

基于ACO-BP神经网络的爆破块度 预测模型及其应用

于庆磊, 吴嘉伟, 李友, 蒲江涌
(东北大学 资源与土木工程学院, 辽宁 沈阳 110819)

摘要: 爆破块度是岩石性质、爆破参数和炸药性质等组合作用结果,其准确预测是实现矿山精细爆破与采选能耗协同优化的关键。为了提升预测精度,构建了基于蚁群优化(ACO)算法和BP神经网络的爆破块度预测模型,并确定了主要影响因素。以司家营露天矿为例,为提升预测精度,通过建立爆破案例样本来训练模型,分析了各影响因素权重。结果表明:ACO显著提高了模型的预测能力;在爆破块度影响因素中,孔距权重最大,最小抵抗线权重最小;爆破参数对爆破块度的影响存在最优范围,单一调节某参数难以持续改善爆破块度。该模型为根据爆破效果要求反向优化爆破设计提供了有效手段和理论依据。

关键词: ACO-BP神经网络;精细爆破;爆破块度;影响因素权重;反向优化

中图分类号: TD 235 文献标志码: A 文章编号: 1005-3026(2025)12-0116-08

Prediction Model of Blasting Fragmentation Based on ACO-BP Neural Network and Its Application

YU Qing-lei, WU Jia-wei, LI You, PU Jiang-yong

(School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: YU Qing-lei, E-mail: yuqinglei@mail.neu.edu.cn)

Abstract: Blasting fragmentation is governed by the combined interplay of rock properties, blasting parameters, and explosive characteristics. Its accurate prediction is the key to achieving the coordinated optimization of precision blasting in mines and energy consumption during mining and processing. To improve prediction accuracy, a blasting fragmentation prediction model was constructed using ant colony optimization (ACO) and a back propagation (BP) neural network, and the key influencing factors of blasting fragmentation were identified. Based on the Sijiaying open pit mine, a blasting case database was established to train the model and improve prediction accuracy, and the weights of the influencing factors were analyzed. Results show that ACO significantly improves model performance. Among the influencing factors of blasting fragmentation, blasthole spacing has the highest weight, and minimum burden has the lowest weight. Blasting parameters exhibit optimal ranges for blasting fragmentation, but single-parameter adjustments cannot sustainably improve blasting fragmentation. This model provides an effective means and theoretical basis for inverse optimization of blasting design based on blasting effect requirements.

Key words: ACO-BP neural network; precision blasting; blasting fragmentation; weight of influencing factor; inverse optimization

在金属矿石开发利用流程中,采矿爆破工序能耗小、成本低,破碎和磨矿等选矿工序能耗大、成本高,因此“以爆代破、能耗前移,采选工序联

合优化”是金属矿山实现生产节能降耗的一个重要途径。预测爆破块度是优化爆破设计、实现以爆代破的关键。然而在实际生产过程中,爆破块

度的大小受到岩体性质、爆破设计参数和炸药参数等因素的影响,这些影响因素与爆破效果之间存在极其复杂的非线性关系^[1].传统的爆破块度预测模型主要是经验模型或理论模型,例如 Kuz-Ram 模型、Rosin-Rammler 模型等^[2],这类模型都存在计算效率低、适用范围小等局限性,难以精确预测复杂工况条件下爆破块度的大小。

随着人工智能技术的发展,计算机强大的数据信息处理能力为爆破块度预测这类多因素与多指标之间的非线性映射关系提供了可靠的描述方式^[3].融合现代智能技术,发展爆破效果预测的模型或方法是未来发展趋势.多种基于人工智能技术理论的预测方法被用于爆破块度预测研究,如 BP 神经网络法^[4]、极限学习机法^[5]、支持向量机法^[6]、随机森林算法^[7]等.其中,BP 神经网络系统作为近年来人工智能系统的重要研究对象,其愈加简化的内部结构能够在适应各种复杂工况条件的同时,保证爆破块度预测的准确性.随着研究的深入,更多学者将 BP 神经网络用于爆破块度预测研究.Gao 等^[8]利用 BP 神经网络模型对宜春钽铌矿 860 水平工作面进行爆破块度分析,预测结果能够满足精度要求;史秀志等^[9]运用主成分分析法使自变量间相关性降低,显著提升了 BP 神经网络模型的预测精度;Guo 等^[10]将随机森林算法、遗传算法与 BP 神经网络相结合,在惠州大亚湾实际爆破工程预测中取得良好效果.BP 神经网络预测模型在实际应用中不断发展完善,但由于其预测过程中初始权值和阈值选取的随机性,普遍存在预测稳定性较差、收敛速度慢且易收敛于局部极小点等问题^[11],这些仍未得到有效解决。

为改善传统 BP 神经网络预测方法的不足,提升预测精度,本文利用蚁群优化(ACO)算法寻求 BP 神经网络模型的最优初始权值和阈值,建立基于 ACO-BP 神经网络的爆破块度预测模型,利用采集的工程爆破实例样本对此模型的准确性和可靠性进行验证,并应用该模型对爆破块度的影响因素进行了深入探讨。

1 基于 ACO-BP 神经网络的爆破块度预测模型

1.1 ACO-BP 神经网络简介

BP 神经网络是一种基于误差反向传播算法训练的多层前馈网络,由非线性变换单元组成。

该网络通过模拟人类大脑认知和处理信息的方式,不断调整网络连接权值与阈值,建立输入层和输出层之间的非线性映射关系.BP 神经网络模型由 1 个输入层、1 个输出层和若干隐含层组成.增加隐含层层数可以降低网络误差、提高精度^[12],但也会使网络结构复杂化,训练时间增加并可能引发过拟合问题.因此通常仅设置单隐含层,通过调整隐含层节点数使模型参数逼近最优网络参数.本文采用包含 1 个隐含层的 3 层 BP 神经网络结构。

蚁群优化算法^[13]是一种模拟蚂蚁觅食行为的仿生智能优化算法.利用蚁群优化算法优化 BP 神经网络的基本思路是:使用权值矩阵和阈值向量的元素构成蚂蚁种群的路径坐标.由于蚂蚁到达食物源的路径越短,路径上的信息素含量越高,因此将均方误差作为蚂蚁的适应度函数。

$$F = \frac{e_{MS,tr} + e_{MS,tc}}{2}. \quad (1)$$

式中: F 为蚂蚁的适应度值; $e_{MS,tr}$ 为使用训练集样本计算的均方误差; $e_{MS,tc}$ 为使用测试集样本计算的均方误差。

利用蚂蚁种群确定的最短路径作为最优的初始权值和阈值参数,将最优的初始权值和阈值参数赋给 BP 神经网络进行训练和测试,并与优化前 BP 神经网络的预测值进行误差对比.ACO-BP 神经网络计算流程图如图 1 所示.具体步骤如下:

1) 读取数据,对 BP 神经网络结构和蚁群优化算法的参数进行初始化处理,包括最大进化代数、自变量个数及取值范围、信息素挥发系数与释放总量、转移概率常数、蚂蚁数量等。

2) 对解空间的维度进行分析计算,对最高信息素值和初始蚂蚁坐标进行初始化处理.令蚁群算法进行迭代寻优.初始化蚂蚁位置后,蚂蚁 k 在时刻 t 从节点 i 转移到节点 j 的概率 $P_{ij}^k(t)$ 由式(2)计算:

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{s \in a_k} [\tau_{is}(t)]^\alpha [\eta_{is}(t)]^\beta}, & j \in a_k; \\ 0, & j \notin a_k. \end{cases} \quad (2)$$

式中: $\tau_{ij}(t)$ 为当前路径 (i, j) 上的信息素浓度; $\eta_{ij}(t) = 1/d_{ij}$ 为启发因子,表示节点 j 相对于节点 i 的吸引程度, d_{ij} 为节点 i 到节点 j 的距离; a_k 为蚂蚁 k 待访问的节点集合; α 为信息素重要因子; β 为启发函数重要程度因子。

3) 根据蚂蚁的位置,计算信息素浓度.信息素更新方式为

$$\left. \begin{aligned} \tau_{ij}(t+1) &= (1-\rho)\tau_{ij}(t) + \rho\tau_{ij}^k \\ \tau_{ij} &= \sum_{k=1}^n \tau_{ij}^k \end{aligned} \right\} \quad (3)$$

式中: $\tau_{ij}(t+1)$ 为路径 (i,j) 在下一个时刻的信息素浓度; $\rho \in (0,1)$ 为信息素挥发系数,表示旧信息素保留比例; τ_{ij}^k 为蚂蚁 k 在路径 (i,j) 上释放的信息素浓度,通常与其路径质量成反比.

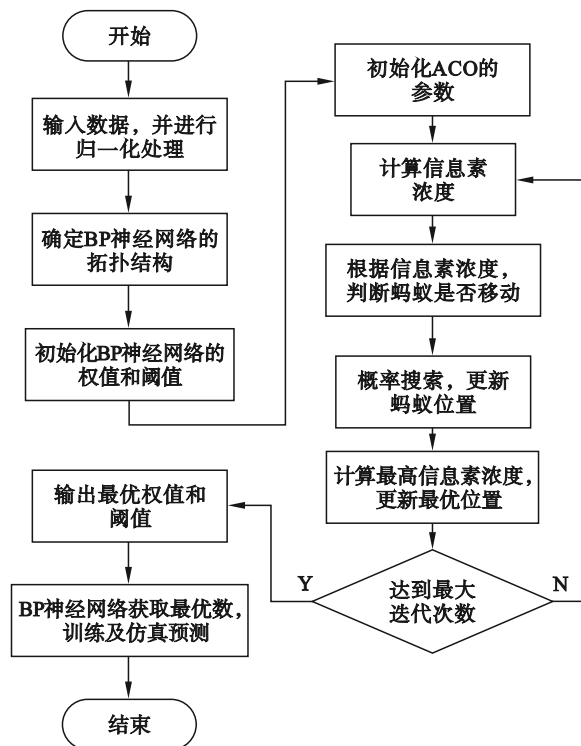


图 1 ACO-BP算法流程图

Fig. 1 Flow chart of ACO-BP algorithm

- 4) 计算最高信息素浓度,更新最优个体位置.
- 5) 按概率转移规则更新蚂蚁位置.
- 6) 重复执行步骤3)~步骤5),直至达到终止代数.
- 7) 利用优化后的最佳蚂蚁位置坐标得到最优的初始权值矩阵和阈值向量,将所得的最优权值和阈值参数代入所建立的BP神经网络.

8) 利用优化后的BP神经网络进行训练与测试,通过均方根误差(e_{RMS})和平均绝对百分比误差(e_{MAP})评价优化前后BP神经网络预测模型的预测精度.

1.2 爆破块度预测模型的输入参数选取

在机器学习模型中,模型输入参数的选取尤为重要.影响爆破效果的主要因素包括3个方面,即矿岩体力学性质、爆破设计参数和炸药类型.矿岩体力学性质与爆破参数、炸药性能等的匹配

关系,最终决定了爆破效果;它们与爆破效果存在直接的因果关系,因此更适合采用机器学习模型进行研究.原则上,为提高爆破块度预测的可靠性,模型的输入参数应尽可能包含所有影响因素,但也需充分考虑影响因素之间的线性相关性,科学合理地选取模型输入参数.这为利用爆破块度的预测结果反演调整爆破设计参数提供了可能.

一般认为,爆破岩石的破碎是由冲击波和爆炸气体压力综合作用的结果.爆炸冲击波(应力波)作用使岩石产生裂隙,并将原始损伤裂隙进一步扩展;随后,爆炸高压气体挤入这些裂隙,借助“气刃效应”使裂隙进一步延伸和扩大,并形成岩块脱离岩体^[14].因此,描述岩体力学性质的参数主要选取了岩石的抗拉强度、抗压强度、结构面体密度、岩石密度和弹性模量;描述爆破设计的参数为孔距、排距、孔深、微差时间和最小抵抗线;描述炸药的参数为炸药密度和爆速.虽然波速是采用波阻抗匹配岩石和炸药的重要依据,但考虑到波速与岩石密度、弹性模量的相关性,在本文的模型中没有选取.

本文认为,爆破效果与其影响因素之间存在的这种因果关系应是相对确定性的,不会因矿山不同而产生显著变化.因此,多个矿山的爆破案例可作为样本进行模型训练,以克服单个矿山爆破案例样本数据单一的不足.但考虑到不同矿山的爆破孔网参数存在差异,其绝对量之间不具备可比性;若直接使用参数的绝对量,可能导致爆破案例样本差异过大.对此,本研究对爆破孔网参数采用孔深归一化处理,将爆破对象量化至以深度度量的单位体积内.最终,模型实际选取的输入参数为:抗拉强度(R_m)、抗压强度(R_c)、弹性模量(E)、结构面体密度(J_v)、岩石密度(ρ)、孔距/孔深(S/H)、排距/孔深(B/H)、炸药单耗(q)、最小抵抗线/孔深(W/H)、微差时间(t)、炸药爆速(v)、炸药密度(ρ_d).

1.3 爆破案例样本库建立

爆破块度预测模型的训练样本共有45组数据,其中11组来自司家营铁矿现场实测的爆破数据,14组取自文献[15]中A矿山的爆破数据,20组取自文献[16]中B矿山的爆破数据.A矿山和B矿山均为露天矿山,其中A矿山含水率较高的地段使用乳化岩石炸药,无水爆区使用硝酸铵炸药,这与司家营铁矿的炸药使用情况较为相似,A矿山的矿岩条件和爆破设计也更为接近司家营

铁矿的现场情况。

为获取司家营铁矿的爆破数据,开展了大量测试工作,如图 2 所示.对司家营铁矿 11 组爆堆进行实地测量和现场取样.利用 YAW-3000 电液伺服压力试验机测量现场岩石样本,获得该爆堆的抗拉强度、抗压强度、弹性模量和矿岩密度数据;通过 3GSM 三维岩体摄影测量系统测量结构面体密度;通过无人机拍摄爆堆照片,再经块度识别软件分析获得爆破块度数据;爆破设计参数和炸药参数参考了每个爆堆的爆破设计说明书.11 组实际测量获得的司家营爆堆数据如表 1 所示,输出参数为平均爆破块度(d).




图 2 模型输入参数的取得方式

Fig. 2 Acquisition mode of model input parameters (a)—司家营不同矿堆的岩石样本; (b)—YAW-3000 电液伺服压力试验机; (c)—3GSM 三维岩体摄影现场测量; (d)—爆破块度识别分析结果示例.

1.4 模型学习控制及隐含层节点确定

BP 神经网络模型的训练次数和学习速率对模型预测结果的准确性影响很大.目前还没有确

定的方法计算给定数据集上给定模型的最佳学习速率,只能通过反复实验观察结果是否逐渐接近最优的学习速率和训练次数.经过多次尝试,模型的训练次数设定为 1 000,学习速率设定为 0.01,训练最小误差设定为 10^{-5} .当达到规定训练次数或者训练误差达到规定范围时,输出结果.模型其他参数根据相关规范确定:显示频率设定为 25(每训练 25 次显示一次),最小性能梯度设定为 10^{-6} ,最高失败次数设定为 6;而 ACO 算法中的初始种群规模设定为 10,最大进化次数设定为 50,信息素挥发系数设定为 0.9.

隐含层节点数的取值范围可根据经验公式初步确定:

$$l = \sqrt{m+n} + a. \quad (4)$$

式中: l 为隐含层节点数; m 和 n 分别为输入层和输出层节点数; a 为 1~10 之间的调节常数.由于输入参数共 12 个,输出参数为 1 个,因此隐含层节点数的取值范围为 4~13.

为确定预测模型最优的隐含层节点数,将隐含层节点数依次设置为 4~13 进行测试,通过比较测试集的均方误差(e_{MS}),选择使用测试集均方误差最小的隐含层节点数构建模型.通过比较不同隐含层节点数对应的模型预测结果均方误差,确定使均方误差最小的隐含层节点数为最优值.当隐含层节点数设置为 7 时,模型预测结果的均方误差达到最小值 0.044 511.

基于 ACO-BP 神经网络的爆破块度预测模型的学习和预测功能均在 MATLAB 平台编程实现.

表 1 司家营 11 组样本数据
Table 1 Sample data of 11 groups from Sijiaoying

样本	R_m MPa	R_c MPa	E GPa	J_v 条·m ⁻³	ρ kg·m ⁻³	S/H	B/H	q kg·t ⁻¹	W/H	t/ms	v m·s ⁻¹	ρ_d g·cm ⁻³	d/cm
1	16.88	175.57	72.53	8.06	3.32	0.57	0.43	0.27	0.29	42	4 500	1.2	25.25
2	17.44	177.90	74.16	7.33	2.69	0.28	0.17	0.24	0.11	42	4 500	1.2	39.52
3	17.44	177.90	74.16	8.43	2.69	0.28	0.17	0.30	0.11	42	4 500	1.2	36.22
4	18.44	198.64	65.46	3.62	2.72	0.21	0.16	0.24	0.11	42	4 500	1.2	34.31
5	15.42	192.46	73.84	3.43	2.74	0.33	0.28	0.25	0.11	42	4 500	1.2	45.82
6	11.33	155.33	55.35	1.84	2.64	0.40	0.30	0.30	0.20	42	4 500	1.2	22.02
7	13.43	183.05	65.37	6.62	2.67	0.27	0.20	0.38	0.13	42	4 500	1.2	30.79
8	17.01	172.02	70.45	5.29	2.65	0.41	0.35	0.16	0.12	42	4 000	1.0	16.11
9	15.37	196.53	66.61	3.33	2.62	0.33	0.28	0.25	0.11	42	4 000	1.0	27.71
10	20.87	218.36	75.66	5.82	2.69	0.47	0.35	0.30	0.12	42	4 500	1.2	19.55
11	12.54	169.36	56.33	3.86	3.38	0.47	0.35	0.29	0.12	42	4 000	1.0	36.18

2 爆破块度预测模型学习与验证

2.1 ACO-BP 模型的预测结果

将样本库中的 45 组数据导入所建立模型中进行训练,按照 8:2 的比例将数据分为 2 组,其中 36 组样本数据作为模型的训练数据,9 组样本数据作为测试数据.由于模型的输入参数取自 3 个矿山,按照 3 个矿山样本数量比例设置测试数据组,其中包含 2 组司家营矿山数据、3 组 A 矿山数据和 4 组 B 矿山数据.

将实际值、BP 神经网络模型的预测结果和 ACO-BP 神经网络模型的预测结果进行对比,结果如表 2 所示.

表 2 爆破块度预测结果与实际值
Table 2 Prediction results and actual values of blasting fragmentation

测试数据 编号	d/cm		实际值
	BP 神经网络 预测值	ACO-BP 神经 网络预测值	
司家营 1#	26.967 0	21.948 1	19.550 0
司家营 2#	13.762 1	27.384 9	36.180 0
A 矿山 1#	33.742 7	28.935 4	29.000 0
A 矿山 2#	51.043 7	31.058 9	29.700 0
A 矿山 3#	29.873 5	29.831 2	29.300 0
B 矿山 1#	20.396 5	23.143 3	35.410 0
B 矿山 2#	24.891 9	23.876 9	22.840 0
B 矿山 3#	27.574 3	27.797 5	31.940 0
B 矿山 4#	27.774 7	24.536 2	21.790 0

2.2 预测结果的分析

为直观对比 BP 神经网络和 ACO-BP 神经网络预测爆破块度的准确性和可靠性,引入均方根误差(e_{RMS})和平均绝对百分比误差(e_{MAP})进行比较,其中 e_{RMS} 表示预测值偏离实际值的程度, e_{MAP} 表示预测值与实际值之间的误差大小,即

$$e_{\text{RMS}} = \sqrt{\frac{1}{p} \sum_{i=1}^p (\hat{y}_i - y_i)^2}, \quad (5)$$

$$e_{\text{MAP}} = \frac{100\%}{p} \sum_{i=1}^p \left| \frac{\hat{y}_i - y_i}{y_i} \right|. \quad (6)$$

式中: p 为样本数量; \hat{y}_i 为块度预测值; y_i 为爆破块度实际值.对比分析结果如表 3 所示.

表 3 不同模型的预测结果指标值
Table 3 Index values of prediction results of different models

评价指标	BP 神经网络预测	ACO-BP 神经网络预测
e_{RMS}	12.112 6	5.390 2
$e_{\text{MAP}}/\%$	31.399 2	11.993 5

由表 3 可知,经 ACO 算法优化初始权值和阈值的 BP 神经网络模型预测值的均方根误差为 5.390 2,平均绝对百分比误差为 11.993 5%,分别是 BP 神经网络预测值的 44.50% 和 38.20%.这说明优化后的 ACO-BP 神经网络预测模型具有更高的准确性和可靠性,能更好地拟合爆破过程中从岩体力学性质、炸药性质和爆破设计参数的科学匹配到爆破平均块度的多因素作用关系.

2.3 学习样本数量对预测结果影响

虽然爆破效果与其影响因素之间存在因果关系,但不同矿山的矿岩性质、爆破设计等参数往往存在较大差异.将不同矿山实测采集的爆破案例作为样本数据进行模型训练能否提高预测准确性,需要进一步论证.为此,将爆破样本数据分为 4 组训练样本(1#,2#,3#,4#):1#样本为司家营铁矿的 11 组数据;2#样本为司家营铁矿和 A 矿山的 25 组数据;3#样本为司家营铁矿和 B 矿山的 31 组数据;4#样本为司家营铁矿、A 矿山和 B 矿山的 45 组数据.分别以这 4 组样本作为训练集进行模型学习,然后利用训练后的模型进行预测,以预测结果的 e_{MAP} 作为模型训练误差的评价标准,对比结果如图 3 所示.




图 3 不同训练样本情况下模型预测结果的误差
Fig. 3 Prediction error of model under different training samples

由图 3 可知,总体上,引入其他矿山数据作为模型训练样本,可以有效降低模型的预测误差.对比 2# 样本和 3# 样本,在选择司家营铁矿 11 组数据作为模型训练样本的前提下,引入 A 矿山数据扩充样本库比引入 B 矿山数据对模型预测精度的提升效果更明显.这主要是因为 A 矿山的矿岩条件、爆破设计与司家营铁矿的现场情况较 B 矿山更为接近.说明当引入矿山情况更接近时,通过增加其他矿山爆破数据来提升训练样本容量,能更有效地提高模型预测精度.为保证模型的预测精度,应尽量选择与所研究矿山的矿岩条件

和爆破参数相近的矿山数据作为训练扩充样本量。

3 爆破块度影响因素权重及影响规律分析

3.1 影响因素的权重分析

为获得良好的爆破效果,提高爆破设计优化的针对性,对模型中选取的 12 个输入参数的权值进行分析.在 BP 神经网络中,各输入参数权值的计算方法如下:

$$y=f\left(\sum_{i=1}^h w_i x_i - \theta\right) \quad (7)$$

式中: y 为输出值; h 为输入参数数量; w_i 为某参数

的权值; x_i 为某参数输入值; θ 为偏置。

将 BP 神经网络预测过程看作线性过程分析,不考虑偏置 θ 的影响.利用 BP 神经网络输入层到隐含层之间、隐含层到输出层之间的权值矩阵,计算得出各个输入参数的权值.根据权值大小,可以得到 12 个输入参数对爆破块度影响的重要性。

输入层到隐含层的权值如表 4 所示;隐含层到输出层的权值如表 5 所示.通过 BP 神经网络输入层到隐含层之间、隐含层到输出层之间的权重矩阵,计算得到输入参数对爆破块度的影响权重,如表 6 所示。

表 4 输入层到隐含层的权值
Table 4 Weights from input layer to hidden layer

节点	w_i											
	R_m	R_c	E	J_v	ρ	S/H	B/H	q	W/H	t	v	ρ_d
1	0.63	0.63	-5.36	-2.75	1.13	-1.59	-0.02	-0.27	-0.56	0.46	-1.72	-0.61
2	1.43	-0.47	2.54	5.27	1.88	0.97	-2.83	0.83	1.60	-2.88	-2.25	-6.90
3	2.25	0.07	-0.16	-2.99	1.50	4.96	0.28	1.28	-1.28	-1.76	-3.96	0.25
4	6.64	1.38	-1.14	-2.74	6.14	6.31	2.45	-3.82	1.59	-3.43	-2.75	-0.31
5	1.01	-0.36	-2.41	6.10	-3.44	4.21	5.57	2.05	0.11	0.53	-0.72	-1.09
6	0.53	3.26	0.14	-2.29	-2.15	-4.81	2.59	4.25	-0.42	0.13	-2.14	-0.86
7	0.32	0.88	-0.83	-2.42	-0.62	7.10	2.41	-5.22	0.88	2.52	0.64	-3.99

表 5 隐含层到输出层之间的权值
Table 5 Weights from hidden layer to output layer

隐含层节点	1	2	3	4	5	6	7
权值	0.409 6	0.060 0	0.143 6	-0.470 8	0.095 2	-0.355 3	-0.302 0

表 6 预测模型中各输入参数的权重
Table 6 Weights of each input parameter in prediction model

参数	R_m	R_c	E	J_v	ρ	S/H	B/H	q	W/H	t	v	ρ_d
权重	0.34	0.24	0.20	-0.28	0.19	0.37	0.32	-0.28	0.15	-0.08	-0.05	-0.12

由表 6 可以看出,在爆破块度预测模型中,影响因素分为正相关性和负相关性两大类.其中,结构面体密度、炸药单耗、微差时间、炸药爆速、炸药密度等 5 个因素的影响为负相关性,这些参数值越大,预测得到的爆破块度越小;而岩体力学性质、孔网参数对爆破块度的影响为正相关性,这些参数值越大,预测得到的爆破块度越大.另外,岩石抗拉强度、结构面体密度、孔网参数的权重比较大,说明爆破块度对这些参数更为敏感,这为优化爆破设计提供了指导和依据。

3.2 主要参数对爆破块度的影响规律

应用训练后的基于 ACO-BP 神经网络的爆破块度预测模型,定量分析了主要影响因素变化

对爆破块度的影响.由于微差时间与炸药性质相对固定,因此选取其他 9 个主要影响因素,以司家营 1# 爆破样本数据为参照数据,采用控制变量法,在其他影响因素不变的前提下,分别令某个输入参数增减 20%、40% 和 60%,作为一组新的爆破工况的输入数据,应用所建的模型预测爆破块度,研究主要影响因素对爆破块度的影响规律。

爆破块度随主要因素变化规律如图 4 所示.由图中曲线变化趋势对比可以看出,9 个主要因素对爆破块度的影响程度由大到小依次为:孔距/孔深、抗拉强度、排距/孔深、炸药单耗、抗压强度、结构面体密度、岩石密度、弹性模量、最小抵抗线/孔深.其中结构面体密度和炸药单耗 2 个参数与

爆破块度呈负相关关系,这与权重分析得到的结果基本一致.

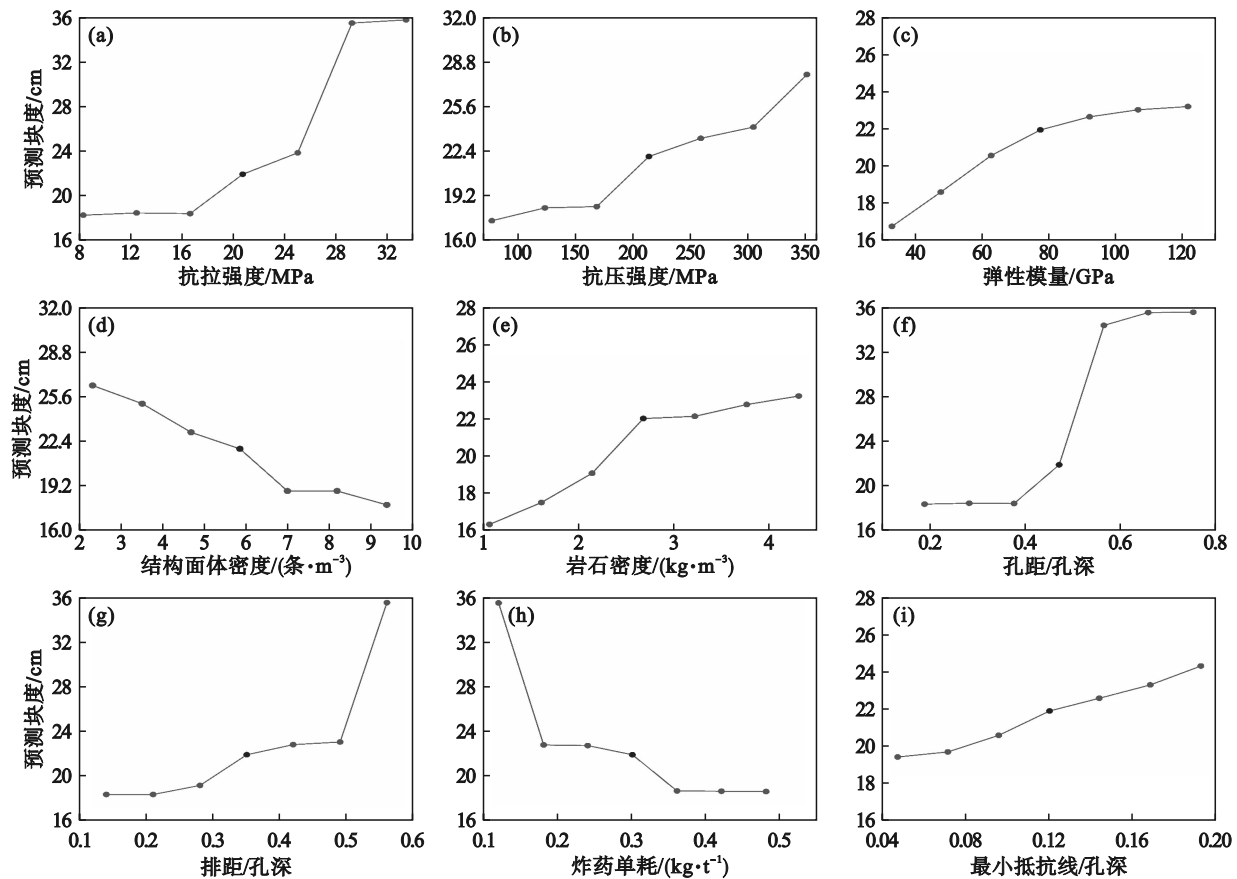


图 4 主要参数对爆破块度的影响规律

Fig. 4 Influence of main parameters on blasting fragmentation

(a)—抗拉强度; (b)—抗压强度; (c)—弹性模量; (d)—结构面体密度; (e)—岩石密度;
(f)—孔距/孔深; (g)—排距/孔深; (h)—炸药单耗; (i)—最小抵抗线/孔深.

在实际爆破设计过程中,结构面体密度、抗拉强度等属于矿岩体的固有性质.对于特定矿山而言,矿岩固有性质难以人为改变;但爆破设计参数如排距、孔距、炸药单耗、最小抵抗线等属于可调控范畴,可通过优化趋近于最优值,从而保证预期的爆破效果.为达到预期爆破块度,可根据爆破块度影响因素的权重,依次调整孔距、排距、炸药单耗及最小抵抗线等参数.

由图 4f, 4g 和 4h 可以看出,对一个矿山而言,矿岩性质是确定的,爆破设计参数(如孔距、排距、炸药单耗等)都有一个最适配的取值范围.不能通过单一减小孔距、排距或增大炸药单耗来持续使爆破块度减小.对司家营露天铁矿的爆破设计,孔距应在 0.38~0.65 倍孔深、排距应在 0.25~0.5 倍孔深、炸药单耗应在 0.19~0.36 kg/t 范围内取值(以上认识有待现场试验验证).对于岩石爆破,孔距和排距可以取较大值;对于矿石爆破可以取较小值.该模型通过目标爆破块度反向优化

爆破设计,进而获得最佳爆破块度,为实现矿石的“以爆代破”提供了理论支撑和技术手段.

4 结 论

1) 采用蚁群算法优化 BP 神经网络模型的初始权重和阈值,提高了 BP 神经网络预测爆破块度的准确性,预测结果也更加稳定.

2) 不同矿山爆破数据可同时作为模型训练样本,以提升模型训练数据量,总体上可提高模型预测精度;矿岩条件越相近,模型精度的提升效果越显著.

3) 爆破块度影响因素分为负相关因素和正相关因素两类,各影响因素权重系数不同.9 个主要影响因素的权重由大到小依次为:孔距/孔深、抗拉强度、排距/孔深、炸药单耗、抗压强度、结构面体密度、岩石密度、弹性模量、最小抵抗线/孔深.

4) 爆破设计参数,如孔距、排距、炸药单耗等

对爆破块度的影响都是有限的,存在一个最优的取值范围.不能通过单一减小孔距、排距或增大炸药单耗来持续减小爆破块度.对于岩石爆破,孔距和排距可以取较大值;对于矿石爆破则可以取较小值.该模型通过预设爆破块度,反向优化爆破设计,为获得最佳爆破效果提供了理论支撑和技术手段.

参考文献:

- [1] Kulatilake P H S W, Wu Q, Hudaverdi T, et al. Mean particle size prediction in rock blast fragmentation using neural networks[J]. *Engineering Geology*, 2010, 114 (3/4): 298-311.
- [2] Shi X Z, Zhou J, Wu B B, et al. Support vector machines approach to mean particle size of rock fragmentation due to bench blasting prediction [J]. *Transactions of Nonferrous Metals Society of China*, 2012, 22(2):432-441.
- [3] Ke B, Pan R H, Zhang J, et al. Parameter optimization and fragmentation prediction of fan-shaped deep hole blasting in Sanxin Gold and Copper Mine[J]. *Minerals*, 2022, 12(7): 788.
- [4] Wang Y C, Guo Q P, Yang S J, et al. A prediction model for blasted block size grouping based on HC and RF-GA-BP neural network [J]. *Arabian Journal of Geosciences*, 2022, 15 (16): 1391.
- [5] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [6] Gao W, Karbasi M, Hasanipah M, et al. Developing GPR model for forecasting the rock fragmentation in surface mines [J]. *Engineering with Computers*, 2018, 34 (2) : 339-345.
- [7] 金长宇, 于佳强, 王强, 等. 基于集成学习 CatBoost 优化模型的爆堆大块率预测[J]. 东北大学学报(自然科学版), 2023, 44(12): 1743-1750.
(Jin Chang-yu, Yu Jia-qiang, Wang Qiang, et al. Prediction of blasting fragment large block percentage ratio based on ensemble learning CatBoost model[J]. *Journal of Northeastern University (Natural Science)*, 2023, 44 (12): 1743-1750.)
- [8] Gao H, Fu Z L. Forecast of blasting fragmentation distribution based on BP neural network [J]. *Advanced Materials Research*, 2012, 619: 3-8.
- [9] 史秀志, 郭霆, 尚雪义, 等. 基于 PCA-BP 神经网络的岩石爆破平均粒径预测 [J]. 爆破, 2016, 33(2): 55-61.
(Shi Xiu-zhi, Guo Ting, Shang Xue-yi, et al. Prediction of mean particle size of rock blast based on combination of PCA and BP neural networks[J]. *Blasting*, 2016, 33(2) : 55-61.)
- [10] Guo Q P, Yang S J, Wang Y C, et al. Prediction research for blasting peak particle velocity based on random GA-BP neural network group[J]. *Arabian Journal of Geosciences*, 2022, 15(15): 1351.
- [11] Yu J Y, Ren S J. Prediction and analysis method of mine blasting quality based on GA-BP neural network [J]. *Mobile Information Systems*, 2022 (1): 9239381.
- [12] Xing Y H, Li F F. Research on the influence of hidden layers on the prediction accuracy of GA-BP neural network [J]. *Journal of Physics: Conference Series*, 2020, 1486 (2): 022010.
- [13] Dorigo M, Maniezzo V, Colomi A. Ant system: optimization by a colony of cooperating agents [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B. Cybernetics*, 1996, 26(1): 29-41.
- [14] Li X D, Liu K W, Zhao X R, et al. Study on rock fracturing in smooth blasting under initial stress [J]. *Engineering Fracture Mechanics*, 2024, 296: 109865.
- [15] 赵翔, 郭小平, 朴志友, 等. BP 神经网络在爆破块度预测中的应用研究[J]. 水泥技术, 2015 (1): 36-39.
(Zhao Xiang, Guo Xiao-ping, Piao Zhi-you, et al. Application research of BP neural network in predication of rock fragmentation [J]. *Cement Technology*, 2015 (1) : 36-39.)
- [16] 邓飞, 肖伟, 程秋亭, 等. 基于 BP 神经网络的爆破参数优化[J]. 矿业研究与开发, 2016, 36(4): 19-21.
(Deng Fei, Xiao Wei, Cheng Qiu-ting, et al. Optimization of blasting parameters based on BP neural network [J]. *Mining Research and Development*, 2016, 36 (4): 19-21.)