

DOI: 10.11779/CJGE20220701

基于数据预处理技术并考虑围岩应力梯度影响的 隧洞岩爆预测

夏元友¹, 张宏伟¹, 吝曼卿², 阎要锋¹

(1. 武汉理工大学土木工程与建筑学院, 湖北 武汉 430070; 2. 武汉工程大学资源与安全工程学院, 湖北 武汉 430074)

摘要: 针对目前岩爆预测研究通常忽视岩爆数据集存在离群样本、缺失值与样本不平衡性问题以及围岩应力梯度的影响, 提出一套完备的岩爆数据预处理流程, 引入可间接表征围岩应力梯度的洞径指标, 建立了隧洞岩爆多因素综合预测模型。在数据采集阶段, 考虑隧道与采场及隧洞群受力条件差异, 从岩爆数据库中分离出隧洞岩爆样本共 306 例。在岩爆预测指标选取阶段, 选取隧洞洞径 D_0 、围岩最大切向应力 $\sigma_{\theta_{max}}$ 、岩石单轴抗压强度 σ_c 、岩石抗拉强度 σ_t 、弹性能变形指数 W_{et} 共 5 个指标。在数据预处理阶段: 针对缺失值, 引入随机森林多重插补法 (MI-RF) 对岩爆样本进行补充; 针对离群样本, 引入最近邻 (KNN)、孤立森林 (Isolation Forest)、局部异常因子 (LOF) 3 种无监督算法综合评估岩爆数据集并剔除离群样本; 针对样本不平衡, 引入自适应综合过采样 (ADASYN) 算法扩容少数类样本。在模型验证阶段: 采用支持向量机 (SVM)、随机森林 (RF)、梯度提升树 (GBDT)、自适应提升树 (AdaBoost)、极限梯度提升树 (XGBoost) 5 类算法构建岩爆预测模型。模型预测结果表明: 基于数据预处理并考虑洞径指标的 5 类模型皆为同类算法模型中的最优; 在不进行数据预处理的条件下, 考虑洞径指标模型要优于不考虑洞径指标的同类算法模型。

关键词: 地下工程; 岩爆预测; 数据预处理; 围岩应力梯度; 洞径

中图分类号: TU431

文献标识码: A

文章编号: 1000-4548(2023)10-1987-08

作者简介: 夏元友(1965—), 男, 教授, 博士生导师, 主要从事岩土工程教学和科研工作。E-mail: xiayy1965@whut.edu.cn。

Prediction of tunnel rockbursts based on data preprocessing technology considering influences of stress gradient of surrounding rock

XIA Yuanyou¹, ZHANG Hongwei¹, LIN Manqing², YAN Yaofeng¹

(1. School of Civil Engineering and Architecture, Wuhan University of Technology, Wuhan 430070, China; 2. School of Resources and Safety Engineering, Wuhan Institute of Technology, Wuhan 430074, China)

Abstract: As the current rockburst prediction investigation frequently ignores outliers, missing values, sample imbalance in the rockburst dataset and the influences of surrounding rock stress gradient, a complete preprocessing process of rockburst data is proposed, and the hole diameter index that indirectly represents the stress gradient of surrounding rock of tunnel is employed to establish the multi-factor comprehensive prediction model for tunnel rockbursts. At the stage of the data collection, considering the variation in stress conditions between the tunnel, stope and tunnel group, 306 samples of rockbursts in tunnels are isolated from the rockburst database. At the stage of determining prediction index, five indices are selected including the hole diameter (D_0), the maximum tangential stress ($\sigma_{\theta_{max}}$), the uniaxial compressive strength (σ_c), the uniaxial tensile strength of the rock (σ_t) and the elastic energy deformation index (W_{et}). At the stage of the data preprocessing, the multiple imputation method of random forest (MI-RF) is introduced to fill in the missing values. Three unsupervised algorithms including the K-nearest neighbor (KNN), the isolation forest (IForest) and the local outlier factor (LOF) are introduced to comprehensively evaluate the rockburst dataset and removed outliers. The adaptive comprehensive oversampling (ADASYN) algorithm is introduced to expand the number of minority samples. At the stage of the model validation, five types of models including the support vector machine (SVM), the random forest (RF), the gradient boosted decision trees (GBDT), the adaptive boosting algorithm (AdaBoost) and the extreme gradient boosting algorithm (XGBoost) are adopted for comparison. The results demonstrate that the aforementioned models based on the data preprocessing and the hole diameter index are all the best among similar algorithm

基金项目: 国家自然科学基金项目 (42077228, 52174085)

收稿日期: 2022-06-01

models. Without the data preprocessing, the model considering the hole diameter index is better than those without considering the hole diameter.

Key words: underground engineering; rockburst prediction; data preprocessing; stress gradient of surrounding rock; hole diameter

0 引言

深部工程的岩爆问题极大地威胁着设备和人员安全^[1-2]。因此,岩爆的预测研究具有重要的理论与工程意义。目前,岩爆风险预测主要有单因素预测与多因素预测,其中单因素预测主要基于单一岩爆理论,多因素预测则考虑了岩爆的多种影响因素。根据数学原理,多因素岩爆预测可被细分为:基于多指标集合的岩爆预测^[3];基于多属性群决策的岩爆预测^[4-6];基于机器学习的岩爆预测^[7-9]。可以看出,岩爆预测集中于创新算法,但在一定程度上忽视或简化了数据预处理。由于岩爆样本来自于世界各地,工况差异较大,这导致了岩爆数据集含有一定数量的离群样本,同时数据集也存在类别不平衡及部分特征值缺失等问题,而这3大类问题,会较大影响样本的特征学习。部分学者如谭文侃等^[10]利用 LOF 去除离群样本,利用改进 SMOTE 平衡样本类别;如 Yin 等^[11]采用 LOF 去除离群样本,利用期望最大化算法(EM)替换离群样本。但上述预处理手段较单一,未有效考虑多种预处理技术的联合运用。

另一方面,现有多因素综合评判在预测指标方面,主要考虑了围岩应力、岩石强度及脆性特征,忽视了隧道围岩应力梯度对岩爆的影响。笔者课题组的试验研究表明^[12],围岩应力梯度对岩爆有重要影响;考虑围岩应力梯度影响能有效提高岩爆预测的准确率^[13]。

为此,本文在数据采集阶段,考虑隧道与采场及隧洞群受力条件差异,分离出隧洞(巷道)岩爆样本。在岩爆预测指标选取阶段,考虑围岩应力梯度对岩爆的影响。在样本数据预处理阶段,针对离群样本、缺失值及样本平衡性问题,引入多种方法进行处理。在模型训练阶段:采用支持向量机(SVM)、随机森林(RF)、梯度提升树(GBDT)、自适应提升树(AdaBoost)、极限梯度提升树(XGBoost)共5类模型对岩爆案例进行对比学习,说明岩爆数据预处理及考虑围岩应力梯度影响的必要性。

1 岩爆数据库及指标选取

1.1 岩爆数据库

由于地下交通与水利工程多为单一路径的隧洞或隧道,开挖尺寸与断面面积较大,断面形式多为圆形或曲墙拱形,开挖相互扰动相对较小,而地下矿山开

挖范围大,开采工作面多,矿房、采场相邻分布,开采路径复杂,开挖相互扰动相对较大,因此本文建立了两类岩爆数据库,一类为隧洞岩爆数据库(样本数479条),一类为地下矿山岩爆数据库(样本数99条)。

1.2 指标选取

岩爆作为一类复杂非线性的灾害问题,存在诸多影响因素,但通常可被分为应力条件和岩性因素。学者们多选定最大切应力与岩石单轴抗压强度之比 σ_θ/σ_c 等指标来反映应力条件。选定脆性系数 B 、弹性能量指数 W_{et} 等指标来反映岩性因素。

其次,圆形隧道围岩切向应力(参见图1)的弹性力学解见式(1)。由式(1)可知 $\theta=0$ 时,两侧洞壁的切向应力最大且随围岩进深 r 的变化规律见图1。由式(1)在 $\theta=0$ 时对 r 进行求导,可得围岩切向应力梯度变化见式(2)。由式(2)可以看出,在地应力一定的条件下,洞壁围岩应力梯度主要由隧道(洞)半径 a 确定。由式(1)可知洞壁最大切向应力 $\sigma_{\theta\max}=3\sigma_1-\sigma_3$,其值包含主应力 σ_1 、主应力 σ_3 两类因素,故在选择 $\sigma_{\theta\max}$ 作为预测指标后需考虑指标的重复性问题。据此,选择洞径 $D_0=2a$ 间接表征围岩应力梯度。

$$\sigma_\theta = \frac{1}{2}(\sigma_1 + \sigma_3) \left(1 + \frac{a^2}{r^2} \right) + \frac{1}{2}(\sigma_1 - \sigma_3) \left(1 + \frac{3a^4}{r^4} \right) \cos 2\theta, \quad (1)$$

$$\frac{d\sigma_\theta}{dr} = \frac{1}{2}(\sigma_1 + \sigma_3) \left(1 - \frac{2a^2}{r^3} \right) - \frac{1}{2}(\sigma_1 - \sigma_3) \left(1 - \frac{12a^4}{r^5} \right) \cos 2\theta. \quad (2)$$

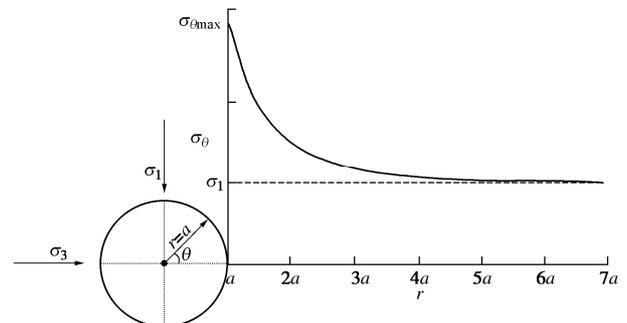


图1 围岩切向应力分布

Fig. 1 Distribution of tangential stress around surrounding rock

2 数据预处理

2.1 案例选取与分析

选取隧洞岩爆案例进行分析,由于案例部分指标值存在缺失,为保证数据预处理不引入过多数据噪声,

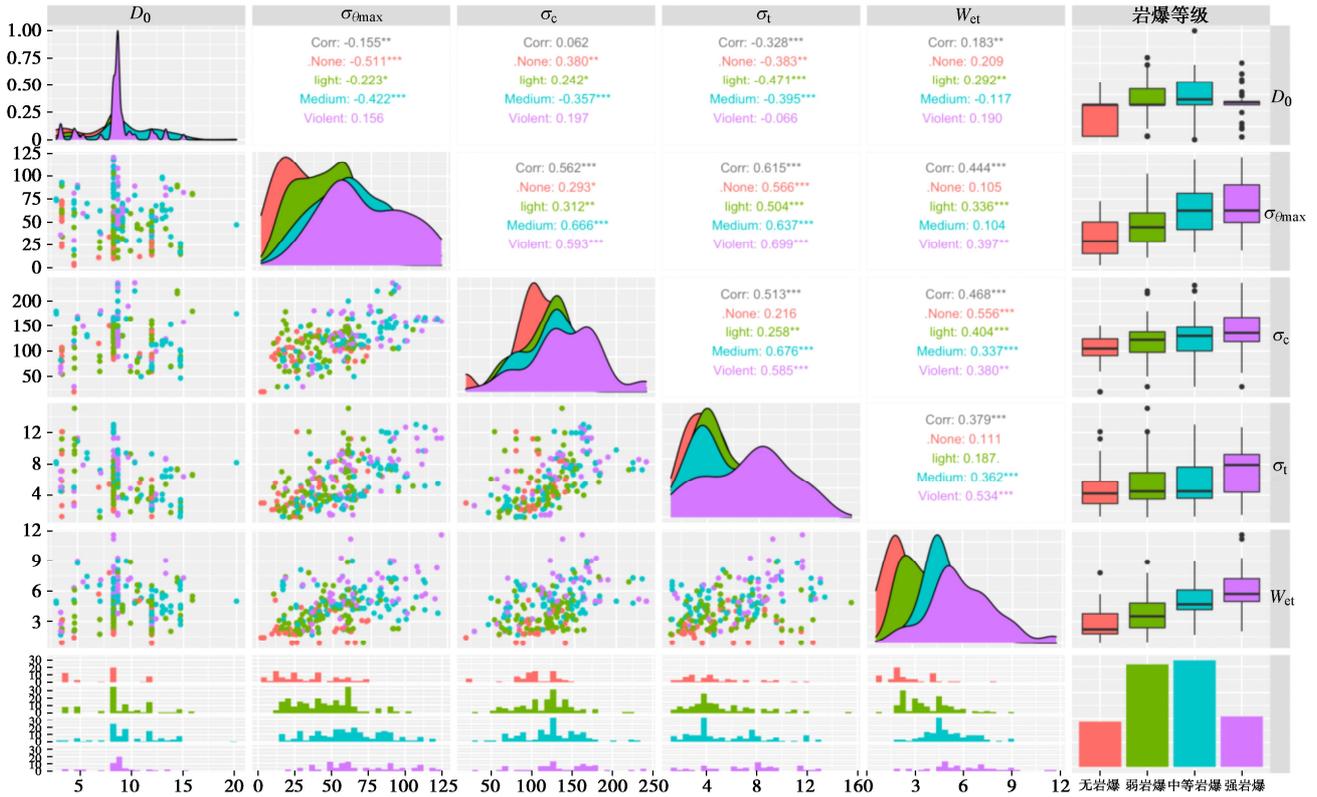


图 2 岩爆案例的五因素统计学关系图例

Fig. 2 Statistical relationship of five factors for rockburst samples

要求所取样本至多缺失一类指标。表 1 为所选的部分隧洞岩爆案例集，其中非圆形隧洞样本的洞径采用当量半径法^[14]进行换算，换算系数见表 2。总案例来源于文献[15~23]，样本数合计 306 条，其中无岩爆样本 46 条，弱岩爆样本 102 条，中等岩爆样本 106 条，强岩爆样本 52 条，可见数据集样本平衡性较差，需处理。

表 1 隧洞岩爆案例集

Table 1 Dataset of tunnel rockburst

样本编号	D_0 /m	$\sigma_{\theta_{max}}$ /MPa	σ_c /MPa	σ_t /MPa	W_{et}	岩爆烈度
1	9.58	30	88.7	3.7	6.6	3
2	10.83	30	88.7	3.7	6.6	3
3	5.00	90	170.0	11.3	9.0	4
...
304	4.72*	60	86.0	7.14	2.85	2
305	4.72*	60	145.2	9.3	3.5	2
306	4.72*	60	136.8	10.4	2.12	2

注：“*”表示 D_0 为换算值；第七列中“1”为无岩爆，“2”为弱岩爆，“3”为中等岩爆，“4”为强岩爆。

表 2 换算系数

Table 2 Conversion factors

断面形状	椭圆	拱形	正方形	正梯形	长方形	单边斜梯
换算系数	1.05	1.1	1.15	1.2	1.2	1.25

为探究岩爆预测指标间的统计学关系，利用 R 语

言(含 GGally 模块)对 306 例样本进行绘图分析，如图 2 所示。其中图 2 对角线处展示了各指标叠合核密度曲线图，图 2 第六行展示的是各指标单核密度直方图，对角线与下底线之间展示的是指标两两之间的关系散点图，图 2 最右列展示的是各指标的箱型图，对角线与最右列之间的图例展示的是各指标两两之间的相关性系数。

(1)由各指标叠合核密度曲线图与单核密度直方图可见， $\sigma_{\theta_{max}}$ ， σ_t ， σ_c ， W_{et} 属性的核密度曲线图展示出属性分布密度 0.5 分位点与岩爆烈度存在数值上的递进关系，这反映出岩爆指标的数值大小、分布密度同岩爆烈度呈现较强的相关性。

(2)由各指标散点图可见，不同指标组合的散点分布较为离散杂乱，但总体分布表现为岩爆烈度越大，与原点的距离也越大。

(3)由各指标的箱型图可见，岩爆烈度越大，相应的岩爆属性值中位数以及 0.25, 0.75 分位值也越大。其次，箱型图 0.25 与 0.75 分位值的差值大小呈现出岩爆烈度越大，该属性值域分布也越大。

(4)由各指标的相关性系数图可见， W_{et} ， σ_t ， σ_c 有一定相关性。

综上图例所示信息，所选案例的统计特征较强。需指出的是，散点图外圈层的大量低密度点与箱型图

的极值点提示了原始样本集具有较多离群样本点。

2.2 数据预处理

标准数据预处理一般包括：数据集成、数据清洗、数据变换、数据规约。数据集成是指不同数据集的合并；数据清洗主要指缺失值填充与离群样本剔除；数据变换主要包括归一化与标准化数据集；数据规约是利用属性降维方法，减少数据量。需指出的是数据集成在数据收集期间已完成；而数据规约适用于维度多达上万的大数据，鉴于岩爆数据维度小、数据量少的特点，本身可以满足算法特征学习的要求，这里可省略。最后，标准岩爆数据预处理的流程如图3所示。

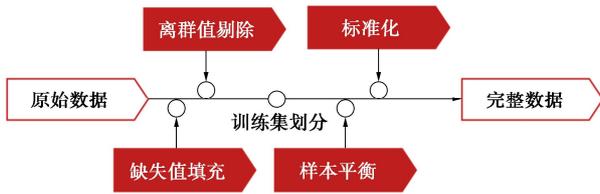


图3 岩爆数据预处理流程

Fig. 3 Flow chart of data preprocessing of rockbursts

(1) 缺失值处理

岩爆案例集存在部分特征值数据缺失，若简单删除含缺失值岩爆样本，这将损失大量样本信息，因此，需对缺失值进行填充处理，最大限度地保留特征信息。抽取样本的指标情况缺失如图4所示。

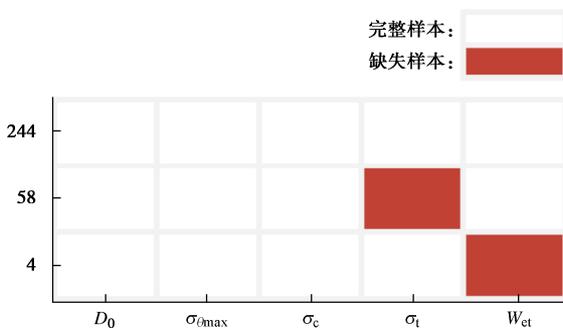


图4 缺失岩爆数据分布图

Fig. 4 Distribution of missing rockburst data

多重插补法 (multiple imputation, MI) 作为一类常用的缺失值填充算法,认为缺失值是随机不确定的,其数值来自于已观测的样本。因为多重插补是多次填充,考虑了缺失值的不确定性因素,所以多重插补法在统计学中更加合理且有效。本文通过 R 语言 (含 mice 模块) 对其进行程序编程。插补步骤如下:

a) 数据插补: 利用随机森林 (RF) 算法将数据集 (为提高插补精度,数据集包含岩爆烈度标签) 中缺失的指标值估算 m 次,得到 m 个完整的数据集;

b) 数据分析: 对填充的 m 个完整数据集进行分析,引入多元线性回归模型,并进行 T 检验,分别评

价 m 个插补数据集的变量优劣;

c) 数据合并: 汇总 m 个多元线性回归模型,对汇总模型进行 F 和 R^2 检验,判断插补模型的有效性。

选择 $m=5$ 对进行多重插补,5次插补数据分布如图5所示,其中第0列为原数据分布,第1~5列分别为5次插补数据的分布 (红色圆点●代表插补数据,灰色圆圈○为原数据)。可看出5次插补均符合原数据分布。最后,综合分析 T 检验结果、F 检验结果、 R^2 检验结果,判定第四次插补结果最优。鉴于篇幅限制,以总体 R^2 检验结果为例,见表3。

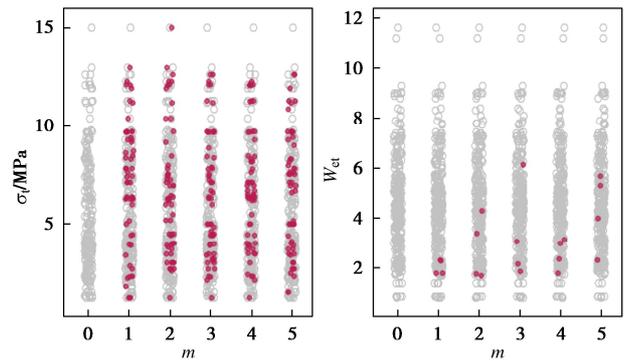


图5 岩爆插补数据分布

Fig. 5 Distribution of imputation data of rockburst

表3 插补数据集的总体 R^2 检验

Table 3 R^2 -tests for imputation dataset

项目	估计值	估计值 95% 置信上限	估计值 95% 置信下限	评价标准
R^2	0.52	0.60	0.42	相关性较强

(2) 离群样本处理

差异化的地质条件与测量手段会导致所测数据与正常数据有较大差值,便会产生离群样本。而离群样本会对特征学习造成较大影响。目前研究中常用局部异常因子 (LOF) 算法剔除岩爆数据离群样本^[10]。但 LOF 作为一种基于密度的算法,对近邻参数敏感、时间复杂度高,仍有改进空间。基于此,本文引入最近邻 (KNN)、孤立森林 (isolation forest)、局部异常因子 (LOF) 3 类离群样本算法,应用集成思想,首先训练出 3 类模型,之后再以相同权重对岩爆样本进行打分,最终输出离群样本分数。利用 Python (Pyod 模块) 编制该离群样本检测程序。LOF 与 KNN 属基于近邻的算法,谭文侃等^[10]已论述, Isolation Forest 是基于划分思想, Liu 等^[24]已论述。

利用离群样本检测算法,获得了 306 例岩爆样本的离群样本分数,如表 4 所示。通过分类比对,选定 0.88 为离群样本分数阈值,31 例离群样本被剔除,余下 275 例非离群样本。为进一步说明离群与非离群样本的差异,以 σ_c 与 σ_t 的离群样本散点图为例,如图 6 所示 (“0”表示正常样本,“1”表示离群样本)。

从图 6 可以看出, 离群点在整体与局部均具有较低的密度, 其分布规律明显异于占多数的正常样本。

表 4 岩爆样本的离群样本分数

Table 4 Outlier scores for rockburst samples

样本编号	1	2	3	...	304	305	306
分数	-0.51	-0.55	0.97	...	0.12	0.08	-0.08
识别	0	0	1	...	0	0	0

注: “0” 表示正常样本, “1” 表示离群样本。

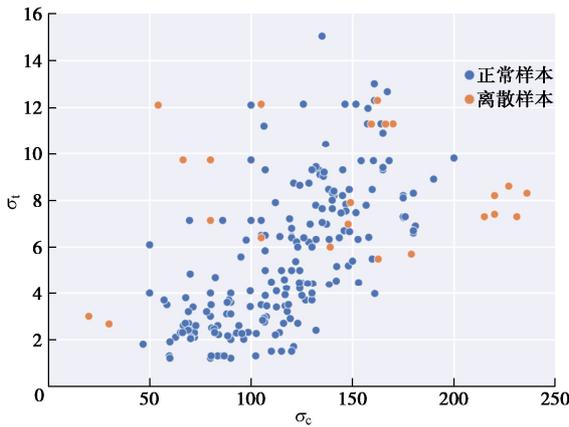


图 6 离群样本散点图(σ_c 与 σ_t)

Fig. 6 Outlier scatter (σ_c vs σ_t)

(3) 样本平衡性处理

多数类样本含有的特征多, 少数类样本含有的特征少, 当样本不均衡时会导致算法在训练过程中更多关注多数类样本而忽视少数类, 所以有必要对样本平衡性进行处理。对于小数据集, 常用的平衡性改进方法为过采样。过采样是在引入少量噪声的基础上扩增少数类, 从而达到样本平衡, 包括 SMOTE 以及 ADASYN^[25]。SMOTE 算法在样本类别边界容易产生重叠数据, 而 ADASYN 则是根据少数类样本的贡献度赋予不同的权重, 从而自适应地生成不同数量的合成样本, 并将决策边界转移至难学习的样本上, 故本文选择 ADASYN。利用 Python (含 Imbalanced-Learn 模块) 对 ADASYN 算法进行编程。

为防止信息泄露, 本文选择先划分训练集与测试集, 并仅对训练集作平衡性处理。每次均按 9:1 的比例划分训练集 247 例与测试集 28 例。以某次平衡性处理为例, 原训练集含无岩爆样本 35 条, 弱岩爆样本 80 条, 中等岩爆样本 93 条, 强岩爆样本 39 条, 在利用 ADASYN 算法对训练集进行平衡性处理后, 训练集样本扩充为 357 例, 其中无岩爆样本 94 条, 弱岩爆样本 80 条, 中等岩爆样本 93 条, 强岩爆样本 90 条, 训练集样本平衡性得到了明显提升。

(4) 标准化

为消除岩爆不同属性的量纲与取值差异, 加速模

型收敛, 需对平衡过的数据集进行标准化。z-score 法基于原始数据的均值与标准差对数据标准化, 对序列 $X=\{x_1, x_2, x_3, \dots, x_i, \dots, x_n\}$ 通过 z-score 法变换至 $Y=\{y_1, y_2, y_3, \dots, y_i, \dots, y_n\}$, 且 Y 均值为 0, 标准差为 1, 其标准化公式如下:

$$y_i = \frac{x_i - \bar{x}}{s} \quad (3)$$

其中:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4)$$

3 机器学习模型构建

3.1 算法模型

为对比考虑数据预处理和围岩应力梯度对岩爆预测效果的影响, 选取 3 类数据集, 分别是经过数据预处理含洞径指标的数据集、含洞径指标的原始数据集、不含洞径指标的原始数据集。最后选取非线性学习性能优秀的 SVM, RF, GBDT, AdaBoost, XGBoost 5 类算法进行模型构建, 并利用 Python (含 Scikit-Learn 模块) 进行编程。随机选取数据集的 90% 作为训练集, 余下作为测试集, 采用 K=5 折网格搜索交叉检验法获得最优模型参数。最后利用 5 类算法模型分别训练 10 次 (为保证结果可重复, 设置分割函数的随机数种子为 1~10), 取测试集的预测准确率均值评价模型性能。

3.2 分析流程

隧洞岩爆模型的预测流程如图 7 所示。

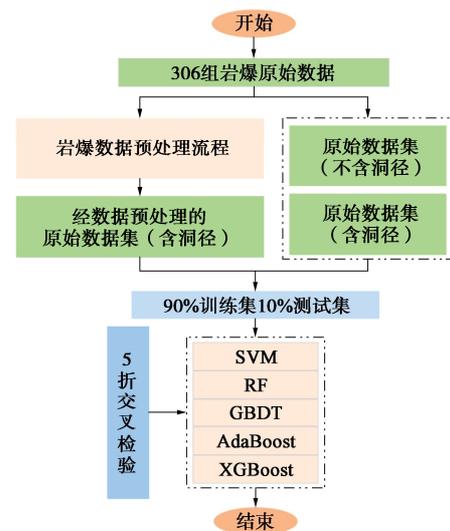


图 7 隧洞岩爆预测流程

Fig. 7 Flow chart of predicting tunnel rockburst

3.3 结果与分析

通过 10 轮对随机抽选的数据集学习, 获得了 5 类模型在 3 种数据集上的预测准确率, 其中考虑数据

预处理及洞径指标模型的岩爆预测结果如表 5 所示, 仅考虑洞径指标模型的岩爆预测结果如表 6 所示, 二者皆不考虑模型的岩爆预测结果如表 7 所示。

表 5 考虑数据预处理及洞径指标的岩爆预测

Table 5 Rockburst prediction considering data preprocessing and hole diameter index

训练 轮次	预测准确率/%				
	SVM	RF	GBDT	Adaboost	XGBoost
1	57.1	57.1	57.1	57.1	53.6
2	67.9	67.9	74.9	67.9	67.9
3	42.9	50.0	50.0	50.0	50.0
4	67.9	71.4	71.4	71.4	71.4
5	71.4	71.4	67.9	71.4	67.9
6	67.9	78.6	75.0	71.4	71.4
7	60.7	67.9	50.0	53.6	53.6
8	75.0	78.6	75.0	78.6	78.6
9	82.1	85.7	82.1	89.3	85.7
10	64.3	67.9	71.4	67.9	67.9
平均值	65.7	69.7	67.5	67.9	66.8

表 6 考虑洞径指标但不考虑数据预处理的岩爆预测

Table 6 Rockburst prediction considering hole diameter index without data preprocessing

训练 轮次	预测准确率/%				
	SVM	RF	GBDT	Adaboost	XGBoost
1	72	80	72	72	68
2	52	48	52	60	56
3	56	72	76	72	72
4	48	48	56	48	44
5	52	64	56	56	52
6	60	64	64	64	64
7	68	52	60	68	68
8	64	64	60	52	64
9	72	68	72	68	64
10	60	72	76	60	72
平均值	60.4	63.2	64.4	62.0	62.4

表 7 不考虑数据预处理及洞径指标的岩爆预测

Table 7 Rockburst prediction without data preprocessing and hole diameter index

训练 轮次	预测准确率/%				
	SVM	RF	GBDT	Adaboost	XGBoost
1	72	72	72	72	68
2	60	56	60	56	56
3	64	64	56	68	60
4	40	40	48	32	44
5	48	52	52	48	48
6	52	52	52	56	56
7	56	56	64	68	56
8	56	68	64	52	60
9	52	64	68	64	64
10	60	72	64	72	64
平均值	56.0	59.6	60.0	58.8	57.6

为直观显示考虑数据预处理和洞径指标对模型预测准确率的影响, 将每类模型的 10 轮预测准确率平均化, 对比了是否考虑数据预处理模型的预测准确率(表 8)与是否考虑洞径指标模型的预测准确率(表 9)。

由表 8 可知, 经过数据预处理并考虑洞径指标的 5 类模型岩爆预测准确率均高于仅考虑洞径指标的岩

爆预测模型, 预测准确率平均提高 5.04%, 其中 SVM, RF, GBDT, Adaboost, XGBoost 分别提高了 5.3%, 6.5%, 3.1%, 5.9%, 4.4%; 由表 9 可知, 在不进行数据预处理情况下, 考虑洞径指标模型的岩爆预测准确率也均高于不考虑洞径指标的岩爆预测模型, 预测准确率平均提高 4.08%, 其中 SVM, RF, GBDT, Adaboost, XGBoost 分别提高了 4.4%, 3.6%, 4.4%, 3.2%, 4.8%。

表 8 是否考虑数据预处理的多模型预测准确率对比

Table 8 Comparison of model prediction accuracy with and without data preprocessing

条件	平均预测准确率/%				
	SVM	RF	GBDT	Adaboost	XGBoost
数据预处理 考虑洞径	65.7	69.7	67.5	67.9	66.8
原始数据集 考虑洞径	60.4	63.2	64.4	62.0	62.4
差值	+5.3	+6.5	+3.1	+5.9	+4.4

表 9 是否考虑洞径指标的多模型预测准确率对比

Table 9 Comparison of model prediction accuracy with and without hole diameter index

条件	平均预测准确率/%				
	SVM	RF	GBDT	Adaboost	XGBoost
原始数据集 考虑洞径	60.4	63.2	64.4	62.0	62.4
原始数据集 不考虑洞径	56.0	59.6	60.0	58.8	57.6
差值	+4.4	+3.6	+4.4	+3.2	+4.8

综上, 经过数据预处理并考虑洞径指标模型分别比未经数据预处理且不考虑洞径指标模型提高预测准确率 9.7%, 10.1%, 7.5%, 9.1%, 9.2%, 平均提高了 9.12%。这表明了数据预处理及考虑围岩应力梯度影响可有效提升岩爆模型的预测准确率。

4 工程验证

采用 2 个工程实例验证本文提出模型的预测效果。

实例 1: 在建的双江口水电站左岸地下主厂房岩爆特征参数见表 10, 采用本文提出模型做岩爆预测, 结果见表 11。由表 10, 11 可以看出, 5 类模型的岩爆预测较为合理。在工程开挖现场, 2018 年 1 月 15 日, 主厂房中导洞上游侧 K0+120 m 发生强烈岩爆, 爆坑深达 1 m。2018 年 5 月 29 日, 主厂房中导洞 K0+66 m 上游拱肩发生中强岩爆, 现 V 形爆坑。说明了本文提出模型对含有单一指标缺失值的情况可以取得较好的预测效果。

实例 2: 苍岭隧道^[26]四条代表性区段的岩爆特征及利用本文提出模型的岩爆预测结果见表 12, 13。对比表 12, 13 可知, 预测结果与实际岩爆情况比较符合。

表 10 地下洞室的岩爆特征参数

Table 10 Rockburst characteristics of underground caverns

开挖段	主厂房岩爆特征参数					实际烈度
	D_0/m	$\sigma_{\theta_{max}}/MPa$	σ_c/MPa	σ_v/MPa	W_{et}	
中导洞I区	11.2*	90	97.3	6.03	6.6#	3~4
扩挖II区	14.8*	90	97.3	6.03	5.5#	3~4
扩挖III区	17.7*	90	97.3	6.03	6.6#	3~4

注: “*” 表示 D_0 为换算值; “#” 表示 W_{et} 为插补值。

表 11 地下洞室的岩爆预测

Table 11 Prediction of rockburst for underground caverns

开挖段	主厂房岩爆倾向性预测				
	SVM	RF	GBDT	Adaboost	XGBoost
中导洞I区	3	4	4	4	4
扩挖II区	3	3	3	4	3
扩挖III区	3	3	4	4	4

表 12 苍岭隧道的岩爆特征参数

Table 12 Rockburst characteristics of Cangling Tunnel

区段	D_0/m	$\sigma_{\theta_{max}}/MPa$	σ_c/MPa	σ_v/MPa	W_{et}	实际烈度
1	11.6*	32.8	160	6.6	4.6	2
2	11.6*	44.8	160	6.8	4.9	2
3	11.6*	50.9	160	7.5	5.3	3
4	11.6*	44.8	160	6.7	4.8	2

注: “*” 表示 D_0 为换算值。

表 13 苍岭隧道的岩爆预测

Table 13 Prediction of rockburst for Cangling Tunnel

区段	SVM	RF	GBDT	Adaboost	XGBoost
1	2	2	2	2	2
2	2	2	2	2	2
3	4	3	3	3	3
4	2	2	2	2	2

5 结 论

在考虑围岩应力梯度影响的基础上, 建立了以数据预处理技术为基础的 5 类岩爆预测模型, 并得到以下 4 点结论。

(1) 基于数据预处理的岩爆模型预测准确率高于不考虑数据预处理的模型, 其中 SVM, RF, GBDT, Adaboost, XGBoost 分别提高了 5.3%, 6.5%, 3.1%, 5.9%, 4.4%, 平均提高 5.04%。

(2) 考虑洞径指标的岩爆模型预测准确率高于不考虑洞径影响的模型, 其中 SVM, RF, GBDT, Adaboost, XGBoost 分别提高了 4.4%, 3.6%, 4.4%, 3.2%, 4.8%, 平均提高 4.08%。

(3) 基于数据预处理并考虑洞径指标 5 类模型 SVM, RF, GBDT, Adaboost, XGBoost 分别比未经数据预处理且不考虑洞径指标模型的预测准确率高出

9.7%, 10.1%, 7.5%, 9.1%, 9.2%, 平均提高 9.12%。

(4) 双江口水电站左岸地下主厂房、苍岭隧道的预测结果与实际岩爆情况比较符合, 说明了本文提出模型的实用性与优越性。

参考文献:

- [1] FENG X T, LIU J, CHEN B, et al. Monitoring, warning, and control of rockburst in deep metal mines[J]. Engineering, 2017, 3(4): 538-545.
- [2] 宫凤强, 潘俊锋, 江 权. 岩爆和冲击地压的差异解析及深部工程地质灾害关键机理问题[J]. 工程地质学报, 2021, 29(4):933-961. (GONG Fengqiang, PAN Junfeng, JIANG Quan. The difference analysis of rock burst and coal burst and key mechanisms of deep engineering geological hazards[J]. Journal of Engineering Geology, 2021, 29(4):933-961. (in Chinese))
- [3] 张传庆, 俞 缙, 陈 珺, 等. 地下工程围岩潜在岩爆问题评估方法[J]. 岩土力学, 2016, 37(增刊 1): 341-349. (ZHANG Chuanqing, YU Jin, CHEN Jun, et al. Evaluation method for potential rockburst in underground engineering[J]. Rock and Soil Mechanics, 2016, 37(S1): 341-349. (in Chinese))
- [4] 徐 琛, 刘晓丽, 王恩志, 等. 基于组合权重-理想点法的应变型岩爆五因素预测分级[J]. 岩土工程学报, 2017, 39(12): 2245-2252. (XU Chen, LIU Xiaoli, WANG Enzhi, et al. Prediction and classification of strain mode rockburst based on five-factor criterion and combined weight-ideal point method[J]. Chinese Journal of Geotechnical Engineering, 2017, 39(12): 2245-2252. (in Chinese))
- [5] WANG C, WU A, LU H, et al. Predicting rockburst tendency based on fuzzy matter-element model[J]. International Journal of Rock Mechanics and Mining Sciences, 2015, 75: 224-232.
- [6] 贾义鹏, 吕 庆, 尚岳全, 等. 基于证据理论的岩爆预测[J]. 岩土工程学报, 2014, 36(6): 1079-1086. (JIA Yipeng, LÜ Qing, SHANG Yuequan, et al. Rockburst prediction based on evidence theory[J]. Chinese Journal of Geotechnical Engineering, 2014, 36(6): 1079-1086. (in Chinese))
- [7] 高 玮. 基于蚁群聚类算法的岩爆预测研究[J]. 岩土工程学报, 2010, 32(6): 874-880. (GAO WEI. Prediction of rock burst based on ant colony clustering algorithm[J]. Chinese Journal of Geotechnical Engineering, 2010, 32(6): 874-880. (in Chinese))
- [8] PU Y, APEL D B, WANG C, et al. Evaluation of burst liability in kimberlite using support vector machine[J]. Acta

- Geophysica, 2018, **66**: 973-982.
- [9] WANG C, CHUAI X, SHI F, et al. Experimental investigation of predicting rockburst using Bayesian model[J]. Geomechanics & engineering, 2018, **15**(6): 1153-1160.
- [10] 谭文侃, 叶义成, 胡南燕, 等. LOF 与改进 SMOTE 算法组合的强烈岩爆预测[J]. 岩石力学与工程学报, 2021, **40**(6): 1186-1194. (TAN Wenkan, YE Yicheng, HU Nanyan, et al. Severe rock burst prediction based on the combination of LOF and improved SMOTE algorithm[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, **40**(6): 1186-1194. (in Chinese))
- [11] YIN X, LIU Q, PAN Y, et al. Strength of stacking technique of ensemble learning in rockburst prediction with imbalanced data: Comparison of eight single and ensemble models[J]. Natural Resources Research, 2021, **30**(2): 1795 - 1815.
- [12] 夏元友, 刘昌昊, 刘夕奇, 等. 均布与梯度应力加载路径下岩爆破坏特征试验[J]. 中国安全科学学报, 2020, **30**(5): 149-155. (XIA Yuanyou, LIU Changhao, LIU Xiqi, et al. Experimental study on rockburst characteristics under uniform and gradient stress loading paths[J]. China Safety Science Journal, 2020, **30**(5): 149-155. (in Chinese))
- [13] 何佳其, 吝曼卿, 刘夕奇, 等. 引入梯度应力的岩爆预测方法[J]. 岩土工程学报, 2020, **42**(11): 2098 - 2105. (HE Guiqi, LIN Manqing, LIU Xiqi, et al. New method for introducing gradient stress into rock-burst prediction[J]. Chinese Journal of Geotechnical Engineering, 2020, **42**(11): 2098-2105.(in Chinese))
- [14] 刘长武, 曹磊, 刘树新. 深埋非圆形地下洞室围岩应力解析分析的“当量半径”法[J]. 铜业工程, 2010(1): 1-5. (LIU Changwu, CAO Lei, LIU Shuxin. Method of “equivalent radius” for the analyzing rock stress of high-buried non-circular underground chambers[J]. Copper Engineering, 2010(1): 1-5. (in Chinese))
- [15] ZHOU J, LI X, MITRI H S. Classification of rockburst in underground projects: comparison of ten supervised learning methods[J]. Journal of Computing in Civil Engineering, 2016, **30**(5): 04016003.
- [16] 李准, 苗勇刚, 夏志远. 深部矿山巷道岩爆倾向性预测及防治技术研究[J]. 有色金属(矿山部分), 2021, **73**(3): 41-47, 60. (LI Zhun, MIAO Yonggang, XIA Zhiyuan. Study on rockburst tendency prediction and prevention technology of deep mine roadway[J]. Nonferrous Metals (Mining Section), 2021, **73**(3): 41-47, 60. (in Chinese))
- [17] QIU D H, LI T B, XUE Y G, et al. Rockburst prediction based on distance discrimination method and optimization technology-based weight calculation method[J]. Electronic Journal of Geotechnical Engineering, 2014, **19**: 1843-1854.
- [18] 王庆武. 拉林铁路桑珠岭隧道地应力场分析及岩爆预测研究[D]. 成都: 成都理工大学, 2017. (WANG Qinwu. Analysis of Geostress Field and Rockburst Prediction in the Sang Zhuling Tunnel of Lasa-Linzhi Railway Engineering[D]. Chengdu: Chengdu University of Technology, 2017. (in Chinese))
- [19] 易迪青. 沪昆高铁雪峰山隧道岩爆灾害评估与防治[D]. 北京: 北京交通大学, 2014. (YI Diqing. Rock Burst Disaster Assessment and Prevention in Xuefeng Mountain Tunnel of Shanghai-Kunming High-Speed Railway[D]. Beijing: Beijing Jiaotong University, 2014. (in Chinese))
- [20] XUE Y G, BAI C H, KONG F M, et al. A two-step comprehensive evaluation model for rockburst prediction based on multiple empirical criteria[J]. Engineering Geology, 2020, **268**: 105515.
- [21] WU S C, WU Z G, ZHANG C X. Rock burst prediction probability model based on case analysis[J]. Tunnelling and Underground Space Technology, 2019, **93**(03069): 1-15.
- [22] JIA Q J, WU L, LI B, et al. The comprehensive prediction model of rockburst tendency in tunnel based on optimized unascertained measure theory[J]. Geotechnical and Geological Engineering, 2019, **37**: 3399-3411.
- [23] XUE Y G, LI Z Q, LI S C, et al. Prediction of rock burst in underground caverns based on rough set and extensible comprehensive evaluation[J]. Bulletin of engineering geology and the environment, 2019, **78**(1): 417-429.
- [24] LIU F T, TING K M, ZHOU Z H. Isolation-based anomaly detection[J]. Acm Transactions on Knowledge Discovery from Data, 2012, **6**(1): 1 - 39.
- [25] HE H, BAI Y, GARCIA E A, et al. ADASYN: Adaptive synthetic sampling approach for imbalanced learning[C]// 2008 IEEE International Joint Conference on Neural Networks, HongKong, 2008.
- [26] 贾义鹏, 吕庆, 尚岳全. 基于粒子群算法和广义回归神经网络的岩爆预测[J]. 岩石力学与工程学报, 2013, **32**(2): 343-348. (JIA Yipeng, LÜ Qing, SHANG Yuequan. Rockburst prediction using particle swarm optimization algorithm and general regression neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2013, **32**(2): 343-348. (in Chinese))