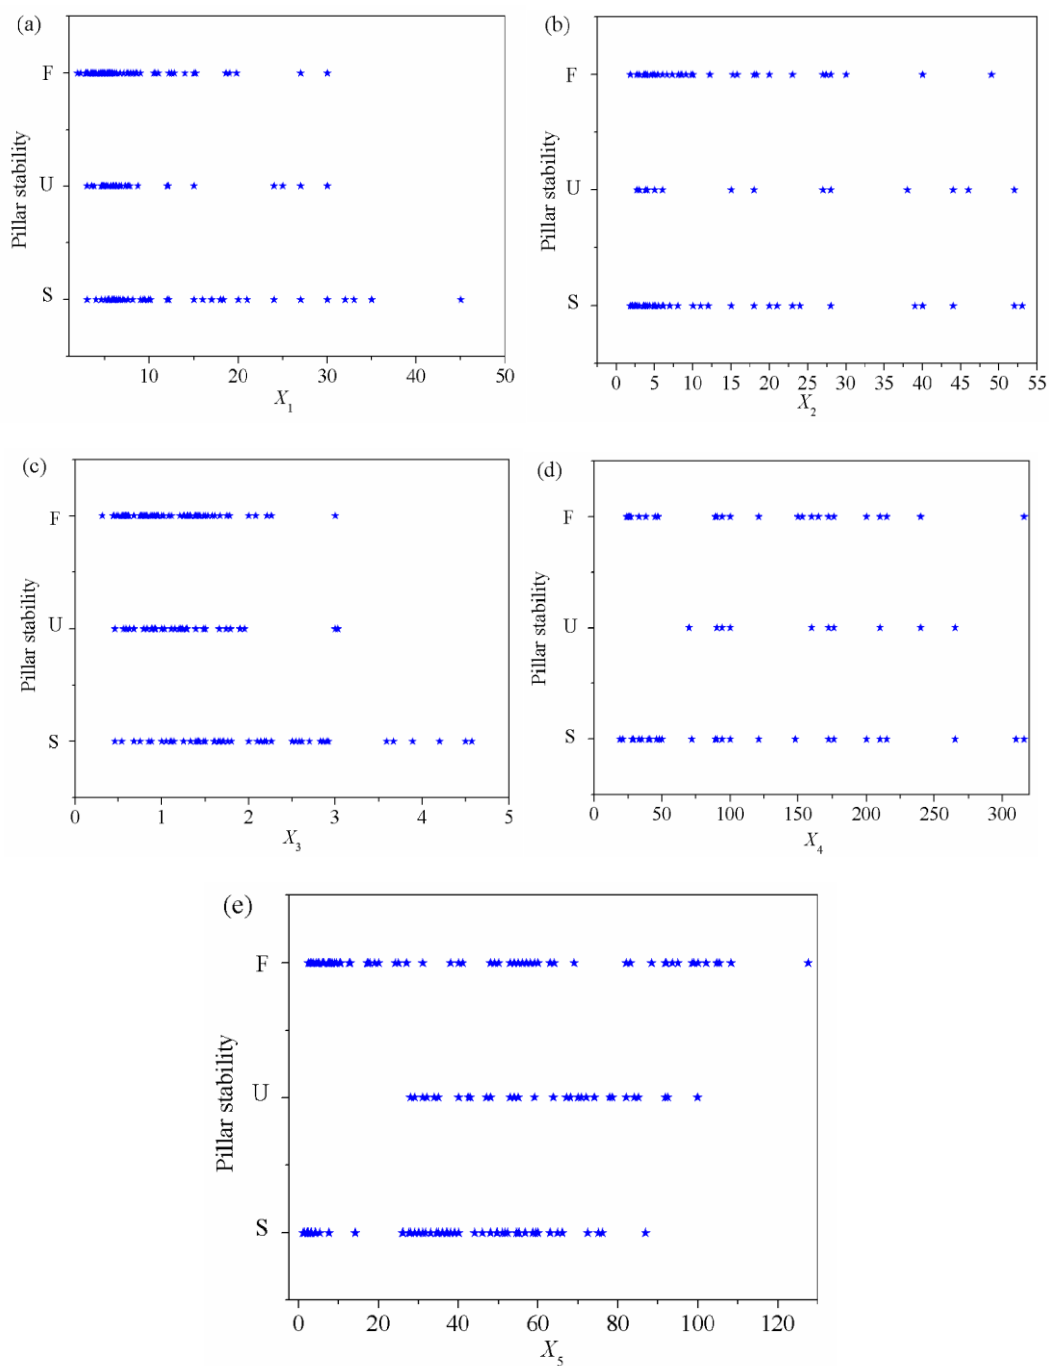
A) جزئیات مدل SGB

الگوریتم SGB توسط Friedman [24] ساخته شد با معرفی ایده کاهش گرادیان به الگوریتم بوستینگ. بوستینگ یک الگوریتم یادگیری گروهی است که با ترکیب بوستینگ و درخت‌های تصمیم استفاده می‌شود، و مدل جدید به اطلاعات کاهش گرادیان تابع از دست داده‌های مدل قبلی ساخته می‌شود. جوهر الگوریتم SGB در کمینه کردن تابع از دست داده‌های مدل طبقه‌بندی و واقعی توسط آموزش تابع طبقه‌بندی $F^*(x)$ است.

توزیع تابع از دست داده‌های مدل، کلید کاربرد مدل SGB است [20]، [24] و الگوریتم SGB قابلیت استفاده از همه توابع از دست داده‌های مدل را دارد. برای مسئله با K کلاس، تابع از دست داده‌های جایگزین (از دست دادن چند کلاس) تابع از دست داده‌های جایگزین پیشنهادی توسط Friedman [23]، [24] است و در بسیاری از زمینه‌ها [20]، [22]، [25]، [27]–[29] به طور گسترده استفاده شده است. تابع از دست داده‌های مدل می‌تواند به صورت زیر بیان شود:

$$\begin{aligned}\psi(y_k, F_k(X)_1^K) &= - \sum_{k=1}^K y_k \log p_k(X) \\ &= - \sum_{k=1}^K y_k \log \left[\frac{\exp(F_k(X))}{\sum_{l=1}^K \exp(F_l(X))} \right]\end{aligned}\quad (1)$$

که در آن $X=\{x_1,x_2,\dots,x_n\}$ متغیر ورودی، k تعداد کلاس‌ها، y متغیر خروجی، و $P_k(X)$ احتمال است.



شکل 3. پایداری ستون با توجه به هر نشانگر

سپس می‌توان معادله زیر را بدست آورد:

$$\begin{aligned}\tilde{y}_{im} &= -\left[\frac{\partial \psi(y_i, F_j(x_i))_{j=1}^K}{\partial F(x_i)}\right]_{(F_j(X)=F_{j,m-1}(X))_1^K} \\ &= y_i^k - p_k(x_i)\end{aligned}\quad (2)$$

که $y_i^k - p_k(x_i)$ در باقیمانده فعلی است، و بنابراین، K درخت تولید می‌شود. در همین حین، این موضوع باعث تولید K درخت با هر کدام دارای L گره پایانی در مرحله m می‌شود.

سپس، هر گره پایانی از هر درخت می‌تواند با یک جستجوی خطی جداگانه حل شود، همانطور که در معادله (3) نشان داده شده است.

$$\gamma_{lm} = \arg \min_{\gamma} \sum_{x_i \in R_{lm}} \psi(y_i, F_{m-1}(x_i) + \gamma) \quad (3)$$

هر یک از توابع به‌روزرسانی شده و سپس مدل SGB ایجاد می‌شود. توضیحات دقیق درباره الگوریتم SGB را می‌توانید در [27]، [29] و [42] پیدا کنید. همانطور که در این مطالعات ذکر شده است، سه پارامتر کلیدی برای الگوریتم SGB وجود دارد: تعداد درختان (تعامل‌های بوستینگ، M)، عمق تعامل (حداکثر عمق درخت، J) و کاهش (نرخ یادگیری، ν) از میان پارامترهای کلیدی الگوریتم SGB هستند. این پارامترها باید تنظیم شوند تا عملکرد و کلیت مدل SGB بهبود یابد.

(B) ارزیابی عملکرد مدل

یکی از ابزارهای اساسی برای ارزیابی اطمینان الگوریتم‌های طبقه‌بند، جدول اشتباه یا ماتریس ابهام است. جدول اشتباه یک ماتریس $m \times m$ است که در معادله (4) نشان داده شده است. برای هر مدل، یک جدول اشتباه ارائه می‌شود. برای تحلیل عملکرد پیش‌بینی مدل‌ها، دو معیار کلی از دقت طبقه‌بندی و شاخص Kappa کوهن، و سه معیار داخلی از بازخوانی، دقت و اندازه F برای تحلیل عملکرد پیش‌بینی و توانایی تعمیم الگوریتم‌ها استفاده می‌شود. توجه کنید که نمادها در این بخش با نمادهای بخش A متفاوت هستند.

$$\text{matrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mm} \end{bmatrix} \quad (4)$$

که در آن X_{ij} در قطر اصلی نمایانگر تعداد نمونه‌های تعلق گرفته به کلاس i که پیش‌بینی شده‌اند، X_{ij} تعداد نمونه‌های تعلق گرفته به کلاس i که به کلاس j پیش‌بینی شده‌اند، و m تعداد کلاس‌ها است.

توانایی تمایز الگوریتم‌ها می‌تواند بر اساس نرخ دقت تمایز ارزیابی شود و دقت می‌تواند به عنوان معادله (5) محاسبه شود. کوهن $Kappa$ ، شاخصی است که برای ارزیابی قابلیت اعتبار بین ارتباط‌دهندگان در هنگام کدگذاری متغیرهای زمینه‌ای به شمار می‌آید. این آمار نیز به عنوان یک بهبود نسبت به استفاده از درصد برای ارزیابی قابلیت اعتبار مورد استفاده قرار می‌گیرد. کاپا می‌تواند با معادله (6) محاسبه شود.

$$Accuracy = \left(\frac{1}{n} \sum_{i=1}^m x_{ii} \right) \times 100\% \quad (5)$$

$$Kappa = \frac{n \sum_{i=1}^m x_{ii} - \sum_{i=1}^m (x_{i+} \cdot x_{+i})}{n^2 - \sum_{i=1}^m (x_{i+} \cdot x_{+i})} \quad (6)$$

که n تعداد کل نمونه‌ها در مجموعه داده، x_{iC} تعداد نمونه‌های تعلق گرفته به کلاس i و x_{Ci} تعداد نمونه‌هایی است که به کلاس j پیش‌بینی شده‌اند.

محدوده‌ی مقدار $Kappa$ از -1 تا 1 می‌باشد و می‌تواند به شش گروه تقسیم شود تا سطوح مختلف سازگاری را نشان دهد (همانطور که در جدول 2 نشان داده شده است). به طور کلی، اگر مقدار $Kappa$ کمتر از $0/4$ باشد، نشان دهنده ضعف توافق است، و اگر مقدار $Kappa$ بیشتر یا مساوی $0/4$ باشد، نشان دهنده توافق خوب است [33]، [45].

توجه به دقت پیش‌بینی کلاس‌ها برای تمام نمونه‌ها تنها یک جنبه از مسائل پایداری ستون نیست، بلکه عملکرد پیش‌بینی بر روی نمونه‌های متعلق به یک کلاس خاص نیز باید مدنظر قرار گیرد. سه معیار داخلی کلاس، شامل بازخوانی (Recall)، دقت (Precision) و اندازه F (F-measure)، به طریق گسترده‌ای برای ارزیابی این موارد استفاده می‌شوند.

جدول 2. مقیاس اصلی توافق با مقدار کاپا.

Strength of agreement	Kappa value
total disagreement	[-1.0, 0)
Slight	[0, 0.2)
Poor	[0.2, 0.4)
Moderate	[0.4, 0.6)
Substantial	[0.6, 0.8)
Perfect	[0.8, 1.0]

قدرت تمایز مدل ها در موارد با درجه معین. دقت به عنوان نسبت تعداد کل نمونه ها تعیین می شود با نمره معینی که به درستی به تعداد کل طبقه بندی شده است از موارد آن درجه توسط یک مدل ارزیابی شده است. یادآوری نسبت است از تعداد کل موارد با درجه معین طبقه بندی شده به طور صحیح به تعداد کل موارد آن درجه [46]. این دو معیار اغلب برای ارائه یک معیار انتخاب می شوند F-Measure نامیده می شود. سه معیار به شرح زیر ارائه شده است:

$$\text{Recall}_i = \left(\frac{x_{ii}}{\sum_{j=1}^m x_{+j}} \right) \times 100\% \quad (7)$$


$$\text{Precision}_i = \left(\frac{x_{ii}}{\sum_{j=1}^m x_{j+}} \right) \times 100\% \quad (8)$$

$$\text{F-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (9)$$

یک منحنی کاراکتری عملکرد گیرنده (ROC) نماینده ای گرافیکی از تعداد واقعی مثبت ها به عنوان مثبت ها و تعداد نادرست مثبت ها به عنوان منفی ها است [33]، [47]. این منحنی ROC برای مقایسه عملکرد الگوریتم های مختلف مورد استفاده قرار می گیرد. به طور کلی، یک دسته بند عملکرد تمایزی برتر دارد زمانی که منحنی ROC آن در گوشه بالا و چپ قرار دارد. عملکرد دسته بند های مختلف همچنین می تواند با تحلیل ناحیه زیر منحنی ROC (AUC) انجام شود. هرچه مقدار AUC بزرگتر باشد، عملکرد دسته بندی بهتر است. در این مطالعه، این روش نیز برای ارزیابی و مقایسه عملکرد تمیزی چهار مدل برای پیش بینی پایداری ستون ها استفاده شده است.

(C) توسعه مدل و بهینه سازی پارامتر

برای آموزش و ارزیابی عملکرد دسته‌بندی ها، باید مجموعه داده اصلی به دو زیرمجموعه تقسیم شود: مجموعه آموزش و مجموعه آزمایش. انتخاب داده‌های آموزش برای آموزش دسته‌بندی اهمیت دارد و مجموعه آموزش باید نماینده کل مجموعه داده باشد. برای یک مجموعه آموزش کوچک، ارتباط به درستی یادگرفته نمی‌شود. برای یک مجموعه آموزش بسیار بزرگ، قابلیت عمومی نمی‌تواند تأیید شود و احتمال بیش‌آموزش وجود دارد [22]، [48]. بنابراین، معمولاً مجموعه آموزش و آزمایش توسط یک تحلیل بهینه‌سازی تعیین می‌شود. در این مطالعه، 165 مورد (80٪ از داده اصلی) به عنوان مجموعه آموزش استفاده شده و 40 مورد باقی‌مانده به عنوان مجموعه آزمایش گرفته شده‌اند.



شکل 4. تنظیم پارامترها برای تعیین مدل بهینه SGB (a) دقت؛ (b) Kappa.

جهت بهینه سازی پارامترهای کلیدی مدل SGB و به دست آوردن عملکرد تمیزتر، روش 10-fold CV که تعدادی تاوان توسط Rodriguez و همکاران [49] توصیه شده است، به عنوان روش اعتبارسنجی استفاده شده است. در طول فرآیند 10-fold CV، مجموعه آموزش به صورت تصادفی به 10 بخش (9 بخش برای آموزش و 1 بخش برای اعتبارسنجی) تقسیم می‌شود، همانطور که در شکل 5 مشاهده می‌شود. بخش آموزشی برای یادگیری ماشین استفاده می‌شود و سپس با تطابق برخی از پارامترهای هیپر-پارامترها، طبقه‌بندی‌ها تشکیل می‌شود.

بخش اعتبارسنجی برای تنظیم پارامترها و اعتبارسنجی قابلیت تعمیم طبقه‌بندها استفاده می‌شود. این فرآیند به صورت 10 بار روی زیرمجموعه‌های آموزش مختلف تکرار می‌شود و در نهایت، هر نمونه یک بار برای آزمون و 9 بار برای آموزش استفاده شده است. دقت fold CV-10 با میانگین ساده از 10 دقت فردی محاسبه شده و تمام fold CV-10 نیز به تکرار 10 بار تکرار شده تا نتایج قابل اعتماد به دست آید. سپس طبقه‌بندها با هیپر-پارامترهای بهینه با استفاده از کل مجموعه آموزش آموزش داده شده و مجموعه آزمون (که هرگز برای توسعه طبقه‌بندها استفاده نشده است) به عنوان یک مجموعه آزمون مستقل برای آزمایش قابلیت پیش‌بینی مدل‌های بهینه استفاده می‌شود.

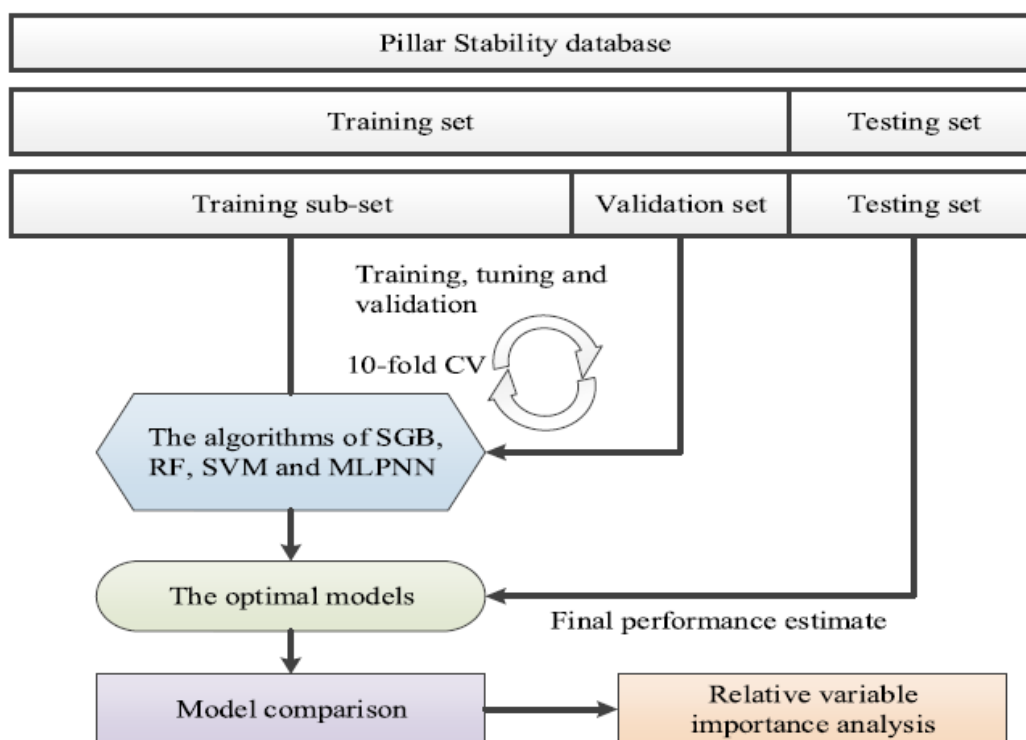
اصولاً اعتقاد بر این است که از طریق روش fold CV-10 می‌توان بهترین توانایی تعمیمی در مدل را ارائه داد. توانایی تعمیمی مدل‌ها بر اساس عملکرد آنها در مجموعه آموزش به دست می‌آید و فرض می‌شود که مدل‌ها قابلیت تعمیم به سایر نمونه‌های ناشناخته را دارند. مجموعه آزمایش به عنوان نمونه‌های ناشناخته برای ارزیابی توانایی تعمیم مدل‌ها استفاده می‌شود.

همانطور که در بخش 3/1 توضیح داده شده است، الگوریتم SGB (Stochastic Gradient Boosting) دارای سه پارامتر کلیدی است: تعداد درخت‌ها (عامل افزایشی، M)، عمق تعامل (حداکثر عمق درخت، J) و کاهش (نرخ یادگیری، v). برای به دست آوردن بهترین عملکرد مدل SGB، پارامترها با استفاده از روش 10-fold CV بررسی می‌شوند. بر اساس بسیاری از مآخذ، پارامترهای تنظیمی به صورت زیر می‌باشد:

$$v = (0.001, 0.01, 0.1), M = (50, 100, 150, \dots, 500), J = (1, 2, 3, \dots, 9)$$

با یک فرآیند 10-fold CV در این مقاله مورد آزمون قرار می‌گیرند. دقت و کوئن Kappa برای تعیین بهترین ترکیب مدل SGB استفاده می‌شوند و نتایج در شکل 4 نشان داده شده‌اند. مدل نهایی با استفاده از بیشترین مقدار دقت و Kappa انتخاب می‌شود. همانطور که مشاهده می‌شود، محدوده دقت مدل‌های SGB از 60٪ تا 81٪ است و مقدار Kappa در بازه [0.35-0.65] قرار دارد. همچنین مشاهده می‌شود که بهترین انتخاب برای سه پارامتر $M = 150$ ، $J = 8$ ، $v = 0.1$ است و دقت و Kappa مدل SGB به ترتیب 81/21٪ و 0/6420 هستند.

برای اثبات امکان‌پذیری و قابلیت اعتبار مدل SGB، عملکرد الگوریتم SGB با عملکرد مدل‌های RF، SVM و MLPNN مقایسه شد. این الگوریتم‌ها به دلیل استفاده روز به روز بیشتر در تجزیه و تحلیل پایه، و همچنین داشتن عملکرد تشخیصی بالاتر انتخاب شده‌اند. مدل‌های RF، SVM و MLPNN نیز توسط روش 10-fold CV بهینه‌سازی شده‌اند. جزئیات انتخاب پارامترهای کلیدی در این مطالعه به شرح زیر است:



شکل 5. فرآیند کلی برای پیش‌بینی پایداری ستون با استفاده از روش‌های یادگیری نظارت‌شده.

(1) مدل RF: الگوریتم دارای دو پارامتر است (یکی تعداد درخت‌های دسته‌بندی n_{tree} و دیگری تعداد متغیرها m_{try}) که نیاز به بهینه‌سازی دارند. متغیر m_{try} حساس‌تر به دقت تمایزی است، و دقت تمایزی به اندازه کمی توسط n_{tree} تحت تأثیر قرار می‌گیرد. برای تعداد عوامل ورودی مورد استفاده در موارد ستون‌ها آزمایش می‌شوند. در این مقاله، محدوده تنظیم برای تعداد درخت‌ها از 100 تا 1000 با گام‌های 50 است. علاوه بر این، در این مطالعه شش شاخص وجود دارد، بنابراین مقادیر m_{try} می‌تواند (1، 2، 3، 4، 5، 6) باشد. بهترین انتخاب برای n_{tree} و m_{try} به ترتیب 500 و 3 است.

(2) مدل SVM: با توجه به تحقیقات Zhou و همکاران [12]، Dong و همکاران [50] و Samui [51]، پارامترهای کلیدی الگوریتم SVM تخلفات محدودیت C و سیگما هستند. مقدار سیگما می‌تواند تقریباً با استفاده از تابع "sigest" نرم‌افزار R تخمین زده شود. بر اساس روش 10-fold CV، برای C مقدار $(2^0, 2^1, 2^2, 2^3, 2^4, 2^5, 2^6, 2^7, 2^8)$ بهینه‌سازی می‌شود تا پارامتر بهینه در این مطالعه یافت شود. در نهایت، C برابر با 20 و سیگما برابر با 0/3525 به عنوان بهترین مقادیر شناخته شده‌اند.

(3) مدل MLPNN: این مدل تعداد نورون‌های مخفی H (1, 2, 3, 4, 5, 6, 7, 8, 9 و 10) و مقداردهی اولیه وزن تصادفی را تنظیم می‌کند. نتایج نشان می‌دهند که مقادیر بهینه پارامترها به شرح زیر هستند: واحدهای مخفی H برابر با 5 و کاهش D برابر با 0/1. بنابراین، مراحل کلی برای پیش‌بینی پایداری ستون با استفاده از مدل SGB در این مطالعه می‌تواند به شکلی نشان داده شود که در شکل 5 آورده شده است.

5) نتایج و بحث

A) نتایج تشخیصی و تجزیه و تحلیل عملکرد

نتایج پیش‌بینی چهار مدل بهینه در جدول 3 آورده شده است. مقادیر قرار گرفته در قطر جدول، تعداد نمونه‌های صحیح پیش‌بینی شده را نشان می‌دهد. تعداد نمونه‌هایی که توسط مدل SGB به درستی پیش‌بینی شده‌اند (کلیه 36 نمونه) بیشترین است. با اینکه تعداد کمتری نمونه توسط مدل SGB نسبت به دیگر مدل‌ها به درستی پیش‌بینی شده است، اما مدل‌های RF (34 نمونه به درستی پیش‌بینی شده)، SVM (33 نمونه به درستی پیش‌بینی شده) و MLPNN (32 نمونه به درستی پیش‌بینی شده) نیز نتایج قابل قبولی دارند. بنابراین، همه چهار مدل توانایی تمییز بالایی برای پایداری ستون‌ها دارند و عملکرد مدل SGB بهترین است.

مقدار دقت و کاپا برای هر مدل در جدول 4 نشان داده شده است. برای مجموعه آموزش، دقت و کاپا توسط 10 بار اعمال fold CV-10 محاسبه شده‌اند و دقت مدل‌ها در محدوده [0/71/52 تا 0/93/33] قرار دارد، همانطور که در جدول 4 نشان داده شده است. به طور واضح، مدل RF با نرخ دقت میانگین بالاترین (0/93/33) را دارا بوده است، دنباله دار آن مدل SVM با نرخ دقت میانگین 0/83/03، سپس مدل‌های SGB و MLPNN با نرخ دقت میانگین به ترتیب 0/81/21 و 0/71/52 می‌آیند. در عین حال، مقادیر کاپا مدل‌های گراف اطلاعاتی (RF)، SVM، SGB و MLPNN در بازه [0/5083 تا 0/8930] قرار دارند و قدرت توافق کاپا در مدل‌های SGB، RF، SVM و MLPNN از متوسط تا عالی است مطابق با مقیاس پایه که در جدول 2 نشان داده شده است. به وضوح مشخص است که کاپا مدل RF با مقدار 0/8930 بیشترین است، سپس مدل‌های SVM، SGB و MLPNN به ترتیب قرار دارند. قدرت توافق مدل SGB معتبر است. برای مجموعه آزمایش، دقت مدل‌ها از 80.00 تا 90.00٪ است و مدل SGB بالاترین نرخ دقت را دارد (90.00٪)، دنباله دار آن مدل‌های SVM، RF و MLPNN با نرخ دقت به ترتیب 85.0٪، 82.5٪ و 80٪ هستند. در عین حال، مقادیر کاپا در بازه [0/6548 تا 0/8351] قرار دارند. قدرت توافق کاپا از معتبر تا عالی است. به وضوح مشخص است که کاپا مدل SGB با

مقدار 0/8351 بیشترین است، سپس مدل‌های RF، SVM و MLPNN به ترتیب قرار دارند. بنابراین، مدل SGB توانایی تعمیم بالاتری نسبت به سایر مدل‌ها دارد.

جدول 3. نتایج پیش‌بینی بر روی مجموعه آزمون برای سه مدل به صورت زیر است:

Predicted	Observed											
	SGB			RF			SVM			MLPNN		
	F	S	U	F	S	U	F	S	U	F	S	U
F	19	2	0	17	1	1	18	2	3	18	1	5
S	0	12	2	0	13	2	1	12	1	1	13	1
U	0	0	5	2	0	4	0	0	3	0	0	1

The diagonal elements are correct decisions.

جدول 4. مقایسه دقت (Accuracy) و ضریب Kappa برای چهار مدل به صورت زیر است:


Date set	Metrics	SGB	RF	SVM	MLPNN
Training set	Accuracy / %	81.21	93.33	83.03	71.52
	Kappa	0.6420	0.8930	0.7202	0.5083
Testing set	Accuracy / %	90.00	85.00	82.50	80.00
	Kappa	0.8351	0.7586	0.7040	0.6548

نتایج پیش‌بینی نمونه‌های آزمایشی نشان می‌دهد که عملکرد مدل SGB بهترین عملکرد جامع پیش‌بینی را دارد و این مدل برای پیش‌بینی پایداری ستون مناسب و قابل استفاده است. همچنین، نتایج نشان می‌دهد که همه چهار مدل توانایی عمومی نسبت به داده‌های آموزش و داده‌های آزمایشی را دارند که نشان می‌دهد ضرورت بهینه‌سازی مدل‌ها با استفاده از روش 10-fold CV وجود دارد [22]، [47].

نتایج به دست آمده برای سه معیار داخلی داخلی کلاس‌بندی بر اساس مجموعه آزمایشی در جدول 5 آورده شده است. به خصوص، بازخوانی، دقت و اندازه‌گیری F برای چهار کلاسیفایر برای پیش‌بینی پایداری ستون انحرافات بزرگی دارد (بازخوانی D 14.29 تا 100٪، دقت D 75 تا 100٪ و اندازه‌گیری F D 25.01 تا 95٪). برای نمونه‌های متعلق به کلاس F و U، بهترین عملکرد تشخیصی توسط مدل SGB نشان داده می‌شود، با بازخوانی 100 و 70/43٪، دقت 90/48 و 100٪، و اندازه‌گیری F 95 و 83/33٪ به ترتیب. برای نمونه‌های متعلق به کلاس S، عملکرد چهار کلاسیفایر مشابه است. همانطور که می‌دانیم، برای پیش‌بینی موارد ناپایدار و شکست در پایداری ستون در معادن زیرزمینی، اهمیت دارد که موارد اینگونه به درستی پیش‌بینی شود. بنابراین، می‌توان نتیجه گرفت که مدل SGB برای پیش‌بینی پایداری ستون در معادن زیرزمینی مناسب‌تر است. علاوه بر این،

مدل RF و SVM نیز در تمام موارد نتایج قابل قبولی را کسب می‌کنند. با این حال، توانایی عمومی مدل MLPNN برای موارد متعلق به کلاس U ضعیف است.

با توجه به مجموعه آزمایشی، منحنی ROC برای چهار مدل به دست آمده و در شکل 6 نشان داده شده است. از شکل 6 مشخص است که شکل منحنی‌های ROC مدل‌های SGB، RF، SVM و MLPNN به ترتیب از راست به چپ است، که نشان‌دهنده این است که مدل SGB عملکرد کلی بهتری دارد. مقادیر AUC چهار کلاسیفایر در بازه 0.791-0.871 قرار دارند. طبق استاندارد دسته‌بندی مقدار AUC در [33]،



شکل 6. برای چهار مدل بر روی مجموعه آزمایشی (AUD) و ارزیابی مساحت زیر منحنی ROC

با توجه به تحلیل‌های انجام شده، می‌توان نتیجه گرفت که توانمندی عمومی چهار رده‌بندی SVM، RF، SGB و MLPNN از متوسط تا خوب است. بر اساس مقادیر AUC، مشخص است که مدل SGB با بالاترین مقدار AUC برابر با 0.891، دنباله‌ای بر روی مدل‌های RF، SVM و MLPNN دارد. همه این نشان می‌دهد که عملکرد مدل SGB بهترین است و سپس به ترتیب مدل‌های RF، SVM و MLPNN قرار دارند.

با توجه به تحلیل‌های انجام شده، می‌توان نتیجه گرفت که مدل SGB با توانایی عمومی برتر، قابلیت و اعتبار پیش‌بینی پایداری ستون‌ها در معادن زیرزمینی را داراست.

(B) اهمیت نسبی متغیرها

تحلیل حساسیت پارامترها از اهمیت برخوردارهای تخصصی برخوردهای نهفته مهندسان معدن و کنترل پایداری ستون‌ها و کفه‌های زمین است. با این حال، تعیین حساسیت مشکل است زیرا همه پارامترها به پایداری ستون


حساس هستند و تأثیر همبستگی میان پارامترهای ورودی نیز وجود دارد. علاوه بر این، روش‌های مختلفی برای به دست آوردن حساسیت پارامترها وجود دارد [33]، [47]، [52] - [56]. در این مطالعه، حساسیت پارامترها با استفاده از روش امتیاز اهمیت نسبی بر اساس مدل‌های بهینه SGB و RF بررسی شد. انتخاب این دو مدل بر اساس عملکرد برجسته آن‌ها در مجموعه آزمون صورت گرفت.

تابع عمومی (varImp) در بسته‌ی caret نرم‌افزار R برای محاسبه اهمیت پارامترها استفاده می‌شود. اهمیت نهایی متغیرها محاسبه شد

جدول 5. مقادیر سه معیار طبقه بندی درون کلاسی برای هر مدل.

Class	MLPNN			SVM			RF			SGB		
	Recall	Precision	F	Recall	Precision	F	Recall	Precision	F	Recall	Precision	F
	%	%	%	%	%	%	%	%	%	%	%	%
F	94.74	75.00	83.72	94.74	78.26	85.72	89.47	89.47	89.47	100.00	90.48	95.00
S	92.86	86.67	89.66	85.71	85.71	85.71	92.86	86.67	89.66	85.71	85.71	85.71
U	14.29	100.00	25.01	42.86	100.00	60.00	57.14	66.67	61.54	71.43	100.00	83.33

Note: F represents the F-Measure.



شکل ۷. رتبه‌بندی اهمیت متغیرهای مرتبط با پایداری ستون به وسیله SGB و RF.

با میانگین‌گیری از اهمیت نسبی متغیرها از مدل‌های بهینه RF و SGB، امتیازهای اهمیت متغیرها نرمال شده‌اند (مجموع تمام امتیازهای اهمیت برابر یک است) و نتیجه در شکل ۷ نشان داده شده است.

واضح است که استرس ستون با امتیاز اهمیت 0/407، عامل حساس‌ترین برای پایداری ستون است که نشان‌دهنده تأثیر قابل توجهی این عامل بر پایداری ستون است. دلیل این امر ممکن است این باشد که پایداری یک ستون

اصلاً تحت تأثیر پاسخ مکانیکی ستون به بار ناشی از استخراج معدن قرار دارد، و پاسخ مکانیکی به طور مستقیم با وضعیت استرس ستون مرتبط است. همچنین مشاهده شده است که استرس بالای ستون ناشی از نسبت‌های استخراج بالا می‌تواند باعث لرزش ستون شود و لرزش ممکن است آغاز شود زمانی که استرس متوسط ستون حدود 10٪ از استحکام فشاری یک محوره سنگ را تجاوز کند [35]، [57]. اهمیت استرس ستون با نتایج حاصل شده توسط Zhou و همکاران [20] همخوانی دارد.

در دسته حساسیت دوم، نسبت عرض به ارتفاع ستون با امتیاز اهمیت 0/360 قرار دارد، که نشان‌دهنده این است که این نسبت نیز یک عامل تأثیرگذار اصلی بر پایداری ستون می‌باشد. این نسبت، اصلی‌ترین شاخص مرجع برای طراحی و ارزیابی استحکام ستون‌ها در معادن زیرزمینی است. مشاهده شد که استحکام یک ستون تقریباً 60٪ کاهش یافته است زمانی که نسبت عرض به ارتفاع از 1 به 0/5 تغییر کرد [35]. بنابراین، نسبت عرض به ارتفاع ستون باید مدنظر قرار گیرد تا پایداری ستون‌ها در معادن زیرزمینی پیش‌بینی شود.

امتیاز اهمیت عرض ستون 0/169 می‌باشد که نشان‌دهنده این است که این متغیر نیز یک عامل تأثیرگذار مهم بر پایداری ستون است. همچنین مشاهده می‌شود که استحکام فشاری یک محوره سنگ (0/049) و ارتفاع ستون (0/015) به اندازه سه عامل اول حساس نیستند. این استنباط همچنین در [20] مورد مطالعه قرار گرفته است.

همانطور که در بالا توضیح داده شد، استرس ستون و نسبت عرض به ارتفاع ستون عوامل اصلی تأثیرگذار بر پایداری ستون هستند. بنابراین، با بهبود وضعیت استرس ستون‌ها و بهینه‌سازی نسبت عرض به ارتفاع ستون، پایداری ستون‌ها در معادن زیرزمینی می‌تواند افزایش یابد.

به‌علاوه، باید توجه داشت که اهمیت نسبی متغیرها به داده‌ها و مدل‌ها وابسته است، و نتایج نماینده‌تر می‌توانند با داشتن موارد معتبرتر ستون حاصل شوند.

6) نتیجه‌گیری‌ها

الگوریتم SGB همراه با مدل‌های RF، SVM و MLPNN در این مطالعه برای پیش‌بینی پایداری ستون‌ها در معادن زیرزمینی معرفی شدند. پنج شاخص ممکناً مرتبط، شامل عرض ستون، ارتفاع ستون، نسبت عرض به ارتفاع ستون، استحکام فشاری یک محوره سنگ و استرس ستون، به عنوان شاخص‌های پیش‌بینی انتخاب شدند. روش 10-fold CV-برای بهبود توانایی کلی مدل‌های طبقه‌بندی استفاده شد. بر اساس تحلیل‌ات انجام‌شده، نتایج زیر قابل استنباط هستند:

1. شکل منحنی ROC مدل SGB به طور کلی نزدیک‌تر به محورهای چپ و بالا بود نسبت به سایر مدل‌ها، و دقت، Kappa و AUC مدل SGB بر روی مجموعه‌های آزمون به ترتیب 90٪، 0/8351 و 0/891 بود، که نشان‌دهنده عملکرد برجسته این مدل برای پیش‌بینی پایداری ستون‌ها است. ترتیب عملکرد چهار مدل به ترتیب SGB، RF، SVM و MLPNN می‌باشد.

2. مدل SGB با ارزش‌های بالاتر recall، precision و F-measure می‌تواند یک ابزار ارزشمند برای پیش‌بینی تمام موارد ستون در معادن زیرزمینی باشد، به‌ویژه برای موارد مستعد به شکست و کلاس‌های ناپایدار، و سپس مدل‌های RF، SVM و MLPNN.

3. استرس ستون و نسبت عرض به ارتفاع ستون به عنوان دو متغیر پرتأثیرتر در پیش‌بینی پایداری ستون‌ها مشاهده شدند، که به ترتیب امتیازهای اهمیت 0/407 و 0/360 را کسب کردند.

در تحقیقات آتی، می‌توان نمونه‌های بیشتری با پارامترهای مهم دیگر معرفی کرد تا مدل SGB را بهبود داده و امکان‌پذیری و قابلیت اعتبار آن را افزایش داد. به عنوان مثال، از سیگنال‌های نگهبانی میکروسیسمی و ویژگی‌های اختلالات دینامیکی می‌توان برای این منظور استفاده کرد.

- [1] M. Naja_, S. E. Jalali, A. Y. Bafghi, and F. Sereshki, ``Prediction of the confidence interval for stability analysis of chain pillars in coal mines," *Saf. Sci.*, vol. 49, no. 5, pp. 651_657, 2011.
- [2] M. D. G. Salamon, ``Stability, instability and design of pillar workings," *Int. J. Rock Mech. Mining Sci. Geomech. Abstr.*, vol. 7, no. 6, pp. 613_631, 1970.
- [3] D. R. Tesarik, J. B. Seymour, and T. R. Yanske, ``Long-term stability of a back_lled room-and-pillar test section at the Buick Mine, Missouri, USA," *Int. J. Rock Mech. Mining Sci.*, vol. 46, no. 7, pp. 1182_1196, 2009.
- [4] B. H. G. Brady and E. T. Brown, *Rock Mechanics: For Underground Mining*. Springer, 2013. [Online]. Available: <https://link.springer.com/book/10.1007/978-1-4020-2116-9>
- [5] P. J. Lunder, ``Hard rock pillar strength estimation an applied empirical approach," Ph.D. dissertation, Appl. Sci., Fac. Mining Eng., Univ. British Columbia, Vancouver, BC, Canada, 1994.
- [6] J. Deng, Z. Q. Yue, L. G. Tham, and H. H. Zhu, ``Pillar design by combining _nite element methods, neural networks and reliability: A case study of the Feng Huangshan copper mine, China," *Int. J. Rock Mech. Mining Sci.*, vol. 40, no. 4, pp. 585_599, 2003.
- [7] A. Mortazavi, F. P. Hassani, and M. Shabani, ``A numerical investigation of rock pillar failure mechanism in underground openings," *Comput. Geotechn.*, vol. 36, no. 5, pp. 691_697, 2009.
- [8] G. York, ``Numerical modelling of the yielding of a stabilizing pillar/foundation system and a new design consideration for stabilizing pillar foundations," *J. Southern Afr. Inst. Mining Metall.*, vol. 98, no. 6, pp. 281_297, 1998.
- [9] W. A. Hustrulid, ``A review of coal pillar strength formulas," *Rock Mech.*, vol. 8, no. 2, pp. 115_145, 1976.
- [10] M. Jawed, R. K. Sinha, and S. Sengupta, ``Chronological development in coal pillar design for bord and pillar workings: A critical appraisal," *J. Geol. Mining Res.*, vol. 5, no. 1, pp. 1_11, 2013.
- [11] C. D. Martin and W. G. Maybee, ``The strength of hard-rock pillars," *Int. J. Rock Mech. Mining Sci.*, vol. 37, no. 8, pp. 1239_1246, 2000.
- [12] J. Zhou, X.-B. Li, X. Shi, W. Wei, and B. Wu, ``Predicting pillar stability for underground mine using Fisher discriminant analysis and SVM methods," *Trans. Nonferrous Metals Soc. China*, vol. 21, no. 12, pp. 2734_2743, 2011.
- [13] E. Ghasemi, H. Kalhori, and R. Bagherpour, ``Stability assessment of hard rock pillars using two intelligent classification techniques: A comparative

- study," *Tunnelling Underground Space Technol.*, vol. 68, pp. 32_37, Sep. 2017.
- [14] R. K. Wattimena, ``Predicting the stability of hard rock pillars using multinomial logistic regression," *Int. J. Rock Mech. Mining Sci.*, vol. 71, pp. 33_40, 2014, doi: 10.1016/j.ijrmms.2014.03.015.
- [15] S. Shnorhokian, H. S. Mitri, and L. Moreau-Verlaan, ``Stability assessment of stope sequence scenarios in a diminishing ore pillar," *Int. J. Rock Mech. Mining Sci.*, vol. 74, pp. 103_118, Feb. 2015.
- [16] M. Cauvin, T. Verdel, and R. Salmon, ``Modeling uncertainties in mining pillar stability analysis," *Risk Anal.*, vol. 29, no. 10, pp. 1371_1380, 2009.
- [17] A. S. Tawadrous and P. D. Katsabanis, ``Prediction of surface crown pillar stability using arti_cial neural networks," *Int. J. Numer. Anal. Methods Geomech.*, vol. 31, no. 7, pp. 917_931, 2007.
- [18] R. K. Wattimena, S. Kramadibrata, I. D. Sidi, and M. A. Azizi, ``Developing coal pillar stability chart using logistic regression," *Int. J. Rock Mech. Mining Sci.*, vol. 58, pp. 55_60, Feb. 2013.
- [19] D. V. Grif_ths, G. A. Fenton, and C. B. Lemons, ``Probabilistic analysis of underground pillar stability," *Int. J. Numer. Anal. Methods Geomech.*, vol. 26, no. 8, pp. 775_791, 2002.
- [20] J. Zhou, X. Li, and H. S. Mitri, ``Comparative performance of six supervised learning methods for the development of models of hard rock pillar stability prediction," *Natural Hazards*, vol. 79, no. 1, pp. 291_316, 2015.
- [21] C. Qi, A. Fourie, G. Ma, X. Tang, and X. Du, ``Comparative study of hybrid arti_cial intelligence approaches for predicting hangingwall stability," *J. Comput. Civil Eng.*, vol. 32, no. 2, p. 04017086, 2017.
- [22] C. Qi and X. Tang, ``Slope stability prediction using integrated metaheuristic and machine learning approaches: A comparative study," *Comput. Ind. Eng.*, vol. 118, pp. 112_122, Apr. 2018.
- [23] J. H. Friedman, ``Greedy function approximation: A gradient boosting machine," *Ann. Statist.*, vol. 29, no. 5, pp. 1189_1232, 2001.
- [24] J. H. Friedman, ``Stochastic gradient boosting," *Comput. Statist. Data Anal.*, vol. 38, no. 4, pp. 367_378, 2002.
- [25] R. Blagus and L. Lusa, ``Boosting for high-dimensional two-class prediction," *BMC Bioinf.*, vol. 16, no. 1, p. 300, 2015.
- [26] R. Lawrence, A. Bunn, S. Powell, and M. Zambon, ``Classi_cation of remotely sensed imagery using stochastic gradient boosting as a re_nement of classi_cation tree analysis," *Remote Sens. Environ.*, vol. 90, no. 3, pp. 331_336, 2004.
- [27] J. Zhou, X.-Z. Shi, R.-D. Huang, X.-Y. Qiu, and C. Chen, ``Feasibility of stochastic gradient boosting approach for predicting rockburst damage in

- burst-prone mines," *Trans. Nonferrous Metals Soc. China*, vol. 26, no. 7, pp. 1938_1945, 2016.
- [28] L. Lombardo, M. Cama, C. Conoscenti, M. Märker, and E. Rotigliano, "Binary logistic regression versus stochastic gradient boosted decision trees in assessing landslide susceptibility for multiple-occurring landslide events: Application to the 2009 storm event in Messina (Sicily, southern Italy)," *Natural Hazards*, vol. 79, no. 3, pp. 1621_1648, 2015.
- [29] J. Zhou, X. Shi, and X. Li, "Utilizing gradient boosted machine for the prediction of damage to residential structures owing to blasting vibrations of open pit mining," *J. Vib. Control*, vol. 22, no. 19, pp. 3986_3997, 2016.
- [30] Y. Gao, J. Pan, G. Ji, and F. Gao, "A time-series modeling method based on the boosting gradient-descent theory," *Sci. China Technol. Sci.*, vol. 54, no. 5, pp. 1325_1337, 2011.
- [31] G. G. Moisen, E. A. Freeman, J. A. Blackard, T. S. Frescino, N. E. Zimmermann, and T. C. Edwards, "Predicting tree species presence and basal area in Utah: A comparison of stochastic gradient boosting, generalized additive models, and tree-based methods," *Ecol. Model.*, vol. 199, no. 2, pp. 176_187, Nov. 2006.
- [32] G. Zhao and J. Liu, "Analysis of the pillar stability based on the Gaussian process for machine learning," *J. Saf. Environ.*, vol. 17, no. 5, pp. 1725_1729, 2017.
- [33] Y. Lin, K. Zhou, and J. Li, "Prediction of slope stability using four supervised learning methods," *IEEE Access*, vol. 6, pp. 31169_31179, 2018.
- [34] G. Rashed and S. S. Peng, "Change of the mode of failure by interface friction and width-to-height ratio of coal specimens," *J. Rock Mech. Geotech. Eng.*, vol. 7, no. 3, pp. 256_265, 2015.
- [35] G. S. Esterhuizen, D. R. Dolinar, and J. L. Ellenberger, "Pillar strength in underground stone mines in the United States," *Int. J. Rock Mech. Mining Sci.*, vol. 48, no. 1, pp. 42_50, 2011.
- [36] W.-D. Song, S. Cao, J.-X. Fu, G.-J. Jiang, and F. Wu, "Sensitivity analysis of impact factors of pillar stability and its application," *Rock Soil Mech.*, vol. 35, pp. 271_277, 2014. [Online]. Available: <http://ytlx.whrsm.ac.cn/EN/abstract/abstract15198.shtml>
- [37] E. Ghasemi, M. Ataei, and K. Shahriar, "Prediction of global stability in room and pillar coal mines," *Natural Hazards*, vol. 72, no. 2, pp. 405_422, 2014.
- [38] J. Sjöberg, "Failure modes and pillar behaviour in the Zinkgruvan mine," in *Proc. 33rd U.S. Symp. Rock Mech. (USRMS)*. New York, NY, USA: American Rock Mechanics Association, 1992, pp. 491_500.

- [39] Y. Potvin, M. Hudyma, and H. Miller, "Rib pillar design in open stope mining," *Bull. Can. Inst. Mining Metall.*, vol. 82, no. 927, pp. 31_36, 1989.
- [40] M. R. Von Kimmelman, B. Hyde, and R. J. Madgwick, "The use of computer applications at BCL Limited in planning pillar extraction and the design of mining layouts," in *Proc. Des. Perform. Underground Excavations, ISRM Symp.*, Cambridge, U.K., Sep. 1984, pp. 53_63.
- [41] D. G. F. Hedley and F. Grant, "Stope-and-pillar design for the Elliot Lake uranium mines," *Can. Mining Metall. Bull.*, vol. 65, no. 723, p. 37, 1972.
- [42] A. Jasra and C. C. Holmes, "Stochastic boosting algorithms," *Statist. Comput.*, vol. 21, no. 3, pp. 335_347, 2010.
- [43] S. Visa, B. Ramsay, A. L. Ralescu, and E. Van Der Knaap, "Confusion matrix-based feature selection," in *Proc. MAICS*, 2011, pp. 120_127.
- [44] A. Yee, R. T. Corlett, S. Liew, and H. T. Tan, "The vegetation of Singapore_An updated map," *Gardens' Bull. Singapore*, vol. 63, nos. 1_2, pp. 205_212, 2011.
- [45] M. L. McHugh, "Interrater reliability: The kappa statistic," *Biochemia Medica*, vol. 22, no. 3, pp. 276_282, 2012.
- [46] J. Zhou, X. Li, and H. S. Mitri, "Classification of rockburst in underground projects: Comparison of ten supervised learning methods," *J. Comput. Civil Eng.*, vol. 30, no. 5, p. 04016003, 2016.
- [47] C. Qi, A. Fourie, X. Du, and X. Tang, "Prediction of open stope hangingwall stability using random forests," *Natural Hazards*, vol. 92, no. 2, pp. 1179_1197, 2018.
- [48] C. Qi, A. Fourie, Q. Chen, and Q. Zhang, "A strength prediction model using artificial intelligence for recycling waste tailings as cemented paste backfill," *J. Cleaner Prod.*, vol. 183, pp. 566_578, May 2018.
- [49] J. D. Rodriguez, A. Perez, and J. A. Lozano, "Sensitivity analysis of k-fold cross validation in prediction error estimation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 32, no. 3, pp. 569_575, Mar. 2010.
- [50] L. Dong, J. Wesseloo, Y. Potvin, and X. Li, "Discrimination of mine seismic events and blasts using the Fisher classifier, Naive Bayesian classifier and logistic regression," *Rock Mech. Rock Eng.*, vol. 49, no. 1, pp. 183_211, 2015.
- [51] P. Samui, "Slope stability analysis: A support vector machine approach," *Environ. Geol.*, vol. 56, no. 2, p. 255, 2008.
- [52] Y. Qin, Z. Wang, C. Xiang, M. Dong, C. Hu, and R. Wang, "A novel global sensitivity analysis on the observation accuracy of the coupled vehicle model," *Vehicle Syst. Dyn.*, pp. 1_22, Sep. 2018, doi: 10.1080/00423114.2018.1517219.

- [53] X. Tang, W. Yang, X. Hu, and D. Zhang, "A novel simplified model for torsional vibration analysis of a series-parallel hybrid electric vehicle," *Mech. Syst. Signal Process.*, vol. 85, pp. 329_338, Feb. 2017, doi: 10.1016/j.ymssp.2016.08.020.
- [54] C. Hu, R. Wang, F. Yan, Y. Huang, H. Wang, and C. Wei, "Differential steering based yaw stabilization using ISMC for independently actuated electric vehicles," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 2, pp. 627_638, Feb. 2018.
- [55] C. Qi, Q. Chen, A. Fourie, and Q. Zhang, "An intelligent modelling framework for mechanical properties of cemented paste backfill," *Minerals Eng.*, vol. 123, pp. 16_27, Jul. 2018.
- [56] C. Qi, A. Fourie, G. Ma, and X. Tang, "A hybrid method for improved stability prediction in construction projects: A case study of stope hangingwall stability," *Appl. Soft Comput.*, vol. 71, pp. 649_658, Oct. 2018.
- [57] C. J. Pritchard and D. G. F. Hedley, "Progressive pillar failure and rockbursting at denison mine," in *Proc. 3rd Int. Symp. Rockbursts Seismicity Mines, Kingston. Rotterdam, AA Balkema*, 1993, p. 111J6.