不均衡数据下融合优化算法的CNN-LSTM岩爆烈度等级预测模型*

郑来耀[1]，梁鹏[1,2]，李国庆[1]，刘言[1]，刘天一[1]，王聚贤[1]

（1.华北理工大学 矿业工程学院， 河北 唐山市 063210；
2.河北省矿山绿色智能开采技术创新中心， 河北 唐山市 063210）

摘要：针对岩爆烈度等级预测模型构建时样本数据不均衡和预测准确度不高的问题，在岩爆样本数据均衡化策略下，融合贝叶斯参数优化算法（BO）和多头注意力机制（Multi-head Attention），提出了一种基于卷积神经网络（CNN）和长短期记忆网络（LSTM）的岩爆烈度等级预测模型（BO-CNN-LSTM-Multi-head Attention）。收集国内外224组岩爆案例，并采用Box-Cox变换和支持向量机合成少数类过采样技术（SVM SMOTE）对岩爆样本数据进行正态化和平衡化处理。将处理后的数据集输入CNN-LSTM预测模型进行训练和预测，并逐步使用贝叶斯参数优化算法、多头注意力机制对模型进行优化。模型预测结果表明：Box-Cox变换与SVM SMOTE采样可以有效减少离群点和数据不平衡对模型的影响，增强数据集可分性；BO-CNN-LSTM-Multi-head Attention岩爆烈度分级预测模型预测准确率为95%，该模型能有效提升岩爆烈度预测在样本数据不均衡情况下的预测精度，具有较高的可行性和实用性。

关键词：岩爆烈度等级预测；CNN-LSTM；贝叶斯参数优化算法；多头注意力机制

中图分类号：TD324；TP183　　**文献标识码**：A　　**文章编号**：1005-2763(2025)06-0111-08

CNN-LSTM Rock Burst Intensity Grade Prediction Model Based on Fusion Optimization Algorithm Under Imbalanced Data

ZHENG Laiyao[1], *LIANG Peng*[1,2], *LI Guoqing*[1], *LIU Yan*[1], *LIU Tianyi*[1], *WANG Juxian*[1]

(1.College of Mining Engineering, North China University of Science and Technology, Tangshan, Hebei 063210, China;
2.Hebei Mining Green Intelligent Mining Technology Innovation Center, Tangshan, Hebei 063210, China)

Abstract: In response to the problems of imbalanced sample data and low prediction accuracy in the construction of rock burst intensity grade prediction models, a rock burst intensity grade prediction model (BO-CNN-LSTM-Multi-head Attention) based on convolutional neural networks (CNN) and long short-term memory networks (LSTM) was proposed by integrating Bayesian parameter optimization algorithm (BO) and Multi-head attention mechanism (Multi-head Attention) under the rock burst sample data balancing strategy. 224 sets of rock burst cases were collected from both domestic and international sources, and Box-Cox transformation and support vector machine synthesis for few class oversampling technique (SVM SMOTE) were used to normalize and balance the rock burst sample data. The processed dataset was input into the CNN-LSTM prediction model for training and prediction, and the model was gradually optimized by Bayesian parameter optimization algorithm and multi-head attention mechanism. The prediction results indicate that Box-Cox transformation and SVM SMOTE sampling can effectively reduce the impact of outliers and data imbalance on the model, and enhance the separability of the dataset. The accuracy of the BO-CNN-LSTM-Multi-head Attention rock burst intensity grade prediction model is 95%. This model can effectively improve the prediction accuracy of rock burst intensity in the case of imbalanced sample data, and has a high feasibility and practicality.

Key words: Prediction of rockburst intensity grade, CNN-LSTM, Bayesian parameter optimization algorithm, Multi-head attention mechanism

---

* **收稿日期**：2024-08-06

基金项目：国家自然科学基金资助项目（52474098）；河北省创新能力提升计划项目（23564201D）；河北省自然科学基金项目（E2024209024）；大学生创新创业训练计划项目（202410081040）

作者简介：郑来耀（2004—），男，江西上饶人，主要从事岩爆烈度等级预测的研究。E-mail：2758033523@qq.com

通信作者：梁鹏（1987—），男，河南南阳人，硕士，副教授，主要从事矿山岩石力学领域的教学与科研工作。E-mail：hnlp87@163.com

0 引言

在高地应力区进行地下硐室或基坑的开挖时,经常会出现突发性的岩爆现象,该现象常伴随着岩石碎片的弹射,对工程结构和施工人员安全造成严重威胁[1]。因此,建立高效、准确的岩爆预测模型对保障工程安全具有重要意义。

许多学者采用不确定评价模型评估岩爆发生的概率,不确定评价模型包括灰色关联法[2]、熵权法[2-3]、云模型[3-7]、证据权重[2,8]、加权马氏距离[9]、VIKOR 模型[9]、未知测度理论[10]、模糊评价[11]、TOPSIS[12]、粗糙集理论[7,12]、CRITIC 法[4]、阶次相关分析法[4]、模糊-C 均值算法[5]、层次分析法[13]、序相关分析[6]、模糊集理论[14]等。这些研究体现了岩爆风险的非线性特征,但预测结果在很大程度上依赖经验,具有较高的主观性和不确定性。

随着机器学习的兴起,其在岩爆灾害预测领域得到了广泛应用[15-17],机器学习方法主要分为神经网络和分类算法,神经网络包括概率神经网络[18-19]、卷积神经网络[20]、SOFM 神经网络[21]、循环神经网络[22]、深度神经网络[23]、广义回归神经网络[24]、极限学习机[25-26]等;分类算法包括支持向量机[27]、随机森林[28-29]等。这些单一的机器学习算法优缺点较为明显,稳定性较差。学者们尝试使用集成学习[30-31]来增强预测模型的鲁棒性和准确性,但是集成学习面临超参数组合优化问题,模型训练的时间大幅增加。基于此,LI 等[26]使用混沌映射和交叉变异算子改进 Harris Hawks 优化算法(HHO),增强其全局搜索能力,构建 IHHO-ELM 模型预测岩爆烈度。满轲等[28]提出了一种采用麻雀搜索算法(SSA)优化随机森林算法(RF)模型的 SSA-RF 模型来提高岩爆等级的预测准确率和预测模型泛化性。贾义鹏等[24]提出一种基于粒子群算法和广义神经网络模型(PSO-GRNN)的岩爆预测方法来评价岩爆发生的可能性。以上方法在解决复杂问题时表现出了高效的计算能力,但在数据量较小的情况下容易出现过度拟合的问题。

岩爆预测的准确性不仅受所用方法的影响,还与收集的岩爆数据集本身密切相关。国内外岩爆案例的岩爆等级分布极不均衡,这导致构建的岩爆数据集存在离群值干扰、各级样本数量不平衡等问题,进而使得数据集的可分性降低,影响岩爆预测精度。

为解决以上问题,本文提出首先采用 Box-Cox 正态变换算法对岩爆数据集进行正态化处理,消除离群值干扰;其次使用支持向量机合成少数类过采样技术(SVM SMOTE)实现各级岩爆数据均衡化;最终构建一种基于贝叶斯参数优化算法和多头注意力机制的优化卷积长短期记忆神经网络(BO-CNN-LSTM-Multi-head Attention)的岩爆预测模型。

1 预测模型原理

1.1 方法流程

BO-CNN-LSTM-Multi-head Attention 模型的研究过程主要分为数据采集、算法处理和结果展示 3 个阶段。在数据采集阶段,通过文献调研方法获取岩爆案例数据,并将其整理成可用的数据集;在算法处理阶段,依次应用 Box-Cox 变换、SVM SMOTE 过采样、CNN-LSTM 模型、BO-CNN-LSTM 模型以及 BO-CNN-LSTM-Multi-head Attention 模型对数据集进行处理;在结果展示阶段,通过图表形式详细展示了模型的预测结果。方法流程如图 1 所示。

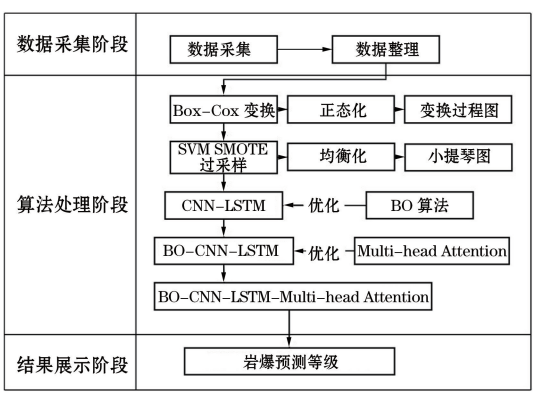


图 1 方法流程

Fig.1 Method flow chart

1.2 CNN-LSTM 原理

卷积神经网络(CNN)是一种深度学习模型,具有良好的特征提取能力和分类性能。长短期记忆网络(LSTM)是一种循环神经网络(RNN)的变体,它解决了 RNN 梯度消失和梯度爆炸的问题。CNN 与 LSTM 结合使用能够充分利用各自优势,提升模型对序列数据的预测性能。基于 CNN-LSTM 进行岩爆灾害预测,通过卷积层、池化层提取岩爆参数的特征,并在卷积层与池化层之间引入 LeakyReLU 激活函数缓解梯度消失问题,可有效提升模型泛化能力。

1.3 贝叶斯参数优化和多头注意力机制

在对数据进行训练、预测时,发现各超参数之间的组合难以调整至最佳状态,影响模型性能。因此,引入贝叶斯参数优化(BO)算法对模型超参数进行

调优。该算法能够高效地进行参数搜索,还可以根据之前的观察结果动态地选择下一个参数组合,从而在相对较少的迭代次数内找到最优解。BO 算法对 CNN-LSTM 模型优化过程:(1) 定义超参数优化范围;(2) 定义目标函数;(3)使用分类交叉熵损失函数和 Adam 优化器,以准确率作为分类模型评价指标;(4) 搜索最优超参数组合。

多头注意力机制(Multi-head Attention)是一种用于增强神经网络模型表现的注意力机制,该机制能够使模型同时关注输入序列中不同位置的信息,从而提升模型性能。

2 构建岩爆烈度预测模型

2.1 原始数据分布分析

岩爆指标体系选取原则是所选定的评价指标能客观反映围岩性质和岩爆的影响因素,本文综合国内外多篇文献[6,8,10-11,17,31],选取了最能反映围岩特性和影响岩爆烈度的 3 个评价指标:弹性能量指数 W_{et}、岩石应力系数 σ_θ/σ_c 以及岩石脆性系数 σ_c/σ_t。岩爆烈度等级分类标准见表 1。

表 1 岩爆烈度等级分类标准

Table 1 Classification standard of rock burst intensity grade

岩爆等级	σ_θ/σ_c	σ_c/σ_t	W_{et}
Ⅰ	<0.3	>40.0	<2.0
Ⅱ	0.3~0.5	26.7~40	2.0~3.5
Ⅲ	0.5~0.7	14.5~26.7	3.5~5.0
Ⅳ	>0.7	>14.5	>5.0

本文选取了国内外 224 组岩爆数据[6,17,20,25,27,32-39],其中Ⅰ级样本 47 组,Ⅱ级样本 59 组,Ⅲ级样本 83 组,Ⅳ级样本 35 组。岩爆数据集部分数据见表 2。

表 2 岩爆数据集部分数据

Table 2 Part of the rock burst data set

编号	预测指标实测值			实际等级
	σ_θ/σ_c	σ_c/σ_t	W_{et}	
1	7.40	29.73	7.30	Ⅱ
2	36.08	0.20	2.29	Ⅰ
3	47.97	0.19	1.87	Ⅰ
4	18.46	0.82	3.80	Ⅲ
5	24.11	0.31	9.30	Ⅲ
…	…	…	…	…
220	20.40	0.46	2.00	Ⅱ
221	19.69	0.84	2.30	Ⅲ
222	12.40	0.65	5.40	Ⅳ
223	20.40	0.46	2.00	Ⅱ
224	11.10	0.46	3.97	Ⅲ

数据离散程度表征数据分布的重要特征,反映了各变量偏离中心值的程度。本文使用极差、四分位差和变异系数反映数据的离散程度,各级岩爆数据集统计参数见表 3。

表 3 岩爆数据集统计参数

Table 3 Statistical parameters of rock burst data set

岩爆等级	统计参数	四分位差	极差	变异系数
Ⅰ	σ_θ/σ_c	0.115	0.83	0.851
	σ_c/σ_t	24.720	41.30	0.544
	W_{et}	4.100	6.92	0.732
Ⅱ	σ_θ/σ_c	1.100	29.51	5.539
	σ_c/σ_t	13.770	27.50	0.377
	W_{et}	2.685	8.10	0.553
Ⅲ	σ_θ/σ_c	0.195	0.57	0.288
	σ_c/σ_t	7.600	67.17	0.482
	W_{et}	2.250	7.30	0.378
Ⅳ	σ_θ/σ_c	0.080	0.99	0.257
	σ_c/σ_t	7.100	24.62	0.364
	W_{et}	1.700	8.90	0.295

由表 3 可以看出,各等级指标的四分位差、极差、变异系数较大,说明数据集中离群点多,离散程度较大。该数据特征会极大地影响机器学习对数据特征的提取,从而降低算法的预测精度。

2.2 数据预处理

通过 Box-Cox 变换,可以将数据转换为正态分布或近似正态分布,从而提高模型的预测能力。其转换公式如下:

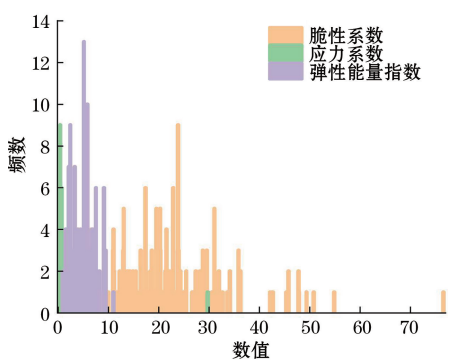
$$y(\lambda)=\begin{cases}\dfrac{y^{\lambda}-1}{\lambda},\lambda\neq 0\\ \ln y,\lambda=0\end{cases} \tag{1}$$

式中:y 为原始数据;λ 为 Box-Cox 变换参数,其值见表 4。Box-Cox 变换结果如图 2 所示。

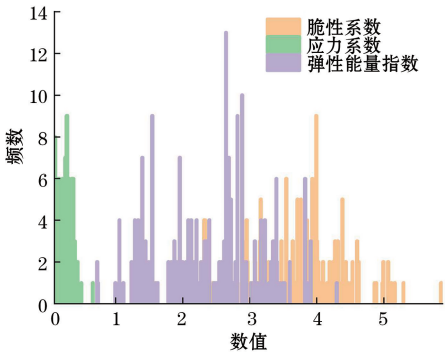
表 4 Box-Cox 变换 λ 值

Table 4 The λ value of Box-Cox transformation

变换参数	σ_θ/σ_c	σ_c/σ_t	W_{et}
λ	−1.506	0.1307	0.408



(a) 变换前



(b) 变换后

图 2 Box-Cox 变换前后数据直方图

Fig.2 Histogram of data before and after Box-Cox transformation

为解决数据集不均衡可能导致算法在训练过程中无法充分提取有效特征的问题,本文考虑采用过采样方法平衡各级岩爆数据。常见的过采样方法包括随机采样、合成少数类过采样技术(SMOTE)、边界线合成少数类过采样技术(Borderline SMOTE)、K-Means 聚类合成少数类过采样技术(K-Means SMOTE)、支持向量机合成少数类过采样技术(SVM SMOTE)以及自适应合成抽样(ADASYN)。通过对比各方法的准确率、精确率、召回率、F_1 分数、ROC 曲线、AUC 曲线等模型评价指标,发现 SVM SMOTE 采样所得到的数据效果最优。

SVM SMOTE 采样是 Borderline SMOTE 采样的变种,该技术结合 SVM 算法识别误分类点。该方法工作流程为:首先在原始训练集上训练 SVM 训练器,利用支持向量逼近边界区域;然后沿着将每个少数类支持向量与其若干近邻连接起来的直线随机创建合成数据。经 SVM SMOTE 采样后,4 个级别的岩爆样本数量均为 75 个,消除了数据不均衡的影响。图 3 为采样数据的小提琴图。

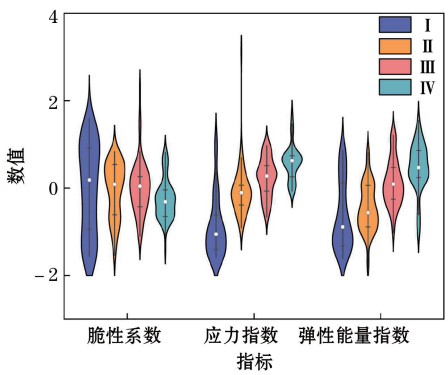


图 3 采样数据小提琴图

Fig.3 Violin plot of sampling data

由图 3 可以看出,各级岩爆指标数据分布有清晰的层次感,说明数据具有较好的可分性。中间的黑色粗条表示四分位差范围,从其延伸的幼细黑线代表 95%置信区间,而白点则为中位数。

2.3 算法预测结果分析

将均衡化后的 300 组岩爆案例按照 4∶1 划分为训练集和测试集,即 300 组样本数据中随机抽取 240 组作为训练集,剩余 60 组为测试集,两部分数据相互独立且均具有代表性。分别对 3 个模型进行训练及预测分析。

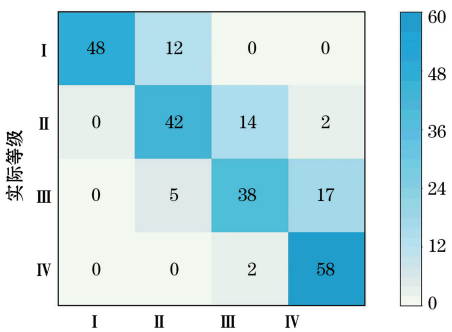
(1) CNN-LSTM 模型。使用混合交叉熵评估模型性能,通过人工反复调参得到一组较优超参数,见表 5。

表 5 CNN-LSTM 预测模型超参数组合

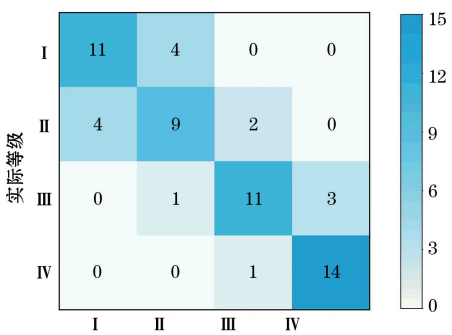
Table 5 Hyper-parameter combination of the CNN-LSTM prediction model

卷积核大小	LSTM 层单元数	卷积层滤波器数量	池化窗口大小
2	10	32	1

将得到的超参数代入模型进行训练,迭代次数设为 5 000 次,添加早停策略回调函数防止过拟合;使用训练好的模型对测试集进行预测。CNN-LSTM 模型预测结果如图 4 所示,其中训练集准确率为 77.50%,测试集准确率为 75.00%。



(a) 训练集混淆矩阵



(b) 测试集混淆矩阵

图 4 CNN-LSTM 模型预测结果

Fig 4 Prediction results of the CNN-LSTM model

（2）BO-CNN-LSTM 模型。在贝叶斯参数优化框架下，定义最小化分类模型的验证集损失为目标函数，分类交叉熵为损失函数，并采用 Adam 优化器进行参数更新，以分类准确率为模型的性能指标。同时，引入早停策略回调函数，以监控验证集上的损失变化，设定耐心参数为 50，即若验证损失在 50 个连续评估周期内未见显著改善，则提前终止训练过程。目标函数的输出为验证集上观察到的最小损失值。

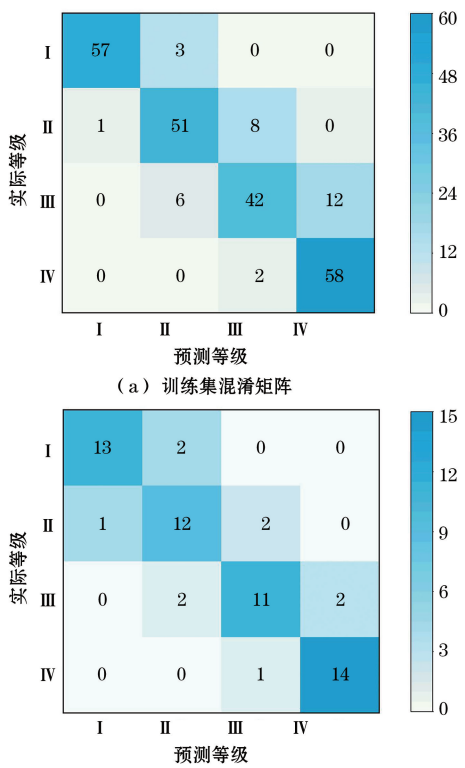
在开始阶段随机选择 5 个点进行探索，以建立高斯过程模型，接着进行 20 次迭代优化，通常找到最优超参数的次数不超过 10 次、每次迭代选择具有最大不确定性的点进行探索，以找到可能的最优解。BO-CNN-LSTM 算法的最优超参数组合见表 6。

表 6　BO-CNN-LSTM 预测模型超参数组合

Table 6　Hyper-parameter combination of the BO-CNN-LSTM prediction model

卷积核大小	LSTM 层单元数	卷积层滤波器数量	池化窗口大小
1	74	78	1

训练及测试方法同上。BO-CNN-LSTM 模型预测结果如图 5 所示，其中训练集准确率为 86.67%，测试集准确率为 83.33%。



（a）训练集混淆矩阵

（b）测试集混淆矩阵

图 5　BO-CNN-LSTM 模型预测结果

Fig.5　Prediction results of the BO-CNN-LSTM model

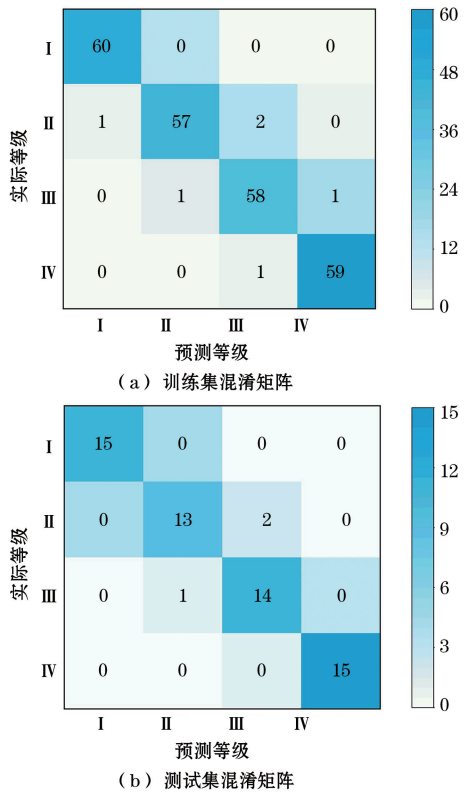
（3）BO-CNN-LSTM-Multi-head Attention 模型。定义超参数优化范围：卷积层滤波器的数量为 32～128，卷积核大小为 1～2，池化层中池化窗口的大小为 1～8，LSTM 层中的单元数量为 16～128，注意力头的数量为 1～10。定义模型目标函数：使用分类交叉熵作为损失函数，Adam 优化器进行参数更新，以分类准确率为分类模型评价指标，得到的最优超参数组合见表 7。

表 7　BO-CNN-LSTM-Multi-head Attention 预测模型超参数组合

Table 7　Hyper-parameter combination of BO-CNN-LSTM-Multi-head Attention prediction model

卷积核大小	LSTM 层单元数	卷积层滤波器数量	池化窗口大小	注意力头数量
1	29	59	5	1

将得到的超参数代入模型进行训练，迭代次数设为 15 000 次，添加早停策略回调函数防止过拟合；使用训练好的模型对测试集进行预测。BO-CNN-LSTM-Multi-head Attention 模型预测结果如图 6 所示，其中训练集准确率为 97.50%，测试集准确率为 95.00%。



（a）训练集混淆矩阵

（b）测试集混淆矩阵

图 6　BO-CNN-LSTM-Multi-head Attention 模型预测结果

Fig.6　Prediction results of the BO-CNN-LSTM-Multi-head Attention model

对3个模型在测试集上60组数据的预测结果进行分析,筛选出所有预测错误的结果,见表8。由表8可知,CNN-LSTM模型预测错误数量为15次,BO-CNN-LSTM模型预测错误数量为10次,BO-CNN-LSTM-Multi-head Attention模型预测错误数量为3次,该模型预测错误数量最少,准确率最高。观察预测错误数据的分布范围,其中Ⅰ级和Ⅳ级预测结果全部正确,准确率为100%;Ⅱ级和Ⅲ级预测错误的情况下,预测等级与实际等级的差异均未超过1级。该结果证实了本研究构建的BO-CNN-LSTM-Multi-head Attention模型具有较高的预测准确性,为岩爆烈度评估提供了可靠的新方法。

表8 各模型预测错误结果对比

Table 8 Comparison of prediction error results of each model

实际岩爆等级	模型预测结果		
	CNN-LSTM	BO-CNN-LSTM	BO-CNN-LSTM-Multi-head Attention
Ⅰ	2*	1	1
Ⅰ	2*	1	1
Ⅰ	2*	2*	1
Ⅰ	2*	2*	1
Ⅱ	1*	1*	2
Ⅱ	1*	2	2
Ⅱ	1*	2	2
Ⅱ	1*	3*	3*
Ⅱ	3*	2	2
Ⅱ	3*	3*	3*
Ⅲ	2*	2*	2*
Ⅲ	4*	2*	3
Ⅲ	4*	4*	3
Ⅲ	4*	4*	3
Ⅳ	3*	3*	4

注:*为预测错误的结果。

3 结论

(1)本文搜集了224组国内外经典岩爆案例构建数据集,使用四分位差、极差和变异系数评估数据的离散程度,发现数据集中离群点多、离散程度大。经过Box-Cox变换实现数据正态化,减少离群点的影响,并使用SVM SMOTE进行过采样以平衡各级岩爆样本的数量。经预处理,数据集具有较高的可分性,解决了岩爆数据不均衡问题。

(2)融合贝叶斯参数优化算法和多头注意力机制,构建了一种基于卷积神经网络(CNN)和长短期记忆网络(LSTM)的岩爆烈度等级预测模型(BO-CNN-LSTM-Multi-head Attention),可有效提升岩爆烈度预测在样本数据不均衡情况下的精度,具有较高的可行性和实用性。

(3)基于处理后的岩爆案例数据集,对CNN-LSTM、BO-CNN-LSTM、BO-CNN-LSTM-Multi-head Attention等3个模型进行训练及测试分析,结果表明,BO-CNN-LSTM-Multi-head Attention模型训练集准确率为97.50%,测试集准确率为95.00%,在测试集上的预测错误数量为3次。本研究构建的岩爆烈度等级预测模型具有较高的预测准确率。

参考文献(References):

[1] 江飞飞,周辉,刘畅,等.地下金属矿山岩爆研究进展及预测与防治[J].岩石力学与工程学报,2019,38(5):956-972.
JIANG Feifei, ZHOU Hui, LIU Chang, et al. Progress, prediction and prevention of rockbursts in underground metal mines[J]. Chinese Journal of Rock Mechanics and Engineering,2019,38(5):956-972.

[2] ZHANG X J, GU X B. The application of evidence-entropy weight gray incidence theory on the risk assessment of rockburst intensity in the Daxiangling tunnel[J]. Frontiers in Earth Science,2023,11:1284243.

[3] LI M L, LI K G, QIN Q C, et al. Rockburst estimation model based on IEWM-SCM and its application[J]. Environmental Earth Science,2023,82:88.

[4] ZHANG Q J, LIU C J, GUO S, et al. Evaluation of the rock burst intensity of a cloud model based on the CRITIC method and the order relation analysis method[J]. Mining, Metallurgy & Exploration,2023,40:1849-1863.

[5] 郝杰,侍克斌,王显丽,等.基于模糊C-均值算法粗糙集理论的云模型在岩爆等级评价中的应用[J].岩土力学,2016,37(3):859-866+874.
HAO Jie, SHI Kebin, WANG Xianli, et al. Application of cloud model to rating of rockburst based on rough set of FCM algorithm[J]. Rock and Soil Mechanics,2016,37(3):859-866+874.

[6] 李明亮,李克钢,刘月东,等.基于变异系数与序关分析法-多维正态云模型的岩爆预测[J].岩石力学与工程学报,2020,39(增刊2):3395-3402.
LI Mingliang, LI Kegang, LIU Yuedong, et al. Rock burst prediction based on coefficient of variation and sequence analysis-multidimensional normal cloud model[J]. Chinese Journal of Rock Mechanics and Engineering,2020,39(Suppl. 2):3395-3402.

[7] LONG G Y, WANG H, HU K, et al. Probability prediction method for rockburst intensity based on rough set and multidimensional cloud model uncertainty reasoning[J]. Environmental Earth Sciences,2024,83:84.

[8] WU S L, YAN Q S, TIAN S, et al. Prediction of rock burst intensity based on multi-source evidence weight and error-eliminating theory[J]. Environmental Science and Pollution Research,2023,30:74398-74408.

[9] CHEN J H, LIU Z, ZHAO Y K, et al. Generalized weighted mahalanobis distance improved VIKOR model for rockburst classification evaluation[J]. Mathematics, 2024, 12(2):181.

[10] LIU Z, CHEN J H, ZHAO Y K, et al. A novel method for predicting rockburst intensity based on an improved unascertained measurement and an improved game theory [J]. Mathematics, 2023, 11(8):1862.

[11] WANG Q W, WANG C, LIU Y, et al. Exploration and improvement of fuzzy evaluation model for rockburst[J]. Mining, Metallurgy & Exploration, 2024, 41:559-587.

[12] 周科平,雷涛,胡建华.深部金属矿山 RS-TOPSIS 岩爆预测模型及其应用[J].岩石力学与工程学报,2013,32(增刊 2):3705-3711.
ZHOU Keping, LEI Tao, HU Jianhua. RS-TOPSIS model of rockburst prediction in deep metal mines and its application[J]. Chinese Journal of Rock Mechanics and Engineering, 2013, 32(Suppl.2):3705-3711.

[13] XING W B, WANG H P, FAN J G, et al. Rockburst risk assessment model based on improved catastrophe progression method and its application [J]. Stochastic Environmental Research and Risk Assessment, 2024, 38: 981-992.

[14] WANG A F, YANG X T, GU X B. The risk assessment of rockburst intensity in the highway tunnel based on the variable fuzzy sets theory[J]. Scientific Reports, 2023, 13:4755.

[15] 田睿.基于机器学习的岩爆烈度等级预测模型研究与应用[D].包头:内蒙古科技大学,2020.
TIAN Rui. Research and application of rockburst intensity classification prediction model based on machine learning algorithms [D]. Baotou: Inner Mongolia University of Science and Technology, 2020.

[16] MA K, SHEN Q Q, SUN X Y, et al. Rockburst prediction model using machine learning based on microseismic parameters of Qinling water conveyance tunnel[J]. Journal of Central South University, 2023, 30(1):289-305.

[17] 李明亮,李克钢,秦庆词,等.岩爆烈度等级预测的机器学习算法模型探讨及选择[J].岩石力学与工程学报,2021,40(增刊 1):2806-2816.
LI Mingliang, LI Kegang, QIN Qingci, et al. Discussion and selection of machine learning algorithm model for rockburst intensity grade prediction[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40 (Suppl. 1): 2806-2816.

[18] ZHOU Y, WANG T L. PNN-based rockburst prediction model and its applications[J]. Earth Sciences Research Journal, 2017, 21(3):141-146.

[19] 吴顺川,张晨曦,成子桥.基于 PCA-PNN 原理的岩爆烈度分级预测方法[J].煤炭学报,2019,44(9):2767-2776.
WU Shunchuan, ZHANG Chenxi, CHENG Ziqiao. Prediction of intensity classification of rockburst based on PCA-PNN principle[J]. Journal of China Coal Society, 2019, 44(9):2767-2776.

[20] 李康楠,吴雅琴,杜锋,等.基于卷积神经网络的岩爆烈度等级预测[J].煤田地质与勘探,2023,51(10):94-103.
LI Kangnan, WU Yaqin, DU Feng, et al. Prediction of rockburst intensity grade based on convolutional neural network[J]. Coal Geology & Exploration, 2023, 51(10): 94-103.

[21] 杨小彬,裴艳宇,程虹铭,等.基于 SOFM 神经网络模型的岩爆烈度等级预测方法[J].岩石力学与工程学报,2021,40(增刊 1):2708-2715.
YANG Xiaobin, PEI Yanyu, CHENG Hongming, et al. Prediction method of rockburst intensity grade based on SOFM neural network model[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(Suppl.1):2708-2715.

[22] ZHANG S C, MU C M, FENG X H, et al. Intelligent dynamic warning method of rockburst risk and level based on recurrent neural network[J]. Rock Mechanics and Rock Engineering, 2024, 57:3509-3529.

[23] 田睿,孟海东,陈世江,等.基于深度神经网络的岩爆烈度分级预测[J].煤炭学报,2020,45(增刊 1):191-201.
TIAN Rui, MENG Haidong, CHEN Shijiang, et al. Prediction of intensity classification of rockburst based on deep neural network[J]. Journal of China Coal Society, 2020, 45(Suppl.1):191-201.

[24] 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, LYU 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.

[25] 苏焕博.数据缺失和不均衡下的 IDPSO-ELM 岩爆烈度等级预测模型研究[D].阜新:辽宁工程技术大学,2022.
SU Huanbo. Research on IDPSO-ELM rockburst intensity grade prediction model under missing and unbalanced data [D]. Fuxin: Liaoning Technical University, 2022.

[26] LI M L, LI K G, QIN Q C. A rockburst prediction model based on extreme learning machine with improved Harris Hawks optimization and its application[J]. Tunnelling and Underground Space Technology, 2023, 134:104978.

[27] 杨玲,魏静.基于支持向量机和增强学习算法的岩爆烈度等级预测[J].地球科学,2023,48(5):2011-2023.
YANG Ling, WEI Jing. Prediction of rockburst intensity grade based on SVM and adaptive boosting algorithm[J]. Earth Science, 2023, 48(5):2011-2023.

[28] 满轲,武立文,刘晓丽,等.基于灰色关联分析和 SSA-RF 模型的岩爆等级预测[J].金属矿山,2023(5):202-212.
MAN Ke, WU Liwen, LIU Xiaoli, et al. Rockburst grade prediction based on grey correlation analysis and SSA-RF model[J]. Metal Mine, 2023(5):202-212.

[29] DONG L J, LI X B, PENG K. Prediction of rockburst classification using Random Forest[J]. Transactions of Nonferrous Metals Society of China,2013,23(2):472-477.

[30] JIA Z C, WANG Y, WANG J H, et al. Rockburst intensity grade prediction based on data preprocessing techniques and multi-model ensemble learning algorithms[J]. Rock Mechanics and Rock Engineering,2024,57:5207-5227.

[31] 刘晓悦,季红瑜.基于 AdaBoost-BAS-SVM 模型的岩爆预测研究[J].金属矿山,2021(10):28-34.
LIU Xiaoyue, JI Hongyu. Research on rockburst prediction based on AdaBoost-BAS-SVM model[J]. Metal Mine,2021(10):28-34.

[32] 周英豪,王文杰,卢西洲,等. 岩爆灾害博弈论组合赋权预测模型及应用[J].中国安全科学学报,2022,32(7):105-112.
ZHOU Yinghao, WANG Wenjie, LU Xizhou, et al. Combination weighting prediction model and application of rock burst disaster based on game theory[J]. China Safety Science Journal,2022,32(7):105-112

[33] 景杨凡,陈玉明,李岳峰,等.基于判别分析法的岩爆烈度预测研究[J].有色金属(矿山部分),2022,74(1):97-102.
JING Yangfan, CHEN Yuming, LI Yuefeng, et al. Study on rockburst prediction based on discriminant analysis method[J]. Nonferrous Metals (Mining Section),2022,74(1):97-102.

[34] 张千俊,刘传举,刘泉,等.基于博弈-灰靶模型的岩爆烈度等级评价[J].矿业研究与开发,2023,43(1):55-60.
ZHANG Qianjun, LIU Chuanju, LIU Quan, et al. Evaluation of rock burst intensity grade based on game-grey target model[J]. Mining Research and Development,2023,43(1):55-60.

[35] 王文通,张千俊,郭沙,等.基于 SSA-BP 神经网络的岩爆烈度等级预测[J].有色金属(矿山部分),2024,76(1):77-83+91.
WANG Wentong, ZHANG Qianjun, GUO Sha, et al. Prediction of rock burst intensity based on SSA-BP neural network[J]. Nonferrous Metals (Mining Section),2024,76(1):77-83+91.

[36] 陈则黄,李克钢,李明亮,等.基于 PCA-SOFM 模型的岩爆烈度等级预测[J].地下空间与工程学报,2022,18(增刊 2):934-942+951.
CHEN Zehuang, LI Kegang, LI Mingliang, et al. Prediction of rockburst intensity based on PCA-SOFM model[J]. Chinese Journal of Underground Space and Engineering,2022,18(Suppl.2):934-942+951.

[37] 石小庆.基于 KPCA-GWO-SVM 模型的岩爆预测及应用[J].黄金,2023,44(4):13-18.
SHI Xiaoqing. Rockburst prediction based on KPCA-GWO-SVM model and its application[J]. Gold,2023,44(4):13-18.

[38] 李军民,张亭,周义升,等.基于 APSO-SVM 模型的岩爆烈度预测方法[J].现代矿业,2023,39(6):167-170.
LI Junmin, ZHANG Ting, ZHOU Yisheng, et al. Rock burst intensity prediction method based on APSO-SVM model[J]. Modern Mining,2023,39(6):167-170.

[39] 滕涛,王国军,周伟胜,等.GA-BP 神经网络模型在岩爆烈度分类预测研究及应用[J].现代矿业,2023,39(9):278-281.
TENG Tao, WANG Guojun, ZHOU Weisheng, et al. Research and application of classification prediction of rockburst intensity based on GA-BP neural network model[J]. Modern Mining,2023,39(9):278-281.