

PCA-GWO-SVR 机器学习用于边坡爆破振动速度峰值预测研究

范勇^{1,2}, 胡名东^{1,2}, 杨广栋^{1,2}, 崔先泽^{1,2}, 高启栋^{1,3}

(1. 三峡大学湖北省水电工程施工与管理重点实验室, 湖北 宜昌 443002;

2. 三峡大学水利与环境学院, 湖北 宜昌 443002; 3. 长安大学公路学院, 陕西 西安 710064)

摘要: 针对复杂场地环境下传统经验公式预测精度不高的问题, 提出了一种主成分分析(PCA)特征选取下基于灰狼优化支持向量回归机算法(PCA-GWO-SVR)的爆破振动速度峰值预测模型。以白鹤滩水电站右岸坝肩槽爆破开挖监测数据为依据, 选取爆心距、单响药量、高程差、纵波波速、炮孔间距、炮孔排距作为输入参数, 通过 PCA 的数据降维对特征值进行选取, 将选取的 6 种特征降维后化为 4 种相关性更高的特征; 使用灰狼优化算法(GWO)改进支持向量回归机(SVR)以获取最优参数; 将参数输入到 SVR 模型中进行计算评估。研究表明: PCA-GWO-SVR 算法对比萨道夫斯基公式, 改进的萨道夫斯基公式, SVR, PCA-SVR 和 GWO-SVR 的预测值和实测值的吻合效果更好, 预测结果的准确度更高, 更能有效地预测边坡爆破振动峰值, 为边坡爆破施工安全控制提供帮助。

关键词: 爆破振动; 主成分分析; 灰狼优化算法; 支持向量回归机

中图分类号: TV542 **文献标志码:** A **文章编号:** 1004-4523(2024)08-1431-11

DOI: 10.16385/j.cnki.issn.1004-4523.2024.08.017

引言

中国西南地区大型水利水电工程通常布置于深切河谷, 均涉及大规模、高强度的高陡边坡开挖。爆破作为边坡开挖的主要手段, 其诱发的振动必然会导致岩体的损伤, 严重影响边坡的安全与稳定。因此, 准确预测爆破振动速度峰值(PPV)对保障大型水电工程边坡开挖安全稳定有重要意义。

目前国内外学者普遍使用的 PPV 预测公式有: 萨道夫斯基公式、考虑高程效应的改进萨道夫斯基公式^[1]、美国矿务局公式和印度标准局公式等。这些经验公式仅仅考虑了最大单响药量、爆心距和高程差对爆破振动峰值的影响, 其他如场地介质和爆破条件等影响因素归为了公式中的经验系数^[2], 无法反映影响 PPV 的参数与 PPV 之间的非线性关系, 这导致其使用具有一定的局限性, 预测精度不高^[3]。

近年来, 机器学习越来越多的运用到实际工程数据分析中, 为 PPV 预测提供了新的思路^[4-5]。彭府华等^[6]利用 SVM(Support Vector Machines)对某

矿山爆破振动实测数据进行预测, 验证了模型的可行性、稳定性。史秀志等^[7]基于基因表达式编程(GEP)实现了爆破振动速度峰值预测。Dindarlo^[8]采用 SVM 对露天矿场 PPV 进行了预测, 选取了 12 个输入变量, 证明了该算法的适用性。陈秋松等^[9]采用灰色关联度理论(GRA)改进了 GEP 算法, 使 PPV 预测误差得到了降低。卢二伟等^[10]运用最小二乘支持向量机(LSSVM)理论对小样本 PPV 数据进行了预测, 取得了良好效果。Faradonbeh 等^[11]利用布谷鸟算法(CS)优化了 GEP 算法, 实现了铁矿爆破振动峰值准确预测。Mokfi^[12]采用数据处理群(GMDH)方法对马来西亚槟城采石场爆破振动进行了预测, 并验证了其可行性。Xu^[13]将主成分分析方法(PCA)和支持向量机(SVM)结合, 实现了红头山铜矿采场爆破振动预测。Yang^[14]分别采用萤火虫算法(FFA)、遗传算法(GA)和粒子群算法(PSO)优化支持向量回归机(SVR), 并比较了几种优化算法在爆破振动预测方面的效果。Ke^[15]将神经网络(NN)和支持向量回归机模型(SVR)混合编码, 形成杂交的智能模型对爆破振动进行预测, 预测精度显著提高。Zeng^[16]将提升卡方自动相互作用

收稿日期: 2022-09-23; **修订日期:** 2023-04-28

基金项目: 国家自然科学基金资助项目(51979152, 52209162); 湖北省高等学校优秀中青年科技创新团队计划项目(T2020005)。

检测(CHAID)与支持向量机(SVM)结合实现了爆破振动预测。

综上所述,机器学习作为一种新型的智能预测方法,在预测爆破振动速度峰值上有着良好的效果,但上述方法在稳定性上仍有不足,实测数据往往复杂多样,噪声数据参杂其中会影响预测的准确度和稳定性。本文首先采用PCA方法进行特征降维,然后采用灰狼优化算法(GWO)改进支持向量回归机(SVR),从而建立基于PCA-GWO-SVR机器学习的爆破振动速度峰值预测模型;以白鹤滩水电站右岸坝肩槽爆破开挖监测数据为依据,加入可反映场地因素的纵波波速作为输入参数,对所提出的模型进行训练和检验,并与传统经验公式和其他智能预测模型进行对比,验证PCA-GWO-SVR模型的适用性和优越性。

1 基于PCA-GWO-SVR算法的爆破振动速度峰值智能预测模型构建

本文提出的基于机器学习的爆破振动速度峰值预测模型构建步骤如下:(1)为了降低爆破振动实测数据内不同参数的量纲和量级差异带来的支配性影响,采用极值归一化处理;(2)采用PCA方法对复杂参数进行特征选取,筛选出影响PPV较大的关键参数作为输入特征;(3)引入GWO算法,利用其收敛性较好,参数选取较少,易实现的优势进行参数优化,迭代选取最有利于提高预测精度的参数;(4)结合SVR方法对优化后的模型参数进行预测建模。

1.1 数据划分及预处理

模型预测前需要对原始数据进行数据划分和预处理,收集有关装药结构、场地环境信息,如装药量、爆心距、纵波波速、高程差及炮孔排间距等。这些不同类型的特征参数量纲各异,且数据量级差距较大。例如,爆破振动在岩石介质中的传播速度可达3000~4000 m/s,而其爆心距仅有几十米。它们都是表征PPV大小的重要因素。

由于大多数特征选择和机器学习算法没有伸缩不变性,因此必须在数据分析之前对数据进行预处理,以避免由于数据挖掘过程中的大小差异而导致某些参数的支配性作用,对数据进行归一化处理可以很好地解决特征向量量纲存在差异的问题:

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中 x_n 为归一化后的无量纲值; x 为原始数据; x_{\min}

为原始数据的最小值; x_{\max} 为原始数据的最大值。极值归一化处理可以将维度数据无量纲化,同时将数据缩放到区间 $[0, 1]$,以增强模型的预测效果,提高其收敛速度和预测精度。

1.2 主成分分析PCA模型构建

工程现场收集到的数据众多,只需选取相关性最高的参数进行数据分析。因此,为了充分挖掘不同参数与PPV间的变化规律,实现有效的爆破振动速度峰值预测,需合理、准确地选取对PPV变化较为敏感的参数作为后续机器学习的输入参数。

本文采用主成分分析(PCA)方法^[17]对数据进行预处理。它的原理是通过空间坐标转换将原有数据对应的坐标转化到另外一组坐标系下,在新的坐标系下,把多种变量数据转化为少数几个彼此互不相关的主成分^[18],其主要的原理是进行数据降维。PCA算法的具体步骤划分为以下6步^[19]:

1.2.1 标准化处理原始数据

原始数据(归一化后的矩阵) X' 、标准化配方 M_{ij} 及标准化矩阵 M 为:

$$\begin{cases} X' = (x_{ij})_{n \times p} = (X'_1 X'_2 \cdots X'_p) \\ M_{ij} = (x_{ij} - \bar{x}_j) / S_j, i = 1, 2, \dots, n; j = 1, 2, \dots, p \\ \bar{x}_j = \sum_{i=1}^n x_{ij} / n, S_j^2 = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2 / (n-1) \\ M = (M_{ij})_{n \times p} = (M_1 M_2 \cdots M_p) \end{cases} \quad (2)$$

式中 $(x_{ij})_{n \times p}$ 表示数据样本有 n 个,每个数据样本有 p 维变量; \bar{x}_j 为第 j 个变量的平均值; S_j 为第 j 个变量的标准差。

1.2.2 计算相关系数矩阵

相关系数矩阵 R'' 为:

$$R'' = \frac{1}{n-1} M^T M \quad (3)$$

式中 R'' 为一个 $n \times n$ 维对称矩阵,对角线数据都为1。

1.2.3 求矩阵的协方差矩阵,进而求出对应的特征值 λ_i 及特征向量

λ_i 通过式 $|\lambda I - R''| = 0$ 获得, I 为单位矩阵,然后将 λ_i 按尺寸大小排序, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ 。

特征向量 MX'_i 通过下式获得:

$$MX'_i = (MX'_{i1} MX'_{i2} \cdots MX'_{ip})' \quad (4)$$

1.2.4 确定主成分的数量

主成分的贡献率 α_{1i} 与前 m 个主成分的累计贡献率 $C_1 T_i$ 为:

$$\begin{cases} \alpha_{1i} = \lambda_i / \sum_{i=1}^p \lambda_i \\ C_1 T_i = \sum_{i=1}^m \lambda_i / \sum_{i=1}^p \lambda_i \end{cases} \quad (5)$$

一般累计贡献率 $C_1 T_i > 86\%$, 选前 m 个主成分。

1.2.5 求主成分的表达式

主成分的表达式为:

$$F_i = MX'_{i1} \times M_1 + MX'_{i2} \times M_2 + \dots + MX'_{ip} \times M_p \quad (6)$$

1.2.6 求综合评价功能

综合评价功能为:

$$F = (\lambda_1 F_1 + \lambda_2 F_2 + \dots + \lambda_m F_m) / (\lambda_1 + \lambda_2 + \dots + \lambda_m) \quad (7)$$

1.3 灰狼优化算法 GWO 模型构建

爆破过程中影响 PPV 大小的参数众多, 并且参数间存在着复杂的非线性关系。对于处理此类维度高及非线性的数据问题, 传统的预测公式在处理非线性问题上预测精度不高。因此需要寻找一种能改善算法精度、增加其稳定性、有效收敛的方法来优化参数。

灰狼优化算法(GWO)具有较强的收敛性、参数较少、容易实现等优点。GWO 算法模拟了自然界灰狼的领导层级和狩猎机制。图 1 所示 4 种类型的灰狼, 包括 α, β, δ 和 ω , 被用于模拟领导层级。GWO 可以描述为 ω 跟随 α, β 和 δ 搜索和包围猎物的过程, 并且猎物 R_1 的位置是最佳的。具体流程如图 1 所示^[19]。

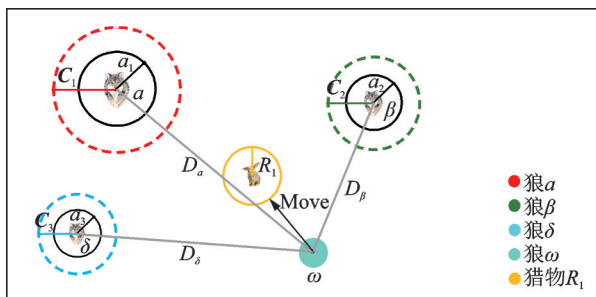


图 1 GWO 算法流程图^[20]

Fig. 1 GWO algorithm flow diagram^[20]

GWO 算法的数学模型如下:

$$\bar{D} = |2\bar{r}_2 \cdot \bar{X}_p(t) - \bar{X}(t)| \quad (8)$$

$$\bar{X}(t+1) = \bar{X}_p(t) - (2\bar{a} \cdot \bar{r}_1 - \bar{a}) \cdot \bar{D} \quad (9)$$

式中 t 表示当前迭代; \bar{X}_p 为猎物的位置向量; \bar{X} 表示 1 只灰狼的位置向量; \bar{D} 表示灰狼与其猎物间的距离; \bar{a} 的分量在迭代过程中从 2 线性减小到 0, \bar{r}_1 和 \bar{r}_2 为 $[0, 1]$ 中的随机向量。

为了对灰狼的捕猎行为进行数学建模, 假设 α, β 和 δ 对猎物 R_1 的潜在位置有了更好的了解。因此, 保存当前可用的 3 个最佳解决方案, 并强制其他搜索代理根据最佳搜索代理的位置更新其位置:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (10)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 = X_\beta - A_2 \cdot D_\beta \\ X_3 = X_\delta - A_3 \cdot D_\delta \end{cases} \quad (11)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (12)$$

式中 C_1, C_2, C_3 表示控制狼的行为的系数向量; $X_\alpha, X_\beta, X_\delta$ 分别为当前种群中的 3 个等级狼群的位置向量; X 表示灰狼的位置向量; $D_\alpha, D_\beta, D_\delta$ 分别表示当前候选狼群与最优 3 只狼的距离; A 表示控制狼行为的系数向量 (A 指代式 (11) 中的 A_1, A_2 和 A_3), 当 $|A| > 1$ 时, 灰狼之间尽量分散在各区域并搜寻猎物; 当 $|A| < 1$ 时, 灰狼将集中搜索某个或某些区域的猎物。

1.4 支持向量回归机 SVR 模型构建

为了探究爆破振动在传播过程中各特征间的相互作用以及存在的非线性关系, 需在特征样本中寻求一个最佳超平面, 通过目标函数将原始训练数据映射到更高维中, 在扩维后的样本空间进行计算, 得到期望值。

支持向量回归机(SVR)作为一种基于统计理论的机器学习方法, 在处理非线性回归问题上具有独特的优势^[21-22]。同时, 因为工程实测数据在收集时不可避免有噪声和异常值^[23], 采用 SVR 方法可以依靠少量样本点作为支持向量来确定预测模型, 对噪声和离群值拥有一定的鲁棒性^[24]。其结构图如图 2 所示^[25]。

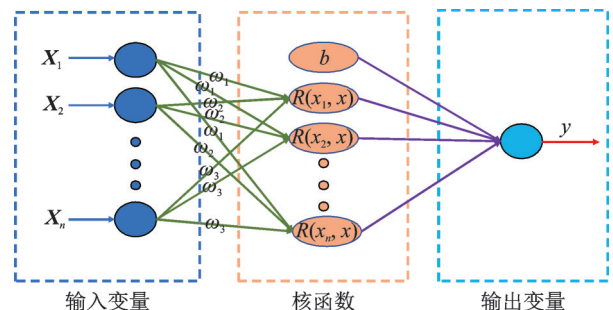


图 2 SVR 结构图^[25]

Fig. 2 Structure diagram of SVR^[25]

SVR 目标函数和约束条件^[26]为:

$$\begin{cases} \min_{w,b} \frac{1}{2} \|\omega'\|^2 + c \sum_{i=1}^m (\xi_i + \xi_i^*) \\ y_i - \omega'x - b' \leq g + \xi_i \\ \omega'x + b'i - y_i \leq g + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (13)$$

式中 ω' 为尺寸权重向量; c 为惩罚因子; ξ_i 和 ξ_i^* 为

$$L = \frac{1}{2} \omega' \cdot \omega' + c \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i [\xi_i + g - y_i + f(x_i)] - \sum_{i=1}^n \alpha_i^* [\xi_i^* + g - y_i + f(x_i)] - \sum_{i=1}^n (\xi_i \gamma_i + \xi_i^* \gamma_i^*) \quad (15)$$

式中 $\alpha_i, \alpha_i^* \geq 0, \gamma_i, \gamma_i^* \geq 0$, 为拉格朗日乘数, $i = 1, 2, \dots, n$ 。

c 和 g 两个参数的设定大小直接影响到最后预测模型的准确度, 为了防止因偶然因素和人为干扰对结果的影响, 选择通过 GWO 算法确定 SVR 算法中 c 和 g 的具体数值。

1.5 基于 PCA-GWO-SVR 的 PPV 预测流程

单纯使用 SVR 对于损失函数构成的模型, 无法确定权重大小, 很容易导致过拟合, 而过拟合的根本原因是样本中太多的特征被包含进来, 从而使得模型预测的准确度降低。其中的两个重要参数惩罚因子 c 和误差系数 g (必须大于 0) 的选取根据经验取得, 对模型的预测准确度有很大的影响。PCA-GWO-SVR 模型的搭建思路为: 通过主成分分析 PCA 将数据特征进行降维, 使得特征相关性简单化, 同时利用 GWO 算法迭代计算优化 SVR 的 2 个参数 c 和 g ; 将最后计算得出的值与实测爆破振动速度峰值进行对比。其具体的流程如图 3 所示。

1.6 模型评估指标

模型经过计算预测后应对计算结果进行评估, 以验证该算法的准确度与适用性。在本研究中, 采用以下 4 个性能评价系数: 决定系数 r^2 、均方误差 MAE、平均绝对误差 RMSE 和平均绝对百分比误差 MAPE^[27-28]。计算公式分别如下:

$$r^2 = 1 - \frac{\sum_{i=1}^N (y - \hat{y})^2}{\sum_{i=1}^N (y - \bar{y})^2} \quad (16)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y - \hat{y}| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y - \hat{y})^2} \quad (18)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y - \hat{y}}{y} \right| \quad (19)$$

式中 y, \hat{y} 和 \bar{y} 分别为实测值、预测值和平均值; N 为数据样本。

松弛变量; y_i 为输出变量; b' 为偏移量; g 为误差系数。 ξ_i 和 ξ_i^* 取值为:

$$\begin{cases} \xi_i = y_i - (\omega'x + b' + g), y_i > \omega'x + b' + g \\ \xi_i^* = (\omega'x + b' - g) - y_i, y_i < \omega'x + b' - g \end{cases} \quad (14)$$

其他情况 ξ_i 和 ξ_i^* 取为 0, 为了使目标函数最小化, 需根据约束条件构造拉格朗日函数:

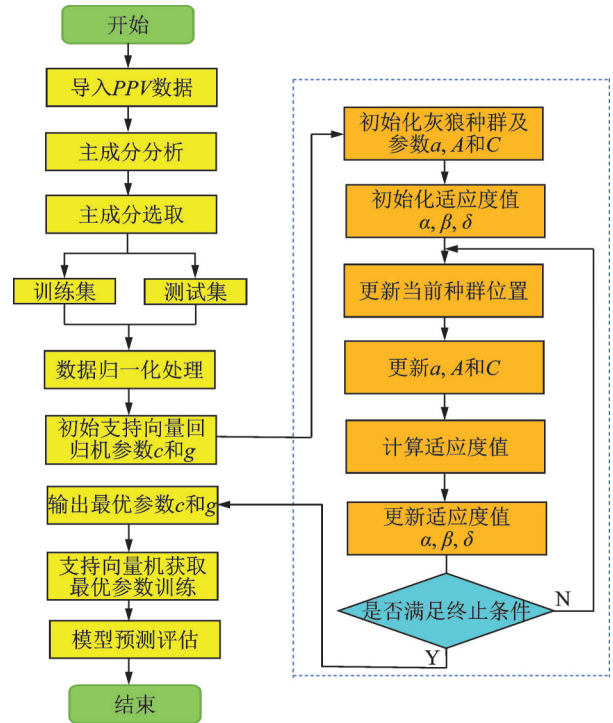


图 3 PCA-GWO-SVR 模型流程图

Fig. 3 PCA-GWO-SVR model flow diagram

2 工程概况和数据收集

2.1 工程概况

白鹤滩水电站位于金沙江下游, 坝型为混凝土双曲拱坝 (如图 4(a) 所示), 坝高 289 m。在混凝土浇筑前, 应先进进行坝址处强风化岩体爆破开挖过程, 如图 4(b) 所示, 边坡开挖高度达 400 m, 采用分层爆破方式依次进行开挖。爆破必然会产生振动, 从而影响边坡稳定, 加上坝址处地质条件复杂, 柱状玄武岩节理发育, 小规模间断层较多 (如图 5 所示), 使得边坡爆破施工的安全稳定问题更加突出。

2.2 爆破振动监测

为了评估爆破损伤, 防止爆破振动过大引起边坡失稳, 在边坡分层开挖过程中进行爆破振动监测。以高程 824~834 m 爆破开挖为例, 相关爆破参数如



(a) 工程概貌 (a) Project overview
(b) 爆破开挖图 (b) Blasting excavation drawing

图 4 白鹤滩水电站工程全貌

Fig. 4 Panorama of Baihetan hydropower station




图 5 坝肩槽开挖边坡典型径向剖面^[29]

Fig. 5 Typical radial profile of excavated slope of dam abutment groove^[29]


表 1 所示。采用预裂爆破技术,爆破设计如图 6(a) 所示。首先起爆预裂孔,然后主爆孔,最后缓冲孔。根据地形条件及现场场地条件,在爆破区域后方共

布置 12 个测点,测点位置如图 6(b)和(d)所示。采用 TC-4850 爆破监测仪,现场安装如图 6(c)所示。

表 1 824~834 m 爆破参数

Tab. 1 824~834 m blasting parameters


序号	孔名	钻孔参数			装药参数				
		孔距/m	孔深/m	孔径/mm	药卷直径/mm	堵塞长度/m	单孔药量/kg	最大单响药量/kg	总装药量/kg
1	预裂孔	0.55~0.80	2.2~11.7	90	32	0.5~2.0	2.40~3.75	18.75	
2	缓冲孔	1.8	9.5~11.7	90	70	0.8~2.0	15.0~19.5	39	800
3	主爆孔	3.0	9.5~11.7	90	70	0.8~2.0	21.0~27.0	54	




(a) 爆破设计 (a) Blasting design



(c) 监测仪器 (c) Monitoring instrument



(b) 爆破振动测点布置图 (b) Layout of blasting vibration measuring points



(d) 现场测点布置图 (d) Layout of on-site measuring points

图 6 爆破设计及振动监测试验

Fig. 6 Blasting design and vibration test

实测爆破振动波形如图 7 所示。波形主要由 3 段组成,分别由预裂孔、主爆破孔和缓冲孔起爆产生,取其最大值,即可获得 PPV。

收集白鹤滩水电站右岸坝肩槽 634~864 m 高程爆破开挖实测振动速度峰值 PPV 如表 2 所示,共计 107 组。表 2 中还给出了对应的单响药量 Q 、爆心距 R 、测点高程差 H 、岩体纵波波速 C_p 、孔间距 a 和排间距 b 。

2.3 岩体声波检测

由于具有高程差,爆破振动的传播路径主要集

中在岩体内部(白鹤滩水电站的测点布置分为两大类:第一类布置在顶部岩体,第二类布置在马道上),因此,采用纵波波速可以反映岩体在传播途径上的结构特征。结合实地环境,采用 HX-SYB 智能型岩石声波仪检测爆源近区 10 m 左右深度的纵波波速,单孔和跨孔声波监测实验如图 8 所示。测试过程中,将声级计传感器放置在测试孔底部,并向测试孔注水,直到水流出孔,关小钻孔注水阀门,保持钻孔孔口有水流出即可;操作声波仪进行检测、读数并记录;按照 0.2 m 的间隔进行读数,对每一测点测读两




图7 实测爆破振动波形图

表2 白鹤滩右岸坝肩槽爆破振动数据

Tab. 2 Blasting vibration data of the right bank dam abutment groove of Baihetan

序号	Q/kg	R/m	H/m	$C_p/(m \cdot s^{-1})$	a/m	b/m	PPV/($m \cdot s^{-1}$)
1	63.68	11.8	10	3737	0.80	0.80	9.53
2	63.68	23.8	20	4292	0.78	0.78	4.94
3	56.85	23.8	20	4536	0.70	0.70	6.74
4	50.25	23.4	20	4567	0.74	0.74	6.47
5	20.80	60.5	50	4375	0.73	0.73	1.21
6	20.80	48.3	40	4375	0.73	0.73	2.83
7	20.80	48.3	40	4199	0.70	0.70	2.12
8	56.85	36.1	30	4536	0.70	0.70	3.67
9	63.68	11.8	10	4292	0.78	0.78	8.24
...
107	64.87	24	20	4755	0.80	0.80	5.27

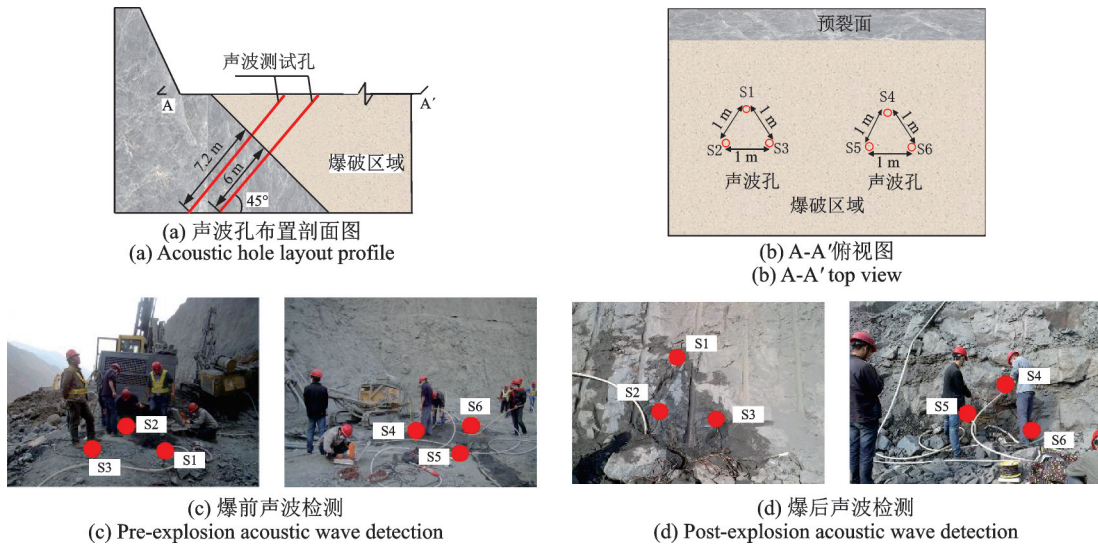


图8 声波孔布置及现场声波监测

Fig. 8 Acoustic wave hole layout and field acoustic wave detection

次,取其平均值。第一类测点的纵波波速选取的是非损伤区爆前、爆后的平均值,第二类选取的是爆后

损伤区声波速度的平均值,某层边坡开挖实测声波曲线如图9所示。




图9 824~834 m 爆前、爆后岩体声波测试结果

Fig. 9 Acoustic wave test results of rock mass before and after 824~834 m blasting

3 模型训练与检验

3.1 萨道夫斯基公式预测

收集整理白鹤滩水电站右岸坝肩槽开挖的 107 组数据的前 96 组数据和高程 824~834 m, 利用萨道夫斯基公式和改进的萨道夫斯基公式进行拟合:

$$PPV = k(\sqrt[3]{Q}/R)^{\alpha_1} \quad (20)$$

$$PPV' = k'(\sqrt[3]{Q'}/R')^{\alpha'}(\sqrt[3]{Q'}/H)^{\beta_1} \quad (21)$$

式中 PPV 和 PPV' 为爆破振动峰值; R, R' 为爆心距; Q, Q' 为最大单响药量; H 为爆区与观测点或建筑物、防护目标的高程差; k, k' 为场地系数; α_1, α' 为爆破振动衰减系数; β_1 为高程影响系数。

拟合时, 先将公式(20)和(21)两边同时取对数, 如下式:

$$\ln PPV = \alpha_1 \ln(\sqrt[3]{Q}/R) + \ln k \quad (22)$$

$$\ln PPV' = \alpha' \ln(\sqrt[3]{Q'}/R') + \beta_1 \ln(\sqrt[3]{Q'}/H) + \ln k' \quad (23)$$

令 $y = \ln PPV, x = \ln(\sqrt[3]{Q}/R), b_1 = \ln k$; 令改进公式 $y' = \ln PPV', x_1 = \ln(\sqrt[3]{Q'}/R'), x_2 = \ln(\sqrt[3]{Q'}/H), b_2 = \ln k'$, 则式(22), (23)可化为:

$$y = \alpha_1 x + b_1 \quad (24)$$

$$y' = \alpha' x_1 + \beta_1 x_2 + b_2 \quad (25)$$

采用最小二乘法及回归分析来进行拟合的结果如表 3 所示。

序号 1 为萨道夫斯基公式, 序号 2 为改进的萨道夫斯基公式。根据表 3 中的拟合结果, 还原后可得到 PPV 衰减公式:

$$PPV = 32.29(\sqrt[3]{Q}/R)^{0.90} \quad (26)$$

$$PPV_1 = 365.74(\sqrt[3]{Q'}/R')^{1.77} \quad (27)$$

$$PPV' = 31.02(\sqrt[3]{Q'}/R')^{0.85}(\sqrt[3]{Q'}/H)^{0.06} \quad (28)$$


表 3 两种公式拟合结果

Tab. 3 Fitting results of two formulas


序号	类型	参数值			
		α_1	β_1	k	r^2
1	96 组	0.90	—	32.29	0.65
	824~834 m	1.77	—	365.74	0.88
2	96 组	0.85	0.06	31.02	0.69
	824~834 m	1.77	-1.40	60.19	0.76

$$PPV'_1 = 60.19(\sqrt[3]{Q'}/R')^{1.77}(\sqrt[3]{Q'}/H)^{-1.40} \quad (29)$$

利用公式(26)和(28)中拟合得到的 k, α_1 和 β_1 对后 11 组实测数据进行预测, 结果如图 10 所示。



(a) 萨道夫斯基公式
(a) Sadaovsk formula



(b) 改进萨道夫斯基公式
(b) Improved Sadaovsk formula

图 10 后 11 组数据实测值与预测值对比

Fig. 10 Comparison between measured values and predicted values of the last 11 groups of data

利用公式(27)和(29)中拟合得到的 k, α_1 和 β_1 对高程 824~834 m 实测数据进行预测, 结果如表 4 所示。

表 4 两种公式预测误差对比

Tab. 4 Comparison of forecast errors of two formulas

序号	实测值/(cm·s ⁻¹)	萨道夫斯基公式		改进萨道夫斯基公式	
		预测值/(cm·s ⁻¹)	误差/%	预测值/(cm·s ⁻¹)	误差/%
1	11.18	30.46	172.44	16.01	43.22
2	9.55	26.18	174.14	13.23	38.55
3	3.32	8.02	141.63	7.87	136.99
4	2.76	8.02	190.66	7.87	185.07
5	2.93	8.27	182.13	8.17	178.88

从表4中实测值与预测值可以看出,萨道夫斯基公式的误差值均在140%以上,预测效果准确度较低,而加入高程效应的改进萨道夫斯基公式各项数据预测误差均比萨道夫斯基公式预测误差要低,说明高程可作为影响PPV的一个重要参数。但改进的萨道夫斯基公式最低误差为38.55%,预测准确度较差,说明还需考虑其他因素的影响。纵波波速可以很好地反映岩体裂隙和结构面发育程度的影响,因此选择加入纵波波速作为PPV的影响因素。

不同炮孔间的炮孔布置也会互相产生干扰,因此,考虑将炮孔排距、间距作为影响因素加入到模型中去。

3.2 GWO-SVR模型内部参数选取

GWO-SVR模型选择输入的参数为 Q, R, H, C_p, a 和 b ,利用GWO优化算法对参数进行优化,GWO-SVR各参数采用试算法^[30]多次取值进行训练,最优参数设置如下:采用径向基(高斯)核函数、种群最大数量设为15、最大迭代数设为50、最小搜索范围设为 $[0, 0, 0]$ 、最大搜索范围设为 $[10, 10, 100]$ 。从表2中随机选取96组数据作为学习样本训练模型,剩余11组作为样本集进行检验。选择的迭代次数为50次,得到的适应度曲线如图11所示,得到的优化改进的参数 $c=4.8353744, g=0.0441592$ 。




图11 GWO-SVR适应度曲线

Fig. 11 GWO-SVR fitness curve

3.3 基于PCA方法的特征选取

在对实测数据进行预测之前,需处理掉与爆破振动速度峰值PPV关联性较小、甚至不相关的特征,从而提高数据处理的速度。影响PPV的参数有6个:最大单响药量 Q 、爆心距 R 、高程差 H 、纵波波速 C_p 、孔间距 a 和排间距 b 。采用PCA进行特征降维,获得各成分的贡献值,如图12所示。

由图12可以看出,前4个主成分 Q, R, H 和 C_p 分别占据了40%,29%,13%和12%的信息量,前4个总和几乎包含了94%(>86%)的特征信息,因此,以占比10%为界,取 Q, R, H 和 C_p 作为输入参数。




图12 PCA降维输入参数占比图

Fig. 12 PCA dimension reduction input parameter ratio diagram

3.4 PCA-GWO-SVR模型内部参数选取

经过PCA降维分析后,选取前4个主成分 Q, R, H 和 C_p 作为输入变量,引入到GWO算法中进行参数优化。参数设置及迭代次数同上,得到的适应度曲线如图13所示,得到的优化改进的参数 $c=4.2562448, g=0.1835821$ 。




图13 PCA-GWO-SVR适应度曲线

Fig. 13 PCA-GWO-SVR fitness curve

3.5 四种模型训练结果

确定模型参数后,采用表2中收集到的数据,分别对SVR,PCA-SVR,GWO-SVR和PCA-GWO-SVR模型进行训练。通过 $r^2, MAE, RMSE$ 和 $MAPE$ 指标进行评估,结果如表5所示。

表5 四种模型预测后评价指标对比

Tab. 5 Comparison of evaluation indexes after prediction of four models

训练模型	评价指标			
	r^2	MAE	RMSE	MAPE/%
SVR	0.628	2.697	1.461	25.51
PCA-SVR	0.524	3.185	1.251	33.04
GWO-SVR	0.786	1.161	0.785	18.35
PCA-GWO-SVR	0.949	0.285	0.435	8.41

由表5可以看出,经过多次模型训练后,PCA-GWO-SVR相较于其他几种模型训练效果最好,相关系数 r^2 达到了0.949,平均绝对百分比误差MAPE减小到了8.41%。从结果上可以看出,经过PCA降维和灰狼算法GWO改进后,支持向量回归

机 SVR 模型训练准确度有了显著提升。

3.6 四种模型预测结果分析与评估

SVR,PCA-SVR,GWO-SVR和PCA-GWO-SVR

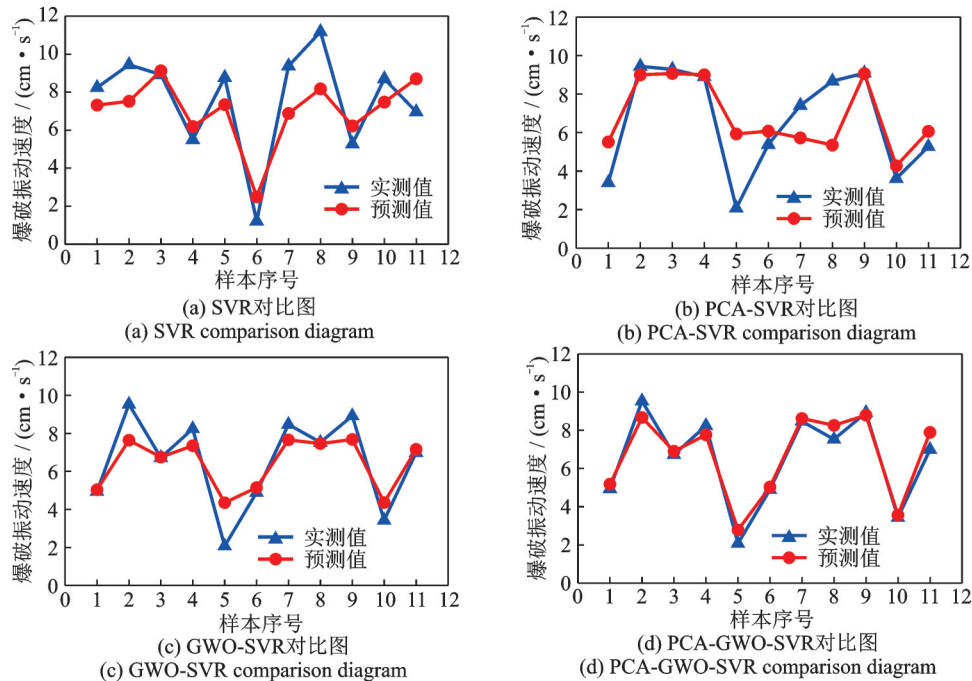


图 14 四种模型实测值与预测值对比

Fig. 14 Comparison between measured values and predicted values of four models

将四种模型预测结果和图 10 两种公式预测结果进行误差分析,如图 15 所示。PCA-GWO-SVR 模型的最大误差为 25.56%,萨道夫斯基公式的最大误差为 30.25%,改进的萨道夫斯基公式的最大误差为 18.21%,SVR 的最大误差达到了 105.75%,

PCA-SVR 的最大误差达到了 186.47%,GWO-SVR 的最大误差达到了 110.3%。对比平均误差百分比可以看出,PCA-GWO-SVR 的平均误差百分比最低,表明该模型预测准确度最高,与真实结果更加接近。

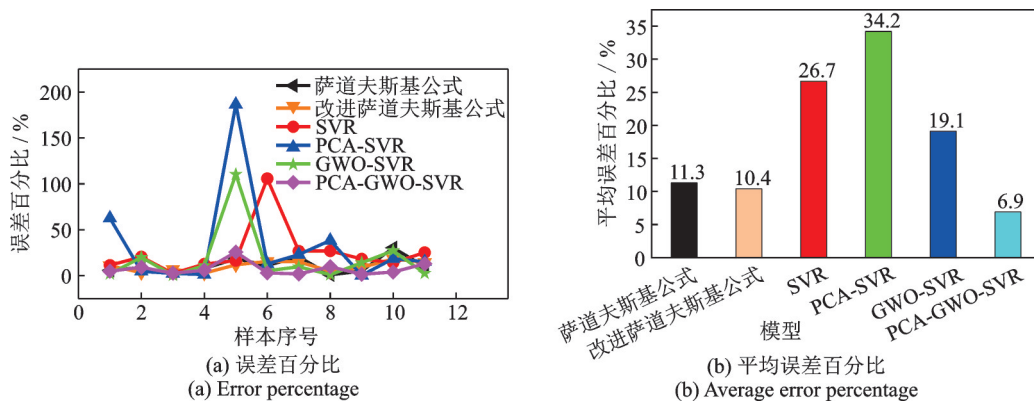


图 15 四种模型和两种公式预测结果误差分析

Fig. 15 Error analysis of predicted results of four models and two formulas

4 结 论

本文采用主成分分析 PCA 方法进行特征降维,利用灰狼优化算法(GWO)改进支持向量回归机(SVR),构建了基于 PCA-GWO-SVR 机器学习的

爆破振动速度峰值预测模型,并成功应用于白鹤滩水电站拱坝坝肩槽爆破开挖振动预测。训练和预测结果显示,基于 PCA-GWO-SVR 算法预测平均误差百分比只有 6.9%,相较于萨道夫斯基公式、改进的萨道夫斯基公式、SVR、PCA-SVR 和 GWO-SVR 算法,分别降低了 4.4%,3.5%,19.8%,27.3% 和

12.2%, 这表明 PCA-GWO-SVR 模型可以有效预测边坡爆破振动峰值, 为边坡爆破施工安全控制提供帮助。

参考文献:

- [1] 蒋楠, 周传波, 平雯, 等. 岩质边坡爆破振动速度高程效应[J]. 中南大学学报(自然科学版), 2014, 45(1): 237-243.
Jiang Nan, Zhou Chuanbo, Ping Wen, et al. Altitude effect of blasting vibration velocity in rock slopes[J]. Journal of Central South University (Science and Technology), 2014, 45(1): 237-243.
- [2] Hu X, Qu S. A new approach for predicting bench blasting-induced ground vibrations: a case study[J]. The Journal of the Southern African Institute of Mining and Metallurgy, 2018, 118(5): 531-538.
- [3] Rezaeineshat A, Monjezi M, Mehrdaneh A, et al. Optimization of blasting design in open pit limestone mines with the aim of reducing ground vibration using robust techniques[J]. Geomechanics and Geophysics for Geo-Energy and Geo-Resources, 2020, 6(2): 1-14.
- [4] 汪磊, 谢彦初, 孙德安, 等. 基于 GS-SVM 的膨胀土边坡防护工程健康预测模型[J]. 中南大学学报(自然科学版), 2022, 53(1): 250-257.
Wang Lei, Xie Yanchu, Sun Dean, et al. Health prediction model of expansive soil slope protection works based on GS-SVM[J]. Journal of Central South University (Science and Technology), 2022, 53(1): 250-257.
- [5] 张伟光, 钟靖涛, 于建新, 等. 基于机器学习和图像处理的路面裂缝检测技术研究[J]. 中南大学学报(自然科学版), 2021, 52(7): 2402-2415.
Zhang Weiguang, Zhong Jingtao, Yu Jianxin, et al. Research on pavement crack detection technology based on convolution neural network[J]. Journal of Central South University (Science and Technology), 2021, 52(7): 2402-2415.
- [6] 彭府华, 刘建. 爆破振动峰值速度预测的 SVM 模型及应用[J]. 湖南有色金属, 2021, 37(3): 11-13.
Peng Fuhua, Liu Jian. SVM model for predicting the peak velocity of blasting vibration and its application[J]. Hunan Nonferrous Metals, 2021, 37(3): 11-13.
- [7] 史秀志, 陈新, 史采星, 等. 基于 GEP 的爆破峰值速度预测模型[J]. 振动与冲击, 2015, 34(10): 95-99.
Shi Xiuzhi, Chen Xin, Shi Caixing, et al. Prediction model for blasting-vibration-peak-speed based on GEP [J]. Journal of Vibration and Shock, 2015, 34(10): 95-99.
- [8] Dindarloo S R. Peak particle velocity prediction using support vector machines: a surface blasting case study [J]. Journal of the Southern African Institute of Mining and Metallurgy, 2015, 115(7): 637-643.
- [9] 陈秋松, 张钦礼, 陈新, 等. 基于 GRA-GEP 的爆破峰值速度预测[J]. 中南大学学报(自然科学版), 2016, 47(7): 2441-2447.
Chen Qiusong, Zhang Qinli, Chen Xin, et al. Prediction of blasting-vibration-peak-speed based on GRA-GEP[J]. Journal of Central South University (Science and Technology), 2016, 47(7): 2441-2447.
- [10] 卢二伟, 史秀志, 陈佳耀. 基于 LS-SVR 小样本容量的爆破振动峰值速度预测研究[J]. 世界科技研究与发展, 2016, 38(6): 1258-1261.
Lu Erwei, Shi Xiuzhi, Chen Jiayao. Prediction research for blasting-vibration-peak-speed based on LS-SVR in small sample space[J]. World Science and Technology Research and Development, 2016, 38(6): 1258-1261.
- [11] Faradonbeh R S, Monjezi M. Prediction and minimization of blast-induced ground vibration using two robust meta-heuristic algorithms[J]. Engineering with Computers, 2017, 33(4): 835-851.
- [12] Mokfi T. Proposing of a new soft computing-based model to predict peak particle velocity induced by blasting [J]. Engineering with Computers, 2018, 34(4): 881-888.
- [13] Xu S D. Optimization of blasting parameters for an underground mine through prediction of blasting vibration [J]. Journal of Vibration and Control, 2019, 25(9): 1585-1595.
- [14] Yang H Q. Prediction of vibration velocity generated in mine blasting using support vector regression improved by optimization algorithms[J]. Natural Resources Research, 2019, 29(2): 807-830.
- [15] Ke B, Nguyen H, Bui X N, et al. Estimation of ground vibration intensity induced by mine blasting using a state-of-the-art hybrid autoencoder neural network and support vector regression model[J]. Natural Resources Research, 2021, 30(3): 3853-3864.
- [16] Zeng J. Prediction of peak particle velocity caused by blasting through the combinations of boosted-CHAID and SVM models with various kernels[J]. Applied Sciences, 2021, 11(8): 3705.
- [17] 叶涛, 韦阿娟, 黄志, 等. 基于主成分分析法与 Bayes 判别法组合应用的火山岩岩性定量识别: 以渤海海域中生界为例[J]. 吉林大学学报(地球科学版), 2019, 43(3): 873-880.
Ye Tao, Wei Ajuan, Huang Zhi, et al. Quantitative identification of volcanic lithology based on the combination of principal component analysis method and Bayes discriminant method: a case study of mesozoic in Bohai Bay[J]. Journal of Jilin University (Earth Science Edition), 2019, 43(3): 873-880.
- [18] 史耀凡, 栾元重, 于水, 等. 基于 PCA-GA-SVM 模型的地表下沉系数预测[J]. 矿业研究与开发, 2022, 42(2): 65-69.
Shi Yaofan, Luan Yuanzhong, Yu Shui, et al. Prediction of surface subsidence coefficient based on PCA-GA-SVM model[J]. Mining Research and Development,

- 2022, 42(2): 65-69.
- [19] Li L M, Zhao J, Wang C R. Comprehensive evaluation of robotic global performance based on modified principal component analysis[J]. International Journal of Advanced Robotic Systems, 2022, 17(4): 220-226.
- [20] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [21] 赖永标. 支持向量机在地下工程中的应用研究[D]. 青岛: 山东科技大学, 2004: 22-24.
Lai Yongbiao. Application and study of support vector machine in the underground engineering[D]. Qingdao: Shandong University of Science and Technology, 2004: 22-24.
- [22] 王健. 基于机器学习的 TBM 掘进性能预测与岩体参数表征方法研究[D]. 济南: 山东大学, 2017: 20-23.
Wang Jian. Research on TBM performance prediction and rock mass parameters characterization method based on machine learning[D]. Jinan: Shandong University, 2017: 20-23.
- [23] Yang J P, Chen W Z, Li M, et al. Structural health monitoring and analysis of an underwater TBM tunnel [J]. Tunnelling and Underground Space Technology, 2018, 82: 235-247.
- [24] Boser B E, Guyon I M, Vapnik V N. A training algorithm for optimal margin classifier[C]//Proceedings of the Fifth Annual Workshop on Computational Learning Theory. New York: Association for Computing Machinery, 1992: 144-152.
- [25] Chen K, Laghrouche S, Djerdir S. Remaining useful life prediction for fuel cell based on support vector regression and grey wolf optimizer algorithm[J]. IEEE Transactions on Energy Conversion, 2021, 37(2): 778-787.
- [26] Shilton A, Lai D, Palaniswami M. A division algebraic framework for multidimensional support vector regression[J]. IEEE Transactions on Systems Man and Cybernetics, Part B: Cybernetics, 2009, 40(2): 517-528.
- [27] Hui Y, Wang Y G, Peng H, et al. Subway passenger flow prediction based on optimized PSO-BP algorithm with coupled spatial-temporal characteristics[J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 210-222.
- [28] Zhou J, Qiu Y G, Khandelwal M, et al. Developing a hybrid model of jaya algorithm-based extreme gradient boosting machine to estimate blast-induced ground vibrations[J]. International Journal of Rock Mechanics and Mining Sciences, 2021, 145: 1365-1609.
- [29] 孙鹏昌, 卢文波, 杨招伟, 等. 白鹤滩坝肩边坡开挖爆破损伤预测研究[J]. 水力发电学报, 2022, 41(10): 1-11.
Sun Pengchang, Lu Wenbo, Yang Zhaowei, et al. Prediction of rock damage induced by blasting excavation in high rock slope of Baihetan Dam Abutment[J]. Journal of Hydroelectric Engineering, 2022, 41(10): 1-11.
- [30] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.

PCA-GWO-SVR machine learning applied to prediction of peak vibration velocity of slope blasting

FAN Yong^{1,2}, HU Ming-dong^{1,2}, YANG Guang-dong^{1,2}, CUI Xian-ze^{1,2}, GAO Qi-dong^{1,3}

(1.Hubei Key Laboratory of Construction and Management in Hydropower Engineering, China Three Gorges University, Yichang 443002, China; 2.College of Hydraulic & Environmental Engineering, China Three Gorges University, Yichang 443002, China; 3.School of Highway, Chang'an University, Xi'an 710064, China)

Abstract: Aiming at the low accuracy of traditional empirical formulas in complex site environment, a predictive model for peak blasting vibration velocity based on grey wolf optimization support vector regression (PCA-GWO-SVR) with principal component analysis (PCA) feature selection is proposed. Based on the monitoring data of blasting excavation of dam abutment trough on the right bank of Baihetan Hydropower Station, the blasting center distance, maximum single-shot charge quantity, elevation difference, longitudinal wave velocity, bore spacing and bore row distance are selected as input parameters, and the characteristic values are selected by data dimension reduction of PCA, and the six selected features are dimensionally reduced to four characteristics with higher correlation. Support vector regression (SVR) is improved by grey wolf optimization algorithm (GWO) to obtain the optimal parameters. Parameters are input into the SVR model for evaluation. The research results show that the PCA-GWO-SVR algorithm has better agreement with the predicted values and the measured values of Sadowski formula, improved Sadowski formula, SVR, PCA-SVR, GWO-SVR. The predicted results are more accurate and can predict the peak value of blasting vibration of slope more effectively, which provides help for safety control of blasting construction of slope.

Key words: blasting vibration; principal component analysis; grey wolf optimization algorithm; support vector regression

作者简介: 范 勇(1988—),男,博士,教授。E-mail: yfan@ctgu.edu.cn。

通讯作者: 杨广栋(1991—),男,博士,副教授。E-mail: ygd@ctgu.edu.cn。