

高压物理学报

基于BKA-CNN-SVM模型的岩爆烈度预测

慕慧文 周宗红 郑发萍 刘剑 曾顺洪 段勇

Prediction of Rockburst Grade Based on BKA-CNN-SVM Model

MU Huiwen, ZHOU Zonghong, ZHENG Faping, LIU Jian, ZENG Shunhong, DUAN Yong

引用本文:

慕慧文, 周宗红, 郑发萍, 等. 基于BKA-CNN-SVM模型的岩爆烈度预测[J]. 高压物理学报, 2025, 39(5):055302. DOI: 10.11858/gywlb.20240880

MU Huiwen, ZHOU Zonghong, ZHENG Faping, et al. Prediction of Rockburst Grade Based on BKA-CNN-SVM Model[J]. Chinese Journal of High Pressure Physics, 2025, 39(5):055302. DOI: 10.11858/gywlb.20240880

在线阅读 View online: <https://doi.org/10.11858/gywlb.20240880>

您可能感兴趣的其他文章

Articles you may be interested in

基于卷积神经网络的两相复合结构动态力学性能研究

Research on Dynamic Mechanical Properties of Two-Phase Composites Based on Convolutional Neural Network
高压物理学报. 2023, 37(3): 034201 <https://doi.org/10.11858/gywlb.20230601>

基于多参量判据的深地下工程岩爆倾向性研究

Rockburst Tendency for Deep Underground Engineering Based on Multi-Parameters Criterion
高压物理学报. 2022, 36(2): 025202 <https://doi.org/10.11858/gywlb.20210857>

基于机器学习的钢筋混凝土板在爆炸作用下的最大位移预测模型

Prediction Model of Maximum Displacement for RC Slabs under Blast Load Based on Machine Learning
高压物理学报. 2023, 37(2): 024205 <https://doi.org/10.11858/gywlb.20220667>

基于WOA-RF的边坡稳定性预测模型

Slope Stability Prediction Based on WOA-RF Hybrid Model
高压物理学报. 2024, 38(3): 035301 <https://doi.org/10.11858/gywlb.20230837>

基于WOA-XGBoost模型的胶结充填体强度预测

Strength Prediction of Cemented Paste Backfill Body Based on WOA-XGBoost Model
高压物理学报. 2023, 37(5): 054201 <https://doi.org/10.11858/gywlb.20230668>

基于数据预处理和改进麻雀算法的岩爆预测

Rock burst prediction based on data preprocessing and improved sparrow algorithm
高压物理学报. 2025, (): <https://doi.org/10.11858/gywlb.20240964>

基于 BKA-CNN-SVM 模型的岩爆烈度预测

慕慧文¹, 周宗红¹, 郑发萍², 刘 剑¹, 曾顺洪³, 段 勇³

(1. 昆明理工大学国土资源工程学院, 云南 昆明 650093;
2. 昆明理工大学公共安全与应急管理学院, 云南 昆明 650093;
3. 云南云天化聚磷新材料有限公司, 云南 昭通 657200)

摘要:为实现准确高效的岩爆烈度预测,做好地下工程灾害防治,提出了一种基于黑翅鸢优化算法-卷积神经网络-支持向量机(BKA-CNN-SVM)的岩爆烈度预测模型。首先,根据岩爆烈度的影响因素,确立6个主要岩爆预测指标,搜集国内外284组岩爆案例,建立岩爆数据库;然后,引入拉依达准则与1.5倍四分位差对数据进行异常值剔除及替换;接着,采用核主成分分析,对数据进行降维及特征提取,并将所提取的特征作为模型输入;最后,通过引入混淆矩阵,结合准确率、精确率、 F_1 值、召回率对模型性能进行评估,并与卷积神经网络(CNN)模型、极限学习机(ELM)模型、卷积神经网络与支持向量机(CNN-SVM)集成模型的性能进行对比。结果表明:BKA-CNN-SVM模型的准确率、精确率、 F_1 值、召回率分别达到95.35%、0.89、0.92、0.94,在预测精度和泛化程度上均明显优于其他模型。采用该模型预测锦屏二级水电站岩爆烈度,结果显示,预测结果与现场情况有较高的一致性。研究结果可为岩爆等级预测提供新方法。

关键词:岩爆;核主成分分析;卷积神经网络;支持向量机;黑翅鸢优化算法

中图分类号:O347; TU45; O521.9

文献标志码:A

岩爆是指在地应力作用下,地下工程开挖、开采或其他外界扰动下,岩体内积聚的弹性势能迅速释放,引发坚硬脆性围岩储存的应变能瞬间释放,岩体产生爆裂、剥落甚至抛射等动力失稳现象^[1-4]。随着地下资源开发和地下工程建设不断向深部发展,地应力增高和更复杂的岩体赋存地质环境等因素导致岩爆灾害日益频繁,直接影响地下工程的进度和施工人员的安全^[5]。因此,精准的岩爆预测对于地下工程建设和安全生产具有重要意义。

为准确预测岩爆强度,国内外学者对岩爆预测方法进行了大量研究。模糊数学综合评判法、物元可拓理论、灰色系统理论、功效系数法、云模型理论等方法已在岩爆烈度预测中广泛应用,但此类方法具有较强的主观性,可能影响预测精度。鉴于岩爆孕育机制不明确、影响因素众多,需要结合多种理论,深入探究各影响因素与岩爆等级间的内在联系,以便更好地实现岩爆等级的准确预测^[6]。

近年来,能处理输入变量与输出变量之间复杂非线性关系的机器学习方法迅速发展^[7],结合数据处理、机器学习算法以及元启发式优化算法来解决岩爆预测问题逐渐成为主流。靳春玲等^[8]采用鲸鱼优化算法优化支持向量机(support vector machine, SVM)中直接影响模型分类效果和评估精度的惩罚参数 c 和核函数参数 g ,在避免局部寻优的条件下进行岩爆预测。李康楠等^[9]将卷积神经网络引入岩爆预测中,通过链式方程多重插补法对数据缺失值进行插补,提高了岩爆预测精度和模型收敛速度。郭延华等^[10]通过核主成分分析(kernel principal component analysis, KPCA)提取岩爆数据特征,采用鲸鱼优化算法对极限学习机(extreme learning machine, ELM)进行参数优化,避免了人工调参对模型预测的影响。

* 收稿日期: 2024-08-29; 修回日期: 2024-10-29

基金项目: 国家自然科学基金(52264019, 51864023); 云南省基础研究计划项目青年项目(202401AU070175)

作者简介: 慕慧文(2000—), 男, 硕士研究生, 主要从事采矿与岩石力学研究. E-mail: 3188486208@qq.com

通信作者: 周宗红(1967—), 男, 博士, 教授, 主要从事采矿与岩石力学研究. E-mail: zhou20051001@163.com

综合上述研究,机器学习结合数据处理以及元启发式优化算法的岩爆预测方法展现出一定的可靠性和普适性,然而,其预测精度对模型参数的敏感性较高,直接影响预测精度。此外,由于岩爆数据中无岩爆和强岩爆样本所占比例偏小,存在数据不均衡的问题,传统单一算法对于少数类别数据的识别能力较弱,难以充分处理复杂多样性数据,间接导致预测精度降低。研究证实,集成模型可以结合多个单一模型的优点,对非均衡数据的处理能力更优,可显著提高模型的准确性和泛化能力^[11]。因此,为解决数据不均衡及参数敏感性对岩爆预测精度的影响,本研究首先通过卷积神经网络(convolutional neural network, CNN)与支持向量机堆叠,建立 CNN-SVM 集成模型;其次,考虑模型参数对模型预测精度的影响,引入黑翅鸢优化算法(black-winged kite optimization algorithm, BKA)优化 CNN 参数,避免人工设置参数对模型预测效果的影响;最后,建立 BKA-CNN-SVM 岩爆强度预测模型。由于岩爆评价指标之间的多维交叉冗余性,在数据预处理阶段,采用五折交叉验证获取最优核参数的 KPCA 法对岩爆数据做特征压缩和非线性降维,将所得的数据特征输入至经 BKA 优化的 CNN 和 SVM 的集成分类器中进行岩爆预测分析。通过分析对比多个评价指标,测试 BKA-CNN-SVM 岩爆预测模型的岩爆预测精度和稳定性,以期对岩爆预测提供一种新思路。

1 模型原理

1.1 KPCA

KPCA 是基于核方法的主成分分析方法,旨在克服传统主成分分析算法在处理非线性可分数据特征时的局限,充分保留数据特征信息^[10]。KPCA 通过核函数将数据映射至高维空间,增强数据在该空间的线性可分性,避免了非线性映射的显式表达,实现了指标数量的压缩和数据复杂度的简化,降低了模型预测所需的时间成本。本研究对 KPCA 采用 5 倍交叉验证,确定最优核参数 σ 的取值,利用 KPCA 对岩爆数据预处理,消除指标间的相关性并降维,提取主要特征。

假设有 n 个样本,每个样本有 m 个特征,建立初始样本矩阵 $\mathbf{X}_{n \times m}^0$,归一化后得样本矩阵 $\mathbf{X}_{n \times m}$ 。

首先,通过映射函数 ϕ 将样本数据 $\mathbf{x}_i \in \mathbf{R}^n$ 映射至高维特征空间 $\mathbf{R}^F$ 中,得到输入变量 $\mathbf{x}_i$ 的中心非线性映射 $\phi(\mathbf{x}_i)$,若映射的均值为零,则 $\mathbf{R}^F$ 空间中协方差矩阵为

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n \phi(\mathbf{x}_i) \phi(\mathbf{x}_i)^T \quad (1)$$

所对应的特征方程为

$$\mathbf{C}\mathbf{v} = \lambda\mathbf{v} \quad (2)$$

式中: λ 和 $\mathbf{v}$ 分别为协方差矩阵的特征值和特征向量,且所有 $\lambda \geq 0$ 的解 $\mathbf{v}$ 都在 $\phi(\mathbf{x}_i)$ 中。

然后,由式 (1)~式 (2) 可得特征向量 $\mathbf{v}$

$$\mathbf{v} = \sum_{i=1}^n \frac{\phi(\mathbf{x}_i)^T \mathbf{v}}{\lambda n} = \sum_{i=1}^n \phi(\mathbf{x}_i) \alpha_i \quad (3)$$

$$\alpha_i = \frac{\phi(\mathbf{x}_i)^T \mathbf{v}}{\lambda n} \quad (4)$$

映射 ϕ 通常不是显式的, $\mathbf{v}$ 的计算较困难,因此,引入核函数 $k(\mathbf{x}_i, \mathbf{x}_j)$ 进行处理

$$k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad (5)$$

最后,计算核矩阵,将式 (1)、式 (3) 分别代入式 (2),并对等式两边进行内积运算,同时将式 (5) 引入运算后的式 (2) 中,求得

$$\mathbf{K}\boldsymbol{\alpha} = \lambda n \boldsymbol{\alpha} \quad (6)$$

式中: $\mathbf{K}$ 为 k 对应的核矩阵, $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_n)$ 。

通过式 (6) 得特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ 及其对应的特征向量 $\alpha_1, \alpha_2, \dots, \alpha_n$ 。选取的 $l (l \leq n)$ 个特征值需满足累计贡献率大于 85%

$$\sum_{j=1}^l \lambda_j / \sum_{i=1}^n \lambda_i \geq 85\% \quad (7)$$

当累计贡献率达到设定要求时, 计算的新样本 $\phi(x_j)$ 投影后的第 $j (j = 1, 2, \dots, p)$ 维坐标为

$$y_i = \sum_{j=1}^n \alpha_j^i [\phi(x_i)^T \phi(x_j)] = \sum_{j=1}^n \alpha_j^i k(x_i, x_j) \quad (8)$$

1.2 CNN-SVM 理论基础

1.2.1 CNN

CNN 属于深度学习领域的一种先进的前馈神经网络架构, 通过局部连接和权值共享的方式显著提高网络模型的优化效率, 降低过拟合的风险。如图 1 所示, CNN 的结构包括输入层、卷积层、池化层、全连接层和输出层^[12-13]。输入层是网络的初始数据输入层, 通过特征提取将图像传递到卷积层。卷积层线性抽取局部范围内的神经元信息与特征, 运用非线性激活函数对神经元进行激活, 利用卷积核在输入数据上滑动实现卷积运算, 提取特征参数并反馈至池化层^[9]。池化层用于下采样, 减少特征图尺寸, 实施数据降维, 并与全连接层相连。全连接层能够将所得到的多维特征图平铺为一维向量, 实现数据高维至低维的转换, 同时学习各种组合特征。CNN 通过卷积、池化等操作提取并汇总特征, 然后解释分类, 从而提高模型的表达能力, 减少模型参数和计算量。




图 1 CNN 模型的基本架构

Fig. 1 Basic architecture of CNN model

1.2.2 SVM

SVM 是一种基于统计学理论和结构风险最小化原则的机器学习方法, 通过运用核函数定义的非线性变换将输入空间变换到高维空间, 以寻找输入与输出之间的非线性映射关系, 具有结构简单、泛化能力强、计算难度小、样本空间维数低等优点, 可以更好地处理非线性、高维数和小样本问题^[14]。关于 SVM 的工作原理, 已有大量文献进行了详细阐述, 这里不再赘述。

1.2.3 CNN-SVM 模型理论

传统 CNN 中的池化层可实现对高维冗余数据的降维, 但经 KPCA 处理后的岩爆数据特征维数较低。鉴于使用池化层可能导致信息丢失, 本研究中的 CNN 采用卷积层—批归一化层—Relu 激活层—丢弃层—全连接层的结构设计, 不采用堆叠到模型结构中的池化层。批归一化层可以在不丢失数据特征的前提下加速收敛; Relu 激活层可以增强模型的收敛性, 并预防过拟合现象; 丢弃层则可进一步提升模型的泛化能力。SVM 是一种高效的分类算法, 特别适合处理小样本数据集, 同时, 其对缺失数据具

有较强的不敏感性,能够在一定程度上规避维度灾难问题^[15]。基于此,采用 SVM 替代传统的 CNN 分类器在理论上是可行的,并且在实际预测中也表现出较高水准^[16]。本研究将堆叠 CNN 和 SVM,建立 CNN-SVM 集成模型,进行分类预测。

CNN-SVM 集成模型将特征提取与分类步骤分离,其中,CNN 作为特征提取器,提取原始数据中的特征,输入至 SVM 分类器进行分类^[17]。CNN-SVM 集成模型利用 SVM 的优化能力,并融合卷积操作和 SVM 的核函数,提升了模型在分类任务中的性能表现和适应性,具体流程见图 2。




图 2 CNN-SVM 算法流程图
Fig. 2 Flowchart of CNN-SVM algorithm

1.3 BKA

BKA 是模拟黑翅鸢在攻击和迁徙中表现出的高度适应性和智能行为提出的群智能优化算法^[17]。该算法集成了柯西突变策略和领导者策略,增强了算法的全局寻优能力,提高了算法的收敛速度。该算法主要包括 3 个阶段:初始化、攻击行为和迁徙行为。

1.3.1 种群初始化

创建一组随机解,矩阵中的每个元素表示每只黑翅鸢的位置

$$\mathbf{B} = \begin{bmatrix} B_{1,1} & B_{1,2} & \cdots & \cdots & B_{1,d} \\ B_{2,1} & B_{2,2} & \cdots & \cdots & B_{2,d} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ B_{p,1} & B_{p,2} & \cdots & \cdots & B_{p,d} \end{bmatrix} \quad (9)$$

式中: p 为潜在解决方案的个数, d 为给定问题的维度大小, $B_{i,j}$ 为第 i 个黑翅鸢的第 j 个维度。均匀分配每只黑翅鸢的位置

$$X_i = B_{l,b} + r(B_{u,b} - B_{l,b}) \quad (10)$$

式中: i 为 $1 \sim p$ 之间的整数, $B_{l,b}$ 和 $B_{u,b}$ 分别为第 i 个黑翅鸢在第 j 维的下界和上界, r 在 $[0, 1]$ 区间随机选值。

在种群初始化中, 黑翅鸢选择适应度最好的个体作为初始种群的领导者, 亦认为是最优位置。其初始领导者 X_L 的数学表示为

$$f_{\text{best}} = \min(f(X_i)) \quad (11)$$

$$X_L = X(f(X_i) = f_{\text{best}}) \quad (12)$$

1.3.2 攻击行为

该策略包括不同的攻击行为, 用于全局探索。以下是黑翅鸢攻击行为的数学模型

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n(1 + \sin r)y_t^{i,j} & p < r \\ y_t^{i,j} + n(2r - 1)y_t^{i,j} & \text{else} \end{cases} \quad (13)$$

$$n = 0.05e^{-2(t/T)^2} \quad (14)$$

式中: $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别为第 i 只黑翅鸢在第 t 步和第 $t+1$ 步迭代中第 j 维的位置, p 为 0.9, T 为总迭代次数。

1.3.3 迁徙行为

自然界中迁移通常由种群的领导者引领, 因而该算法假设: 若当前种群的适应度值小于随机种群的适应度值, 则更换领导者; 反之, 则确定领导者并引导种群到达目的地。这种策略可以动态地选择优秀的领导者, 确保迁移成功。以下是黑翅鸢迁徙行为的数学模型

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0, 1)(y_t^{i,j} - L_t^j) & F_i < F_{ri} \\ y_t^{i,j} + C(0, 1)(L_t^j - my_t^{i,j}) & \text{else} \end{cases} \quad (15)$$

$$m = 2\sin(r + \pi/2) \quad (16)$$

式中: L_t^j 为迄今为止第 t 次迭代的第 j 维黑翅鸢的领先得分者, 即最优解; F_i 为任一黑翅鸢在第 t 次迭代中得到的第 j 维当前位置; F_{ri} 为第 t 次迭代中任意黑翅鸢在第 j 维随机位置的适应度值; $C(0, 1)$ 为柯西突变。一维柯西分布是具有 2 个参数 (δ 和 μ) 的连续概率分布, 概率密度函数为

$$f(x, \delta, \mu) = \frac{1}{\pi} \frac{\delta}{\delta^2 + (x - \mu)^2} \quad (17)$$

当 $\delta = 1, \mu = 0$ 时, 式 (17) 变为标准概率密度函数

$$f(x, \delta, \mu) = \frac{1}{\pi} \frac{1}{x^2 + 1} \quad (18)$$

2 岩爆烈度预测模型建立

2.1 岩爆数据库建立

岩爆发生机理十分复杂且影响因素众多, 呈现出明显的随机性、突发性和复杂性等特征^[18]。其主要影响因素包括岩性条件、地质构造、开挖扰动、围岩初始应力状态等。研究表明, 相较于单一指标, 多指标岩爆预测方法可以更为全面地揭示岩爆机理的复杂性, 避免单一指标的岩爆判据在高精度预测方面的局限性^[8]。本研究借鉴前人成果, 基于岩石的性质和岩爆影响因素, 选取 3 个反映岩石力学主要特征的参数, 即单轴抗压强度 (uniaxial compressive strength, UCS)、单轴抗拉强度 (uniaxial tensile

strength, UTS)、围岩最大切应力(maximum tangential stress, MTS), 以及 3 个反映围岩性质的指标, 即岩体应力系数(Biot's coefficient of friction, BCF)、脆性系数(stress concentration factor, SCF)和弹性能量指数(elastic energy index, EEI), 作为岩爆预测特征指标。为探究选取的 6 个指标之间的相关性, 对以下岩爆预测评价指标组合进行研究: (1) UTS、BCF、SCF, (2) UCS、UTS、BCF、SCF、EEI, (3) MTS、UCS、UTS、BCF、SCF、EEI。

模型可靠性受岩爆案例数量和数据质量的双重影响, 多数研究因预测模型基于少量案例构建, 普遍存在泛化性能不足的问题。因此, 本研究收集了 284 例国内外岩爆工程实例, 部分数据见表 1^[19-21], 岩爆预测结果以岩爆等级表示。目前, 一般按岩爆烈度将岩爆分为 4 级: 无岩爆(1)、轻微岩爆(2)、中等岩爆(3)、强烈岩爆(4)。本研究收集的 284 个案例的岩爆等级分布如图 3 所示。

表 1 部分岩爆工程实例数据^[19-21]
Table 1 Part of engineering data of rockburst^[19-21]

Serial No.	Rockburst prediction index						Actual grade
	MTS/MPa	UCS/MPa	UTS/MPa	BCF	SCF	EEI	
1	21.50	107.52	2.98	0.20	36.04	2.29	1
2	56.10	131.99	9.44	0.43	13.98	7.44	3
3	66.77	148.48	8.47	0.45	17.53	5.08	2
4	39.82	128.46	2.98	0.31	43.11	2.40	3
5	9.57	99.70	4.80	0.10	20.77	3.80	1
6	30.10	88.70	3.70	0.34	23.97	6.60	4
7	9.74	88.51	2.98	0.11	29.70	1.77	1
8	57.97	96.16	3.77	0.46	25.51	2.53	2
9	91.30	225.60	17.20	0.40	13.12	7.30	4
10	55.40	176.00	7.30	0.31	24.11	9.30	3
11	29.04	124.15	5.00	0.23	24.83	4.39	1

2.2 数据预处理

为实现较高的预测准确率, 需对原始数据进行预处理。依据岩爆烈度等级对 284 个样本案例的基本特征情况进行汇总, 结果如表 2 所示。由表 2 可知: MTS 的最大值为 148.81 MPa, 四分位数为 30.79 MPa, 最小值为 2.60 MPa, 呈现明显的右偏现象; UTS 的最大值为 17.68 MPa, 四分位数为 4.05 MPa, 最小值为 0.38 MPa, 也呈现出明显的右偏分布; 其余数据同样具有一定的右偏特征。因表 2 所列数据有限, 为更直观地描述样本的分布情况, 绘制了 6 个特征的高斯函数分布曲线及不同特征中 4 个岩爆等级的箱型图, 如图 4 所示。

指标特征数据在采集和测量过程中可能受到人工操作或采动因素的干扰, 导致数据存在误差, 因而, 若个别样本值与大多数测量值不同, 则为异常数据或离群值^[22]。为消除离群值对模型预测精度的影响, 本研究采用拉依达准则对数据进行甄别, 剔除离群值, 然后用 1.5 倍四分位差对离群值进行替换, 以确保数据的稳定性和预测模型的可靠性。拉依达准则表示为

$$|v_a| = |q_a - \bar{q}| > 3\beta \quad (19)$$

式中: β 为标准偏差, q_a 和 v_a 分别为数据集中第 a 个数据及其剩余误差, $\bar{q}$ 为数据集的均值。




图 3 实际岩爆等级分布

Fig. 3 Actual grade distribution of rockburst

表 2 原始数据的特征描述

Table 2 Features description of original data

Items	MTS/MPa	UCS/MPa	UTS/MPa	BCF	SCF	EEI
Mean value	51.93	118.52	6.56	0.42	20.18	4.67
Standard deviation	29.08	50.28	3.62	0.23	9.94	2.29
Minimum value	2.60	18.23	0.38	0.10	0.15	0.85
Lower quartile	30.79	88.65	4.05	0.27	13.11	2.98
Median	50.05	120.00	6.30	0.40	18.96	5.00
Upper quartile	66.87	150.43	8.92	0.55	25.22	6.43
Maximum value	148.81	260.64	17.68	1.03	44.70	11.28




图 4 数据分布曲线及箱型图

Fig. 4 Data distribution curve and box diagram

2.3 BKA-CNN-SVM 模型构建

将收集的 284 组地下工程和矿山岩爆案例作为原始数据,按 7 : 3 的比例将数据集随机分为训练集和测试集。

模型构建流程主要包括以下步骤:

- (1) 根据选定指标搜集岩爆案例数据,基于拉依达准则将原始数据中的异常值替换成 1.5 倍四分位差;
- (2) 将预处理后的原始数据标准化,以消除不同指标间量纲和数量级的差异;
- (3) 采用五折交叉验证确定 KPCA 的最优核参数 σ , 并利用 KPCA 对岩爆数据预处理,消除指标间的相关性并降维,提取主要特征;
- (4) 采用堆叠技术将 SVM 替代传统的 CNN 分类器,构建 CNN-SVM 集成模型,并应用于岩爆预测,为避免模型参数对预测精度的影响,引入黑翅鸢优化算法优化预测模型,以规避局部最优陷阱,增强模型的收敛速度和稳定性;
- (5) 输入提取的特征,根据建立的 BKA-CNN-SVM 模型获得预测结果,并与其他模型预测结果进行比较,测试准确率。

BKA-CNN-SVM 模型预测岩爆烈度的流程见图 5。




图 5 BKA-CNN-SVM 流程图

Fig. 5 Flowchart of BKA-CNN-SVM

3 预测模型实现过程

3.1 KPCA 数据处理

KPCA 是利用核函数将原始数据映射至高维空间进行主成分分析进而对数据进行降维处理,其充分保留了数据的特征信息。为消除指标间的相关性,基于 KPCA 对岩爆预测评价指标组合进行相关性探究,结果见表 3。

表 3 各指标间的相关性系数
Table 3 Correlation coefficient of each index

Predictive parameters	Correlation coefficient					
	MTS	UCS	UTS	BCF	SCF	EEI
MTS	1.0000	0.3330	0.3760	0.6545	-0.0863	0.4534
UCS	0.3330	1.0000	0.5810	-0.2786	0.0760	0.5760
UTS	0.3760	0.5810	1.0000	0.0308	-0.5903	0.3787
BCF	0.6545	-0.2786	0.0308	1.0000	-0.2210	0.0785
SCF	-0.0863	0.0760	-0.5903	-0.2210	1.0000	-0.0185
EEI	0.4534	0.5760	0.3787	0.0785	-0.0185	1.0000

由表 3 可知: 组合 1 与组合 2 的指标间相关系数均小于 0.28, 呈现出微弱的相关性。组合 3 中, MTS 与 BCF 的相关系数为 0.6545, 说明两者有较为明显的相关性, 会影响岩爆预测最终结果。因此, 组合 3 需采用 KPCA 进行数据处理, 消除指标间相关性。

选用高斯核函数对标准化的 284 组岩爆案例数据进行 KPCA 数据处理。高斯核函数参数经五折交叉验证得到最优值为 9, 其特征提取步骤如 1.1 节所述, 特征提取结果见表 4。

表 4 特征提取结果
Table 4 Feature extraction results

Component	Eigenvalue	Principal component contribution rate/%	Cumulative contribution rate/%
1	2.4777	41.29	41.29
2	1.5666	26.11	67.40
3	1.2470	20.78	88.19
4	0.4580	7.63	95.82
5	0.1280	2.13	97.96
6	0.1227	2.04	100.00

由表 4 可知, 前 3 个主成分的累计贡献率达 88.19%, 即前 3 个主成分共包含 88.19% 的原始信息。前 3 个主成分的特征值均大于 1, 满足特征值大于 1 且累计贡献率大于 85% 的条件, 因此, 选取这 3 个主成分。建立数据压缩后的矩阵 F_1 、 F_2 、 F_3 作为 BKA-CNN-SVM 的输入数据。

3.2 BKA 优化 CNN 模型

由于 CNN 相关参数的取值往往影响模型的准确度, 因此, 采用 BKA 算法对 CNN 模型中的参数 (包括学习率、每次训练样本个数、正则化系数) 进行优化。算法其他相关参数设置如下: 种群规模数为 30, 优化参数搜索范围分别取 $[1 \times 10^{-3}, 5 \times 10^{-2}]$ 、 $[64, 512]$ 、 $[1 \times 10^{-5}, 1 \times 10^{-2}]$ 。全局寻优后获得的最优参数见表 5。

表 5 CNN 的最优参数
Table 5 Optimal parameters of CNN

Learning rate	Number of training samples per session	Regularization parameter
0.05	64	1×10^{-5}

3.3 模型实测与分析

为进一步验证模型的可靠性, 选用 CNN、SVM、CNN-SVM、ELM 预测模型对同一组数据进行训练测试, 并采用 F_1 值、准确率、精确率、召回率对比分析模型的预测性能。将 86 组经 KPCA 特征提取的测试样本输入各模型, 各模型预测性能见表 6。相应的混淆矩阵见图 6, 其中, 对角线元素 (从左上到右

下)表示被正确分类的样本数量,非对角线元素表示错误分类的样本数量。

由表 6 可知: BKA-CNN-SVM 的预测准确率可达 95.35%, 与 CNN-SVM 模型相比, 预测准确率增长了 12.79%, 与 CNN 模型相比, 预测精度亦提升了 22.09%。BKA-CNN-SVM 的 F_1 值、精确率、召回率均明显优于其他模型。综合考虑模型的准确率及相关评价指标, 本研究建立的 BKA-CNN-SVM 模型在岩爆烈度预测分级方面表现出较好的预测性能, 证明其在岩爆预测应用中的合理性和可行性。

表 6 各模型预测的性能结果

Table 6 Predicted performance results of each model

Test set classification accuracy/%				Precision			
BKA-CNN-SVM	CNN	CNN-SVM	ELM	BKA-CNN-SVM	CNN	CNN-SVM	ELM
95.35	73.26	82.56	67.44	0.89	0.73	0.70	0.61
F_1 score				Recall			
BKA-CNN-SVM	CNN	CNN-SVM	ELM	BKA-CNN-SVM	CNN	CNN-SVM	ELM
0.92	0.67	0.74	0.52	0.94	0.61	0.78	0.44




图 6 测试集混淆矩阵

Fig. 6 Confusion matrix of test set

4 工程应用

锦屏二级水电站位于我国西南高地应力区, 共有 7 条隧道, 包括 4 条引水隧道、2 条平行交通辅助洞以及 1 条施工排水隧道。洞线平均长度约为 16.67 km, 开挖洞径约为 13 m, 引水隧洞之间的间距为 60 m; 2 条辅助洞间隔 35 m, 平行布置在引水隧洞南侧。辅助洞围岩岩性主要为大理岩, 其饱和单轴抗压强度为 65~90 MPa, 抗拉强度为 3~6 MPa, 隧洞埋深大体处于 1 500~2 000 m, 最大埋深约为 2 525 m,

由于隧洞地质复杂、埋深大,加之高地应力等特性,导致岩爆灾害发生率较高^[23-25]。收集锦屏二级水电站岩爆实例数据 20 组^[26],将 BKA-CNN-SVM 模型应用于锦屏二级水电站岩爆烈度预测。将收集的 284 例岩爆数据作为训练集,完成 BKA-CNN-SVM 模型训练后,将 20 组岩爆实例数据作为测试集代入预测模型。为检验 BKA-CNN-SVM 模型对锦屏二级水电站岩爆预测的准确率,在相同的训练集和测试集条件下,将其与 CNN、SVM、CNN-SVM、ELM 预测模型进行对比,结果见表 7。

表 7 不同模型得到的岩爆烈度预测结果
Table 7 Rockburst intensity prediction results obtained by various models

Parameters						Actual grade	Grade predicted by models			
MTS/MPa	UCS/MPa	UTS/MPa	BCF	SCF	EEI		BKA-CNN-SVM	CNN	CNN-SVM	ELM
42.00	117.00	4.80	0.36	24.38	3.20	2	2	2	2	2
46.40	100.00	4.90	0.46	20.40	2.00	2	2	2	2	2
40.99	186.30	12.67	0.22	14.70	4.10	3	3	3	3	3
9.74	88.51	2.98	0.11	29.70	1.77	1	1	1	1	3
31.05	147.85	11.96	0.21	12.36	3.00	3	3	3	3	1
16.47	156.90	10.33	0.10	15.19	4.39	3	3	3	3	3
20.00	112.00	4.70	0.18	23.83	2.50	1	1	1	1	3
52.00	117.00	4.80	0.44	24.38	3.20	2	2	2	2	2
19.14	106.31	11.96	0.18	8.89	2.07	1	1	1	1	1
12.00	85.00	3.60	0.14	23.61	1.50	1	1	2	1	3
46.20	105.00	5.30	0.44	19.70	2.30	2	2	2	2	2
39.82	128.46	2.98	0.31	43.11	2.40	3	3	3	3	3
16.43	157.95	11.06	0.10	14.28	4.99	4	4	3	4	4
47.00	122.00	5.50	0.39	22.18	3.40	2	2	2	2	2
28.00	100.00	3.90	0.28	25.64	2.30	2	2	2	2	2
23.00	80.00	3.00	0.29	26.80	0.85	2	2	2	3	2
36.09	164.05	12.67	0.22	12.95	3.59	3	3	3	3	2
21.00	103.00	4.10	0.20	25.12	2.40	2	2	3	2	2
15.97	114.07	11.96	0.14	9.54	2.40	1	1	1	1	1
33.15	106.94	2.98	0.31	35.89	2.15	3	3	3	3	3

由表 7 可知,ELM 模型在岩爆实例判断中出现了 5 例误判,CNN 模型误判了 3 例,CNN-SVM 集成模型表现出较优的特征提取与泛化能力,仅发生 1 次误判。BKA-CNN-SVM 模型预测结果与实际情况一致,证实了该模型在实际工程应用中的可靠性与实用价值,可为实际工程提供一定的参考。

5 结 论

(1) 采用拉依达准则和 1.5 倍四分位差对数据进行清洗,消除样本中异常值对模型精度的干扰。同时,引入 KPCA 进行数据降维,保留主要特征,去除数据中的冗余信息,从而减小了模型输入参数,避免了维度灾难,提高了模型收敛速度及预测可靠性。

(2) 建立了 CNN-SVM 集成模型并应用于岩爆预测,利用 CNN 进行数据特征提取,并采用 SVM 替代传统的 CNN 分类器进行分类预测。相较于 CNN 模型,CNN-SVM 集成模型的预测精度提高了 9.3%,显示出集成模型对不平衡岩爆数据的较高预测性能。为降低人为设置参数的影响,引入黑翅鸢优化算法,建立了 BKA-CNN-SVM 预测模型,有效提升了模型的全局寻优能力,避免陷入局部最优,进一步提高了预测精度。

(3) 对锦屏二级水电站岩爆实例进行预测, BKA-CNN-SVM 的预测结果与实际情况符合得较好, 证明该模型具有较强的工程适用性。相较于 CNN、CNN-SVM、ELM 岩爆预测模型, BKA-CNN-SVM 岩爆预测模型具有更高的岩爆预测精度和稳定性。鉴于岩爆实例数据偏少, 且未考虑地质条件、岩体质量、开挖断面尺寸等因素, 因此, BKA-CNN-SVM 模型在其他工程应用中的预测性能还需进一步研究。

参考文献:

- [1] 冯夏庭, 肖亚勋, 丰光亮, 等. 岩爆孕育过程研究 [J]. 岩石力学与工程学报, 2019, 38(4): 649–673.
FENG X T, XIAO Y X, FENG G L, et al. Study on the development process of rockbursts [J]. Chinese Journal of Rock Mechanics and Engineering, 2019, 38(4): 649–673.
- [2] 汤志立, 徐千军. 基于 9 种机器学习算法的岩爆预测研究 [J]. 岩石力学与工程学报, 2020, 39(4): 773–781.
TANG Z L, XU Q J. Rockburst prediction based on nine machine learning algorithms [J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(4): 773–781.
- [3] 李宁, 王李管, 贾明涛. 基于粗糙集理论和支持向量机的岩爆预测 [J]. 中南大学学报 (自然科学版), 2017, 48(5): 1268–1275.
LI N, WANG L G, JIA M T. Rockburst prediction based on rough set theory and support vector machine [J]. Journal of Central South University (Science and Technology), 2017, 48(5): 1268–1275.
- [4] 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 S C, ZHANG C X, CHENG Z Q. Prediction of intensity classification of rockburst based on PCA-PNN principle [J]. Journal of China Coal Society, 2019, 44(9): 2767–2776.
- [5] 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(Suppl 1): 2806–2816.
LI M L, LI K G, QIN Q C, 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.
- [6] 吴茜, 郭永刚, 何军杰, 等. 基于 GWO-SVM 岩爆分级预测模型 [J]. 路基工程, 2023(1): 49–54.
WU H, GUO Y G, HE J J, et al. Rock burst classification prediction model based on GWO-SVM [J]. Subgrade Engineering, 2023(1): 49–54.
- [7] BASNET P M S, MAHTAB S, JIN A B. A comprehensive review of intelligent machine learning based predicting methods in long-term and short-term rock burst prediction [J]. [Tunnelling and Underground Space Technology](#), 2023, 142: 105434.
- [8] 靳春玲, 姬照泰, 贡力, 等. 基于 WOA-SVM 的引水隧洞岩爆烈度评估模型 [J]. 中国安全科学学报, 2023, 33(9): 41–48.
JIN C L, JI Z T, GONG L, et al. Evaluation model of rockburst intensity of diversion tunnel based on WOA-SVM [J]. China Safety Science Journal, 2023, 33(9): 41–48.
- [9] 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 K N, WU Y Q, DU F, et al. Prediction of rockburst intensity grade based on convolutional neural network [J]. [Coal Geology & Exploration](#), 2023, 51(10): 94–103.
- [10] 郭延华, 赵帅. 基于 KPCA-WOA-KELM 的岩爆烈度预测 [J]. 河北工程大学学报 (自然科学版), 2021, 38(2): 1–7.
GUO Y H, ZHAO S. Classified prediction model of rockburst using KPCA-WOA-KELM [J]. Journal of Hebei University of Engineering (Natural Science Edition), 2021, 38(2): 1–7.
- [11] YIN X, LIU Q S, PAN Y C, 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] 刘慧敏, 徐方远, 刘宝举, 等. 基于 CNN-LSTM 的岩爆危险等级时序预测方法 [J]. 中南大学学报 (自然科学版), 2021, 52(3): 659–670.
LIU H M, XU F Y, LIU B J, et al. Time-series prediction method for risk level of rockburst disaster based on CNN-LSTM [J]. Journal of Central South University (Science and Technology), 2021, 52(3): 659–670.
- [13] 辛付宇, 邢雨坤, 刘笑. 基于 CNN-GRU 神经网络的锂电池 SOH 估计与 RUL 预测 [J]. 上海节能, 2024(5): 819–826.
XIN F Y, XING L K, LIU X. SOH estimation and RUL prediction of lithium battery based on CNN-GRU neural networks [J]. Shanghai Energy Saving, 2024(5): 819–826.

- [14] 全跃, 陈亮, 黄宏伟. 基于 PSO-SVM 算法的高放废物处置北山预选区岩爆预测 [J]. *长江科学院院报*, 2017, 34(5): 68–74.
TONG Y, CHEN L, HUANG H W. Rockburst prediction of Beishan pre-selected area for disposal of high-level radioactive waste based on PSO-SVM [J]. *Journal of Yangtze River Scientific Research Institute*, 2017, 34(5): 68–74.
- [15] 陈志勇, 杜江. 基于 1D-CNN-PSO-SVM 的电力变压器故障诊断 [J]. *计算机仿真*, 2024, 41(3): 71–75, 87.
CHEN Z Y, DU J. Fault diagnosis of power transformer based on 1D-CNN-PSO-SVM [J]. *Computer Simulation*, 2024, 41(3): 71–75, 87.
- [16] WANG J, WANG W C, HU X X, et al. Black-winged kite algorithm: a nature-inspired meta-heuristic for solving benchmark functions and engineering problems [J]. *Artificial Intelligence Review*, 2024, 57(4): 98.
- [17] LIU W T, REN Y Y, MENG X Y, et al. Analysis of potential water inflow rates at an underground coal mine using a WOA-CNN-SVM approach [J]. *Water*, 2024, 16(6): 813.
- [18] 刘剑, 周宗红, 刘军, 等. 基于主成分分析和改进 Bayes 判别的岩爆等级预测 [J]. *采矿与岩层控制工程学报*, 2022, 4(5): 16–26.
LIU J, ZHOU Z H, LIU J, et al. Prediction of rockburst grade based on principal component analysis and improved Bayesian discriminant analysis [J]. *Journal of Mining and Strata Control Engineering*, 2022, 4(5): 16–26.
- [19] XU G, LI K G, LI M L, et al. Rockburst intensity level prediction method based on FA-SSA-PNN model [J]. *Energies*, 2022, 15(14): 5016.
- [20] GUO J, GUO J W, ZHANG Q L, et al. Research on rockburst classification prediction based on BP-SVM model [J]. *IEEE Access*, 2022, 10: 50427–50447.
- [21] WANG Z Y, WANG Y L, JIN X L. Prediction of grade classification of rock burst based on PCA-SSA-PNN architecture [J]. *Geofluids*, 2023(1): 5299919.
- [22] 贾义鹏. 岩爆预测方法与理论模型研究 [D]. 杭州: 浙江大学, 2015.
JIA Y P. Study on prediction method and theorial model of rockburst [D]. Hangzhou: Zhejiang University, 2015.
- [23] 张恒源, 范俊奇, 郭佳奇, 等. 基于多参量判据的深地下工程岩爆倾向性研究 [J]. *高压物理学报*, 2022, 36(2): 025202.
ZHANG H Y, FAN J Q, GUO J Q, et al. Rockburst tendency for deep underground engineering based on multi-parameters criterion [J]. *Chinese Journal of High Pressure Physics*, 2022, 36(2): 025202.
- [24] 张春生, 周垂一, 刘宁. 锦屏二级水电站深埋特大引水隧洞关键技术 [J]. *隧道建设 (中英文)*, 2017, 37(11): 1492–1501.
ZHANG C S, ZHOU C Y, LIU N. Key technologies for extremely-large deep-buried headrace tunnel: a case study of Jinping II Hydropower Station [J]. *Tunnel Construction*, 2017, 37(11): 1492–1501.
- [25] SHAN Z G, YAN P. Management of rock bursts during excavation of the deep tunnels in Jinping II Hydropower Station [J]. *Bulletin of Engineering Geology and the Environment*, 2010, 69(3): 353–363.
- [26] XIE X B, JIANG W, GUO J. Research on rockburst prediction classification based on GA-XGB model [J]. *IEEE Access*, 2021, 9: 83993–84020.

Prediction of Rockburst Grade Based on BKA-CNN-SVM Model

MU Huiwen¹, ZHOU Zonghong¹, ZHENG Faping², LIU Jian¹, ZENG Shunhong³, DUAN Yong³

(1. Faculty of Land Resources Engineering, Kunming University of Science and Technology,
Kunming 650093, Yunnan, China;

2. School of Public Safety and Emergency Management, Kunming University of Science and Technology,
Kunming 650093, Yunnan, China;

3. Yunnan Yuntianhua Polyphosphorus New Materials Co., Ltd., Zhaotong 657200, Yunnan, China)

Abstract: In order to realize efficient and accurate rockburst grade prediction, and prevent underground engineering disasters, this paper proposes a prediction model based on black-winged kite optimization algorithm-convolutional neural network-support vector machine (BKA-CNN-SVM). Firstly, the prediction

index system was established according to six influence factors of rockburst, and 284 groups of rockburst cases at home and abroad were collected to establish a rockburst database. Secondly, Laida criterion and 1.5 times quartile difference were introduced to remove and replace the outliers in the data. The kernel principal component analysis (KPCA) was used to reduce the dimension of the data and extract the features. The extracted features were used as the model inputs. Finally, the confusion matrix was used to evaluate the model performance in terms of accuracy, precision, recall, and F_1 value. BKA-CNN-SVM model was compared with convolutional neural network (CNN) model, extreme learning machine (ELM) model, and convolutional neural network and support vector machine (CNN-SVM) integrated model. The results showed that the accuracy, precision, F_1 value, and recall of BKA-CNN-SVM model are 95.35%, 0.89, 0.92, and 0.94, respectively, which are significantly better than the other models in terms of prediction accuracy and generalization degree. In order to verify the feasibility of the BKA-CNN-SVM model, it was used to prediction the rockburst grade of the Jinping secondary hydro-power station. The prediction results have high consistency with the actual field conditions. This research can provides a new method for rockburst grade prediction.

Keywords: rockburst; kernel principal component analysis; convolutional neural network; support vector machine; black-winged kite optimization