

# 基于 POA-ELM 的含煤地层异常构造分类

高 洁<sup>1</sup>, 伊 雨<sup>1</sup>, 赵雯宇<sup>1</sup>, 王元军<sup>2</sup>, 王 亮<sup>3</sup>

(1. 山东科技大学电子信息工程学院, 山东 青岛 266590; 2. 中天合创能源有限责任公司, 内蒙古 鄂尔多斯 010300; 3. 山东科技大学机械电子工程学院, 山东 青岛 266590)

**摘要:**为了更准确地对含煤地层异常构造识别分类, 提出了一种基于鹈鹕优化算法 (Pelican Optimization Algorithm, POA) 和极限学习机 (Extreme Learning Machine, ELM) 的含煤地层异常构造识别分类模型 POA-ELM。针对极限学习机随机生成输入权值和隐含层偏置导致性能不稳定的缺点, 利用鹈鹕优化算法对极限学习机的输入权值和隐含层偏置进行寻优, 从而改进极限学习机模型性能, 并将 POA-ELM 应用到含煤地层异常构造的识别分类。首先利用 COMSOL Multiphysics5.5 建立小断层、冲刷带和陷落柱 3 种含煤地层仿真模型, 以雷克子波作为震源信号, 采用透射波法采集 3 种模型的槽波信号, 建立槽波信号数据集。通过 z-score 法和主成分分析法 (Principal Component Analysis, PCA) 对槽波数据进行标准化和降维处理。通过 MATLAB 构建鹈鹕优化算法改进的极限学习机分类模型 POA-ELM, 对小断层、冲刷带和陷落柱进行分类, 并通过准确率、精确率和召回率等评价指标以及交叉验证法对比和评估 ELM、POA-ELM 的分类性能, 结果表明 POA 能够有效优化 ELM, POA-ELM 模型具有更高的分类准确率和更好的稳定性, POA-ELM 对含煤地层异常构造的分类准确率可达 99% 以上。为验证 POA-ELM 的实际应用效果, 将实际断层槽波数据进行小波去噪等预处理后, 作为测试集导入 POA-ELM 模型进行识别, 结果表明 POA-ELM 模型对实际断层识别准确率可达 97% 以上。基于同样的槽波数据集将 POA-ELM 与 ELM、支持向量机 (Support Vector Machine, SVM) 和 BP 神经网络进行识别分类效果对比, 结果表明 POA-ELM 模型的识别分类准确率最高。经研究与分析, POA 能够有效优化 ELM, POA-ELM 模型能够准确分类地质构造, 并有效识别出实际断层, 效果优于其他方法。

**关键词:**极限学习机; 鹈鹕优化算法; 含煤地层异常构造; 识别分类; 槽波地震勘探

中图分类号: P548; TN929.4 文献标志码: A 文章编号: 0253-9993(2023)11-4135-10

## Classification of coal-bearing strata abnormal structure based on POA-ELM

GAO Jie<sup>1</sup>, YI Yu<sup>1</sup>, ZHAO Wenyu<sup>1</sup>, WANG Yuanjun<sup>2</sup>, WANG Liang<sup>3</sup>

(1. College of Electronic Information Engineering, Shandong University of Science and Technology, Qingdao 266590, China; 2. Zhongtian Hechuang Energy Co., Ltd., Ordos 010300, China; 3. College of Mechanical and Electronic Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

**Abstract:** In order to identify and classify the abnormal structures in coal-bearing strata more accurately, a POA-ELM model based on the pelican optimization algorithm (POA) and the extreme learning machine (ELM) is proposed. The performance of extreme learning machine is unstable because the input weights and hidden layer bias are generated randomly.

收稿日期: 2022-12-29 修回日期: 2023-04-13 责任编辑: 韩晋平 DOI: 10.13225/j.cnki.jcgs.2022.1877

基金项目: 山东省自然科学基金面上资助项目 (ZR2020MF014); 青岛市博士后应用研究资助项目

作者简介: 高 洁 (1981—), 女, 山东滨州人, 副教授, 博士。E-mail: imgj@sdust.edu.cn

通讯作者: 王 亮 (1980—), 男, 山东德州人, 副教授, 博士。E-mail: wliang@sdust.edu.cn

引用格式: 高洁, 伊雨, 赵雯宇, 等. 基于 POA-ELM 的含煤地层异常构造分类[J]. 煤炭学报, 2023, 48(11): 4135-4144.

GAO Jie, YI Yu, ZHAO Wenyu, et al. Classification of coal-bearing strata abnormal structure based on POA-ELM[J]. Journal of China Coal Society, 2023, 48(11): 4135-4144.



移动阅读

The POA can be used to optimize the input weights and hidden layer bias of extreme learning machine, so as to improve the performance of extreme learning machine model. The POA-ELM model is applied to identify and classify the abnormal structures in coal-bearing strata. Firstly, three coal-bearing strata simulation models of small fault, scour zone and collapse column are established with the COMSOL Multiphysics5.5. The Ricker wave is the source signal. The in-seam wave signals are collected by wave transmission method, and the in-seam wave data set is established. Then the z-score method is used to standardize the in-seam wave data and the principal component analysis (PCA) is used to reduce the dimension. Secondly, the POA is used to optimize the extreme learning machine, and the POA-ELM classification model is constructed with MATLAB. The POA-ELM model is used to classify small fault, scour zone and collapse column. The classification performance of ELM and POA-ELM is evaluated and compared by cross-validation method and evaluation indices such as accuracy, precision and recall rate. The results show that the POA can effectively optimize the ELM, and the POA-ELM model has higher classification accuracy and better stability. The classification accuracy of POA-ELM for abnormal structures can reach more than 99%. Thirdly, in order to verify the classification effect of POA-ELM in practical applications, after wavelet de-noising, z-score standardization and PCA dimensionality reduction, the real fault in-seam wave data are used as the test set and imported into the POA-ELM model for classification. The results show that the identification accuracy of POA-ELM model for real fault can reach more than 97%. Finally, based on the same data set, the classification effects of POA-ELM, ELM, support vector machine (SVM) and BP neural network are compared. The results show that the identification and classification accuracy of POA-ELM model is the highest. Through research and analysis, the POA can effectively optimize the ELM, and the POA-ELM model can accurately classify different geological structures and effectively identify real faults, which is better than other methods.

**Key words:** extreme learning machine (ELM); pelican optimization algorithm (POA); abnormal structure of coal-bearing strata; identify and classify; in-seam seismic (ISS)

煤矿事故的发生会造成大量的人员伤亡和巨大的经济损失,煤层异常构造的存在会增加煤矿事故发生概率<sup>[1]</sup>,因此含煤地层异常构造识别研究对提高煤矿开采的安全性十分重要。槽波地震勘探作为一种极具发展前景的地球物理勘探方法,不仅能够有效探测陷落柱、小断层等,同时对采空区及废弃巷道等探测效果也较显著<sup>[2]</sup>。该技术具有探测精度高、距离大、波形特征易于识别、抗干扰能力强等优势<sup>[3]</sup>,尤其在探测精度和距离方面优于其他煤矿井下物探方法<sup>[4]</sup>,近年来被广泛应用<sup>[5-7]</sup>。

槽波地震数据的处理与解释是槽波地震勘探的重要一环,目前常用的方法有层析成像、偏移成像等成像法<sup>[8-11]</sup>,通过成像能直观地确定构造的种类和位置,但数据处理与成像过程繁杂,耗时耗力,并且成像结果多依靠人工经验解释,易出现偏差,此外,共中心点叠加法、速度分析法也常用于处理槽波数据<sup>[12-14]</sup>,但多与成像技术结合,同样易出现偏差。近些年,机器学习也被应用到地震勘探领域<sup>[15]</sup>,通过地震数据识别异常地质构造,但多以识别断层为主<sup>[16-19]</sup>,在其他构造识别方面研究较少。

极限学习机 (ELM) 是由 HUANG 等<sup>[20]</sup>于 2004 年提出的一种单隐含层前馈神经网络,与传统训练算法相比,ELM 具有设置参数少、学习速度快、训练误

差小以及泛化性能好等优势<sup>[21-23]</sup>,但由于 ELM 的输入权值与隐含层偏置是随机产生的,导致分类性能不稳定<sup>[24-26]</sup>;鹈鹕优化算法 (POA) 是 2022 年由 Pavel Trojovsky 和 Mohammad Dehghani 提出的,是一种模拟鹈鹕群体狩猎的智能优化算法,其在逼近最优解方面具有较强的挖掘能力,并且不易陷入局部最优<sup>[27]</sup>,能够为极限学习机寻到最优的输入权值与隐含层偏置,经过优化后的极限学习机更加适合处理数量庞大、包含信息复杂的槽波数据,可以更好地完成煤层构造的识别分类任务。因此,笔者提出基于 POA-ELM 的含煤地层构造识别分类方法,对小断层、冲刷带和陷落柱进行识别分类研究,并对分类结果进行评价与分析。

## 1 方法原理

### 1.1 极限学习机

与传统的前馈神经网络不同,ELM 未采用基于梯度的算法,而是随机选择输入权值和隐含层偏置<sup>[28-29]</sup>,并根据最小二乘准则,依据 Moore-Penrose 广义逆矩阵理论求出输出权值<sup>[30]</sup>。

假设有  $N$  个任意样本  $(\mathbf{x}_i, \mathbf{t}_i)$ , 其中  $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ ,  $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ ,  $n$  为输入层节点数,  $m$  为输出层节点数, 中间有  $L$  个隐含层, 第  $k$  个隐含层节点的输出为  $h_k(\mathbf{x}_i)$ , 可表示为

$$h_k(\mathbf{x}_i) = g(\mathbf{w}_k, b_k, \mathbf{x}_i) = g(\mathbf{w}_k \cdot \mathbf{x}_i + b_k), k = 1, 2, \dots, L \quad (1)$$

式中,  $\mathbf{w}_k = [\omega_{k1}, \omega_{k2}, \dots, \omega_{kn}]^T$  为输入节点与第  $k$  个隐含层节点的输入权值向量;  $b_k$  为第  $k$  个隐含层节点的阈值;  $\mathbf{w}_k \cdot \mathbf{x}_i$  为  $\mathbf{w}_k$  和  $\mathbf{x}_i$  的内积;  $g(\mathbf{w}_k, b_k, \mathbf{x}_i)$  为激活函数。

ELM 原理如图 1 所示。ELM 的学习目标可转化为使输出误差最小, 即存在  $\beta_k$ 、 $\mathbf{w}_k$  和  $b_k$ , 使得

$$\sum_{k=1}^L \beta_k g(\mathbf{w}_k \cdot \mathbf{x}_i + b_k) = \mathbf{y}_i, i = 1, 2, \dots, N \quad (2)$$

式中,  $\beta_k = [\beta_{k1}, \beta_{k2}, \dots, \beta_{km}]^T$  为第  $k$  个隐含层节点与输出层节点的输出权重向量;  $\mathbf{y}_i$  为第  $i$  个样本对应的模型输出。

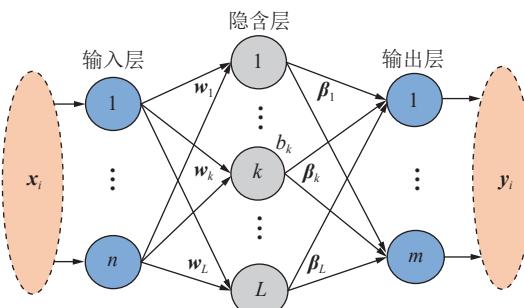


图 1 极限学习机原理

Fig.1 Principle diagram of extreme learning machine

式(2)用矩阵表示为

$$\mathbf{H}\beta = \mathbf{Y} \quad (3)$$

其中,  $\mathbf{H}$  为隐含层节点的输出矩阵;  $\beta$  为隐含层与输出层连接权重矩阵;  $\mathbf{Y}$  为期望输出矩阵。式(3)展开形式为

$$\mathbf{H} = [\mathbf{h}(\mathbf{x}_1), \mathbf{h}(\mathbf{x}_2), \dots, \mathbf{h}(\mathbf{x}_N)]^T = \begin{bmatrix} h_1(\mathbf{x}_1) \dots h_L(\mathbf{x}_1) \\ \vdots \\ h_1(\mathbf{x}_N) \dots h_L(\mathbf{x}_N) \end{bmatrix}_{N \times L} \quad (4)$$

$$\beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T, \mathbf{Y} = [\mathbf{y}_1^T, \mathbf{y}_2^T, \dots, \mathbf{y}_N^T]^T_{m \times N} \quad (5)$$

通常将期望输出矩阵  $\mathbf{Y}$  与样本标签  $\mathbf{T}$  求残差最小平方和作为评价目标函数, 使该目标函数最小的解就是最优解, 目标函数可表示为

$$\min \|\mathbf{H}\beta - \mathbf{T}\|^2 \quad (6)$$

式中,  $\mathbf{T} = [t_1^T, t_2^T, \dots, t_N^T]^T$ 。

通过线性代数和矩阵理论的知识推导得出式(6)的最优解为

$$\hat{\beta} = \mathbf{H}^{\dagger} \mathbf{T} \quad (7)$$

式中,  $\mathbf{H}^{\dagger}$  为矩阵  $\mathbf{H}$  的 Moore-Penrose 广义逆矩阵。

## 1.2 鹦鹉优化算法

鹦鹉优化算法模拟了鹦鹉在狩猎过程中的自然行为, 每个种群成员代表一个候选解。鹦鹉种群初始化数学描述为

$$q_{u,v} = l_v + \text{rand}(d_v - l_v), u = 1, 2, \dots, M; v = 1, 2, \dots, r \quad (8)$$

式中,  $q_{u,v}$  为第  $u$  个鹦鹉的第  $v$  维位置;  $M$  为鹦鹉的种群数量;  $r$  为求解问题的维度, 即待优化变量的个数;  $\text{rand}$  为  $[0, 1]$  内的随机数,  $d_v$  和  $l_v$  分别为求解问题的第  $v$  维的上、下边界。

鹦鹉种群可用种群矩阵表示, 即

$$\mathbf{Q} = \begin{bmatrix} Q_1 \\ \vdots \\ Q_u \\ \vdots \\ Q_M \end{bmatrix}_{M \times r} = \begin{bmatrix} q_{1,1} & \dots & q_{1,v} & \dots & q_{1,r} \\ \vdots & & \vdots & & \vdots \\ q_{u,1} & \dots & q_{u,v} & \dots & q_{u,r} \\ \vdots & & \vdots & & \vdots \\ q_{M,1} & \dots & q_{M,v} & \dots & q_{M,r} \end{bmatrix}_{M \times r} \quad (9)$$

其中,  $\mathbf{Q}$  为鹦鹉的种群矩阵;  $Q_u$  为第  $u$  个鹦鹉的位置。鹦鹉的目标函数值可用目标函数向量表示为

$$\mathbf{F} = \begin{bmatrix} F_1 \\ \vdots \\ F_u \\ \vdots \\ F_M \end{bmatrix}_{M \times 1} = \begin{bmatrix} F(Q_1) \\ \vdots \\ F(Q_r) \\ \vdots \\ F(Q_M) \end{bmatrix}_{M \times 1} \quad (10)$$

其中,  $\mathbf{F}$  为鹦鹉种群的目标函数向量;  $F_u$  为第  $u$  个鹦鹉的目标函数值。

鹦鹉的狩猎过程主要为逼近猎物和水面飞行, 在 POA 算法中, 则主要分为勘探阶段和开发阶段。

(1) 勘探阶段。

$$q_{u,v}^{P_1} = \begin{cases} q_{u,v} + \text{rand}(p_v - Iq_{u,v}), F_p < F_u \\ q_{u,v} + \text{rand}(q_{u,v} - p_v), \text{else} \end{cases} \quad (11)$$

其中,  $q_{u,v}^{P_1}$  为基于第 1 阶段更新后第  $u$  个鹦鹉的第  $v$  维的位置;  $p_v$  为猎物的第  $v$  维的位置;  $F_p$  为猎物的目标函数值;  $I$  为 1 或 2 的随机整数。若目标函数值在该位置得到改善, 则接受鹦鹉的新位置:

$$Q_u = \begin{cases} Q_u^{P_1}, F_u^{P_1} < F_u \\ Q_u, \text{else} \end{cases} \quad (12)$$

式中,  $Q_u^{P_1}$  为第  $u$  个鹦鹉的新位置;  $F_u^{P_1}$  为基于第 1 阶段更新后的第  $u$  个鹦鹉的新位置的目标函数值。

(2) 开发阶段。

$$q_{u,v}^{P_2} = q_{u,v} + R \left( 1 - \frac{t}{S} \right) (2\text{rand} - 1) q_{u,v} \quad (13)$$

其中,  $q_{u,v}^{P_2}$  为基于第 2 阶段更新后第  $u$  个鹦鹉的第  $v$  维

的位置;  $R$  为常数, 取值为 0.2;  $R(1-t/S)$  为  $q_{u,v}^{P_2}$  的邻域半径;  $t$  为当前迭代次数;  $S$  为最大迭代次数。这一阶段对鹅鹕位置更新为

$$Q_u = \begin{cases} Q_u^{P_2}, F_u^{P_2} < F_u \\ Q_u, \text{else} \end{cases} \quad (14)$$

其中,  $Q_u^{P_2}$  为第  $u$  个鹅鹕的新位置;  $F_u^{P_2}$  为基于第 2 阶段的目标函数值。

## 2 含煤地层异常构造模型与槽波信号数据集建立

### 2.1 含煤地层异常构造仿真模型建立

笔者利用 COMSOL Multiphysics5.5 仿真软件, 分别建立小断层、冲刷带和陷落柱的三维含煤地层异常构造仿真模型, 模型尺寸为  $100 \text{ m} \times 10 \text{ m} \times 10 \text{ m}$ , 上下围岩厚度均为 4 m, 煤层厚度为 2 m, 采用主频为 200 Hz 的雷克子波作为地震子波。在煤层中激发后, 检波器

会接收到携带各构造信息的槽波信号。三维等效介质模型参数见表 1, 模型结构如图 2 所示, 为了更好的模拟实际煤层, 避免模型表面边界发生反射现象影响仿真结果的准确性, 在 3 种构造模型中均设置了低反射边界。

表 1 3 种仿真模型物性参数

Table 1 Physical parameters of three simulation models

介质	纵波速度/ ( $\text{m} \cdot \text{s}^{-1}$ )	横波速度/ ( $\text{m} \cdot \text{s}^{-1}$ )	密度/ ( $\text{kg} \cdot \text{m}^{-3}$ )
上围岩	4 200	2 400	2 700
煤层	2 000	1 200	1 300
下围岩	4 200	2 400	2 700
小断层上下盘破碎带	3 710	1 900	2 400
冲刷带	2 200	1 100	2 800
陷落柱	1 800	900	1 150

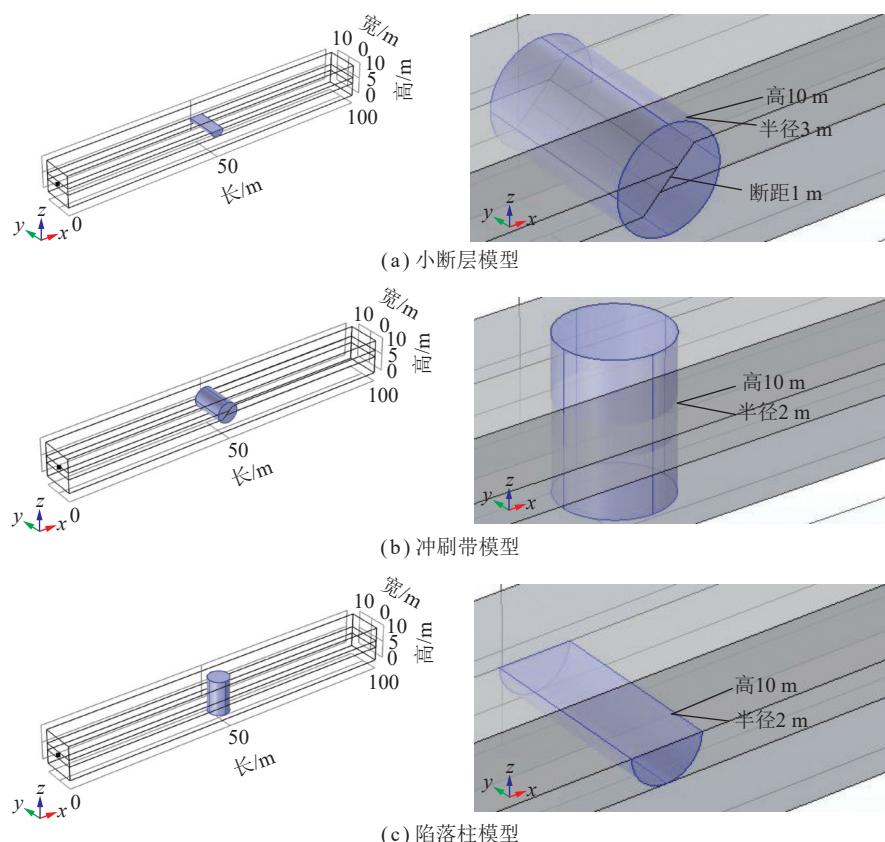


图 2 3 种构造仿真模型

Fig.2 Simulation model of three structures

### 2.2 槽波模拟与数据处理

笔者采用槽波勘探中的透射波法<sup>[31]</sup>, 分别采集小断层、冲刷带、陷落柱的槽波信号。将震源激发点置于模型  $x=0$  的中央处, 在模型  $x=100 \text{ m}$  处共设置 606 个检波器, 检波器在模型中的位置如图 3 所示, 所

有检波器在  $x=100 \text{ m}$  处的排列如图 4 所示, 图 4 中每条红色线由 101 个检波点排列形成, 红色线间距均为 3 m, 6 条红色线共排列 606 个检波点, 检波点间距为 0.1 m, 坐标见表 2, Range(2,3,10) 表示在  $y$  方向检波器位于从 2~10 m 以 3 m 为步长取点处。

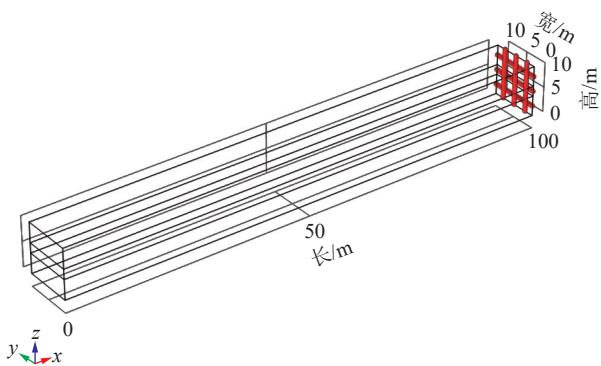


图3 检波器位置示意

Fig.3 Schematic diagram of the position of geophones

每种构造模型采集到606个槽波数据样本,3种构造模型共得到1818个样本,每个样本为时长0.2 s的时序数据,包含501个采样点,得到 $1818 \times 501$ 的样本数据,如图5所示,3种模型的槽波信号能量都集中于0.05~0.10 s,但每类信号的轮廓与幅值具有明显差异,这为实现3种构造模型的分类提供了可能。

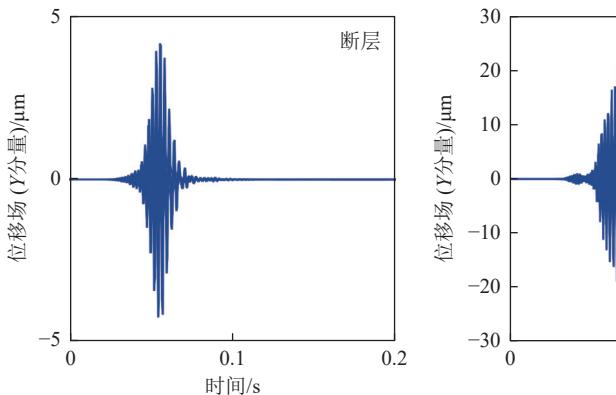


图5 槽波样本数据

Fig.5 In-seam wave sample data

在利用极限学习机处理分类问题时,数据的预处理效果直接关系到模型的分类效果。采集到槽波数据后,首先对其进行z-score标准化,消除由不同量纲与数值量级所引起的数据偏差,使得数据具有可比性。最后采用主成分分析法(PCA)对标准化后的数据进行降维,消除冗余数据,提高分类模型的训练速度,同时也尽可能保留各数据的原始特征,保证分类结果的准确率。PCA降维时,若第 $p$ 个特征贡献率接近于1,则选取前 $p$ 个主成分代替原来的槽波数据。特征累计贡献率情况如图6所示,第30个特征贡献率达0.9985,因此选取前30个特征,最终将501个数据特征降为30个数据特征,得到 $1818 \times 30$ 的样本数据。

### 3 基于POA-ELM的煤层异常构造分类模型建立

#### 3.1 传统极限学习机分类模型建立

笔者对极限学习机分类模型的激活函数、隐含层

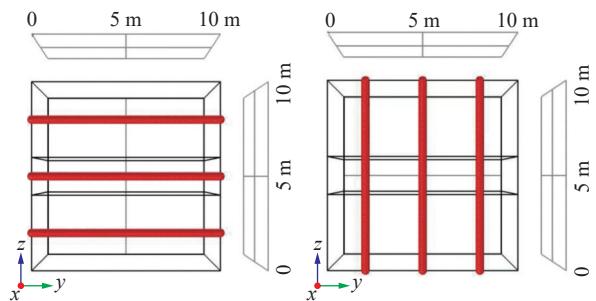
图4 检波器布置示意( $x=100$  m)Fig.4 Schematic diagram of geophones( $x=100$  m)

表2 检波器位置坐标

Table 2 Position coordinates of the detector

方向	坐标	坐标
$x$	100	100
$y$	Range(2,3,10)	Range(0,0.1,10)
$z$	Range(0,0.1,10)	Range(2,3,10)

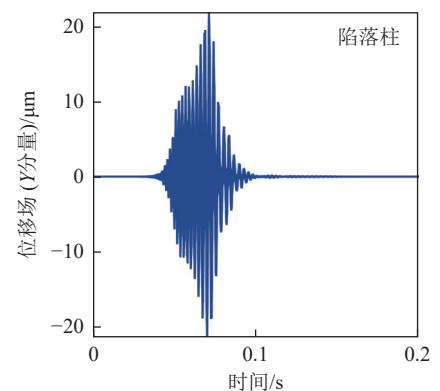


图6 特征累计贡献率

Fig.6 Cumulative contribution rate of characteristics

节点数进行研究。如图7所示,通过比较分类准确率,选择最佳激活函数和隐含层节点数,实验结果表明:随着隐含层节点数的增多分类准确率总体趋势也增高,能够明显看出,当激活函数为Sigmoid函数或

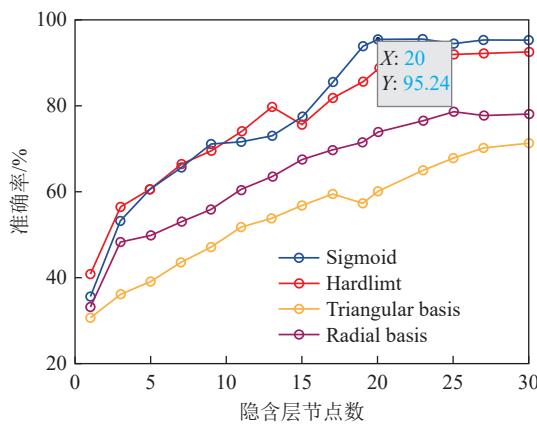


图 7 隐含层节点与激活函数的选择

Fig.7 Selection of hidden layer nodes and activation function

Hardlimt 函数时, 分类准确率远高于 Tribas 函数和 Radbas 函数。当隐含层节点数设为 20、激活函数设为 Sigmoid 函数时, ELM 分类准确率达到了最大值 95.24%, 隐含层节点数大于 20 时分类准确率趋于平稳。根据以上分析, 笔者将 Sigmoid 函数作为极限学习机分类模型的激活函数, 隐含层节点数设置为 20。

### 3.2 鹈鹕算法优化的极限学习机模型

基于前文的 ELM 分类模型, 利用鹈鹕优化算法对极限学习机进行优化, 在有限的迭代次数里, 找到使得 ELM 分类效果最佳的输入权值和隐含层偏置, 从而弥补 ELM 因随机生成输入权值和隐含层偏置导致分类效果不稳定的缺点, 提高分类模型性能, 优化过程如图 8 所示。将极限学习机的分类准确率作为

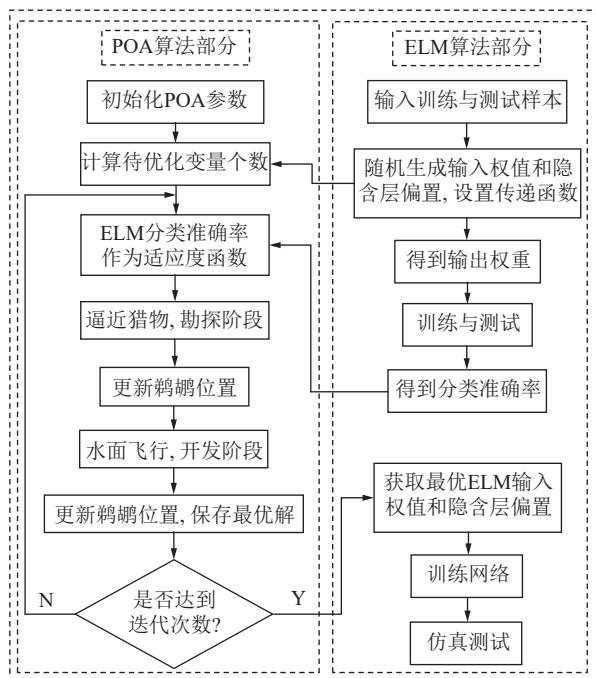


图 8 鹈鹕算法优化极限学习机

Fig.8 Flowchart of pelican optimization algorithm optimizing extreme learning machine

鹈鹕优化算法的适应度函数, 进行数次迭代, 比较适应度值, 不断更新鹈鹕位置, 并保存目前最优输入权值与隐含层偏置。笔者将鹈鹕种群数量设置为 30, 最大迭代次数设置为 100, 迭代过程如图 9 所示, 当迭代次数为 37 时, POA 为 ELM 寻到全局最优解, 收敛速度较快。

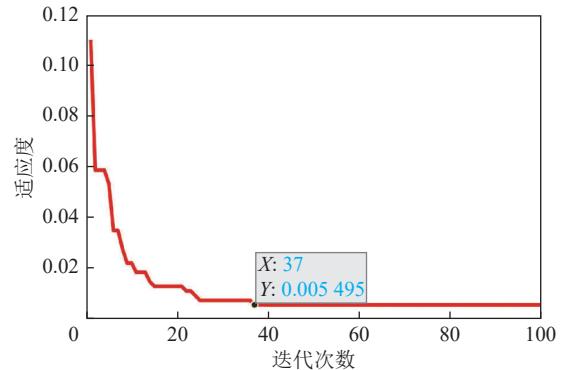


图 9 POA 寻优迭代过程

Fig.9 POA optimization iterative process

## 4 测试结果与分析

### 4.1 分类结果与分析

实验中随机选取 70% 的样本数据作为训练集, 剩余 30% 个样本数据作为测试集, 将小断层标签设为 1, 冲刷带标签设为 2, 陷落柱标签设为 3。ELM 测试集的分类结果如图 10 所示, 分类准确率为 95.238 1%, 共有 26 个样本被分类错误。POA-ELM 测试集的分类结果如图 11 所示, 分类准确率达 99.450 5%, 共有 3 个样本被分类错误, 从准确率和错误分类样的本分布情况来看, POA-ELM 分类效果优于传统 ELM。

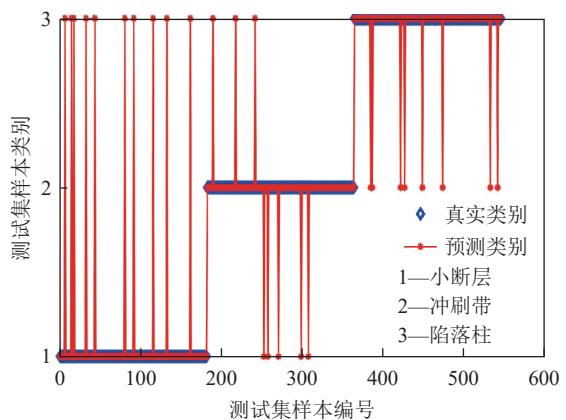


图 10 ELM 分类结果

Fig.10 Classification result of ELM

前文通过准确率对整体分类效果进行了分析, 下面通过精确率 ( $P$ )、召回率 ( $R$ ) 2 个评价指标, 对 ELM 和 POA-ELM 的分类结果进行评价和对比,  $P$  和  $R$  均是针对每类模型的分类结果进行评价。将 ELM 和

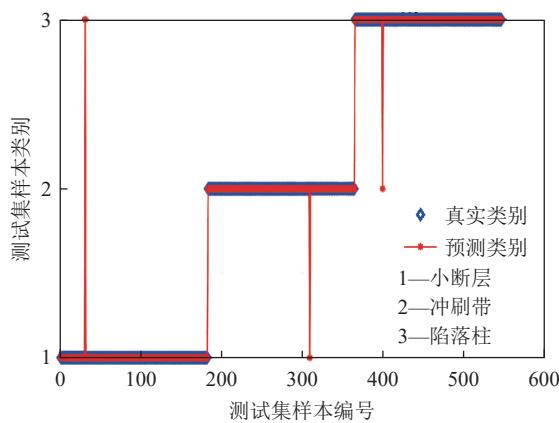


图 11 POA-ELM 分类结果

Fig.11 Classification result of POA-ELM

POA-ELM 分类结果的  $P$  和  $R$  整合为如图 12 所示, ELM 各模型的  $P$  和  $R$  指标均大于 93%; POA-ELM 各模型的  $P$  和  $R$  指标均在 99% 以上, POA-ELM 分类效果明显优于传统 ELM, 分类效果较为理想。

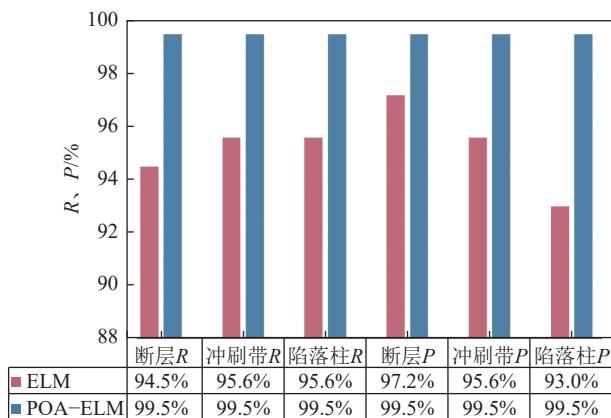


图 12 分类结果评价指标

Fig.12 Evaluation index of classification results

为消除数据集分布带来的分类性能波动, 笔者采用十折交叉验证评估分类模型的性能, 将  $1818 \times 30$  的样本数据集和  $1818 \times 1$  的标签数据集打乱顺序并均匀

分为 10 份, 依次选取其中 1 份作为测试集, 其余 9 份作为训练集, 每份数据均作为测试集后, 完成 1 次十折交叉验证, 取均值作为 1 次十折交叉验证的结果。将以上过程重复 10 次, 结果如图 13 所示, 经验证传统 ELM 分类准确率波动较大, 而 POA-ELM 基本保持平稳状态, 且分类准确率均保持在 99% 左右, 说明本文构建的 POA-ELM 分类模型对于含煤地层异常构造识别分类具有稳定且良好的分类性能。

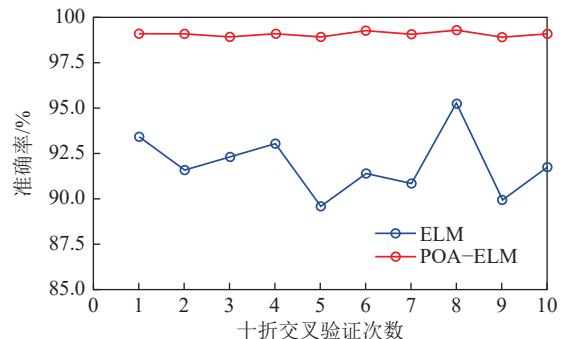


图 13 十折交叉验证结果

Fig.13 Result of ten-fold cross validation

#### 4.2 POA-ELM 的实际应用

为说明本文构建的 POA-ELM 模型对实际构造的分类性能, 将长城五号矿 1901N 工作面的槽波地震勘探数据引入测试集进行分类。1901N 工作面中槽波观测系统如图 14 所示, 在 1901N 运输巷布置 53 个炮点, 1901N 回风巷布置 61 个接收点, 采用透射法勘探, 得到 2 个异常区 YC1 和 YC2(图 14 洋红色线圈定的范围), 经分析 YC1、YC2 异常区均为贯穿工作面的断层影响区。选取  $P_{1-34} \sim P_{1-36}$  三炮槽波数据用于实际断层的识别, 共 183 组槽波数据样本, 为保证 POA-ELM 模型对实际断层的识别效果, 与仿真槽波数据中断层测试集样本量一致, 将  $P_{1-36}$  炮中包含断层信息较少的第 61 组槽波数据剔除, 剩余 182 组作为识别实际断层的测试集样本, 如图 15 所示。为保证

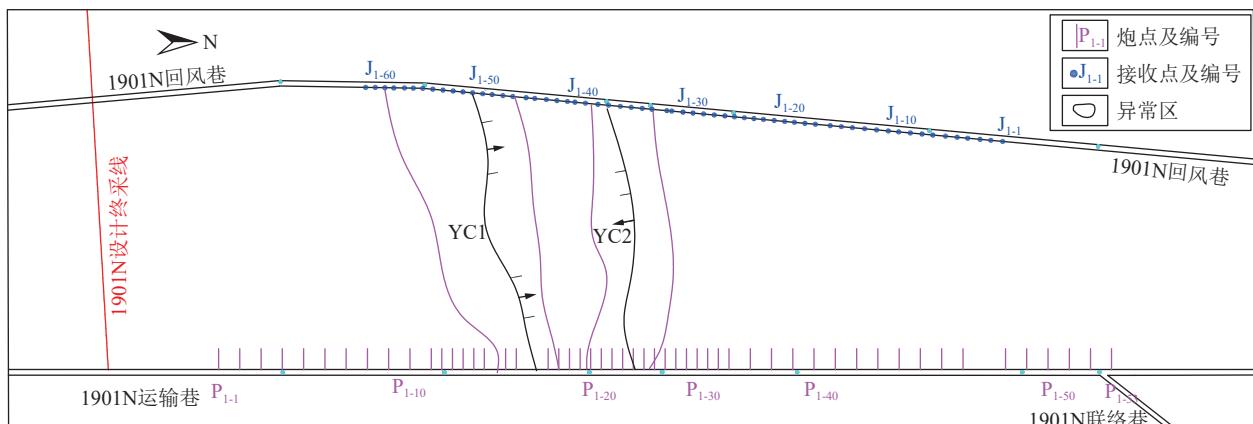
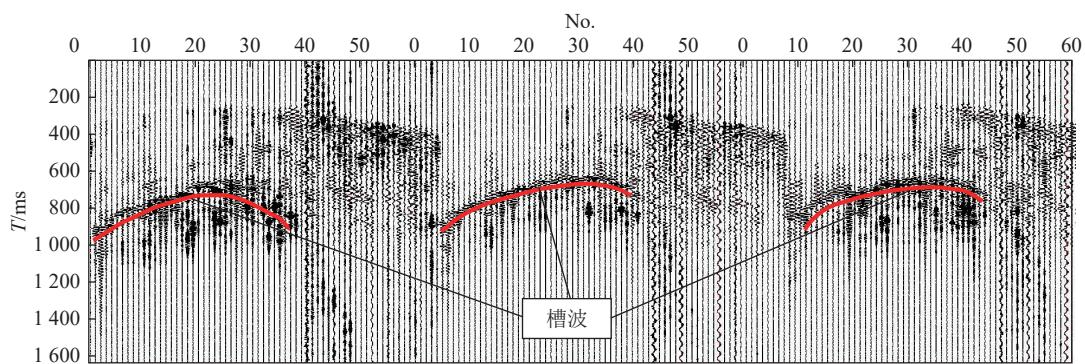


图 14 槽波观测系统示意

Fig.14 In-seam wave observation system diagram

图 15 P<sub>1-34</sub> 至 P<sub>1-36</sub> 炮槽波时间-振幅Fig.15 Time-amplitude diagram of P<sub>1-34</sub> to P<sub>1-36</sub> shot in-seam wave

分类速度与准确率,首先对三炮断层槽波进行4层小波去噪,去噪前后的槽波如图16所示,去噪之后波形噪声有所减少,进而对其进行z-score标准化和PCA

降维,得到182×30的断层测试集数据。182组断层槽波数据经过数据预处理后,将代替原本的仿真断层测试集数据进行识别分类。

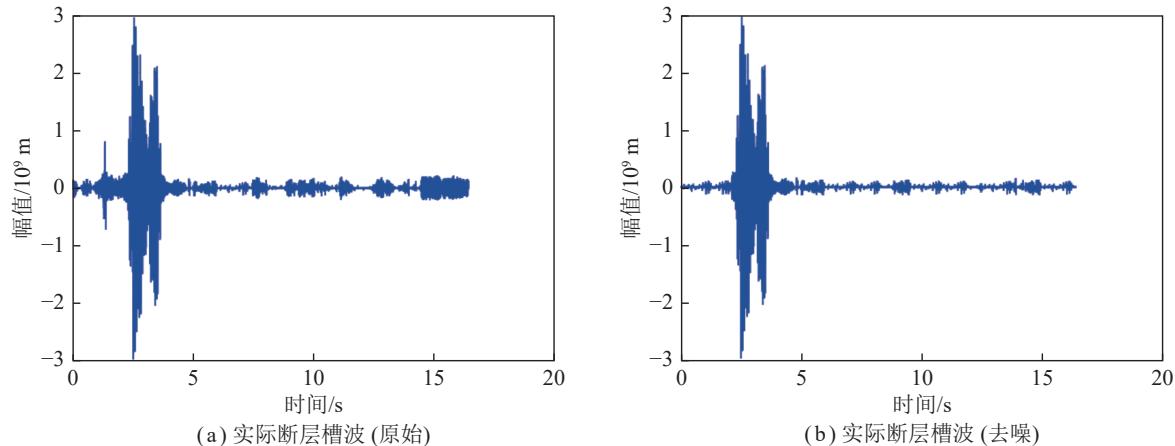


图 16 原始槽波数据与去噪槽波数据对比

Fig.16 Comparison of original in-seam wave data and denoised in-seam wave data

分类结果如图17所示,整体分类准确率为97.435 9%,与图11仿真分类结果相比,准确率有所下降,小断层被错误分类的数据有所增多。结合图18混淆矩阵分析,有4组断层数据被错误分类为冲刷带,8组被错误分类为陷落柱,小断层召回率为93.4%,相

对于图12召回率下降6.1%,准确率和小断层召回率下降的主要原因是相对于仿真槽波数据,实际槽波会含有部分残留噪声,且与训练集的仿真数据特征存在差别。总体来看,准确率、召回率及精确率均高于93%,

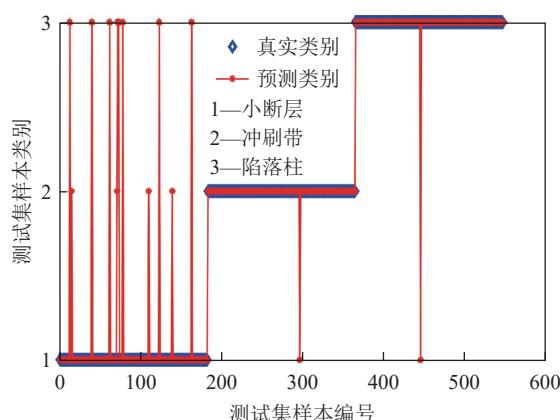


图 17 POA-ELM 实际数据分类结果

Fig.17 POA-ELM classification result of real data

混淆矩阵			召回率 (R)			
真实类别						
	1	2	3	1		
1	170	4	8	93.4%	6.6%	
2	1	181		99.5%	0.5%	
3	1		181	99.5%	0.5%	
	98.8%	97.8%	95.8%			
	1.2%	2.2%	4.2%			
	1—小断层		2—冲刷带		3—陷落柱	

图 18 实际数据分类混淆矩阵与评价指标

Fig.18 Confusion matrix and evaluation index of real data

分类结果较为理想, 说明本文构建的 POA-ELM 模型能够有效分类实际槽波数据, 实现地质构造的分类识别。

#### 4.3 不同方法分类结果对比

基于相同的样本数据, 分别采用支持向量机(SVM)和BP 神经网络 2 种方法对含煤地层异常构造进行识别分类, 分类结果如图 19 所示, 对于仿真数据 4 种方法的分类准确率都达到了 90% 以上, 其中 POA-ELM 和 SVM 的准确率都达到了 97% 以上; 对于含断层的槽波数据 POA-ELM 的分类准确率达 97.44%, 高于其他 3 种方法。综合分析, 无论是仿真槽波数据还是含实际断层槽波数据, 笔者提出的 POA-ELM 分类模型都更具优势。

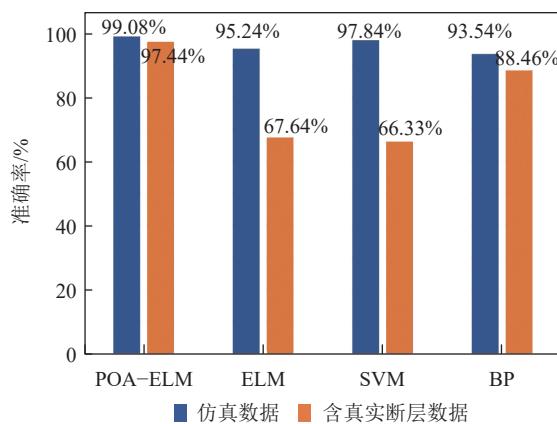


图 19 分类结果对比

Fig.19 Comparison of classification results

## 5 结 论

(1) 提出了一种鹤鹏优化算法优化的极限学习机分类模型 POA-ELM, 利用鹤鹏优化算法对极限学习机的输入权值和隐含层偏置进行寻优, 提高了极限学习机分类模型的分类准确率和稳定性。

(2) 将 POA-ELM 分类模型应用到含煤地层异常构造识别分类中, 通过建立含煤地层仿真模型, 对断层、冲刷带和陷落柱模型进行了识别分类, 取得了良好的分类效果, 分类准确率达 99% 以上, 分类性能更稳定, 效果远优于原始 ELM, 证明了 POA 对 ELM 的良好优化效果和 POA-ELM 在含煤地层异常构造识别分类中应用的可行性。

(3) POA-ELM 模型对于实际断层的识别准确率达 97% 以上, 识别效果较为理想。与 ELM、SVM、BP 的分类结果进行对比, 无论是仿真槽波数据还是含实际断层槽波数据, POA-ELM 的分类识别准确率都最高, 更具优势。

由于实际槽波数据资源有限, 本文只对实际断层进行了识别, 今后将对冲刷带、陷落柱等其他含煤地

层异常构造进行识别, 并进一步应用于槽波地震勘探。

#### 参 考 文 献(References):

- [1] 朱金华. 透射法槽波地震勘探在煤矿小构造探测中的应用[J]. 工程建设与设计, 2021(4): 42–43, 46.  
ZHU Jinhua. The application of transmitted in-seam wave seismic exploration in coal mine small structure detection[J]. Engineering Construction and Design, 2021(4): 42–43, 46.
- [2] 何文欣. 槽波地震勘探在煤层构造探测中的应用[J]. 煤炭技术, 2017, 36(2): 99–102.  
HE Wenxin. Application of in-seam wave exploration in coal structure detection[J]. Coal Technology, 2017, 36(2): 99–102.
- [3] 王文德. 煤层的槽波赋存状况及其分类[J]. 煤炭学报, 1997, 22(4): 32–35.  
WANG Wende. Occurrence of the channel waves in coal seams and its classification[J]. Journal of China Coal Society, 1997, 22(4): 32–35.
- [4] 田树伟, 姚春艳, 崔伟雄. 槽波地震探测技术在玉华煤矿开采中的应用[J]. 能源技术与管理, 2018, 43(3): 151–152.  
TIAN Shuwei, YAO Chunyan, CUI Weixiong. Application of ISS exploration technique to Yuhua coal mine exploration[J]. Energy Technology and Management, 2018, 43(3): 151–152.
- [5] 姚小帅, 冯磊, 廉洁, 等. 槽波地震反射法在断裂构造探测中的应用[J]. 中州煤炭, 2015(9): 101–104.  
YAO Xiaoshuai, FENG Lei, LIAN Jie, et al. Application of in-seam seismic reflection method in fault structure detection[J]. Zhongzhou Coal, 2015(9): 101–104.
- [6] 聂荣花. 槽波探测技术在湾图沟煤矿的应用研究[J]. 内蒙古煤炭经济, 2021(14): 31–32.  
NIE Ronghua. Application of in-seam wave exploration technology in Wantugou coal mine[J]. Inner Mongolia Coal Economy, 2021(14): 31–32.
- [7] 赵伟, 马济国, 梁红波. 淮南矿区煤层冲刷带槽波地震探测试验[J]. 能源技术与管理, 2020, 45(6): 170–172.  
ZHAO Wei, MA Jiguo, LIANG Hongbo. In-seam seismic exploration experiment of coal seam washout zone in Huainan mining district[J]. Energy Technology and Management, 2020, 45(6): 170–172.
- [8] 周恒心, 杨焱钧, 程继东, 等. 透射槽波地震勘探在济宁二号煤矿的应用[J]. 陕西煤炭, 2022, 41(2): 63–66, 100.  
ZHOU Hengxin, YANG Yanjun, CHENG Jidong, et al. Application of transmission trough wave seismic exploration in Jining No. 2 coal mine[J]. Shaanxi Coal, 2022, 41(2): 63–66, 100.
- [9] 王会林, 赵护林. 槽波反射法勘探在煤矿生产中的应用[J]. 西部探矿工程, 2021, 33(3): 141–143.  
WANG Huilin, ZHAO Hulin. Application of in-seam wave reflection method in coal mine production[J]. West-China Exploration Engineering, 2021, 33(3): 141–143.
- [10] 朱金华. 透射法槽波地震勘探在煤矿小构造探测中的应用[J]. 工程建设与设计, 2021(4): 42–43, 46.  
ZHU Jinhua. The application of transmitted in-seam wave seismic exploration in coal mine small structure detection[J]. Engineering Construction and Design, 2021(4): 42–43, 46.

- Construction and Design, 2021(4): 42–43,46.
- [11] 焦阳, 卫金善, 杨新亮, 等. 煤矿陷落柱槽波探查技术及应用[J]. 能源与环保, 2019, 41(1): 62–69.
- JIAO Yang, WEI Jinshan, YANG Xinliang, et al. Slot wave detection technology and application of collapsed column in coal mine[J]. China Energy and Environmental Protection, 2019, 41(1): 62–69.
- [12] 张万鹏, 李松营, 姚小帅, 等. 地震槽波断层探测观测系统设计和数据解译技术[J]. 煤矿安全, 2022, 53(2): 142–148.
- ZHANG Wanpeng, LI Songying, YAO Xiaoshuai, et al. Observation system and data interpretation of fault exploration by in-seam seismic survey[J]. Safety in Coal Mines, 2022, 53(2): 142–148.
- [13] 贾靖. 煤矿槽波地震反射法偏移成像技术在霍宝干河矿的应用研究[J]. 中国煤炭, 2016, 42(11): 34–38, 48.
- JIA Jing. Applied research on migration imaging technology of mine channel wave seismic reflection method in Huobaoganhe Mine[J]. China Coal, 2016, 42(11): 34–38,48.
- [14] 李雪梅. 三维地震勘探预测煤层冲刷带[J]. 能源技术与管理, 2017, 42(2): 173–175.
- LI Xuemei. Prediction of coal seam scouring zone by 3D seismic exploration[J]. Energy Technology and Management, 2017, 42(2): 173–175.
- [15] 王博睿. 机器学习算法在断层识别及地震相波形分类中的应用探讨[D]. 成都: 成都理工大学, 2020.
- WANG Borui. Application and discussion of machine learning in faults recognition and seismic facies waveform classification[D]. Chengdu: Chengdu University of Technology, 2020.
- [16] 李辉. 基于改进 AlexNet 模型的断层识别方法[J]. 油气地质与采收率, 2022, 29(1): 107–112.
- LI Hui. Fault recognition method based on improved AlexNet[J]. Petroleum Geology and Recovery Efficiency, 2022, 29(1): 107–112.
- [17] 周东红, 李辉, 阎建国. CNN 标签数据迭代优化及在小断层识别中的应用[J]. 地球物理学进展, 2022, 37(1): 338–347.
- ZHOU Donghong, LI Hui, YAN Jianguo. Iterative optimization of label data CNN algorithm and its application to small fault identification[J]. Progress in Geophysics, 2022, 37(1): 338–347.
- [18] 何易龙, 文晓涛, 王锦涛, 等. 基于 3D U-Net++L<sup>3</sup> 卷积神经网络的断层识别[J]. 地球物理学进展, 2022, 37(2): 607–616.
- HE Yilong, WEN Xiaotao, WANG Jintao, et al. Fault recognition based on 3D U-Net++L<sup>3</sup> convolutional neural network[J]. Progress in Geophysics, 2022, 37(2): 607–616.
- [19] 常德宽, 雍学善, 王一惠, 等. 基于深度卷积神经网络的地震数据断层识别方法[J]. 石油地球物理勘探, 2021, 56(1): 1–8, 230.
- CHANG Dekuan, YONG Xueshan, WANG Yihui, et al. Seismic fault interpretation based on deep convolutional neural network[J]. Oil Geophysical Prospecting, 2021, 56(1): 1–8, 230.
- [20] HUANG G, HU Q, SIEW C. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1–3): 489–501.
- [21] 张宪国, 吴啸啸, 黄德榕, 等. 极限学习机驱动的地震多属性融合识别曲流带单一点坝[J]. 石油地球物理勘探, 2021, 56(6): 1340–1350, 1200–1201.
- ZHANG Xianguo, WU Xiaoxiao, HUANG Derong, et al. Single point bar interpretation in meandering belt with extreme learning machine driven multiple seismic attributes fusion[J]. Oil Geophysical Prospecting, 2021, 56(6): 1340–1350, 1200–1201.
- [22] 周恒平, 牛志刚. 基于极限学习机的驾驶员制动意图识别[J]. 汽车技术, 2021(11): 30–34.
- ZHOU Hengping, NIU Zhigang. Recognition of driver's braking intention based on extreme learning machine[J]. Automobile Technology, 2021(11): 30–34.
- [23] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势[J]. 计算机学报, 2019, 42(7): 1640–1670.
- XU Rui, LIANG Xun, QI Jinshan, et al. Advances and trends of extreme learning machines[J]. Chinese Journal of Computers, 2019, 42(7): 1640–1670.
- [24] 张莲, 贾浩, 张尚德, 等. 基于改进极限学习机的高压断路器故障诊断[J]. 电工电气, 2022(10): 50–56.
- ZHANG Lian, JIA Hao, ZHANG Shangde, et al. Fault diagnosis of high voltage circuit breaker based on improved extreme learning machine[J]. Electrotechnics Electric, 2022(10): 50–56.
- [25] 李昕, 赵二峰, 王嘉毅, 基于 PCA-SSA-ELM 的混凝土坝变形预测模型[J]. 水力发电, 2022, 48(12): 62–66, 91.
- LI Xin, ZHAO Erfeng, WANG Jiayi, Prediction model of concrete dam deformation based on PCA-SSA-ELM[J]. Water Power, 2022, 48(12): 62–66, 91.
- [26] 朱孝驰, 张席, 沙云东, 等. 基于灰狼算法优化极限学习机的中介轴承故障诊断方法[J/OL]. 推进技术: 1–12[2022–11–23]. DOI: 10.13675/j.cnki.tjjs.2205105.
- LUAN Xiaochi, ZHANG Xi, SHA Yundong, et al. Method on intermediate bearing fault diagnosis based on extreme learning machine optimized by grey wolf optimization [J/OL]. Journal of Propulsion Technology: 1–12[2022–11–23]. DOI: 10.13675/j.cnki.tjjs.2205105.
- [27] TROJOVSKÝ Pavel, DEHGHANI Mohammad. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications[J]. Sensors, 2022, 22(3): 4–10.
- [28] 马骥, 马忠彧, 马宏锋. 基于极限学习机的风电输出功率预测[J]. 计算机与数字工程, 2021, 49(7): 1465–1468.
- MA Ji, MA Zhongyu, MA Hongfeng. Wind power output prediction based on extreme learning machine[J]. Computer & Digital Engineering, 2021, 49(7): 1465–1468.
- [29] 周捷, 王萍, 毛倩, 等. 基于极限学习机的乳房形态识别[J]. 西安工程大学学报, 2022, 36(1): 17–24.
- ZHOU Jie, WANG Ping, MA Qian, et al. Breast shape recognition based on extreme learning machine[J]. Journal of Xi'an Polytechnic University, 2022, 36(1): 17–24.
- [30] 陈芊澍, 文晓涛, 何健, 等. 基于极限学习机的裂缝带预测[J]. 石油物探, 2021, 60(1): 149–156, 174.
- CHEN Qianshu, WEN Xiaotao, HE Jian, et al. Prediction of a fracture zone based using an extreme learning machine[J]. Geophysical Prospecting for Petroleum, 2021, 60(1): 149–156,174.
- [31] 郭曼, 李志勇, 何达喜. 透射槽波勘探在矿井小型构造探测中的应用研究[J]. 能源与环保, 2020, 42(12): 89–94.
- GUO Man, LI Zhiyong, HE Daxi. Research on application of transmission channel wave exploration in mine small-scale structure exploration[J]. China Energy and Environmental Protection, 2020, 42(12): 89–94.