

DOI: 10.11779/CJGE20240378

# 基于原岩随钻振动信号的岩石单轴抗压强度快速预测 试验研究

刘河清<sup>1,2,3</sup>, 刘建康<sup>\*1,2</sup>, 郝建<sup>1,2</sup>, 郑义宁<sup>4</sup>, 肖勇<sup>5</sup>, 胡慧<sup>1,2</sup>, 栾学坤<sup>1,2</sup>

(1. 山东科技大学能源与矿业工程学院, 山东 青岛 266590; 2. 山东科技大学省部共建矿山岩层智能控制与绿色开采国家重点实验室培育基地, 山东 青岛 266590; 3. 中国矿业大学(北京)隧道工程灾变防控与智能建养全国重点实验室, 北京 100083; 4. 山东能源集团鲁西矿业有限公司 郭屯煤矿, 山东 菏泽 274700; 5. 山西省煤炭地质 115 勘查院有限公司, 山西 大同 037000)

**摘 要:** 为了揭示随钻振动信号与岩石单轴抗压强度之间的响应关系, 实现单轴抗压强度的快速感知预测, 基于随钻振动信号提出了混合遗传算法优化(GA-BP)的单轴抗压强度人工神经网络快速预测方法。运用傅里叶变换及数学运算提取花岗岩、石灰岩、页岩、砂岩和煤 5 种原岩(煤)振动信号时域、频域的特征值, 构建不同神经网络预测模型并分析比较各模型的预测性能。研究结果表明: 经遗传算法优化的 GA-BP 神经网络模型决定系数  $R^2$  为 0.778, 较之 BP 神经网络模型提升了 9.4%; 构建的模型对于单轴抗压强度有着较好的预测能力, 所用方法为岩石力学参数快速获取技术的智能化和自动化发展提供了新的技术路径。

**关键词:** 随钻振动信号; 单轴抗压强度; 时域、频域特征; 神经网络

中图分类号: TU459

文献标识码: A

文章编号: 1000-4548(2025)08-1700-11

**作者简介:** 刘河清(1998—), 女, 博士研究生, 主要从事机器学习方法在岩石力学参数预测应用等方面的研究工作。

E-mail: liuhq46@163.com。

## Experimental study on rapid prediction of uniaxial compressive strength of rock based on vibrating signals of raw rock with drilling

LIU Heqing<sup>1,2,3</sup>, LIU Jiankang<sup>\*1,2</sup>, HAO Jian<sup>1,2</sup>, ZHENG Yining<sup>4</sup>, XIAO Yong<sup>5</sup>, HU Hui<sup>1,2</sup>, LUAN Xuekun<sup>1,2</sup>

(1. College of Energy and Mining Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 2. State Key Laboratory of Strata Intelligent Control and Green Mining Co-founded by Shandong Province and the Ministry of Science and Technology, Shandong University of Science and Technology, Qingdao 266590, China; 3. State Key Laboratory for Tunnel Engineering, China University of Mining and Technology (Beijing), Beijing 100083, China; 4. Guotun Coal Mine of Shandong Energy Group Luxi Mining Co., Ltd., Heze 274700, China; 5. Shanxi Coal Geology 115 Exploration Institute Co., Ltd., Datong 037000, China)

**Abstract:** In order to reveal the response relationship between the vibrating signals with drilling and the uniaxial compressive strength(UCS) of rock and to realize the rapid sensory prediction of the UCS, a hybrid genetic algorithm optimization (GA-BP) artificial neural network rapid prediction method for the UCS is proposed based on the vibrating signals with drilling. The Fourier transform and mathematical operations are used to extract the eigenvalues of the vibrating signals of granite, limestone, shale, sandstone and coal in the time and frequency domains to establish different neural network prediction models and to analyze and compare the prediction performance of each model. The results show that the coefficient of determination  $R^2$  of the GA-BP neural network model optimized by the genetic algorithm for the training set is 0.778, which is improved by 9.4% compared with that by the BP neural network model. The proposed model has a good prediction capability for the UCS, and the method used provides a new technological path for the development of intelligent and automated techniques for rapid acquisition of mechanical parameters of rock.

**基金项目:** 国家自然科学基金项目(52204099, 52174121); 山东省自然科学基金项目(ZR2022QE203); 省部共建矿山岩层智能控制与绿色开采国家重点实验室培育基地开放基金项目(MDPC2024ZR03) This work was supported by the Natural Science Foundation of China (Grant Nos.52204099, 52174121), the Natural Science Foundation of Shandong (Grant No.ZR2022QE203), and the Open Fund for Cultivation Base of State Key Laboratory of Intelligent Control and Green Mining of Mine Rock Stratum Co-constructed by Province and Ministry (Grant No.MDPC2024ZR03).

收稿日期(Received): 2024-04-18 修回日期(Revised): 2024-10-21 接受日期(Accepted): 2024-10-25 网络出版日期(Online): 2024-10-26

\*通信作者(E-mail: ljk@sdust.edu.cn)

**Key words:** vibrating signal with drilling; uniaxial compressive strength; time and frequency domain characteristic; artificial neural network

## 0 引言

岩石力学参数特别是单轴抗压强度的实时、准确感知对岩石力学及其相关工程的智能化发展具有重要意义。目前, 岩石单轴抗压强度等力学参数通常采用单轴压缩试验和点荷载试验获取, 试验周期长, 耗费大量成本, 过程繁琐复杂, 无法及时将获取的岩石力学参数应用于工程现场。钻机钻孔破岩是煤炭开采、隧道开挖等工程的重要组成部分, 钻进过程中产生大量的随钻振动信号, 但庞大的随钻振动信号与岩石力学参数的响应关系并不十分明确, 仍需开展进一步研究。因此, 探究随钻振动信号与岩石力学参数间的响应关系, 并寻求一种能够充分利用随钻振动信号实时准确感知预测单轴抗压强度的方法意义重大。

利用传统随钻参数(例如扭矩、钻进速度、转速等), 国内外学者开展了大量研究, 其中主要包括两个方面: ①建立随钻参数与目标参数之间的响应关系模型<sup>[1]</sup>, 以达到智能识别<sup>[2-7]</sup>的目的, 例如识别岩性、地层等; ②通过随钻参数实现对目标参数的预测<sup>[8-12]</sup>, 例如对岩石力学参数的感知预测。应用传统随钻参数对目标参数的感知预测都颇有成效, 但随钻参数采集过程较复杂、研究过程经历时间较长, 所需成本投入较大。

随钻参数的采集过程中大都处处伴随着振动信号的产生, 与钻进参数相比, 振动信号更易于采集获取。针对振动信号的产生特性和振动信号与岩石力学参数的响应关系, 各位学者做出如下研究。Liu 等<sup>[13]</sup>、Qin 等<sup>[14]</sup>、Lazarova 等<sup>[15]</sup>应用理论分析、室内试验、模型构建等方法分析了不同岩石的振动特性、构建了振动特性模型, 并对其进行归纳总结; 国内外部分学者<sup>[16-22]</sup>通过随钻振动信号分别对顶板岩层破裂、钻进介质、刀具磨损水平、煤矸石、不同岩性、工作面、不同岩石介质进行识别; 利用随钻振动信号不仅可以实现识别功能, 还可以实现对目标参数的预测等<sup>[23-24]</sup>。以上研究中, 振动信号分析应用的过程更加快速, 振动信号特征值提取的方法多样, 运用空间广泛。

与此同时, 单轴抗压强度的随钻感知、智能预测是近年来开展最为广泛的, 国外学者<sup>[25-28]</sup>分别基于贝叶斯模型、PSO-BP 神经网络、声级信号等方法构建了单轴抗压强度的预测模型。以上研究在感知预测岩石力学参数方面都有所突破, 但在与随钻振动信号相结合方面仍需进一步研究。

基于上述, 本文将继续探索随钻振动信号与岩石力学参数之间的响应关系, 探究岩石力学参数快速获取方法。以室内钻取花岗岩、石灰岩、页岩、砂岩及

煤 5 种原岩试样的随钻振动信号为基础, 建立基于随钻振动信号的岩石单轴抗压强度神经网络预测模型。岩石钻测试验研究流程图如图 1 所示。

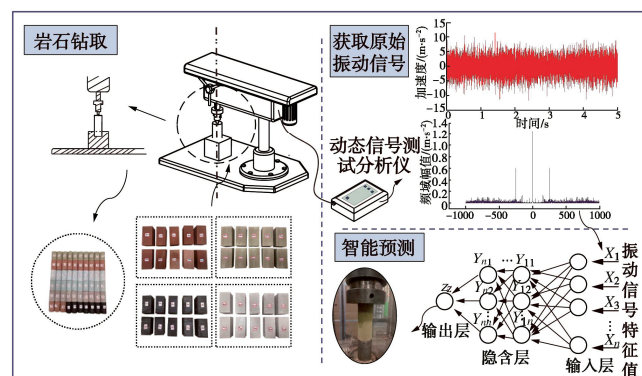


图 1 岩石钻测试验研究流程图

Fig. 1 Flow chart of experimental research on rock drilling and testing

## 1 试验方法及数据预处理

### 1.1 试验材料及方法

#### 1.1.1 试验材料

根据岩石强度等级划分标准并结合煤矿井下常见岩石种类, 本文选取了 5 种原岩作为试验材料, 分别为花岗岩、石灰岩、页岩、砂岩、煤。选取的岩石均质地致密均匀、无明显裂缝。五类原岩选取不同单轴抗压强度(0~150 MPa)的岩样 20 余种, 共 200 个试件。其中, 煤和砂岩的单轴抗压强度主要分布于 0~50 MPa, 煤试件共 20 块, 砂岩试件共 80 块; 石灰岩和页岩的单轴抗压强度主要分布在 50~90 MPa, 石灰岩共 30 块, 页岩共 20 块; 花岗岩的单轴抗压强度主要分布于 70~150 MPa, 共 50 块。



图 2 部分原岩试件

Fig. 2 Part of original rock specimens

#### 1.1.2 试验方法

##### (1) 试件制作

将选取的原岩石料切成 70 mm×70 mm×110 mm

大小的立方体,如图2所示,将加工好的试件进行编号并张贴标签。花岗岩编号为  $G_{mJ}$ , 石灰岩编号为  $L_{mJ}$ , 页岩编号为  $SH_{mJ}$ , 砂岩编号为  $SA_{mJ}$ , 煤的编号为  $C_{mJ}$ ,  $m$  为强度种类编号(1, 2, 3,  $\dots$ ,  $n$ ),  $J$  为同种强度的试件序号(1, 2, 3,  $\dots$ ,  $n$ ), 例如  $SA_{32}$  为砂岩试件第3种强度第2个试件编号。

## (2) 室内试验

室内试验主要包括随钻振动信号采集部分和单轴抗压强度测定部分。

### a) 随钻振动信号采集

随钻振动信号采集设备采用室内 YJ-2 型岩芯钻取机、UBP-02 型岩芯切磨机和 DH5909N 手持式动态信号测试分析仪(如图3所示)共同完成数据采集过程。其中岩芯钻取机和岩芯切磨机将试件加工成标准岩芯( $\Phi 50\text{ mm} \times 100\text{ mm}$ ), 随钻振动信号采用 DH5909N 手持式动态信号分析仪连接 IEPE 加速度传感器采集, 采样频率为 2000 Hz。





图3 振动信号采集仪器及过程

Fig. 3 Acquisition instruments and processes of vibrating signals

具体采集步骤: ①调试好岩芯钻取机和 DH5909N 手持式动态信号分析仪, 将立方体试件固定于操作台上。②连接 IEPE 式加速度传感器至室内岩芯钻取机, 开启岩芯钻取机的同时点击动态信号测试分析仪上的“开始采集”按钮, 在钻取岩芯的过程中采集试件的随钻振动信号, 其中动态信号测试分析仪采集的原始

信号为时域的振动波形信号(如图4所示)。③将钻取的岩芯切磨成大小为  $\Phi 50\text{ mm} \times 100\text{ mm}$  的标准岩芯(如图5所示)。




图4 振动信号波形图

Fig. 4 Waveform of vibrating signals



图5 部分标准岩心试件

Fig. 5 Selected standard core specimens

### b) 单轴抗压强度测定

采用 BGYD-600 变刚度试验加载系统对取好的岩芯进行单轴压缩, 获取单轴抗压强度等岩石力学参数。

## 1.2 振动信号分析

本文将对随钻振动信号进行时域、频域分析, 提取时、频域的数学特征值, 将振动信号用数字的形式直观地表现出来。

### (1) 振动信号时域特征值

表1为时域特征值提取的计算公式:  $x(n)$  为信号的时域序列,  $n=1, 2, \dots, N$ ;  $N$  为样本点数。

根据时域特征值公式并借助软件 MATLAB 计算出每一个样本的时域特征值: 分别为 A1 平均值、B1 标准差、C1 偏度、D1 峭度、E1 最大值、F1 最小值、G1 峰峰值、H1 均方差、I1 振幅因数、J1 波形因数、K1 冲击因数、L1 裕度因数、M1 能量等 13 个参数。

### (2) 频谱特征值提取方法

频谱特征采用傅里叶变换法将时域谱转化为频域谱。

连续傅里叶变换将平方可积的函数  $f(t)$  表示成复指数函数的积分或级数形式。这是将频率域的函数  $F(\omega)$  表示为时间域的函数  $f(t)$  的积分形式。



$$F(\omega) = F[f(t)] = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \quad (1)$$

连续傅里叶变换的逆变换 (inverse Fourier transform)为

$$f(t) = F^{-1}[F(\omega)] = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{i\omega t} d\omega \quad (2)$$

即将时间域的函数  $f(t)$  表示为频率域的函数  $F(\omega)$  的积分。一般可称函数  $f(t)$  为原函数，而称函数  $F(\omega)$  为傅里叶变换的像函数，原函数和像函数构成一个傅里叶变换对 (transform pair)。

表 1 时、频域特征值计算公式

Table1 Formulas for eigenvalues of time and frequency domains			
特征值名称	计算公式	特征值名称	计算公式
平均值	$\bar{x} = \frac{1}{N} \sum_{n=1}^N x(n)$	均方差	$x_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)}$
标准差	$\sigma_x = \sqrt{\frac{1}{N-1} \sum_{n=1}^N [x(n) - \bar{x}]^2}$	振幅因数	$x_r = \left( \frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) } \right)^2$
偏度	$S = \frac{\sum_{n=1}^N [x(n) - \bar{x}]^3}{(N-1)\sigma_x^3}$	波形因数	$W = \frac{x_{rms}}{x}$
峭度	$K = \frac{\sum_{n=1}^N [x(n) - \bar{x}]^4}{(N-1)\sigma_x^4}$	冲击因数	$I = \frac{x_p}{x}$
最大值	$x_{max} = \max(x_n)$	裕度因数	$L = \frac{x_p}{x_r}$
最小值	$x_{min} = \min(x_n)$	能量	$E = \sum_{n=1}^N x^2(n)$
峰峰值	$x_p = \max x(n) $		

经傅里叶变换后得到的频谱（如图 6），应用 1.2（1）时域特征值提取方法，可同样得到频谱的数字表征特征值：A2 平均值、B2 标准差、C2 偏度、D2 峭度、E2 最大值、F2 最小值、G2 峰峰值、H2 均方差、I2 振幅因数、J2 波形因数、K2 冲击因数、L2 裕度因数、M2 能量等 13 个参数。

2 神经网络模型简介与构建

2.1 基本算法介绍

（1）BP（Back Propagation）神经网络

BP 神经网络是一种监督学习的多层前馈网络算法，学习算法正向传播，误差反向传播，经过不断调整各层节点的权值提高算法精度。BP 神经网络拓扑结构包含输入层、隐含层和输出层，输入层和输出层都只含一层，隐含层可为一层或多层，如图 7 所示。




图 6 频率谱




图 7 BP 神经网络拓扑图

Fig. 7 Topology of BP neural network

（2）遗传算法（Genetic Algorithm, GA）

遗传算法（Genetic Algorithm, GA）是一种基于自然选择和群体遗传机理的搜索算法，它模拟了自然选择和自然遗传过程中的繁殖、杂交和突变现象，在求解问题时，问题的每一个可能解都被编码成一个“染色体”，即个体，若干个体构成了群体（所有可能解）。在遗传算法开始时，总是有机的产生一些个体（即初始解），根据预定的目标函数对每一个个体进行评估，给出一个适应度，基于此适应度值，选一些个体用来产生下一代，选择操作体现了“适者生存”的原理，“优”的个体被用来产生下一代。“劣”的个体则被淘汰。选择出来的个体，经过交叉和变异算子进行再组合生成新一代，这一代的个体由于继承了上一代的一些优良性状，因而在性能上要优上一代，依此逐步朝着最优解的方向进化。

GA-BP 神经网络模型流程图如图 8 所示。

2.2 神经网络模型构建

（1）BP（Back Propagation）神经网络构建

输入层为时域和频域的 26 个特征值，分别为时域的 A1 平均值、B1 标准差、C1 偏度、D1 峭度、E1 最大值、F1 最小值、G1 峰峰值、H1 均方差、I1 振幅因数、J1 波形因数、K1 冲击因数、L1 裕度因数、M1 能量和频域的 A2 平均值、B2 标准差、C2 偏度、D2



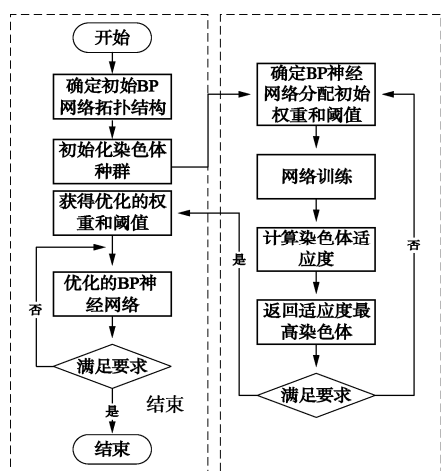


图8 GA-BP 算法流程图

Fig. 8 Flow chart of GA-BP algorithm

峭度、E2 最大值、F2 最小值、G2 峰峰值、H2 均方差、I2 振幅因数、J2 波形因数、K2 冲击因数、L2 裕度因数、M2 能量。神经网络输入共为 850 个数据，其中，训练集 680 (80%) 个，测试集 170 (20%) 个。

BP 神经网络迭代次数设置为 800 次，隐含层作为变量条件设置对照组，隐含层分别设置为 5, 8, 10, 13, 15, 18, 20, 23, 25, 30 共 10 组。训练模型均以  $R^2$ 、RMSE、MAE 作为标准来衡量模型的拟合程度。

a) 决定系数。解释离差平方和与总离差平方和之比值，反映模型拟合程度：

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (3)$$

b) 均方根误差。均方根误差是预测值与真实值偏差的平方与观测次数  $n$  比值的平方根。衡量的是预测值与真实值之间的偏差，并且对数据中的异常值较为敏感：

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (4)$$

c) 平均绝对误差。表示预测值和观测值之间绝对误差的平均值：

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m \left| y_i - \hat{y}_i \right| \quad (5)$$

## (2) GA-BP 神经网络模型构建

GA-BP 神经网络模型是在神经网络模型基础上，运用遗传算法改进神经网络输入、权值和阈值，得到更优的预测模型。

本文试验样本预测输出指标单轴抗压强度的跨度为 0~150 MPa，范围较大。康红普等<sup>[29]</sup>认为除具有一般岩体的特征外，中国煤矿煤系沉积岩地层还有以

下特点：①强度低。煤层单轴抗压强度一般为 5~20 MPa，有的煤层强度更低；泥岩、粉砂岩等岩层单轴抗压强度大多在 10~60 MPa，单轴抗压强度小于 30 MPa 的软弱岩层在很多煤矿普遍存在。②很多煤矿地质构造复杂，煤岩体中层理、节理、裂隙发育。③煤矿开采深度不断杂。④开采空间与范围大，采动影响强烈。

考虑到煤矿井下实际情况，同一个矿井的岩石力学强度范围跨度较小，故选取部分样本 0~40 MPa 作为输入建立一个适合现场应用的神经网络预测模型。

### a) 全样本模型

GA-BP 神经网络模型的输入参数与 BP 神经网络模型输入同为时域和频域的 26 个参数，分别为时域 A1 平均值、B1 标准差、C1 偏度、D1 峭度、E1 最大值、F1 最小值、G1 峰峰值、H1 均方差、I1 振幅因数、J1 波形因数、K1 冲击因数、L1 裕度因数、M1 能量和频域 A2 平均值、B2 标准差、C2 偏度、D2 峭度、E2 最大值、F2 最小值、G2 峰峰值、H2 均方差、I2 振幅因数、J2 波形因数、K2 冲击因数、L2 裕度因数、M2 能量。输出为单轴抗压强度。GA-BP 神经网络输入样本总数为 850 个数据，其中，训练集样本数 680 (80%) 个，测试集样本数 170 (20%) 个。

GA-BP 神经网络的迭代次数通过数次反复试训练得出，如图 9 所示，当迭代次数到达 800 次左右即趋于稳定，此时模型训练达到最好水平，故迭代次数设置为 800 次。




图9 适应度曲线

Fig. 9 Curves of fitness

隐含层和种群大小作为变量条件设置对照组，隐含层分别设置为 5, 8, 10, 13, 15, 18, 20, 23, 25, 30 共 10 组；种群大小设置为 10, 20, 30, 40, 50, 60, 70, 80, 90, 100 共 10 种。训练模型均以  $R^2$ 、RMSE、MAE 作为标准来衡量模型的拟合程度与误差。

### b) 部分样本模型

GA-BP 神经网络模型的输入参数与 BP 神经网络模型输入同为时域和频域的 26 个参数，输出为单轴抗压强度。GA-BP 神经网络输入样本总数为 225 个数据，强度范围在 0~40 MPa。其中，训练集样本数 180

(80%) 个, 测试集样本数 45 (20%) 个。  
迭代次数、隐含层和种群大小与全样本模型相同。

3 结果分析讨论

3.1 BP 神经网络结果与分析

经多次训练, 为去除最终结果的偶然性影响, 各隐含层对照组的运行结果取 10 次结果的平均值, 2.2 (1) 中建立的神经网络模型预测结果如表 2 所示。

表 2 BP 神经网络模型预测结果

Table 2 Predicted results by BP neural network model

隐含层	训练集			测试集		
	$R_1^2$	RMSE <sub>1</sub> /MPa	MAE <sub>1</sub> /MPa	$R_2^2$	RMSE <sub>2</sub> /MPa	MAE <sub>2</sub> /MPa
5	0.690	23.776	18.865	0.625	25.985	22.364
8	0.699	23.435	18.596	0.579	28.249	23.554
10	0.680	24.237	19.362	0.564	27.008	22.985
12	0.632	26.168	21.391	0.616	25.865	22.016
15	0.684	24.056	18.963	0.659	24.634	21.695
18	0.651	25.341	20.613	0.528	28.997	23.129
20	0.676	24.461	18.634	0.501	29.971	24.603
23	0.693	24.193	19.023	0.506	29.222	24.153
25	0.659	24.821	19.992	0.610	26.999	22.543
30	0.639	25.900	21.018	0.508	29.906	24.308

根据 BP 模型预测结果, 各隐含层对照组的训练集决定系数都在 0.63 以上, 测试集决定系数都在 0.5 以上, 能够说明振动信号与岩石单轴抗压强度有一定的响应关系,BP 神经网络模型可以用来研究本文所提出的问题。

由表 2 和图 10 可知: BP 模型预测结果中训练集结果相对稳定,而测试集结果上下浮动仍有一定差距。





图 10 BP 神经网络模型预测结果

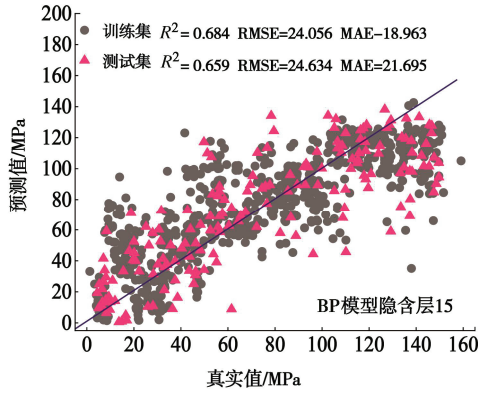
Fig. 10 Predicted results by BP neural network model

(1) 隐含层数为 8 时 (拟合结果如图 11 (a)) , 训练集预测结果  $R_1^2$  为 0.699、RMSE<sub>1</sub> 为 23.435、MAE<sub>1</sub> 为 18.598, 测试集预测结果  $R_2^2$  为 0.579, RMSE<sub>2</sub> 为 28.249, MAE<sub>2</sub> 为 23.554。虽然  $R_1^2$  在训练集中结果最好, 但  $R_2^2$  偏小, 训练集与测试集的决定系数相差 0.12; 与其他对照组相比, 均方根误差 RMSE<sub>2</sub> 和平均绝对误差 MAE<sub>2</sub> 结果较其它结果偏大, 可见隐含层数为 8 的

一组不能选做最优模型。



(a) BP-8



(b) BP-15

图 11 BP 神经网络模型拟合曲线

Fig. 11 Fitting curves of BP neural network model

(2) 隐含层数为 15 时 (拟合结果如图 11 (b)) , 训练集预测结果  $R_1^2$  为 0.684, RMSE<sub>1</sub> 为 24.056、MAE<sub>1</sub> 为 18.963, 测试集预测结果  $R_2^2$  为 0.659, RMSE<sub>2</sub> 为 24.634, MAE<sub>2</sub> 为 21.695, 训练集与测试集的决定系数仅差 0.025, 训练集均方根误差 RMSE<sub>1</sub> 和平均绝对误差 MAE<sub>1</sub> 结果在训练集中较小, 测试集均方根误差 RMSE<sub>2</sub> 和平均绝对误差 MAE<sub>2</sub> 结果在测试集中最小, 此模型稳定效果好。

综上所述, 隐含层为 15 的一组模型最优, 可选作优秀 BP 神经网络模型。

3.2 GA-BP 神经网络结果与分析

(1) GA-BP 神经网络全样本模型结果

BP 神经网络模型作为一种最简单最常用的神经网络模型, 虽然能够做到感知预测, 但其精度往往达不到预期效果。3.1 节所示的结果仍然有进一步提升的空间, 故建立了 2.2 (2) 所述 GA-BP 神经网络全样本模型, 优化 BP 神经网络模型的预测精度。

GA-BP 神经网络全样本模型以隐含层和种群数作为自变量, 建立 10×10 共 100 组对照试验进行模拟预测。例如隐含层为 5 时, 分别设置种群数量为 10, 20, 30, 40, 50, 60, 70, 80, 90, 100 等 10 组, 依此, 设置 10 种隐含层共 100 组对照试验。通过反复训

练，分别得到 100 组对照模拟试验的结果（如图 12）。经对比分析，选出每一隐含层中预测精度最高的种群数量组，整理出 10 组运行结果进行分析讨论。GA-BP 全样本模型预测结果如表 3 所示。

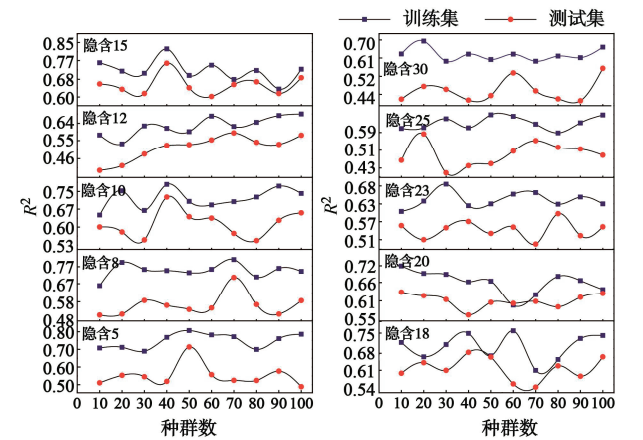


图 12 GA-BP  $R^2$  100 组预测结果

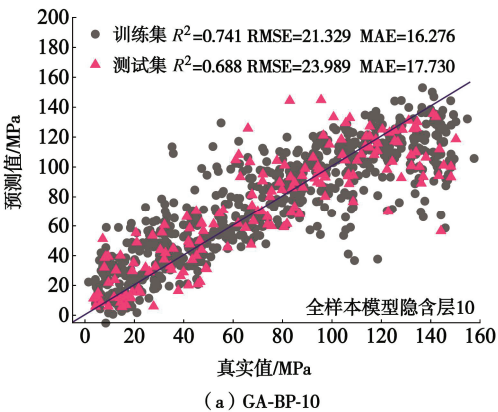
Fig. 12 Predicted results of GA-BP  $R^2$  100 groups

表 3 GA-BP 全样本模型预测结果

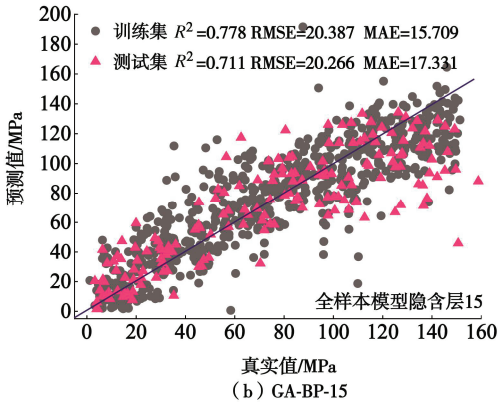
Table 3 Predicted results by GA-BP full sample model

隐 含 层	种 群 数	训练集			测试集		
		$R_1^2$	RMSE <sub>1</sub> / MPa	MAE <sub>1</sub> / MPa	$R_2^2$	RMSE <sub>2</sub> / MPa	MAE <sub>2</sub> / MPa
5	50	0.756	21.256	15.430	0.663	25.466	18.822
8	70	0.754	21.193	16.537	0.659	24.126	18.752
10	40	0.741	21.329	16.276	0.688	23.989	17.730
12	100	0.728	22.443	16.159	0.62	26.898	22.800
15	40	0.778	20.387	15.709	0.711	20.266	17.331
18	40	0.703	22.829	17.868	0.632	25.829	22.947
20	10	0.699	23.609	18.971	0.618	26.997	23.559
23	30	0.718	22.705	16.895	0.579	27.971	21.059
25	20	0.681	23.414	18.513	0.588	28.113	20.734
30	100	0.705	23.321	16.486	0.603	27.212	22.512

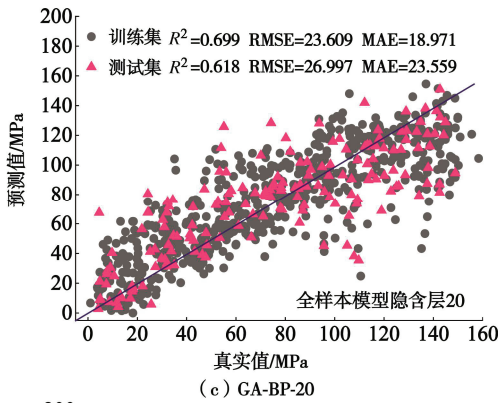
由 GA-BP 全样本模型拟合曲线（如图 13）和 GA-BP 全样本模型预测结果（如图 14）可知：隐含层为 15、种群数量为 40 时训练集决定系数  $R_1^2$  为 0.778，测试集决定系数  $R_2^2$  为 0.711，均为最高。均方根误差 RMSE<sub>1</sub> 为 20.387，RMSE<sub>2</sub> 为 20.266，平均绝对误差 MAE<sub>1</sub> 为 15.709，MAE<sub>2</sub> 为 17.331，均较小，可确定隐含层为 15、种群数量为 40 时的预测模型为 GA-BP 全样本模型的最佳模型。




(a) GA-BP-10



(b) GA-BP-15



(c) GA-BP-20



(d) GA-BP-23

图 13 GA-BP 神经网络模型全样本拟合曲线

Fig. 13 Fitting curves of full samples by GA-BP neural network model

与 BP 神经网络模型相比，GA-BP 全样本模型训练集  $R_1^2$  最高为 0.778，测试集  $R_2^2$  最高为 0.711，训练集和测试集的决定系数都有一定提升，训练集提升了 0.079，测试集提升了 0.052。训练集与测试集预测结果整体都更加稳定、精确。

表 4 总结了类似研究的拟合结果，通过对比可以发现：与选用转速、钻速、给进压力等随钻参数作为输入参数进行建模相比，选用随钻振动信号时尽管预测精度稍低，但选用随钻振动信号具有采集便捷、成本低的重要优势。后续研究将围绕如何提高预测精度这一核心问题，从输入参数特征选取、振动信号降噪等多个方面开展相关研究，以期获得更加优越的预测精度。因此，本文开展的随钻振动信号预测岩石力学参数的初步探索，仍具有较为实用的探索意义。






图 14 GA-BP 神经网络全样本模型预测结果

Fig. 14 Predicted results by GA-BP neural network full sample model

表 4 相关类似文献拟合结果对比表

Table 4 Comparison of fitting results from relevant similar literatures

对比文献	输入、输出参数	选用预测模型	评价参数
王玉杰等 <sup>[3]</sup>	输入: 转速、钻进压强、扭矩、钻进速度 输出: UCS	RDP-Rc 模型	原岩 $R^2$ (0.772)
宋超等 <sup>[9]</sup>	输入: 岩性参数指标 输出: UCS	贝叶斯高斯过程回归 fB-GPR	$R^2$ (0.8~0.9)
Kumar 等 <sup>[28]</sup>	输入: 干密度、孔隙率百分比、P 波速度、施密特硬度 输出: UCS	径向基函数神经网络 RBFNN	$R^2$ (0.831)

(2) GA-BP 神经网络部分样本模型结果

为了研究样本跨度与预测精度之间的关系, 选取强度范围为 0~40 MPa 的样本共 225 个进行与全样本模型一样的对照模拟试验。对照组仅选取了隐含层为 10, 15, 20, 23 等 4 个对照组, 每组种群数量依然设置为 10, 20, 30, 40, 50, 60, 70, 80, 90, 100。通过反复训练, 分别得到 40 组对照模拟试验的结果, 选出每一隐含层中预测精度最高的种群数量组, 整理出 4 组预测结果 (如表 5) 进行分析讨论。

表 5 GA-BP 神经网络部分样本模型预测结果

Table 5 Predicted results by GA-BP neural network partial sample model

隐含层	种群数	训练集			测试集		
		$R_1^2$	RMSE <sub>1</sub> /MPa	MAE <sub>1</sub> /MPa	$R_2^2$	RMSE <sub>2</sub> /MPa	MAE <sub>2</sub> /MPa
10	50	0.723	5.422	3.923	0.606	7.547	5.721
15	30	0.708	5.962	4.366	0.641	6.321	5.269
20	60	0.726	5.496	3.952	0.629	7.332	5.903
23	80	0.739	5.317	3.885	0.653	6.132	4.374

图 15 为 GA-BP 神经网络部分样本模型预测结果。  
图 16 为 GA-BP 神经网络模型部分样本拟合曲线。

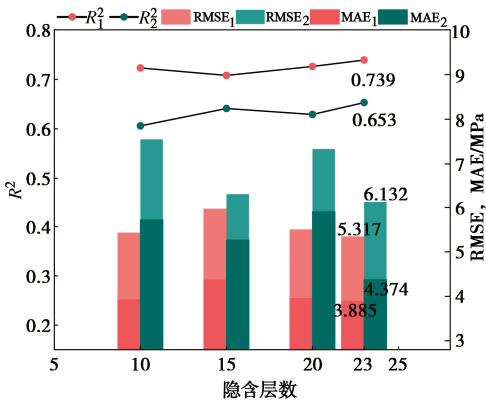





图 15 GA-BP 神经网络部分样本模型预测结果

Fig. 15 GA-BP neural network partial sample model prediction results






图 16 GA-BP 神经网络模型部分样本拟合曲线

Fig. 16 Fitting curves of partial samples by GA-BP neural network model

由图 15, 16 可知: GA-BP 神经网络部分样本模型整体效果稳定, 隐含层为 23, 种群数量为 80 时, 训练集决定系数  $R_1^2$  为 0.739, 均方根误差  $RMSE_1$  为 5.317, 平均绝对误差  $MAE_1$  为 3.855, 测试集决定系数  $R_2^2$  为 0.653,  $RMSE_2$  为 6.132,  $MAE_2$  为 4.374, 最优。

与 GA-BP 神经网络全样本模型相比, 训练集与测试集的决定系数稍有降低但均方根误差和平均绝对误差均减小, 预测精度有所提高。

### (3) 不同岩性对预测精度影响分析

为了讨论不同岩性对预测模型准确度的影响程度, 以 GA-BP 全样本模型的最优结果—隐含层为 15, 种群数为 40 时为例, 将不同岩性的预测结果分别作出分析, 其结果如图 17 所示。

全样本模型整体准确度为 0.778, 图 17 中分析可知, 砂岩样本的准确率最高为 0.653, 花岗岩和页岩的准确率在 0.470 以上, 煤和石灰岩的准确率较低在 0.2 左右。单种岩性的预测准确度都低于整体, 是由于整体样本的单轴抗压强度分布较为均匀, 而单种原岩岩性中离散型较强。在接下来的研究中, 根据不同岩性岩石的特性, 分别构建具有针对性的预测模型, 从而提高预测准确度, 并将预测模型应用于不同岩性环境下的现场。

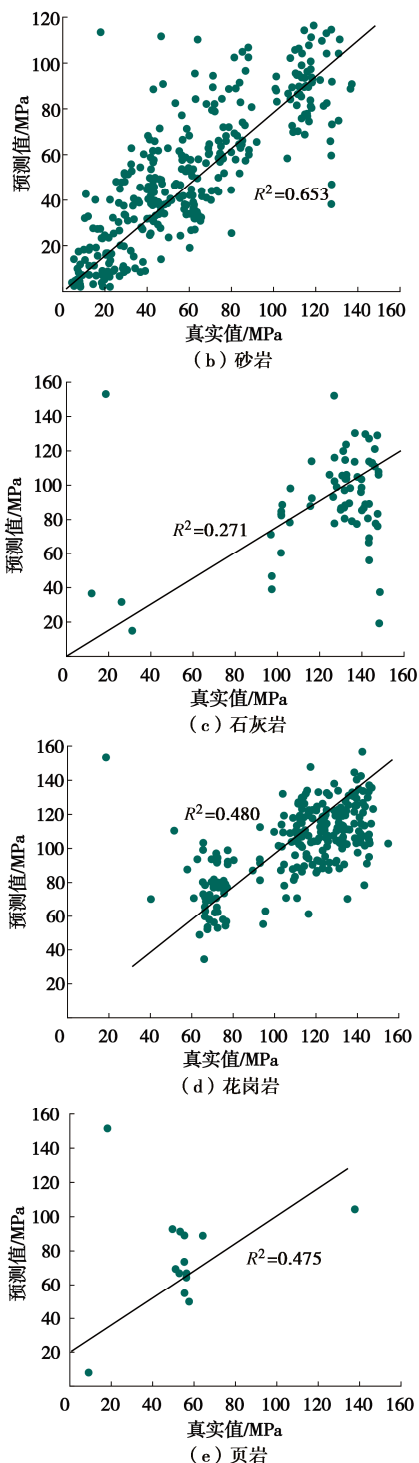


图 17 不同岩性预测结果对比


Fig. 17 Comparison of predicted results for different lithologies

## 4 结论与展望

### 4.1 结论

在设计、实施室内试验的基础上, 通过本文构建的 BP 神经网络模型、经遗传算法优化的 GA-BP 神经网络全样本模型和部分样本模型的预测结果, 可得到如下 3 点结论。

(1) 经遗传算法优化的 GA-BP 神经网络全样本



模型提高了预测精度( $R^2$ ),较之BP神经网络模型提升了9.4%。隐含层为15、种群数为40时预测结果最优,决定系数 $R^2$ 为0.778,均方根误差RMSE为20.387,平均绝对误差MAE为15.709。

(2)训练样本的强度范围跨度影响预测精度( $R^2$ ),对于有针对性的小强度范围模型,均方根误差和平均绝对误差相应减小。与GA-BP神经网络全样本模型相比,GA-BP神经网络部分样本模型在决定系数 $R^2$ 水平相同情况下,均方根误差降低了15.070,平均绝对误差降低了11.854。

(3)随钻振动信号与岩石单轴抗压强度之间密切相关,采用本文构建的神经网络预测模型,对单轴抗压强度的预测准确率可达到0.778。本文提出的方法可为岩石力学参数快速预测技术的创新和推广提供技术支持。但在工程实践的应用中,还需进行进一步深入探索。

#### 4.2 展望

(1)本文所建立的单轴抗压强度预测模型预测精度仍有提升空间,可应用随钻振动信号建立新的模型方法达到更高的预测精度。

(2)本文应用的随钻振动信号参数均为原始随钻振动信号所提取,可对随钻振动信号进行降噪处理,消除其余信号对其的干扰,提取更有效的振动参数从而提高预测精度。

(3)本文研究结果仅仅限于实验室和某种特定的完整、均匀、致密的岩石,对于围岩不均匀、裂隙发育的情况仍需进一步扩大研究范围,特别是裂隙岩体的岩石力学参数的反演方法。

**利益冲突声明/Conflict of Interests:** 所有作者声明不存在利益冲突。All authors disclose no relevant conflict of interest.

**作者贡献/Authors' Contributions:** 郝建、刘建康和刘河清参与实验设计;刘河清、胡慧和栾学坤完成实验操作;郑义宁和肖勇进行技术和试验材料支持;郝建、刘建康、刘河清、胡慧和栾学坤参与论文的写作和修改。所有作者均阅读并同意最终稿件的提交。The study was designed by HAO Jian, LIU Jiankang and LIU Heqing. The experimental operation was completed by LIU Heqing, HU Hui and LUAN Xuekun. ZHENG Yining and Xiao Yong carried out technical and experimental material support. The manuscript was drafted and revised by HAO Jian, LIU Jiankang, LIU Heqing, HU Hui and LUAN Xuekun. All authors read and agree to the submission of the final manuscript.

#### 参考文献:

[1] WANG Q, GAO H K, JIANG B, et al. Relationship model for the drilling parameters from a digital drilling rig versus the rock mechanical parameters and its application[J]. Arabian

Journal of Geosciences, 2018, 11(13): 357.

- [2] 谭卓英,李 文,岳鹏君,等. 基于钻进参数的岩土地层结构识别技术与方法[J]. 岩土工程学报, 2015, 37(7): 1328-1333. (TAN Zhuoying, LI Wen, YUE Pengjun, et al. Techniques and approaches for identification of geo-formation structure based on diamond drilling parameters[J]. Chinese Journal of Geotechnical Engineering, 2015, 37(7): 1328-1333. (in Chinese))
- [3] 王玉杰,余 磊,赵宇飞,等. 基于数字钻进技术的岩石强度参数测定试验研究[J]. 岩土工程学报, 2020, 42(9): 1669-1678. (WANG Yujie, SHE Lei, ZHAO Yufei, et al. Experimental study on measurement of rock strength parameters based on digital drilling technology[J]. Chinese Journal of Geotechnical Engineering, 2020, 42(9): 1669-1678. (in Chinese))
- [4] 张幼振,张 宁,邵俊杰,等. 基于钻进参数聚类的含煤地层岩性模糊识别[J]. 煤炭学报, 2019, 44(8): 2328-2335. (ZHANG Youzhen, ZHANG Ning, SHAO Junjie, et al. Fuzzy identification of coal-bearing strata lithology based on drilling parameter clustering[J]. Journal of China Coal Society, 2019, 44(8): 2328-2335. (in Chinese))
- [5] LIU C C, ZHAN Q J, YANG L, et al. Recognition of interface and category of roadway roof strata based on drilling parameters[J]. Journal of Petroleum Science and Engineering, 2021, 204: 108724.
- [6] DENG L C, LI X Z, XU W T, et al. Integrated monitoring of lithology parameters while drilling in small-scale coring platform[J]. Rock Mechanics and Rock Engineering, 2022, 55(11): 7269-7288.
- [7] 岳中文,戴诗清,李 杨,等. 煤巷液压锚杆钻机随钻参数采集系统及其应用[J]. 矿业科学学报, 2023, 8(1): 66-73. (YUE Zhongwen, DAI Shiqing, LI Yang, et al. The drilling parameter acquisition system of hydraulic anchor drilling rig in coal mine roadways and its application[J]. Journal of Mining Science and Technology, 2023, 8(1): 66-73. (in Chinese))
- [8] KUMAR R, KUMARASWAMIDHAS L A, MURTHY V M S R, et al. Experimental investigations on machine vibration in blast-hole drills and optimization of operating parameters[J]. Measurement, 2019, 145: 803-819.
- [9] 宋 超,赵腾远,许 领. 基于贝叶斯高斯过程回归与模型选择的岩石单轴抗压强度估计方法[J]. 岩土工程学报, 2023, 45(8): 1664-1673. (SONG Chao, ZHAO Tengyuan, XU Ling. Estimation of uniaxial compressive strength based on fully Bayesian Gaussian process regression and model selection[J]. Chinese Journal of Geotechnical Engineering, 2023, 45(8): 1664-1673. (in Chinese))



- [10] LIU J K, LUAN H J, ZHANG Y C, et al. Prediction of unconfined compressive strength ahead of tunnel face using measurement-while-drilling data based on hybrid genetic algorithm[J]. *Geomechanics and Engineering*, 2020, **22**(1): 81-95.
- [11] LIU J K, JIANG Y J, HAN W, et al. Optimized ANN model for predicting rock mass quality ahead of tunnel face using measure-while-drilling data[J]. *Bulletin of Engineering Geology and the Environment*, 2021, **80**(3): 2283-2305.
- [12] WANG H T, HE M M, ZHANG Z Q, et al. Determination of the constant  $m$  in the Hoek-Brown criterion of rock based on drilling parameters[J]. *International Journal of Mining Science and Technology*, 2022, **32**(4): 747-759.
- [13] LIU S W, FU M X, JIA H S, et al. Numerical simulation and analysis of drill rods vibration during roof bolt hole drilling in underground mines[J]. *International Journal of Mining Science and Technology*, 2018, **28**(6): 877-884.
- [14] QIN M, WANG K, PAN K, et al. Analysis of signal characteristics from rock drilling based on vibration and acoustic sensor approaches[J]. *Applied Acoustics*, 2018, **140**: 275-282.
- [15] LAZAROVÁ E, KRULÁKOVÁ M, KRÚPA V, et al. Regime and rock identification in disintegration by drilling based on vibration signal differentiation[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2022, **149**: 104984.
- [16] 郭书英, 马念杰. 岩层破裂状态与钻削机构振动响应特性研究[J]. *采矿与安全工程学报*, 2016, **33**(5): 911-916. (GUO Shuying, MA Nianjie. Strata fracturing state and vibration response characteristics of drill[J]. *Journal of Mining & Safety Engineering*, 2016, **33**(5): 911-916. (in Chinese))
- [17] 刘 刚, 张家林, 刘 闯, 等. 钻头钻进不同介质时的振动信号特征识别研究[J]. *振动与冲击*, 2017, **36**(8): 71-78, 104. (LIU Gang, ZHANG Jialin, LIU Chuang, et al. An identification method of vibration signal features when bit drills different mediums[J]. *Journal of Vibration and Shock*, 2017, **36**(8): 71-78, 104. (in Chinese))
- [18] KLAIC M, MURAT Z, STAROVESKI T, et al. Tool wear monitoring in rock drilling applications using vibration signals[J]. *Wear*, 2018, **408**: 222-227.
- [19] YANG Y, ZENG Q L, YIN G J, et al. Vibration test of single coal gangue particle directly impacting the metal plate and the study of coal gangue recognition based on vibration signal and stacking integration[J]. *IEEE Access*, 2019, **7**: 106784-106805.
- [20] 陈晓君, 梁 楠, 陈根龙, 等. 基于 HHT 方法的岩石钻进振动信号分析[J]. *地质与勘探*, 2020, **56**(6): 1258-1265. (CHEN Xiaojun, LIANG Nan, CHEN Genlong, et al. Analysis of rock drilling vibration signal based on the HHT method[J]. *Geology and Exploration*, 2020, **56**(6): 1258-1265. (in Chinese))
- [21] LIU M B, LIAO S M, YANG Y F, et al. Tunnel boring machine vibration-based deep learning for the ground identification of working faces[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2021, **13**(6): 1340-1357.
- [22] 李彦忠, 胡 坤, 汪浅予. 基于随钻振动信号对钻进介质的识别研究[J]. *煤矿机电*, 2022, **43**(2): 1-5, 16. (LI Yanzhong, HU Kun, WANG Qianyu. Research on identification of drilling medium based on vibration signal while drilling[J]. *Colliery Mechanical & Electrical Technology*, 2022, **43**(2): 1-5, 16. (in Chinese))
- [23] ZHANG W L, LI C, JIN J X, et al. A new monitoring-while-drilling method of large diameter drilling in underground coal mine and their application[J]. *Measurement*, 2021, **173**: 108840.
- [24] 杨招伟, 卢文波, 高启栋, 等. 基于地表实测爆破振动的岩体动力学参数快速反演方法[J]. *岩土工程学报*, 2019, **41**(4): 775-781. (YANG Zhaowei, LU Wenbo, GAO Qidong, et al. Inversion of dynamic parameters of rock mass based on field blasting vibration[J]. *Chinese Journal of Geotechnical Engineering*, 2019, **41**(4): 775-781. (in Chinese))
- [25] ALADEJARE A E, AKEJU V O, WANG Y. Probabilistic characterisation of uniaxial compressive strength of rock using test results from multiple types of punch tests[J]. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 2021, **15**(3): 209-220.
- [26] ASEM P, GARDONI P. A generalized Bayesian approach for prediction of strength and elastic properties of rock[J]. *Engineering Geology*, 2021, **289**: 106187.
- [27] MOMENI E, JAHED ARMAGHANI D, HAJIHASSANI M, et al. Prediction of uniaxial compressive strength of rock samples using hybrid particle swarm optimization-based artificial neural networks[J]. *Measurement*, 2015, **60**: 50-63.
- [28] KUMAR R B, VARDHAN H, GOVINDARAJ M, et al. Regression analysis and ANN models to predict rock properties from sound levels produced during drilling[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2013, **58**: 61-72.
- [29] 康红普. 煤岩体地质力学原位测试及在围岩控制中的应用[M]. 北京: 科学出版社, 2013. (KANG Hongpu. In-situ Geomechanics Measurements for Coal and Rock Masses and Their Application on Strata Control[M]. Beijing: Science Press, 2013. (in Chinese))