

基于黏菌优化极限学习机的煤矸石多光谱识别

周孟然¹, 凌 胜², 来文豪¹, 卞 凯¹, 朱梓伟¹, 沈汝涵²

1. 安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

2. 安徽理工大学 力学与光电物理学院, 安徽 淮南 232001

摘 要:煤和矸石的精准辨识是煤矸分选和煤炭清洁高效利用的重要前提, 针对传统方法存在效率低、需加装辐射隔离以及受环境干扰等诸多不足, 提出了基于多光谱图像特性和光谱特性来识别煤和矸石, 构建黏菌优化极限学习机(Slime Mold Algorithm Extreme Learning Machine, SMA-ELM)的分类模型。搭建多光谱数据采集系统完成煤与矸石的光谱图像采集, 通过 LBP 对光谱图像进行特征提取并使用 PCA 主成分分析对提取后的特征向量降维, 输入 SMA-ELM 分类模型、蚁狮优化极限学习机(Antlion Algorithm Optimized Extreme Learning Machine, ALO-ELM)分类模型、鲸鱼优化极限学习机(Whale Algorithm Optimized Extreme Learning Machine, WOA-ELM)分类模型进行对比, 重点研究不同波长响应下煤和矸石的辨识精度来筛选最佳波长, 通过多评价指标对优化后的最优波段进行比较。实验结果表明, SMA-ELM 分类效果最佳, 第 6 波段为最优波段, SMA-ELM 在该波段的平均识别准确率为 95.08%, 煤和矸石的识别 F1-Score 分别为 96.47%和 92.68%, 用时 10.6 s。所提出的方法可以实现煤和矸石的精准识别, 这对煤和矸石的智能分选具有重要的研究意义。

关键词:多光谱成像技术; 黏菌优化; 极限学习机分类; 波段选择; LBP 算法

中图分类号:TD94; TP391 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2023.0005.001

Multi-spectral Identification of Coal and Gangue Based on Slime Mold Algorithm Extreme Learning Machine

ZHOU Mengran¹, LING Sheng², LAI Wenhao¹, BIAN Kai¹, ZHU Ziwei¹, SHEN Ruhan²

1. School of Electrical and Information Engineering, Anhui University of Science & Technology, Anhui Huainan 232001, China

2. School of Mechanics and Optoelectronic Physics, Anhui University of Science & Technology, Anhui Huainan 232001, China

Abstract: Accurate identification of coal and gangue is an important prerequisite for coal and gangue sorting and clean and efficient utilization of coal. In view of the many shortcomings of traditional methods such as low efficiency, the need to install radiation isolation, and environmental interference, a classification model called Slime Mold Algorithm Extreme Learning Machine (SMA-ELM) was proposed to recognize coal and gangue based on multi-spectral image characteristics and spectral characteristics. A multi-spectral data acquisition system was built to complete the acquisition of spectral images of coal and gangue. The extracted feature vectors were downsampled by LBP and PCA principal component analysis,

收稿日期:2022-03-05 **修回日期:**2022-05-18 **文章编号:**1672-058X(2023)05-0001-07

基金项目:国家重点研发计划重点专项子课题(2018YFC0604503);安徽省科技重大专项项目(201903A07020013);安徽省能源互联网联合基金重大项目(2008085UD06);煤炭安全精准开采国家地方联合工程研究中心开放基金资助(EC2021006)。

作者简介:周孟然(1965—),男,安徽淮南人,博士,教授,从事矿山机电系统监测、光电信息处理和煤矿安全监测监控研究。

通讯作者:凌胜(1997—),男,安徽安庆人,硕士研究生,从事图像处理研究。Email:ling7712007@163.com。

引用格式:周孟然,凌胜,来文豪,等.基于黏菌优化极限学习机的煤矸石多光谱识别[J].重庆工商大学学报(自然科学版),2023,40(5):1—7.

ZHOU Mengran, LING Sheng, LAI Wenhao, et al. Multi-spectral identification of coal and gangue based on slime mold algorithm extreme learning machine[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(5): 1—7.

and input to SMA-ELM classification model, Antlion Algorithm Optimized Extreme Learning Machine (ALO-ELM) classification model, and Whale Algorithm Optimized Extreme Learning Machine (WOA-ELM) classification model for comparison. It focused on the recognition accuracy of coal and gangue under different wavelength responses to screen the best wavelength, and the optimized optimal wavelengths were compared by multiple evaluation indexes. The experimental results showed that SMA-ELM had the best classification effect and the 6th band was the optimal band, the average recognition accuracy of SMA-ELM in this band was 95.08%, and the recognition F1-Scores of coal and gangue were 96.47% and 92.68%, respectively, with a time of 10.6 s. The proposed method can achieve the accurate recognition of coal and gangue, which has important research significance for the intelligent separation of coal and gangue.

Keywords: multi-spectral imaging technology; slime molds optimization; extreme learning machine classification; bands selection; LBP algorithm

1 引言

在人类社会的发展过程中,煤炭起到了非常重要的作用。作为世界煤炭生产和消费第一大国,2019 年中国煤炭生产量占世界总产量的 47.3% 为 27.5 亿 t; 煤炭消费量占全球总消费量的 51.7% 为 28 亿 t^[1]。煤炭开采收集的过程中矸石会不可避免地混入其中,混入矸石的煤燃烧效率会降低,并且燃烧会带有污染^[2]。因此在煤炭开采过程中,做到煤与矸石的准确辨识可以为后面的煤矸分选及煤炭高效利用打下基础。

传统的煤矸分选方法有三种^[3]。一为人工分选方法,此方法不仅速度缓慢,而且对体力消耗大、分类准确率往往偏低。另外两种方法,分别是湿选法和干选法。湿选法^[4]效率一般,而且选矸过程消耗水资源过多、设备保养维护工作量大。干选法^[5-6]利用激光和射线等,虽然操作简单,但是会对操作人员的身体造成很大的不可逆伤害。

多光谱成像技术就是把入射的光信号(全波段或宽波段),分成若干个窄波段的光束,然后在相应的探测器上分别成像,最后获得不同光谱波段对应的图像。在土壤成分含量检测的应用中,多光谱成像技术可以用于水分检测^[7]、有机质检测、氮磷钾检测和其他成分检测,但土壤颗粒大小和重金属等会影响检测效果。在食品领域的应用中,张华峰等^[8]通过采集冻融猪肉的光谱图像,经过经典判别分析(CDA)图像切割,提取感兴趣区域的光谱信息,运用支持向量机(SVM)和神经网络建立识别模型。但区域分割对检测精度起决定作用,检测精度依赖人的主观选择。周孟然等^[9]通过采集苹果的多光谱数据,采用完全局部二值模式算法提取特征向量,结合支持向量机分类模型对有损苹果和无损苹果实现精准识别。对于煤矸石识别,Hu 等^[10]

用多光谱成像技术对煤和矸石完成数据采集,利用特征提取结合分类器模型,表明了多光谱成像技术用于煤和矸石识别的可行性。

局部二值模式(LBP)算法是 1994 年由 Ojala 等^[11]提出的。由于 LBP 简单的计算方式、提取效果较好,因此 LBP 多用于对人脸进行识别或对纹理进行分析^[12]。极限学习机(Extreme Learning Machine, ELM)是 2006 年由 Huang^[13]提出的一种新型学习算法。由于 ELM 训练速度快、分类精度高和泛化性能好,因此得到了广泛的应用^[14]。黏菌算法(Slime Molds Algorithm, SMA)是 Li 等^[15]于 2020 年提出,算法的想法来源于黏菌两种行为:扩散和觅食。SMA 原理简单,通过对黏菌传播正负反馈过程进行模拟,找到食物最优路径。

本研究将多光谱成像技术应用于对煤与矸石的识别分类,并在对煤与矸石的特征提取上采用了 LBP 算法,将提取的特征向量经过 PCA 主成分分析确定主成分个数。首先将整体 25 波段光谱数据用于确定极限学习机的隐含层节点数,然后将黏菌优化极限学习机(SMA-ELM)与蚁狮算法优化极限学习机(ALO-ELM)、鲸鱼算法优化极限学习机(WOA-ELM)对比 25 波段上的识别准确率,最后通过多评价指标对优化后的最优波段进行比较。

2 算法介绍及实验方法

2.1 极限学习机的原理

ELM 是一种能够快速学习的新型算法。在训练过程中,随机初始化输入权值和隐含层偏置矩阵,最后通过计算广义逆矩阵,求得最优解。和传统学习算法比较,ELM 由于克服参数需要多次迭代的特点,故 ELM 在学习速度和泛化能力表现更好。

对于 N 任意不同的样本 $(\mathbf{x}_i, \mathbf{t}_i)$, 其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in R^n, \mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ 。那么标准的 L

个隐含层神经元的单隐层前馈神经网络如式(1):

$$\sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = t_j$$

$$j=1, 2, \dots, L; b_i, \beta_i \in R; w_i \in R^n \quad (1)$$

式(1)中: $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T \in R^n$ 表示输入权值; β_i 为输出权值; b_i 为隐含层偏置。

ELM 目标函数 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$, 具体如下式(2):

$$\mathbf{H}(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_L) =$$

$$\begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (2)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_L^T \end{bmatrix}_{L \times m}$$

$\mathbf{H}$ 是神经网络的隐含层输出的矩阵; $\mathbf{K}$ 是期望输出。

使用最小二乘法求解最小的输出权值 $\hat{\boldsymbol{\beta}}$, 用 $\mathbf{H}^-$ 表示 $\mathbf{H}$ 广义逆, 即求解公式为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^- \mathbf{K} \quad (3)$$

2.2 黏菌算法的原理

黏菌算法由 Li 等于 2020 年提出, 根据黏菌多头绒毛菌在觅食过程中的动作行为和整体变化情况来建立数学模型。详细的数学模型如下:

(1) 寻找食物。黏菌可以依靠空气中的气味来接近食物, 具体用式(4)表示为

$$\vec{X}(q+1) = \begin{cases} \vec{X}_b(q) + vb \cdot (\vec{W} \cdot \vec{X}_A(q) - \vec{X}_B(q)), \gamma < p \\ \vec{vc} \cdot \vec{X}(q), \gamma \geq p \end{cases} \quad (4)$$

式(4)中: $\vec{vb}$ 的范围是 $[-a, a]$; $\vec{vc}$ 的范围是 $[0, 1]$ 并呈线性递减; q 为当前迭代次数; $\vec{X}_b$ 为当前迭代中找到的最高气味浓度对应的个体位置; $\vec{X}$ 为黏菌的位置; $\vec{X}_A$ 和 $\vec{X}_B$ 为随机选取的两个黏菌的位置; $\vec{W}$ 为权重。其中 $p, a, \vec{W}$ 的值由式(5)、式(6)、式(7)计算如下:

$$p = \tanh |S(i) - DF|, i=1, 2, \dots, n \quad (5)$$

其中: $S(i)$ 表示为每个黏菌的适应度; DF 为迭代过程中最佳适应度。

$$a = \operatorname{arctanh} \left(- \left(\frac{q}{\max_t} \right) + 1 \right) \quad (6)$$

$$\vec{W}(\operatorname{smellIndex}(i)) = \begin{cases} 1 + \gamma \cdot \log \left(\frac{F_b - S(i)}{F_b - F_w} + 1 \right), \text{condition} \\ 1 - \gamma \cdot \log \left(\frac{F_b - S(i)}{F_b - F_w} + 1 \right), \text{其他} \end{cases} \quad (7)$$

$$\operatorname{smellIndex} = \operatorname{sort}(S)$$

其中: condition 表示适应度值能够排在种群数前面一半的个体; r 为在 $[0, 1]$ 上的随机数; $\max_q$ 为最大迭代次数; F_b 和 F_w 为当前迭代中的最优和最差适应度值; $\operatorname{smellIndex}$ 为排序后的适应度值序列。

(2) 搜索食物时, 黏菌会受食物浓度在体内产生一种信号。黏菌的位置更新主要是通过模拟静脉组织正负反馈来实现, 如式(8):

$$\vec{X}^* = \begin{cases} \operatorname{rand} \cdot (B_u - B_l) + B_l, \operatorname{rand} < z \\ \vec{X}_b(q) + vb \cdot (\vec{W} \cdot \vec{X}_A(q) - \vec{X}_B(q)), \gamma < p \\ \vec{vc} \cdot \vec{X}(q), \gamma \geq p \end{cases} \quad (8)$$

其中: $\vec{X}^*$ 为更新后的位置; B_l, B_u 分别为搜索空间的下界和上界; rand 为 $[0, 1]$ 之间的随机值。

2.3 黏菌优化极限学习机

为改进极限学习机, 黏菌优化算法需要对输入权值 $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ 以及隐含层偏置 b_i 进行优化。

黏菌优化算法对极限学习机参数进行优化的实验步骤描述如下:

步骤一 按照比例, 将数据分为用于训练的数据集与用于测试的数据集。

步骤二 设置 SMA-ELM 模型参数, 分别为最大迭代次数、种群的规模大小、ELM 隐含层节点数。

步骤三 对种群进行初始化操作, 将待优化的 ELM 输入权值 w 的寻优范围设置为 $[-1, 1]$, 隐含层偏置 b 的寻优范围设置为 $[0, 1]$ 。

步骤四 计算 SMA-ELM 模型中每个黏菌的适应度值。这里适应度值表示数据集分类准确率, 并且按照适应度值从大到小排序。

步骤五 根据式(7)更新黏菌位置。即如果存在黏菌种群最优个体的适应度值优于当前黏菌适应度值, 则更新位置。

步骤六 判断 SMA 算法是否达到最大迭代次数。如果是, 就输出 ELM 的最佳优化参数 w 与 b , 否则跳回步骤四, 继续循环迭代, 直至满足停止条件。

2.4 识别模型的评价指标

准确率(A)表示总体识别的正确率。考虑样本不均衡,并不能只通过准确率(A)来衡量识别效果。故在对煤和矸石的识别效果除了通过准确率(A)这个指标进行判断,引入精准率(P)、召回率(R)、 $F1$ -Score 评价指标,能够对识别效果进行更加详细的分析。首先对混淆矩阵中的参数定义,定义如下表 1。

表 1 混淆矩阵的定义

Table 1 Definition of confusion matrix

混淆矩阵		实际类别	
		正 类 (Positive)	负 类 (Negative)
预测类别	真	正类判别为真(T_p)	负类判别为真(F_p)
	假	正类判别为假(F_N)	负类判别为假(T_N)

介绍完混淆矩阵,准确率(A)定义如式(9)、精准率(P)如式(10)、召回率(R)如式(11)、 $F1$ -Score 定义如式(12)。准确率(A)反映的是煤和矸石总体的识别程度。精准率(P)反映的是所有被预测为真的样本中实际为正的样本的概率。如果将煤视为正类,就是求所有被预测为煤的样本中实际为煤的样本的概率。召回率(R)反映的是实际为正的样本中被预测为真的样本的概率。如果将煤视为正类,就是求实际为煤的样本中被预测为煤的样本的概率。由此可知,精准率(P)与召回率(R)是“对立”的关系。如果精确率高,则召回率就低;如果召回率高,则通常会影响精确率。对于煤和矸石二分类而言,希望精准率(P)和召回率(R)都能越高越好,两者越高表示煤和矸石识别效果越好而且稳定。 $F1$ -Score 由精准率(P)和召回率(R)求解而得,能够综合表示两者的数值对应的识别效果。 $F1$ -Score 越高,识别效果越好,越精准。故选择煤和矸石识别的 $F1$ -Score 作为后续最优波段主要判别依据。

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (9)$$

$$P = \frac{T_p}{T_p + F_p} \quad (10)$$

$$R = \frac{T_p}{T_p + F_N} \quad (11)$$

$$F1\text{-Score} = \frac{(\alpha^2 + 1) \times P \times R}{\alpha^2 (P + R)} \quad (12)$$

当 A 的常用表达形式中 α 取值为 1,即可得式(13):

$$F1\text{-Score} = \frac{2 \times P \times R}{(P + R)} \quad (13)$$

2.5 材料设备与实验方法

实验所用的煤和矸石均采集于淮南矿区。实验设备包括 LS-LHA 光源、MQ022HG-IM-SM5X5-NIR 多光谱成像仪、675 nm 高通滤光片与 975 nm 低通滤光片、神舟战神笔记本等。




图 1 多光谱数据采集系统

Fig. 1 System of multi-spectral data acquisition

数据采集时,电脑端通过上位机软件 HSIImager 控制多光谱成像仪,将多光谱成像仪的焦距设置为 2.8 mm,曝光时间设为 20.006 ms。打开光源,采集系统在 675~975 nm 采集煤与矸石位于镜头正下方的 25 波段光谱图像,每个光谱图像的分辨率为 409×216 像素大小。25 波段对应的光谱波长分别为 891、900、882、872、959、798、811、786、773、682、748、762、736、722、697、932、939、924、914、954、851、863、841、829 和 946 nm。

将采集的光谱图像首先经过 LBP 特征提取,通过 PCA 主成分分析(选取贡献率 95% 以上的主成分),选择 ELM 分类模型进行分类(对 ELM 隐含层节点数进行选取),最后通过三种优化算法优化 ELM 分类模型(黏菌算法、鲸鱼算法、蚁狮算法)找到分类最好的波段。本研究模型均在 MATLAB2016b 中运行,硬件环境为 Inter Core i5-8300H 2.30GHZ CPU。

3 结果与分析

本次研究采集了煤块 212 块,矸石 106 块,一共 318 块。每一块采集的光谱数据含有 25 张对应波段下的光谱图像。其中选取 255 块(煤 170 块,矸石 85 块)为训练数据,63 块(煤 42 块,矸石 21 块)为测试数据。模型训练中,煤对应数字 1,矸石对应数字 2。一块煤块采集的 25 波段光谱图像如图 2 所示。



图 2 煤块样本的 25 波段光谱图像

Fig. 2 25 bands spectral image of coal sample

3.1 特征提取的结果

提取多光谱图像的 LBP 特征,得到的 LBP 特征向量维数为 59。LBP 图谱如图 3(a)、图 3(b)所示。可以看到,煤与矸石的图谱纹理差异较大,煤的边缘纹理比矸石更加地突出。




图 3 LBP 图谱 (a) 煤

Fig. 3 LBP map (a) coal




图 3 LBP 图谱 (b) 矸石

Fig. 3 LBP map (b) gangue

3.2 ELM 隐含层节点数的选择

LBP 处理后得到的特征向量进行 PCA 主成分分析,设定累计贡献率为 95%以上,得到主成分个数为 25。进行 ELM 分类,选择 Sigmoid 作为 ELM 核函数,隐含层节点数选择从 1~50,循环次数设置为 20 次。将测试集 的识别准确率作为隐含层节点数选取的标准。

从图 4 可知,识别准确率在隐含层节点数 1~4 之间随着节点数的增加呈现下降趋势;在隐含层节点数 4~28 之间,识别准确率大部分呈现坡度上升趋势;在隐含层节点数 28~50 之间,识别准确率随着节点数的增加趋于平缓。在隐含层节点数为 4 时,煤与矸石的识别准确率达到最低为 64.74%。在隐含层节点数为 48 时,煤与矸石的识别准确率达到最高为 69.04%。故接下来的 ELM 优化过程中,隐含层节点数选为 48,并

保持不变。




图 4 ELM 隐含层节点数与识别准确率的关系图

Fig. 4 The relationship between node number and recognition accuracy of ELM hidden layer

3.3 三种算法优化 ELM 的比较

为了验证 SMA-ELM 模型用于煤矸石的识别精度,本文将 SMA-ELM 与蚁狮算法 (ALO)、鲸鱼算法 (WOA) 这两种算法优化的极限学习机识别结果进行对比。ELM 隐含层节点数为 48。ELM 输入权值 w 的寻优范围为 $(-1,1)$,隐含层偏置 b 的寻优范围为 $(0,1)$ 。模型训练中,煤对应数字 1,矸石对应数字 2。为了保证条件统一,三种优化算法种群数量设置为 30,迭代次数为 70 次。循环次数设为 10 次,分别记录 25 个波段下的平均识别准确率。

从图 5 可知,三种算法优化 ELM 在平均识别准确率上都有很大提升。SMA-ELM 整体波段大部分的平均识别准确率比 ALO-ELM 和 WOA-ELM 高,其中在波段 6、14、23 平均识别准确率分别达到 95.08%、94.60%、94.92%。ALO-ELM 在波段 6 达到最高 91.75% 的平均识别准确率,WOA-ELM 在波段 3 达到最高平均识别准确率为 92.86%。基于此,选择三种优化 ELM 分类模型最优波段最后一次循环下的测试集样本进行对比。




图 5 三种优化算法 25 波段下的平均识别准确率

Fig. 5 Average recognition accuracy of the three optimization algorithms at 25 bands

图 6 提供了测试集样本的 SMA-ELM 分类模型第 6 波段下的分类效果(标签 1 为煤,标签 2 为矸石)。可

以发现,63 个测试集样本中有 3 个分类不正确(分别为煤识别错误 1 块,矽石识别错误 2 块)。




图 6 第 6 波段黏菌测试集的实际分类和预测分类图

Fig. 6 Actual and predicted classification diagram of band 6 slime molds test set

图 7 提供了测试集样本的 ALO-ELM 分类模型第 6 波段下的分类效果(标签 1 为煤,标签 2 为矽石)。可以发现,63 个测试集样本中有 5 个分类不正确(分别为煤识别错误 3 块,矽石识别错误 2 块)。




图 7 第 6 波段蚁狮测试集的实际分类和预测分类图

Fig. 7 Actual and predicted classification diagram of band 6 antlion test set

图 8 提供了测试集样本的 WOA-ELM 分类模型第 3 波段下的分类效果(标签 1 为煤,标签 2 为矽石)。可以发现,63 个测试集样本中有 5 个分类不正确(分别为煤识别错误 2 块,矽石识别错误 3 块)。




图 8 第 3 波段鲸鱼测试集的实际分类图和预测分类图

Fig. 8 Actual and predicted classification diagram of band 3 whale test set

上述最优波段下测试集样本的精准率(P)、召回率(R)、 $F1$ -Score、循环一次所用时间值(t)如表 2 所示。对煤来说,三种算法优化后得到的精准率、召回率、 $F1$ -Score 都在 90% 以上,其中 SMA-ELM 分类模型最优(精准率 97.62%、召回率 95.35%、 $F1$ -Score 96.47%);对矽石来说,对比三种算法优化后得到的精准率、召回率、 $F1$ -Score, SMA-ELM 分类模型最优(精准率 90.48%、召回率 95%、 $F1$ -Score 92.68%)。通过对比时间,虽然 WOA-ELM 用时 5.83 s 比 SMA-ELM 用时 10.6 s 短。但是综合考虑准确率、精准率、召回率、 $F1$ -Score、时间这些评价指标,最终的 SMA-ELM 模型用于煤矽石识别是可靠且最优的。

表 2 三种优化算法测试集样本煤与矽石的评价指标

Table 2 Evaluation indexes of coal and gangue samples tested by three optimization algorithms

优化算法	波段	类别	精准率/%	召回率/%	$F1$ -Score/%	t/s
SMA-ELM	6	煤	97.62	95.35	96.47	10.6
		矽石	90.48	95	92.68	
ALO-ELM	6	煤	92.86	95.12	93.98	46.54
		矽石	90.48	86.36	88.37	
WOA-ELM	3	煤	95.24	93.02	94.12	5.83
		矽石	85.71	90	87.80	

4 结 论

本研究探索利用多光谱图像特性和光谱特性结合黏菌优化极限学习机的分类模型来识别煤和矽石。第一步通过多光谱成像技术获取煤和矽石对应的光谱图像。第二步通过特征提取算法 LBP 提取特征向量,提取的特征向量再通过 PCA 主成分分析确定主成分个数。第三步确定 ELM 的隐含层节点数。最后输入 SMA-ELM、ALO-ELM、WOA-ELM 分类模型中,重点研究不同波长响应下煤和矽石的辨识精度来筛选最佳波长,通过多评价指标对优化后的最优波段进行比较。通过引入精准率、召回率、 $F1$ -Score、时间评价指标对最优波段下的测试集样本进行比较。最终求得 SMA-ELM 分类模型第 6 波段下煤和矽石的 $F1$ -Score 分别为 96.47%和 92.68%,用时 10.6 s,且此时第 6 波段平均识别准确率为 95.08%。但本研究仅仅是对煤与矽石的二分类进行了识别,对于煤和矽石在一起的情况

没有比较。本研究可以为多光谱成像技术和 ELM 分类对煤与矸石识别提供一定的理论依据。

参考文献(References):

- [1] 姜大霖,程浩.中长期中国煤炭消费预测和展望[J].煤炭经济研究,2020,40(7):16—21.
JIANG Da-lin, CHENG Hao. Medium and longterm China coal consumption forecast and outlook [J]. Coal Economic Research, 2020, 40(7): 16—21.
- [2] 彭皓,王宝凤,杨凤玲,等.煤矸石及煤泥燃烧过程重金属排放特性[J].洁净煤技术,2019,25(5):118—124.
PENG Hao, WANG Bao-feng, YANG Feng-ling, et al. Characteristics of heavy metal emissions from coal gangue and coal sludge combustion process [J]. Clean Coal Technology, 2019, 25(5): 118—124.
- [3] 曹现刚,李莹,王鹏,等.煤矸石识别方法研究现状与展望[J].工矿自动化,2020,46(1):38—43.
CAO Xian-gao, LI Ying, WANG Ping, et al. Research status and prospect of coal gangue identification method [J]. Industrial and Mining Automation, 2020, 46(1): 38—43.
- [4] SAHU A K, BISWAL S K, PARIDA A. Development of air dense medium fluidized bed technology for dry beneficiation of Coala review[J]. International Journal of Coal Preparation and Utilization, 2009, 4: 216—241.
- [5] ZHANG N, LIU C. Radiation characteristics of natural gamma-ray from coal and gangue for recognition in top coal caving[J]. Scientific Reports, 2018, 8(1): 190—198.
- [6] 王鹏. X射线识别煤矸选煤技术对煤质分析的要求[J].洁净煤技术,2018,24(1):59—61.
WANG Peng. X-ray identification of coal gangue beneficiation technology requirements for coal quality analysis [J]. Clean Coal Technology, 2018, 24(1): 59—61.
- [7] 李鑫星,曹闪闪,白雪冰,等.多光谱技术在土壤成分含量检测中的研究进展[J].光谱学与光谱分析,2020,40(7):2042—2047.
LI Xin-xing, CAO Shan-shan, BAI Xue-bing, et al. Research progress of multispectral techniques in soil composition content detection [J]. Spectroscopy and Spectral Analysis, 2020, 40(7): 2042—2047.
- [8] 张华锋,王武,白玉荣,等.多光谱成像无损识别冻融猪肉中危害级碎骨[J].光谱学与光谱分析,2021,41(9):2892—2897.
ZHANG Hua-feng, WANG Wu, BAI Yu-rong, et al. Non-destructive identification of hazard grade broken bones in frozen and thawed pork by multispectral imaging [J]. Spectroscopy and Spectral Analysis, 2021, 41(9): 2892—2897.
- [9] 周孟然,燕晶晶,来文豪,等.基于完全局部二值模式的多光谱法识别损伤苹果[J].食品安全质量检测学报,2021,12(23):9086—9092.
ZHOU Meng-ran, YAN Jing-jing, LAI Wen-hao, et al. Identification of damaged apples by multispectral method based on fully localized binary mode [J]. Journal of Food Safety and Quality Inspection, 2021, 12(23): 9086—9092.
- [10] HU F, ZHOU M, YAN P, et al. Multispectral imaging: a new solution for identification of coal and gangue [J]. IEEE Access, 2019, 7: 169697—169704.
- [11] OJALA T, PIETIKAINEN M, HARWOOD D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions [C]//Conference A: Computer Vision & Image Processing. Proceedings of the 12th IAPR International Conference on. IEEE, 1994, 1: 582—585.
- [12] 刘丽,谢毓湘,魏迎梅,等.局部二进模式方法综述[J].中国图象图形学报,2014,19(12):1696—1720.
LIU Li, XIE YU-xiang, WEI Ying-mei, et al. A review of local binary pattern methods [J]. Chinese Journal of Graphical Graphics, 2014, 19(12): 1696—1720.
- [13] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1—3): 489—501.
- [14] 陆思源,陆志海,王水花,等.极限学习机综述[J].测控技术,2018,37(10):3—9.
LU Si-yuan, LU Zhi-hai, WANG Shui-hua, et al. A review of extreme learning machines [J]. Measurement and Control Technology, 2018, 37(10): 3—9.
- [15] LI S, CHEN H, WANG M, et al. Slime mould algorithm: a new method for stochastic optimization [J]. Future Generation Computer Systems, 2020, 111: 300—323.