

基于PCA-LM-BP神经网络的岩石可钻性预测研究

蒲先渤, 李泽群*, 尹飞, 范杰, 曹鲁刚, 智亮

(中国地质调查局廊坊自然资源综合调查中心, 河北 廊坊 065000)

摘要:预测岩石的可钻性等级能够为钻探工程项目的开展提供有效帮助,根据岩石的可钻性等级选择合理的工艺、方法、技术为项目提供技术支撑。本文考虑岩石在地下空间中受复杂环境因素影响,从地球物理勘探数据、岩石的力学性质和物理性质中选择5种影响岩石可钻性的等级因素,用主成分分析法(PCA)解释每种影响因素之间的相关性及贡献率,消除5种影响因素之间的相关性,选择相关性低的3个主成分代替数据样本进行预测评价。编写LM-BP算法,合理设置预测模型参数值,以主成分分析后的数据样本作为基础,建立岩石可钻性等级预测模型,对预测结果与室内实验法的实测结果进行分析对比,经分析得知,PCA-LM-BP预测模型在岩石可钻性等级预测中,具有预测精准度高、预测时间短的特点,可被应用于钻探工程中的岩石可钻性分析。

关键词:岩石可钻性;主成分分析法;LM-BP算法;误差分析;预测模型

中图分类号:P634.1 **文献标识码:**A **文章编号:**2096-9686(2023)06-0063-06

Research on rock drill ability prediction based on PCA-LM-BP neural network

PU Xianbo, LI Zequn*, YIN Fei, FAN Jie, CAO Lugang, ZHI Liang

(Langfang Natural Resources Comprehensive Survey Center, China Geological Survey, Langfang Hebei 065000, China)

Abstract: Predicting the drill ability level of rocks can provide effective assistance for the development of drilling engineering projects, and selecting reasonable processes, methods, and technologies based on the drillability level of rocks can provide technical support and assistance for the project. In this paper, considering the impact of complex environmental factors on rocks in underground space, five factors affecting rock drill ability grade are selected from geophysical exploration data, mechanical properties and physical properties of rocks. Principal component analysis (PCA) is used to explain the correlation and contribution rate between each influencing factor, and the correlation between the five factors is eliminated. Three principal components with low correlation were selected to replace the data samples for prediction evaluation. The LM-BP algorithm was compiled, reasonably set the parameter values of the prediction model, and based on the data samples after principal component analysis, establish a rock drill ability level prediction model. Analyze and compare the prediction results with the measured results of indoor experimental methods. It was found through analysis that the PCA-LM-BP prediction model has the characteristics of high prediction accuracy and short prediction time in rock drill ability level prediction, it can be applied to rock drill ability analysis in drilling engineering.

Key words: rock drill ability; principal component analysis; LM-BP; error analysis; prediction model

0 引言

岩石的可钻性指岩石抵抗破碎的能力^[1],在地

质钻探设计中,提前预知岩石的可钻性等级,能够合理的选择钻探工艺、方法和技术,提高钻进效率,

收稿日期:2023-05-06; 修回日期:2023-07-20 DOI:10.12143/j.ztgc.2023.06.008

基金项目:中国地质调查局地质调查项目“战略性矿产靶区查证技术支撑(廊坊自然资源综合调查中心)”(编号:040904)

第一作者:蒲先渤,男,汉族,1985年生,二级技师,钻探工程专业,从事深孔钻探工作,河北省廊坊市广阳区广阳道93号,780210243@qq.com。

通信作者:李泽群,男,汉族,1994年生,助理工程师,地质工程专业,硕士,从事中深孔钻探技术工作,河北省廊坊市广阳区广阳道93号,794680208@qq.com。

引用格式:蒲先渤,李泽群,尹飞,等.基于PCA-LM-BP神经网络的岩石可钻性预测研究[J].钻探工程,2023,50(6):63-68.

PU Xianbo, LI Zequn, YIN Fei, et al. Research on rock drill ability prediction based on PCA-LM-BP neural network[J]. Drilling Engineering, 2023, 50(6): 63-68.

减少卡钻、烧钻、孔壁坍塌等安全事故的发生^[2],为钻探施工设计提供合理的参数性能。目前岩石可钻性的分析方法主要以取样后室内实验法^[3]为主,以取样岩石的物理性质、力学性质、化学性质为基础信息量,可直接反映岩石的可钻性等级,为后续此工作区附近的钻探施工提供地质信息数据参考^[4]。机器学习算法也被应用于预测岩石可钻性等级^[5-8],但是,单一的机器学习算法预测的岩石可钻性等级不够精准,相关系数不强,不能很好地应用于可钻性等级预测。

本文从岩石可钻性等级的基础因素考虑,以地球物理勘探数据、岩性特征、物理性质3个方面筛选5个影响因素,用主成分分析法(PCA)消除影响因素之间的相关性^[9],解决影响因素之间的非线性关系。结合BP神经网络算法的优点^[10-13]:(1)非线性映射能力,实现输入层至输出层的三层映射功能,解决系统内部机制的复杂性运算。(2)学习能力,能够学习并运算系统内的“算法规则”,提供合理的参数数据。(3)容错能力,局部数据的突变性不能影响系统内的整体运算。LM算法^[14-17]解决BP神经网络的缺点:(1)设置阈值,防止BP神经网络算法陷入局部极值。(2)用梯度下降法和高斯牛顿法解决BP神经网络收敛速度慢、过度学习的问题。通过以上3种方式结合,形成PCA-LM-BP岩石可钻性等级预测模型。

1 基本原理

1.1 主成分分析^[18]

根据岩石可钻性的影响因素,用主成分分析法(PCA)消除影响因素之间的相关性,建立新的预测样本数据,具体运算步骤如下:

$$X_{mn} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \quad (1)$$

式中: m ——样本个数; n ——变量个数。

为了更好的用于主成分分析法,将原数据进行标准化处理,标准化公式如下:

$$z_{x_{ij}} = \frac{x_{ij} - \bar{x}_{ij}}{\sqrt{\text{var}(x_j)}} \quad (2)$$

$$\text{var}(x_j) = \frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2 \quad (3)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (4)$$

计算相关系数矩阵如下所示,其中相关系数矩阵 R 的表达式为:

$$R = X^{*T} X^* \quad (5)$$

在式(5)中, X^* 为标准化处理原数据后的矩阵,根据相关系数矩阵 R ,计算标准化数据矩阵的特征值 λ , $|\lambda - R| = 0$,求出特征值,最终得到主成分的贡献率,公式如下:

$$P = \sum_{i=1}^m \lambda_i \quad (6)$$

一般认为选择新的主成分个数主要有2种方法,第一种方法为当第 m 个主成分的累积贡献率达到85%时,可以用 m 个主成分代替预测可钻性等级影响因素的个数;第二种方法为选择主成分特征值 >1 的个数,用来代替预测可钻性等级影响因素的个数。本文从工程实例中共选取22个钻孔数据进行分析,5个影响因素为钻孔深度、纵深时差 Δt 、密度 ρ 、电阻率 R_t 、泥质含量 V_{sh} ,预测岩石的可钻性等级。

1.2 LM-BP人工神经网络

LM算法收敛速度快,在系统运算中,忽略二阶以上的导数项,转化为线性二乘问题,因此,具备提高BP神经网络模型的运行效率,增加容错率,有效提升岩石可钻性分析的预测精准率。

BP神经网络具有良好的自适应性,自组织性,及很强的学习、联想、容错和抗干扰能力,并且具有高度的非线性映射能力,因此被应用于此次可钻性分析的预测模型的建立。本文采用的BP神经网络模型采用了多层次结构,包括输入层、隐含层和输出层。输入层节点为主成分个数,隐含层公式如式(7)所示,输出层节点为岩石的可钻性等级,共计1节点。预测模型整体系统采用激励函数(传递函数)处理后,对于隐含层的激励函数,采用Sigmoid函数进行系统运算。

隐含层节点数的确立计算公式为^[19]:

$$n = \sqrt{n_i + n_o} + a \quad (7)$$

式中: n_i ——输入层节点数; n_o ——输出层节点数; a ——常数,取值范围为1~10。

通过试触法确立隐含层节点数。

2 预测模型的建立

2.1 样本数据的处理

根据工程实例^[20]研究发现岩石可钻性与地层岩性、物理性质、电性、流体特性密切相关,即与声波时差、地层密度、电阻率、泥质含量、深度影响因素相关联,因此建立数据样本,以试验区 22 组数据作为基础数据样本,随机选择其中 17 组数据作为预测模型建立的训练样本见表 1,其余 5 组数据作为预测模型建立的测试样本见表 2,将所有数据进行归一化处理,以便于更好地应用于分析测试,可钻性极值 K_d 作为期望值输出于预测模型的系统中,期望值越接近于 1,代表该处地层可钻性越强,期望值越接近于 0,代表该处地层可钻性越弱。

表 1 试验区训练样本归一化						
Table 1 Normalization of training samples in the test area						
序 号	深度/ m	纵深时差 $\Delta t/(\mu s \cdot ft)$	密度 $\rho/$ $(g \cdot cm^{-3})$	电阻率 $R_t/(\Omega \cdot m)$	泥质含量 $V_{sh}/\%$	可钻 性 K_d
1	0.00	0.13	0.71	0.04	0.07	0.26
2	0.02	0.45	0.33	0.00	0.05	0.71
4	0.06	0.47	0.79	0.01	0.03	0.80
5	0.07	0.00	1.00	0.03	0.05	0.93
6	0.14	0.25	0.83	0.04	0.01	0.66
8	0.23	0.24	0.88	0.07	0.04	1.00
9	0.28	0.33	0.71	0.06	0.01	0.49
10	0.32	0.01	0.17	0.34	0.10	0.63
11	0.44	0.71	0.42	0.08	0.00	0.00
12	0.49	0.55	0.17	0.02	0.02	0.30
13	0.51	0.96	0.08	0.02	0.00	0.31
14	0.54	1.00	0.00	0.02	0.00	0.15
17	0.77	0.55	0.46	0.03	0.02	0.63
18	0.89	0.25	0.42	1.00	0.03	0.56
20	0.93	0.27	0.63	0.09	0.05	0.50
21	0.97	0.53	0.33	0.03	0.02	0.54
22	1.00	0.27	0.88	0.09	0.19	0.76

表 2 试验区测试样本归一化

Table 2 Normalization of training samples in the test area

序 号	深度/ m	纵深时差 $\Delta t/(\mu s \cdot ft)$	密度 $\rho/$ $(g \cdot cm^{-3})$	电阻率 $R_t/(\Omega \cdot m)$	泥质含量 $V_{sh}/\%$	可钻 性 K_d
3	0.05	0.64	0.25	0.01	0.00	0.89
7	0.21	0.08	0.96	0.08	0.05	0.74
15	0.65	0.44	0.63	0.00	1.00	0.39
16	0.75	0.71	0.42	0.03	0.01	0.52
19	0.90	0.33	0.50	1.00	0.01	0.57

2.2 主成分分析法处理数据

将整体数据(包括训练样本和测试样本)进行主成分分析,得到岩石可钻性影响因素之间的相关系数矩阵见表 3。两种影响因素的相关系数越接近 1,代表两种影响因素之间的相关性越强。如果将相关性强的两种因素直接用于建立预测模型,影响因素之间会发生共线性现象,导致预测结果不够合理。

经过主成分分析法(PCA)得到 5 个主成分见表 4。一般认为,建立预测模型所需主成分的个数有 2 种方法,一种方法为主成分的累计贡献率 $>85\%$,另一种方法为主成分的特征值 >1 。根据以上 2 种方法的共性,本文选择 3 个主成分(3 个主成分的累计贡献率 $85.937\% > 85\%$,第三个主成分 >1),从而满足预测模型的建立。

建立新的主成分中,每种影响因子的公因子方差比见表 5。在公因子方差比列表中,可得知影响岩石可钻性等级因素中泥质含量 V_{sh} 、纵深时差 Δt 、电阻率 R_t ,信息提取较为充分,密度 ρ 影响因素有 18.7% 的信息并未提取,深度影响因素有 20.8% 的信息未提取。

根据因子得分系数矩阵(见表 6),用 3 个主成分(F_1 、 F_2 、 F_3)代替 5 个影响因素,每个主成分的线性表达为 λ_j 是第 j 个变尺度变量的方差(即特征值), u_j 是第 j 个变尺度变量(即主成分)。F 的第 j 个主成分

表 3 相关系数矩阵					
Table 3 Correlation coefficient matrix					
影响因素	深度/m	纵深时差 $\Delta t/(\mu s \cdot ft)$	密度 $\rho/(g \cdot cm^{-3})$	电阻率 $R_t/(\Omega \cdot m)$	泥质含量 $V_{sh}/\%$
深度/m	1.000	0.210	-0.220	0.401	0.146
纵深时差 $\Delta t/(\mu s \cdot ft)$	0.210	1.000	-0.687	-0.258	-0.098
密度 $\rho/(g \cdot cm^{-3})$	-0.220	-0.687	1.000	-0.087	0.153
电阻率 $R_t/(\Omega \cdot m)$	0.401	-0.258	-0.087	1.000	-0.100
泥质含量 $V_{sh}/\%$	0.146	-0.098	0.153	-0.100	1.000

表4 主成分特征值及贡献率

Table 4 Principal component eigenvalue and contribution rate

主成分	初始特征值			提取载荷平方和		
	特征值	方差/%	累计/%	特征值	方差/%	累计/%
1	1.820	36.403	36.403	1.820	36.403	36.403
2	1.403	28.054	64.457	1.403	28.054	64.457
3	1.074	21.480	85.937	1.074	21.480	85.937
4	0.501	10.019	95.955			
5	0.202	4.045	100.000			

表5 公因子方差比

Table 5 Variance ratio of common factors

影响因素	原始值	公因子方差比
深度/m	1.000	0.792
纵深时差 $\Delta t/(\mu s \cdot ft)$	1.000	0.898
密度 $\rho/(g \cdot cm^{-3})$	1.000	0.813
电阻率 $R_t/(\Omega \cdot m)$	1.000	0.874
泥质含量 $V_{sh}/\%$	1.000	0.920

表6 因子分析

Table 6 Factor analysis

影响因素	主成分		
	F_1	F_2	F_3
深度/m	0.463	0.706	0.282
纵深时差 $\Delta t/(\mu s \cdot ft)$	0.870	-0.344	0.152
密度 $\rho/(g \cdot cm^{-3})$	-0.897	0.069	0.061
电阻率 $R_t/(\Omega \cdot m)$	0.073	0.872	-0.330
泥质含量 $V_{sh}/\%$	-0.198	0.148	0.927

计算方程为:

$$F_j = u_{j1}X_1 + u_{j2}X_2 + \cdots + u_{jp}X_p \quad i = 1, \cdots, p \quad (8)$$

在因子得分系数矩阵中,每个影响因素的系数为:

$$\begin{cases} F_1 = 0.463x_1 + 0.870x_2 - 0.897x_3 + 0.073x_4 - 0.198x_5 \\ F_2 = 0.706x_1 - 0.344x_2 + 0.069x_3 + 0.872x_4 + 0.148x_5 \\ F_3 = 0.282x_1 + 0.152x_2 + 0.061x_3 - 0.330x_4 + 0.927x_5 \end{cases} \quad (9)$$

根据主成分分析法,用3个无相关性的主成分代替原数据样本的5种影响因素,从而有效地降低了影响因素之间的相关性,减少了数据运行量,提高了建立预测模型的效率。

2.3 LM-BP神经网络算法建立模型

本文采用MatLAB软件编写LM算法和BP神经网络算法,用LM算法设置了运行BP神经网络的基本程序设置,其中,运行的最大迭代次数为10000,运行的学习目标为 $1e^{-6}$,运行的初始学习效率为0.02。输入层节点数为3个(新主成分的个数),隐含层个数和隐含层节点数通过试触法选择了1个隐含层和10个隐含层节点数。BP神经网络预测模型的结构设计见图1。




图1 BP神经网络模型结构

Fig.1 Model structure of BP neural network

BP神经网络预测模型建立中,运行的最大迭代次数、学习目标、学习效率3项中有一项达到设置的阈值,即训练终止。预测过程数据见图2。




图2 BP神经网络预测过程

Fig.2 Prediction process diagram of BP neural network

预测结果见图3。图3(a)为BP神经网络训练样本共计17组数据的原始值和预测值对比,图3(b)为BP神经网络测试样本共计5组数据的原始值和预测值对比。由于预测模型的建立中每组数据实测值的特性(实测值精确度高,非固定的范围数值),因此,训练样本中差异性较大,但预测样本相关性强。

PCA-LM-BP预测模型的原始值和预测值相关值 R 见图4,相关系数为0.96091,相关值 R 代表了预测模型中原始值和预测值的精确度。

2.4 结果分析

基于PCA-LM-BP建立的预测模型和LM-BP预测模型中的5个预测研究样本实测值与室内实验法测出的实测值进行分析对比(见表7),可以得知,主成分分析法可有效提升建模效率,相关性强的影




图 3 训练样本与测试样本的预测结果与实际结果对比

Fig.3 Comparison between predicted results and actual results of training samples and test samples




图 4 原始值与预测值的相关系数曲线

Fig.4 Correlation coefficient curve between original value and predicted value

响因素会降低预测模型的精度率,消除因素之间的相关性会提高预测模型的精度率。

表 7 预测样本实测值与实验法实测值的分析对比

Table 7 Analysis and comparison table between predicted sample measured values and experimental method measured values		PCA-LM-BP 模型(运行时间 4.36 s)			LM-BP 模型(运行时间 7.37 s)		
		预测值	绝对误差	相对误差/%	预测值	绝对误差	相对误差/%
岩石序号	可钻性实测值						
3	0.8891	0.8300	0.0591	5.91	0.8171	0.0720	7.20
7	0.7443	0.8109	−0.0666	6.66	0.8145	−0.0702	7.02
15	0.3894	0.3651	0.0243	2.43	0.3453	0.0441	4.41
16	0.5175	0.4974	0.0201	2.01	0.4676	0.0499	4.99
19	0.5652	0.5574	0.0078	0.78	0.5479	0.0173	1.73

将归一化后的可钻性等级预测值的实测值(0~1)还原于岩石的可钻性等级(1~12),则 PCA-LM-BP 预测模型对岩石可钻性等级与室内实验法测出的岩石可钻性等级对比见表 8。

3 结论

(1)提前预测可钻性等级能够有效为工程开展

提供技术支撑,可钻性等级受众多因素影响,本文选用了主成分分析法解释了各影响因素之间的关系。

(2)主成分分析法用小于影响因素个数的主成分替代影响因素的个数进行预测,建立预测模型,结果更加精准,提取了 3 个主成分,携带的信息量为 85.937%,满足建立预测模型的需要,消除影响因子之间的相关性,用小于影响因素个数的主成分来建立预测模型,运行效率提高,为大数据建立预测模型提供了思路。

(3)单一的机器学习算法对数据样本的提前预测相关性不强,本文采用了 PCA-LM-BP 建立预测模型,与室内实验法测出的可钻性等级实测值进行了结果对比,相关值高,预测时间短,预测结果精准。为岩石的可钻性等级的预测提供了一个实用、有效的方法。

表 8 可钻性等级预测对比表

Table 8 Comparison table for drill ability level prediction			
岩石序号	可钻性等级	PCA-LM-BP 预测模型预测的可钻性等级	相对误差/%
3	7.769	7.457	2.6
7	7.003	7.355	2.93
15	5.128	5.000	1.07
16	5.805	5.699	0.88
19	6.057	6.016	0.342

参考文献(References):

- [1] 王颖颖, 庄毅, 孙逸帆. 基于粒子群优化BP神经网络的可靠性评估模型[J]. 计算机与现代化, 2022(12):42-49.
WANG Yingying, ZHUANG Yi, SUN Yifan. Reliability evaluation model of BP network based on particle swarm optimization [J]. Computer and Modernization, 2022(12):42-49.
- [2] Cagnato Clarissa, Nlend Pascal, Ngouoh François, et al. Analysis of Early Iron Age (2500 BP) and modern period (150 BP) starch grains in Western Central Africa [J]. Scientific Reports, 2022, 12(1).
- [3] 孔祥伟, 陈昊, 叶佳杰, 等. 基于PCA预测岩石可钻性级值的钻头优选[J]. 新疆石油天然气, 2022, 18(3):6-11.
KONG Xiangwei, CHEN Hao, YE Jiajie, et al. Bit selection based on PCA to predict drillability level of hard rocks [J]. Xinjiang Oil & Gas, 2022, 18(3):6-11.
- [4] 岳永东, 渠洪杰, 谭春亮, 等. 基于支持向量机的测井岩性识别在松散沉积物调查中的应用研究[J]. 钻探工程, 2021, 48(4):29-36.
YUE Yongdong, QU Hongjie, TAN Chunliang, et al. Application of logging lithology identification based on support vector machines in unconsolidated sediment investigation [J]. Drilling Engineering, 2021, 48(4):29-36.
- [5] YANG Zonglin, SHI Yaqi, LI Pinglin, et al. Application of Principal Component Analysis (PCA) to the Evaluation and Screening of Multiactivity Fungi [J]. Journal of Ocean University of China, 2022, 21(3):763-772.
- [6] 冯上鑫, 王善勇. 旋切作用下岩石破碎机理及岩石可钻性的试验研究[J]. 煤炭学报, 2022, 47(3):1395-1404.
FENG Shangxin, WANG Shanyong. Experimental study of rock-bit interaction mechanism for rock drillability assessment in rotary drilling [J]. Journal of China Coal Society, 2022, 47(3):1395-1404.
- [7] Hirofumi Miyajima, Noritaka Shigei, Hiromi Miyajima, et al. Simplified Secure Distributed Processing of BP with Decomposition Data [J]. IEICE Proceeding Series, 2022, 71.
- [8] 王亚飞, 张占荣, 刘华吉, 等. 基于模型融合的钻进参数识别岩石类型研究[J]. 钻探工程, 2023, 50(2):17-25.
WANG Yafei, ZHANG Zhanrong, LIU Huaji, et al. Data-driven model for the identification of the rock type by drilling data [J]. Drilling Engineering, 2023, 50(2):17-25.
- [9] 许梦国, 刘红阳, 王平, 等. 基于RES理论的岩石可钻性综合预测研究[J]. 金属矿山, 2022(1):113-119.
XU Mengguo, LIU Hongyang, WANG Ping, et al. Comprehensive prediction study on rock drillability based on RES theory [J]. Metal Mine, 2022(1):113-119.
- [10] 王林清, 马汉臣, 许本冲, 等. 浅海伸缩套管钻探工艺研究[J]. 钻探工程, 2021, 48(7):40-45.
WANG Linqing, MA Hanchen, XU Benchong, et al. Research on shallow sea drilling technology with telescopic casing [J]. Drilling Engineering, 2021, 48(7):40-45.
- [11] 李谦, 曹彦伟, 朱海燕. 基于人工智能的钻速预测模型数据有效性下限分析[J]. 钻探工程, 2021, 48(3):21-30.
LI Qian, CAO Yanwei, ZHU Haiyan. Discussion on the lower limit of data validity for ROP prediction based on artificial intelligence [J]. Drilling Engineering, 2021, 48(3):21-30.
- [12] FANG Xinxin, FENG Hong, WANG Hao. Study on intelligent prediction method of rock drillability based on Bayesian lithology classification and optimized BP neural network [J]. Petroleum Science and Technology, 2022, 40(13/18):2141-2162.
- [13] Karrari Seyed Sajjad, Heidari Mojtaba, Hamidi Jafar Khademi, et al. Predicting geomechanical, abrasivity, and drillability properties in some igneous rocks using fabric features and petrographic indexes [J]. Bulletin of Engineering Geology and the Environment, 2023, 82(4).
- [14] Hemmat Esfe Mohammad, Amoozadkhalili Fatemeh, Toghraie Davood. Determining the optimal structure for accurate estimation of the dynamic viscosity of oil-based hybrid nanofluid containing MgO and MWCNTs nanoparticles using multilayer perceptron neural networks with Levenberg-Marquardt Algorithm [J]. Powder Technology, 2023, 415.
- [15] Livet Claire, Rouvier Théo, Sauret Christophe, et al. A penalty method for constrained multibody kinematics optimization using a Levenberg-Marquardt algorithm [J]. Computer methods in biomechanics and biomedical engineering, 2022.
- [16] Cliff Drubin. LM selected to prototype next-generation USMC 5G communications [J]. Microwave Journal, 2022, 65(4).
- [17] Gupta Ankush, Shrivastava Abhinav, Chhikara Sanya. TCT-341 OCT predictors of side branch restenosis during LM bifurcation angioplasty using DK crush technique [J]. Journal of the American College of Cardiology, 2021, 78(19S).
- [18] 周游, 张广智, 高刚, 等. 核主成分分析法在测井浊积岩岩性识别中的应用[J]. 石油地球物理勘探, 2019, 54(3):667-675.
ZHOU You, ZHANG Guangzhi, GAO Gang, et al. Application of kernel principal component analysis method in lithologic identification of turbidite in logging [J]. Petroleum Geophysical Exploration, 2019, 54(3):667-675.
- [19] 张俊虎, 刘赞玥, 王玲玲, 等. 基于属性核特征选择与隐含层节点数动态确定的BP神经网络模型[J]. 青岛科技大学学报(自然科学版), 2021, 42(4):113-118.
ZHANG Junhu, LIU Yunyue, WANG Lingling, et al. BP neural network model based on attribute core feature selection and dynamic determination of hidden layer node number [J]. Journal of Qingdao University of Science and Technology (Natural Science Edition), 2021, 42(4):113-118.
- [20] 夏宏泉, 刘之的, 陈平, 等. 基于BP神经网络的岩石可钻性测井计算研究[J]. 测井技术, 2004(2):148-150, 157-179.
XIA Hongquan, LIU Zhidi, CHEN Ping, et al. On calculating rock drill ability from log data based on BP neural network technology [J]. Well Logging Technology, 2004(2):148-150, 157-179.

(编辑 荐华)