

doi:10.3963/j.issn.1001-487X.2026.01.023

融合粒子群优化与集成学习的 爆破振动峰值预测研究*

徐琛^{1,2}, 李其乐², 邱浪², 王超², 任高峰², 赵亮², 刘驰¹, 穆鹏宇¹

(1. 煤炭科学研究总院有限公司, 北京 100013; 2. 武汉理工大学资源与环境工程学院, 武汉 430070)

摘要: 为实现爆破振动峰值速度的精准预测并降低爆破振动的危害, 基于某工程实测数据, 选取爆心距、单段药量、孔距、堵塞长度、孔深等5个关键参数作为影响因子, 提出了一种基于粒子群优化算法(PSO)优化的Stacking集成学习模型(PSO-Stacking)。通过PSO优化Stacking基模型中随机森林(RF)的决策树数量与决策树深度、支持向量回归(SVR)的惩罚系数以及梯度提升决策树(GBDT)的树数量等超参数, 显著提升了模型的预测性能。结果表明: PSO-Stacking模型的准确率(AR)为85.54%, 均方误差(MSE)、均方根误差(RMSE)和决定系数(R^2)分别为2.39、1.54和0.7361, 较PSO-RF、BPNN、AdaBoost等6种模型表现出更优的预测性能与泛化能力。

关键词: 爆破振动峰值速度; 粒子群优化; 集成学习

中图分类号: TD235.3 文献标识码: A 文章编号: 1001-487X(2026)01-0213-12

Research on Peak Particle Velocity Prediction of Blasting Vibration based on Particle Swarm Optimization and Ensemble Learning

XU Chen^{1,2}, LI Qi-le², QIU Lang², WANG Chao², REN Gao-feng², ZHAO Liang², LIU Chi¹, MU Peng-yu¹

(1. Chinese Institute of Coal Science, Beijing 100013, China; 2. School of Resources and Environmental Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract: To accurately predict blasting vibration peak particle velocity and mitigate vibration hazards, this study develops a Stacking ensemble learning model (PSO-Stacking) optimized via a particle swarm optimization (PSO) algorithm, using field data from engineering applications. Five critical parameters were identified as key influencing factors: blast center distance, single-stage drug volume, borehole spacing, stemming length, and hole depth. The model's predictive performance was substantially enhanced through PSO-based hyperparameter optimization, including the number of depth levels of random forest (RF) decision trees, the support vector regression (SVR) penalty coefficient, and the number of trees in the gradient boosting decision tree (GBDT) within the Stacking framework. Experimental results demonstrate that the PSO-Stacking model achieves 85.54% accuracy (AR), with the mean square error (MSE), root mean square error (RMSE), and coefficient of determination (R^2) being 2.39, 1.54, and 0.7361, respectively.

收稿日期 (Date of reception): 2025-06-13

网络首发日期 (Published online): 2025-10-20

作者简介: 徐琛 (1994-), 男, 讲师、博士, 从事TBM数值模拟、水射流辅助破岩以及智慧爆破相关研究, (E-mail) xuchen_office@163.com。

通信作者: 邱浪 (2000-), 男, 硕士研究生, 从事爆破振动安全控制研究, (E-mail) qiulangwut@163.com。

基金项目: 国家自然科学基金项目 (52409143, 52304089); 天地科技股份有限公司科技创新创业资金专项资助项目 (2023-TD-ZD001-004, 2023-TD-QN003)

About the author: XU Chen (1994-), male, lecturer, Ph. D, engaged in research on TBM numerical simulation, waterjet-assisted rock breaking and smart blasting, (E-mail) xuchen_office@163.com.

Corresponding author: QIU Lang (2000-), male, postgraduate students, engaged in blasting vibration safety control research, (E-mail) qiulangwut@163.com.

Fund Programs: National Natural Science Foundation of China (No. 52409143, 52304089), the Special Project of Science and Technology Innovation and Venture Capital of Tiandi Co., Ltd. (2023-TD-ZD001-004, 2023-TD-QN003)

spectively, which shows better prediction performance and generalization ability than the six models, such as PSO-RF, BPNN, and AdaBoost.

Key words: blasting vibration peak velocity; particle swarm optimization; ensemble learning

爆破作为现代工程中广泛应用的施工技术,在提升施工效率的同时也伴随着显著的负面环境效应。根据工程实际监测数据显示,其主要危害形式为六大类型:爆破振动、冲击波、飞石、噪音、有毒气体扩散、粉尘。其中,爆破振动以其作用范围广、传播距离远、能量衰减慢的特征,在各类负面效应中危害程度居于首位。爆破应力波在传播过程中与建筑结构产生共振效应,当峰值质点振速超过某一阈值时,会导致结构破坏,同时爆破振动在其持续时间内也可以导致材料疲劳损伤累积。因此,研究并优化爆破控制技术以减小爆破振动的影响具有重要的工程价值和实际意义^[1]。

近年来,随着人工智能的发展,机器学习因其具有强大的非线性关系处理能力,被研究者们广泛应用于实际工程中^[2,3]。国内外学者结合实际工程条件,开展了大量研究,如郭鹏钦等运用遗传算法(GA)对BP神经网络的权值与阈值进行优化^[4],构建GA-BP神经网络爆破振动速度预测模型。范勇等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^[5]。张鹏飞等提出了一种灰色关联度特征选取下基于集成粒子群优化支持向量机算法(GRA-EPSO-SVM)的爆破振动速度预测模型^[6]。刘亚群等使用灰色关联分析理论^[7],并结合遗传神经网络较强的非线性映射优势和全局化的搜索能力,建立基于灰色关联分析的遗传神经网络模型(GRA-GA-BP)。赵荣溪等提出了一种基于马氏距离判别(MD)和主成分分析(PCA)的改进BP神经网络预测模型^[8],即MD-PCA-BP模型。刘博等利用基于回归分析的经验公式和BP神经网络模型以及基于拟牛顿法的改进BP神经网络(QN-BP)模型对爆破振动峰值速度进行预测^[9]。张文涛等提出了一种主成分分析(PCA)特征降维条件下^[10],基于鲸鱼算法(WOA)优化极端梯度提升算法(PCA-WOA-XGBoost)的爆破振动峰值速度预测模型。张艺峰等应用改进的神经网络建立爆破振动峰值-主频预测模型^[11]。李振阳等借助粒子群优化算法^[12],结合优化极端梯度提升树(XGBoost),构建了一种参数自优化的PSO-XGBoost预测模型。Wang等分析281组钻进参数和岩石力学参数^[13],分别采用3种机器学习算法(PSO-ELM, SVM, ELM)预测岩

石的UCS,其中PSO-ELM为精度最高的算法。

尽管机器学习方法在爆破振动峰值速度(PPV)预测领域展现出应用潜力,但现有研究仍面临诸多技术瓶颈。为此,本研究提出PSO-Stacking算法,根据某爆破工程138组实测数据,选取了单段药量,孔距,孔深,堵塞长度,炮孔直径,药卷直径,爆心距7个指标作为爆破振动峰值速度的影响因子,而后通过特征重要性分析选取了单段药量,孔距,孔深,堵塞长度,爆心距5个关键变量作为特征变量^[14],通过PSO算法优化Stacking集成模型中GBDT、RF和SVR的参数构建边坡开挖爆破振动峰值速度预测模型,以实现爆破振动效应的精准预测,为边坡开挖工程的安全提供科学依据,为复杂地质条件下爆破振动效应的精准预测提供了解决方案。

1 算法原理

1.1 PSO 算法原理

PSO是由Kennedy和Eberhart所提出可用于处理多维连续优化问题的算法^[15,16]。其基本思想是将待优化问题看作一个多维空间中的搜索问题,其中每个粒子表示一个潜在的解,这些粒子通过学习和合作的方式来寻求解空间里的最优解^[17]。PSO在搜寻最优参数、收敛速度以及鲁棒性等方面都具有良好的性能^[18]。其流程见图1,基本步骤如下:

(1)初始化粒子群。设置粒子数量、最大迭代次数、惯性权重、自我学习因子、群体学习因子,而后随机生成一群粒子,每个粒子的初始位置和速度在预设范围内随机初始化。

(2)更新粒子速度和位置。根据以下公式更新每个粒子的速度和位置。

速度更新公式

$$v_i^{t+1} = wv_i^t + c_1r_1(pBest_i - x_i^t) + c_2r_2(gBest - x_i^t) \quad (1)$$

位置更新公式

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

式中: v_i^t 为粒子*i*在时间*t*的速度; x_i^t 为粒子*i*在时间*t*的位置; c_1 、 c_2 为学习粒子的搜索经验; r_1 、 r_2 为在[0,1]范围的随机值; w 为惯性函数; $pBest$ 为个体最优解; $gBest$ 为全局最优解。

(3)边界条件处理。检查粒子的位置和速度是否超出预设的边界范围。如果超出,则将其限制在

边界内。

(4) 计算适应度并更新最优值。通过每个粒子的当前位置 x_i , 计算其适应度值 $f(x_i)$, 若粒子当前解的适应度优于个体历史最优解的适应度, 则令最优解等于该粒子的当前解。而后比较群体中所有粒

子的适应度值, 得到全局最优值。

(5) 终止条件判定。若已达到最大迭代次数或全局最优解的适应度值已满足预设要求, 则输出全局最优解及其适应度值; 否则, 跳转至步骤2进行下一轮迭代。




图1 PSO 算法流程图

Fig. 1 PSO algorithm flowchart

1.2 Stacking 算法原理介绍

Stacking 也称 Stacked Generalization, 它是一个两层的异质集成算法, 第一层为不同种类的基模型, 第二层的元模型将基模型的预测结果结合在一起, 多样性来源于不同类型的基模型, Stacking 集成学习使用一个算法来学习如何结合多种基模型的输出, 该策略往往优于使用数学函数的结合策略^[19]。其具体流程见图2, 主要包括以下步骤:

(1) 数据预处理。对原始数据进行归一化处理, 确保数据适合模型训练。

(2) 划分训练集与测试集。将数据集的 80% 用于基模型和元模型的训练, 20% 用于评估模型性能。

(3) 基模型训练。使用训练集训练多个基模型, 基模型包括 RF、GBDT、SVR。

(4) 元模型训练。将基模型在训练集上的预测结果作为元特征, 形成元模型的训练集, 而后使用此训练集训练元模型。

(5) 进行预测。将测试集输入三种基模型, 得到预测结果, 以此作为元特征输入训练好的元模型, 最后输出预测结果。

1.3 对比模型算法原理

研究还选取了 PSO-RF 模型、BPNN 模型、Ada-Boost 模型、GBDT 模型、XGBoost 模型、SVR 模型, 用来与 PSO-Stacking 进行对比分析, 它们的基本原理如下。

RF 算法的基本原理为集成学习, 其实质是包含若干决策树的分类器。该算法通过组合随机形成的决策树, 形成一个预测性能更加稳定的强分类器, 最终由所有决策树的预测结果综合决定输出值^[20]。算法流程步骤为: 随机抽取 n 组训练样本集, 在每组样本上建立相应的决策树模型。接着使用 CART 算法在训练集上构建决策树模型, 在每个非叶节点从全部特征中随机选取特征子集作为选定特征, 根据选定特征的最优分裂点划分左右子树; 重复前述步

骤,一直到决策树的数量达到随机森林的数量要求。值作为最终输出。
最后,集成所有决策树的预测结果,计算其加权平均




图 2 Stacking 集成算法流程图

Fig. 2 Flow chart of the stacking integration algorithm

BPNN 是由一个或多个隐藏层组成的前馈神经网络。其核心在于利用误差反向传播算法进行有监督学习。其基本流程包含两个交替进行的阶段前向传播和误差反向传播。通过反复迭代上述前向计算输出、计算误差、反向传播误差、更新参数的过程, BPNN 能够不断修正其内部的权值和阈值,使得网络的输出逐渐逼近期望的目标值,从而学习输入与输出之间复杂的非线性映射关系^[21]。前向传播中,输入数据逐层计算,隐藏层与输出层神经元的输出为

$$z^{(l)} = W^{(l)} a^{(l-1)} + b^{(l)}, a^{(l)} = f[z^{(l)}] \quad (3)$$

式中: $W^{(l)}$ 和 $b^{(l)}$ 为第 l 层权重与偏置; f 为激活函数。

AdaBoost 是一种集成学习算法,其基本原理是

组合多个弱分类器,通过提升被误分类样本的权重,迫使后续分类器重点学习困难样本,最终加权投票形成强预测模型。流程如下:首先,初始化训练集每个样本的权重: $w_j^{(1)} = \frac{1}{N}$;而后在每一轮中训练一个弱回归模型,使用当前样本权重 $w_j^{(l)}$ 分布训练一个弱分类器。依据模型回归误差对样本权重进行重新分配,提升预测误差大的样本权重,降低预测误差小的样本权重;接着,训练弱分类器 h_t 并根据式(4)计算其分类错误率。分类器权重的计算公式见式(5)。若 $\epsilon_t \geq 0.5$,则丢弃当前分类器并终止,否则重复这一过程,直到达到预设的迭代次数或误差要求,最终将所有弱回归模型加权组合成一个强回归模型,用于对新数据的预测。

$$\delta_i = \sum_{i=1}^N w_i^{(t)} \cdot I[y \neq h_i(x_i)] \quad (4)$$

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \delta_t}{\delta_t} \right) \quad (5)$$

式中: y_i 是样本的真实值; t 是迭代次数。

GBDT 是一种迭代的决策树算法, 是一种基于 boosting 增强策略的加法模型, 由多棵决策树组成。其基本原理是通过加法模型与前向分步算法, 每轮新增一棵树拟合前一模型预测值与真实值的残差, 逐步降低偏差^[22]。通过不断地迭代, 在上一次建立预测结果的弱学习器基础上, 构建新的学习器, 拟合上一次学习结果产生的残差以提高模型精度, 直至函数残差达到预定值或达到最大迭代次数。第 m 次迭代的残差计算公式如下

$$r_i^{(m)} = - \frac{\partial L[y_i, F_{m-1}(x_i)]}{\partial F_{m-1}(x_i)} \quad (6)$$

式中, $F_{m-1}(x_i)$ 是当前模型。

XGBoost 是一种高效梯度提升框架, 通过 CART 算法优化目标函数实现高精度预测。在 XGBoost 模型中建立目标函数, 并通过加入正则化项进行优化, 巧妙地减少了过拟合问题^[12]。此外, XGBoost 还通过并行计算、缩放学习率、欠采样等技术提高了计算效率和模型的泛化能力。第 t 轮迭代的目标函数如式(7), 模型更新公式为式(8)。

$$L(t) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t O(f_k) \quad (7)$$

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + V f_t(x_i) \quad (8)$$

式中, $\hat{y}_i^{(t)}$ 为第 t 轮的预测值。

SVR 是基于支持向量机(SVM)的回归方法, 其核心思想是构造一个“ ε -不敏感带”, 允许预测值与真实值的偏差在 ε 范围内不计损失, 对超出该带的样本施加惩罚, 从而平衡模型复杂性与拟合精度。

通过引入核函数将输入向量映射到高维度特征空间, 通过定义损失函数和优化目标构建出最优决策函数模型, 使回归模型的复杂度最小, 从而达到较好的预测效果。其目标函数见式(9), 损失函数见式(10)。

$$f(x) = w^T \phi(x) + b \quad (9)$$

$$L_\varepsilon[f(x_i), y_i] = \begin{cases} 0 & \text{if } |f(x_i) - y_i| \leq \varepsilon \\ |f(x_i) - y_i| - \varepsilon & \text{otherwise} \end{cases} \quad (10)$$

式中: w 是权重向量; b 是偏置项; $\phi(x)$ 为核函数映射的高维特征。

1.4 算法评价指标

为评估预测模型的精度与误差水平, 本研究选取了四项指标, 包括准确率(AR)、均方误差(MSE)、均方根误差(RMSE)、决定系数(R^2)。AR 表示正确预测的样本比例。MSE 表示了预测值与真实值误差平方的平均值, 反映了预测误差的离散程度。RMSE 为 MSE 的平方根。 R^2 表示了模型解释的目标变量方差比例。各评价指标取值范围见表 1。这些评价指标可根据以下公式计算。

$$AR = \frac{1}{n} \sum_{i=1}^n \left(1 - \frac{|y_i - \hat{y}_i|}{y_i} \right) \quad (11)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

式中: i 是第 i 个测试样本; y_i 是样本数据的实际值; $\hat{y}_i$ 是预测模型的预测值; $\bar{y}$ 是 y 的平均值; n 是样本的数量。

表 1 评价指标取值范围及含义

Table 1 The value range and numerical meaning of the evaluation index

评价指标 Evaluation indicators	取值范围 Range of values	含义 Hidden meaning
AR	[0, 1]	越接近 1 预测效果越好 The closer to 1 the better the prediction
MSE	[0, +∞)	数值越小预测效果越好 The smaller the value the better the prediction
RMSE	[0, +∞)	数值越小预测效果越好 The smaller the value the better the prediction
R^2	[-∞, 1]	越接近 1 预测效果越好 The closer to 1 the better the prediction

2 PSO-Stacking 预测模型构建

2.1 数据处理

研究数据来源于西部某保密项目边坡工程,该项目工程地段出露基岩均为震旦-寒武系喀纳斯群二段,岩性以黑云母石英片岩为主,间有二云母石英片岩、黑云母斜长石英片岩等,具鳞片状变(细)晶结构,片状构造,片理较不发育~发育,总体属中硬~坚硬岩。工程区未发现区域性断裂通过,构造形迹为Ⅳ级以下结构面为主,主要为挤压破碎带或顺片理错动产生的短小断层。组成的新鲜围岩以Ⅲ类为主,Ⅳ类次之。爆破方法为台阶爆破法,使用电子雷管网路进行爆破施工,钻孔形式为垂直深孔,布孔方式为多排矩形或三角形布孔,炸药为乳化炸药,装药结构为不耦合装药,起爆顺序为多排孔排间毫秒延时爆破,排间延时为 35 ms。

基于此爆破工程的 138 组实测数据,本研究选

取了 7 个关键影响因子构建预测模型,包括爆心距、单段药量、孔距等特征指标,模型输出为爆破振动峰值速度。表 2 给出了数据集的描述性统计结果,包括各变量的均值、标准差、最大值和最小值。峰值速度变化范围较大,平均值为 8.61 cm/s,表明爆破振动强度存在显著差异。爆心距跨度达 6~65 m,显示测点分布广泛。这些参数的显著差异和分布特征为研究爆破振动预测模型提供了数据基础。图 3 直观展示了各变量的数据分布特征。

考虑到各影响因子的量纲和数值范围差异较大,对所有数据进行了归一化处理,将其转换到[0, 1]区间,以消除量纲影响并提高模型的收敛速度和预测精度。归一化公式如下式

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (15)$$

式中: X 是数据集的初始数据; $X_{\max}$ 为最大值; $X_{\min}$ 为最小值。




图 3 数据分布图

Fig. 3 Data distribution

图 4 通过相关性系数热力图直观地展示了各指标之间的相关性关系。图中每个单元格的数值代表对应行与列两个变量之间的 Pearson 相关系数,其绝对值大小反映了二者线性相关性的强弱,而正负号则表明相关性的方向(正相关或负相关)。从结果可以看出,其中,炮孔直径与药卷直径呈现出极强的正相关,堵塞长度与孔距、抵抗线以及炮孔直径表现出较强正相关。孔距与抵抗线和堵塞长度之间存在正相关关系。这些相关性表明这些参数在实际爆破作业中可能相互影响。整体而言,该相关系数热力图揭示了爆破参数之间复杂的相关关系,为特征选

择提供了重要参考。

2.2 特征重要性 SHAP 值分析

SHAP 是一种基于博弈论中 Shapley 值的模型可解释性方法。它的核心思想是将预测值视为所有特征协作产生的“收益”,并公平地分配该收益到每个特征上。SHAP 的优势在于其能够提供一个统一的方法解释机器学习模型的预测结果,而且能够考虑特征之间的相互作用。这使得 SHAP 值分析可以帮助更好地理解机器学习模型的决策过程,从而提高模型的透明度和可解释性^[23]。

表 2 数据描述性统计
Table 2 Descriptive statistics

指标 Norm	最大值 Maximum value	最小值 Minimum value	平均值 Average value	标准差 Standard deviation
峰值速度 Peak Particle Velocity/($\text{cm} \cdot \text{s}^{-1}$)	17.18	0.94	8.61	4.48
爆心距 Burst center distance/m	65	6	19.37	9.73
药卷直径 Charge diameter/mm	90	25	52.06	27.51
炮孔直径 Blast hole diameter/mm	105	90	95	7.1
堵塞长度 Stemming length/m	3.3	0.8	2.1	0.89
孔深 Hole depth/m	15.9	2.5	9.56	3.4
孔距 Hole spacing/m	5.2	0.7	2.49	1.91
单段药量 Single-hole charge/kg	68.4	5.1	34.48	21.69




图 4 相关性系数图
Fig. 4 Correlation coefficient chart

如图 5 所示,爆心距为最具影响力的特征,远超其他特征变量,这与爆破振动随距离衰减的基本规律相符。单段药量位居第二位,遵循萨道夫斯基公式,当爆心距固定时,振动速度与单段药量呈指数正相关。孔深、堵塞长度和孔距对于模型较为重要。炮孔直径与装药直径对模型影响较小。所以在后续模型预测当中选取爆心距、单端药量、孔深、堵塞长度和孔距作为特征变量输入。

2.3 爆破振动峰值预测模型建模

RF、SVR 和 GBDT 是机器学习中广泛应用的模型,它们各自具有不同的优势。RF 擅长处理高维数据,抗过拟合能力强。SVR 适用于小样本数据,在高维空间具有较好的泛化能力。GBDT 通过迭代优化提升预测精度,对复杂非线性关系拟合能力强。然而,单一模型的预测能力有限,而 Stacking 集成学习可以通过结合多个基模型的优势,进一步提升预

测精度。由于 RF、SVR、GBDT 的超参数对模型性能影响显著,所以本研究采用粒子群优化算法对 RF、SVR、GBDT 三个基模型进行超参数优化,并构建 PSO-Stacking 集成模型。图 6 为 PSO-Stacking 集成模型的构建过程,基本流程如下:

(1)对数据集进行标准化,然后采用随机抽样方法将数据按 8:2 的比例划分为训练集(110 组)和测试集(28 组)。

(2)基模型参数优化。以 MSE 为适应度函数,使用 PSO 优化 RF、SVR、GBDT 模型的超参数,然后输出各基模型的最优参数组合,得到优化后的 RF、SVR、GBDT 模型。




图 5 特征重要性

Fig. 5 Feature importance




图 6 PSO-Stacking 集成模型流程图

Fig. 6 Flowchart of the PSO-Stacking integration model

(3)基模型的训练与预测。使用优化后的基模型在训练集上进行训练,采用 K 折交叉验证方法生成元特征:将训练集分为 K 个子集,每次用 K-1 个子集训练,在剩余子集预测,整合得到完整的 RF、SVR 和 GBDT 预测结果。

(4)元模型训练与预测。将三个基模型的预测结果合并,构成新的元特征数据集,使用元特征训练元模型,最后输入测试集进行预测。

3 结果分析

3.1 训练 PSO-Stacking 模型和对比模型

使用预处理后的训练集训练 PSO-Stacking 模型,基学习器的超参数由粒子群优化算法搜索得到。PSO 算法参数配置如下:粒子数量为 40,最大迭代次数为 80,搜索空间维度为 4。超参数搜索范围见表 3。经 80 次迭代后,PSO 算法取得最优适应度值,然后,依据此适应度值对应参数训练 PSO-Stacking 模型。

对 PSO-RF、BPNN、AdaBoost、GBDT、XGBoost 和 SVR 六类模型使用 K 折交叉验证与网格搜索结合的方法进行统一优化。基本流程如下:将训练集随机划分为 5 个等规模子集,每次选取 4 个子集作为训练子集,剩余 1 个子集作为验证子集,然后基于当

前超参数组合在训练子集上构建模型,接着计算验证子集的评估指标,重复上述过程 5 次,确保每个子集均被用作验证集 1 次,对 5 次验证结果取均值作为当前参数组合的最终性能指标,最后,采用网格搜索完成参数空间遍历,实现模型性能的最大化。

表 3 超参数搜索范围
Table 3 Hyperparameter search range

超参数 Hyperparameter	搜索范围 Search range
RF 的决策树数量 Number of decision trees for RF	[50,200]
RF 的最大深度 Maximum depth of RF	[3,10]
SVR 的惩罚系数 The penalty factor of SVR	[0.01,0.2]
GBDT 的决策树数量 Number of decision trees for GBDT	[50,200]

3.2 预测结果分析

将训练集数据分别输入到七个模型中完成训练过程,随后使用测试集数据进行预测。图 7 展示了各模型的预测结果。图 8 中对比了 7 种模型的 4 个评价指标的计算结果。




图 7 七种模型的实际值与预测值对比
Fig. 7 Comparison of the actual and predicted values of the seven models

如图 7 所示,在 28 个样本中,PSO-Stacking 模型相较于其他 6 种模型误差更小,28 个样本的预测值与实际值更为接近,实际值与预测值的皮尔逊相关系数最大,为 0.907。这种预测性能的显著提升主要归因于模型中融合的粒子群优化算法对基学习器参数优化机制。

如图 8 所示,在评估指标中,PSO-Stacking 模型都是最优的,PSO-Stacking 模型的 AR、MSE、RMSE 和 R² 的值分别为 85.54%、2.39、1.54、0.7361。与 PSO-RF 模型、SVR 模型、BPNN 模型、GBDT 模型、XGBoost 模型、AdaBoost 模型相比,其 AR 分别提升了 4.11%、7.68%、11.25%、18.4%、14.83%、

19.31%, MSE 分别减小了 17.87%、49.14%、48.01%、56.15%、59.80%、55.36%, RMSE 分别减小了 9.37%、28.68%、34.65%、33.78%、36.59%、

33.18%, R^2 分别提升了 6.85%、5.08%、15.17%、34.22%、19.59%、12.27%。




图8 七种模型的评估指标

Fig. 8 Four evaluation indicators for seven models

4 研究结论

研究针对爆破振动峰值速度预测精度不足的难题,提出了一种融合 PSO 与 Stacking 集成学习的预测模型。通过理论分析的研究手段,依次开展了数据预处理、Stacking 集成学习基模型优选与 PSO 超参数优化机制、模型性能优势验证和特征贡献度解析等方面的研究工作,旨在构建高精度爆破振动峰值速度预测模型并验证其工程适用性。通过预测结果对比分析和评价指标对比,结果表明,PSO-Stacking 模型的预测精度显著优于 PSO-RF、BPNN、AdaBoost、GBDT、XGBoost、SVR、AdaBoost 模型,其 AR 为 85.54%,MSE、RMSE 和 R^2 分别达到 2.39、1.54 和 0.7361,较其余模型表现出最优的预测稳定性与泛化能力。特征重要性 SHAP 值分析中明确爆心距为爆破振动峰值速度预测的核心特征,符合振动波衰减的物理规律。研究成果为爆破振动预测提供了高精度、低误差的解决方案,对优化爆破设计参数及控制振动危害具有重要的理论意义与实践价值。

参考文献 (References)

- [1] 王延雨,温小宝,王 军,等. 隧道近接穿越古迹爆破施工安全控制技术[J]. 地下空间与工程学报,2024,20(2):645-656.
- [1] WANG Yan-yu, WEN Xiao-bao, WANG Jun, et al. The safety control technology of the blasting construction of the tunnel in close distance with the historic site[J]. Chinese Journal of Underground Space and Engineering, 2024, 20(2):645-656. (in Chinese)
- [2] XU Chen, LIU Xiao-li, WANG En-zhi, et al. Prediction of tunnel boring machine operating parameters using various machine learning algorithms[J]. Tunnelling and Underground Space Technology, 2021, 109:103699.
- [3] XU Chen, LIU Xiao-li, WANG En-zhi, et al. Calibration of the microparameters of rock specimens by using various machine learning algorithms[J]. International Journal of Geomechanics, 2021, 21(5):04021060.
- [4] 郭钦鹏,杨仕教,朱忠华,等. 运用 GA-BP 神经网络对爆破振动速度预测[J]. 爆破,2020,37(3):148-152.

- [4] GUO Qin-peng, YANG Shi-jiao, ZHU Zhong-hua, et al. Prediction of blasting vibration velocity using GA-BP neural network[J]. *Blasting*, 2020, 37(3): 148-152. (in Chinese)
- [5] 范勇, 胡名东, 杨广栋, 等. PCA-GWO-SVR 机器学习用于边坡爆破振动速度峰值预测研究[J]. *振动工程学报*, 2024, 37(8): 1431-1441.
- [5] FAN Yong, HU Ming-dong, YANG Guang-dong, et al. PCA-GWO-SVR machine learning applied to prediction of peak vibration velocity of slope blasting[J]. *Journal of Vibration Engineering*, 2024, 37(8): 1431-1441. (in Chinese)
- [6] 张鹏飞, 袁永, 何运华, 等. 基于 GRA-EPSO-SVM 模型的露天矿山爆破振动速度预测[J]. *煤炭科学技术*, 2025, 53(7): 105-115.
- [6] ZHANG Peng-fei, YUAN Yong, HE Yun-hua, et al. Blasting vibration velocity prediction of open pit mines based on GRA-EPSO-SVM model[J]. *Coal Science and Technology*, 2025, 53(7): 105-115. (in Chinese)
- [7] 刘亚群, 李海波, 裴启涛, 等. 基于灰色关联分析的遗传神经网络在水下爆破中质点峰值振动速度预测研究[J]. *岩土力学*, 2013, 34(S1): 259-264.
- [7] LIU Ya-qun, LI Hai-bo, PEI Qi-tao, et al. Prediction of peak particle velocity induced by underwater blasting based on the combination of grey relational analysis and genetic neural network[J]. *Rock and Soil Mechanics*, 2013, 34(S1): 259-264. (in Chinese)
- [8] 赵荣溪, 杨玉民, 周传波, 等. 基于 MD-PCA-BP 模型的露天矿山爆破振动速度预测[J]. *爆破*, 2024, 41(2): 203-211.
- [8] ZHAO Mo-xi, YANG Yu-min, ZHOU Chuan-bo, et al. Prediction of blasting vibration velocity in open-pit mine based on MD-PCA-BP model[J]. *Blasting*, 2024, 41(2): 203-211. (in Chinese)
- [9] 刘博, 史秀志, 黄宣东, 等. 基于拟牛顿法的 QN-BP 预测爆破振动峰值速度[J]. *中国有色金属学报*, 2013, 23(5): 1427-1433.
- [9] LIU Bo, SHI Xiu-zhi, HUANG Xuan-dong, et al. Prediction of blasting-vibration-peak-speed by QN-BP based on Quasi-Newton method[J]. *The Chinese Journal of Nonferrous Metals*, 2013, 23(5): 1427-1433. (in Chinese)
- [10] 张文涛, 汪海波, 高朋飞, 等. 基于 PCA-WOA-XGBoost 的露天矿山爆破振动峰值振速预测[J]. *工程爆破*, 2024, 30(6): 155-167, 177.
- [10] ZHANG Wen-tao, WANG Hai-bo, GAO Peng-fei, et al. Prediction of PPV of blasting vibration in open-pit mine based on PCA-WOA-XGBoost model[J]. *Engineering Blasting*, 2024, 30(6): 155-167, 177. (in Chinese)
- [11] 张艺峰, 姚道平, 谢志招, 等. L-M 优化算法在爆破振动参数预测中的应用[J]. *地震学报*, 2008(5): 540-544, 550.
- [11] ZHANG Yi-feng, YAO Dao-ping, XIE Zhi-zhao, et al. Application of the L-M optimization algorithm to predicting blast vibration parameters[J]. *Acta Seismologica Sinica*, 2008(5): 540-544, 550. (in Chinese)
- [12] 李振阳, 张宝岗, 熊信, 等. 基于 PSO-XGBoost 的露天矿山 PPV 预测模型研究[J]. *黄金科学技术*, 2024, 32(4): 620-630.
- [12] LI Zhen-yang, ZHANG Bao-gang, XIONG Xin, et al. Research on PPV prediction model of open-pit mine based on PSO-XGBoost[J]. *Gold Science and Technology*, 2024, 32(4): 620-630. (in Chinese)
- [13] WANG Shao-feng, WU Yu-meng, CAI Xin, et al. Strength prediction and drillability identification for rock based on measurement while drilling parameters[J]. *Journal of Central South University*, 2023, 30(12): 4036-4051.
- [14] 任高峰, 邱浪, 徐琛, 等. 基于 PSO-XGBoost 的爆破振动峰值速度预测研究[J]. *金属矿山*, 2025(4): 256-265.
- [14] REN Gao-feng, QIU Lang, XU Chen, et al. Prediction of blasting vibration peak velocity based on PSO-XGBoost[J]. *Metal Mine*, 2025(4): 256-265. (in Chinese)
- [15] KENNEDY J, EBERHART R. Particle swarm optimization[C] // IEEE Int Conf on Neural Networks. Perth, Australia: IEEE, 1995: 1942-1948.
- [16] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory[C] // Proc of the Sixth International Symposium on Micro Machine and Human Science, Nagoya, Japan, 1995: 39-43.
- [17] 代仕明, 李敏, 唐金良, 等. 基于粒子群优化的相关向量机算法的井震联合储层参数预测与不确定性评估[J]. *石油地球物理勘探*, 2023, 58(6): 1436-1445.
- [17] DAI Shi-ming, LI Min, TANG Jin-liang, et al. Seismic and well logs integration for reservoir parameter prediction and uncertainty evaluation based on relevance vector machine optimized by particle swarm optimization[J]. *Oil Geophysical Prospecting*, 2023, 58(6): 1436-1445. (in Chinese)
- [18] 张研, 黄兰淘, 唐北昌, 等. 基于 PSO-RVM 的落煤瓦斯涌出量预测[J]. *太原理工大学学报*, 2025, 56(4): 742-749.
- [18] ZHANG Yan, HUANG Lan-tao, TANG Bei-chang, et al. Prediction of falling coal gas emission based on particle swarm optimization relevance vector machine[J]. *Journal of Taiyuan University of Technology*, 2025, 56(4): 742-749. (in Chinese)
- [19] 徐继伟, 杨云. 集成学习方法: 研究综述[J]. *云南*

- 大学学报(自然科学版),2018,40(6):1082-1092.
- [19] XU Ji-wei, YANG Yun. A survey of ensemble learning approaches[J]. Journal of Yunnan University (Natural Science Edition), 2018, 40(6):1082-1092. (in Chinese)
- [20] 张 石, 郑东健, 陈卓研. 基于改进 PSO-RF 算法的大坝变形预测模型[J]. 水利水电科技进展, 2022, 42(6):39-44.
- [20] ZHANG Shi, ZHENG Dong-jian, CHEN Zhuo-yan. Dam deformation prediction model based on improved PSO-RF algorithm[J]. Advances in Science and Technology of Water Resources, 2022, 42(6):39-44. (in Chinese)
- [21] 鞠 晨, 张 超, 樊红卫, 等. 基于小波包分解和 PSO-BPNN 的滚动轴承故障诊断[J]. 工矿自动化, 2020, 46(8):70-74.
- [21] JU Chen, ZHANG Chao, FAN Hong-wei, et al. Rolling bearing fault diagnosis based on wavelet packet decomposition and PSO-BPNN[J]. Journal of Mine Automation, 2020, 46(8):70-74. (in Chinese)
- [22] 邢 昭, 孟小军, 袁晶晶, 等. 信息量支持下 SVM-GBDT 模型的滑坡危险性评价[J]. 科学技术与工程, 2025, 25(7):2712-2720.
- [22] XING Zhao, MENG Xiao-jun, YUAN Jing-jing, et al. Landslides hazard assessment based on SVM-GBDT and gradient boosting decision tree model supported by information quantity[J]. Science Technology and Engineering, 2025, 25(7):2712-2720. (in Chinese)
- [23] 王冠杰, 刘盛威, 周 健, 等. 材料研究中的可解释机器学习[J]. 金属学报, 2024, 60(10):1345-1361.
- [23] WANG Guan-jie, LIU Sheng-xian, ZHOU Jian, et al. Explainable machine learning in the research of materials science[J]. Acta Metallurgica Sinica, 2024, 60(10):1345-1361. (in Chinese)

(上接第 73 页)

- [7] 郇成群, 李 旺, 李祥龙. 裂隙岩体爆生裂纹扩展机理数值模拟研究[J]. 有色金属工程, 2023, 13(10):95-104, 134.
- [7] TAI Cheng-qun, LI Wang, LI Xiang-long. Numerical simulation study on the mechanism of blast-induced crack propagation of fractured rock mass[J]. Nonferrous Metals Engineering, 2023, 13(10):95-104, 134.
- [8] 张少秋. 裂隙发育岩体光面爆破成缝机理及参数优化研究[D]. 武汉: 武汉科技大学, 2017.
- [8] ZHANG Shao-qiu. Research on smooth blasting cracking mechanism and parameters optimization of fractured rock [D]. Wuhan: Wuhan University of Science and Technology, 2017. (in Chinese)
- [9] 张飞燕, 陈玥玥, 韩 颖, 等. 低透气性煤层预裂爆破裂纹扩展特征数值模拟研究[J]. 爆破, 2022, 39(3):106-111.
- [9] ZHANG Fei-yan, CHEN Yue-yue, HAN Ying, et al. Numerical simulation on crack propagation characteristics of pre-split blasting in low permeability coal seam[J]. Blasting, 2022, 39(3):106-111. (in Chinese)
- [10] 师天真, 杨启涛, 代周超, 等. 节理对岩体爆破破坏特性的影响研究[J]. 矿冶工程, 2025, 45(3):8-13.
- [10] SHI Tian-zhen, YANG Qi-tao, DAI Zhou-chao, et al. Effect of joints on blasting-induced failure characteristics of rock mass[J]. Mining and Metallurgical Engineering, 2025, 45(3):8-13. (in Chinese)
- [11] 陈星良, 关富儒, 付兆凯, 等. 裂隙发育岩体水电工程地下洞室预裂爆破试验研究[J]. 爆破, 2024, 41(2):67-74.
- [11] CHEN Xing-gen, GUAN Fu-su, FU Yao-kai, et al. Experimental study on pre-splitting blast of underground caverns in fractured rock mass[J]. Blasting, 2024, 41(2):67-74. (in Chinese)
- [12] 许守信, 黄绍威, 李二宝, 等. 复杂破碎岩体矩形聚能药包预裂爆破试验研究[J]. 金属矿山, 2021(11):55-63.
- [12] XU Shou-xin, HUANG Shao-wei, LI Er-bao, et al. Experimental study on pre-splitting blasting of rectangular shaped charge in complex fractured rock mass[J]. Metal Mine, 2021(11):55-63. (in Chinese)
- [13] 石 崇, 张 强, 王盛年. 颗粒流(PFC5.0)数值模拟技术及应用[J]. 岩土力学, 2018(202):36.
- [13] SHI Chong, ZHANG Qiang, WANG Sheng-nian. Numerical simulation technology and application with particle flow code(PFC 5.0)[J]. Rock and Soil Mechanics, 2018(202):36. (in Chinese)
- [14] 袁增森, 徐振洋, 潘 博, 等. 不同不耦合系数下花岗岩爆破损伤特性的离散元模拟[J]. 高压物理学报, 2022, 36(1):202-212.
- [14] YUAN Zeng-sen, XU Zhen-yang, Pan Bo, et al. Discrete element simulation of blasting damage characteristics of granite under different decoupling coefficients[J]. Chinese Journal of High Pressure Physics, 2022, 36(1):202-212. (in Chinese)
- [15] 许 彪. 基于 PFC 的岩石控制爆破技术研究[D]. 淮南: 安徽理工大学, 2018.
- [15] XU Biao. Research on controlled blasting technology of rock based on PFC[D]. Huainan: Anhui University of Science and Technology, 2018. (in Chinese)