

激光与光电子学进展

激光诱导击穿光谱技术结合 PCA-PSO-SVM 对矿石分类识别

文大鹏¹, 梁西银^{1*}, 苏茂根², 杨富春², 张天辰¹, 陈瑞霖¹, 吴梦¹

¹西北师范大学物理与电子工程学院甘肃省智能信息技术与应用工程研究中心, 甘肃 兰州 730070;

²西北师范大学物理与电子工程学院甘肃省原子分子物理与功能材料重点实验室, 甘肃 兰州 730070

摘要 利用激光诱导击穿光谱(LIBS)技术结合主成分分析-粒子群优化-支持向量机(PCA-PSO-SVM)算法对 12 类矿石进行分类识别。运用 Savitzky Golay 滤波、分段特征值提取法对光谱进行平滑滤波与基线校正预处理。选取经主成分分析(PCA)降维后的前 25 个主成分作为 PSO-SVM 分类模型的输入, 得到对 12 类矿石的最佳识别准确率为 100%。分别建立主成分-线性判别分析(PCA-LDA)、主成分-粒子群优化-误差反向传播神经网络(PCA-PSO-BP)两种分类模型, 并与 PCA-PSO-SVM 模型进行对比实验, 结果表明, PCA-PSO-SVM 分类模型的识别准确度最高, 其平均识别准确率可达 99.90%。

关键词 激光光学; 激光诱导击穿光谱; 主成分分析; 粒子群优化算法; 支持向量机; 矿石分类

中图分类号 O433.4

文献标志码 A

doi: 10.3788/LOP202158.2314006

Classification of Ores Using Laser-Induced Breakdown Spectroscopy Combined with PCA-PSO-SVM

Wen Dapeng¹, Liang Xiyin^{1*}, Su Maogen², Yang Fuchun², Zhang Tianchen¹,
Chen Ruilin¹, Wu Meng¹

¹Engineering Research Center of Gansu Province for Intelligent Information Technology and Application,
College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China;

²Key Laboratory of Atomic and Molecular Physics & Functional Material of Gansu Province,
College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China

Abstract Twelve types of ores were identified using laser-induced breakdown spectroscopy combined with the principal component analysis-particle swarm optimization-support vector machine (PCA-PSO-SVM) algorithm. A Savitzky-Golay filter was used to smooth the spectrum, and the segmented eigenvalue extraction method was used to perform baseline correction on the spectrum. The first 25 principal components reduced by PCA were selected as the input to the PSO-SVM classification model, and the best recognition accuracy rate for the 12 types of ore was 100%. The PCA-PSO-SVM model was compared with two classification models, i.e., principal component-linear discriminant analysis and a PCA-particle swarm optimization-error back propagation neural network. Experimental results showed that the recognition accuracy of the PCA-PSO-SVM classification model was the highest with an average recognition accuracy rate of up to 99.90%.

收稿日期: 2021-03-04; 修回日期: 2021-04-01; 录用日期: 2021-04-09

基金项目: 甘肃省引导科技创新专项(2019zx-10)

通信作者: *silver@nwnu.edu.cn

Key words laser optics; laser-induced breakdown spectroscopy; principal component analysis; particle swarm optimization algorithm; support vector machine; ore classification

OCIS codes 140.3440; 200.4260; 300.6365

1 引言

矿产资源是经济社会发展的重要物质基础,而矿石鉴定是地质勘探中必不可少的工作。传统的鉴定方法是依靠矿石的外形与物理性质进行手标本鉴定,该方法简便易行且成本低,但鉴定的准确度较差,且对鉴定人员的专业知识要求高^[1]。随着地质勘探数字化技术的不断发展,X射线荧光光谱法(XRF)、X射线衍射分析法(XRD)、 γ 能谱法陆续被应用到矿石鉴别,但这些方法大都需要在实验室进行,且样品制作过程复杂,很难实现对矿石的快速在线识别^[2-3]。

激光诱导击穿光谱(LIBS)检测是一种原子发射光谱分析方法,具有快速实时在线检测、样品制备简单、破坏性小等优点,已被广泛应用于地质分析、食品安全、文化遗产、生物医学分析等领域^[4-7]。将LIBS技术与机器学习方法结合可实现对物质种类、等级、产地等的快速分类识别。Yang等^[2]采用LIBS技术结合主成分分析(PCA)与人工神经网络(ANN)对来自3个产出国12个品牌的铁矿石进行鉴别,该方法对铁矿石产出的识别率达到100%,对铁矿石品牌的平均识别率为99.19%。董鹏凯等^[4]采用LIBS技术结合PCA后,再分别结合误差反向传播神经网络(BPNN)和支持向量机(SVM)对人参产地进行分类识别,两种算法对人参产地的平均识别率分别达到99.08%和99.5%。Sheng等^[8]将LIBS技术分别与SVM、随机森林(RF)方法结合,对10个等级的铁矿石进行分类识别,结果表明LIBS技术结合SVM对铁矿石等级的识别率为96%,LIBS技术结合RF对铁矿石的等级识别率达到100%。

目前采用LIBS技术结合机器学习方法对矿石进行分类识别的研究还比较少。本文以公开发表的LIBS矿石数据集为实验数据集^[9],首先对矿石的LIBS光谱数据进行平滑、基线校正、归一化等预处理,通过PCA对光谱数据进行降维;然后,建立粒子群优化(PSO)的支持向量机分类模型(PCA-PSO-SVM),对矿石的LIBS光谱数据进行分类识别;最后,分别建立PCA-线性判别分析分类模型(PCA-

LDA)、PCA-粒子群优化-BP神经网络分类模型(PCA-PSO-BP),并将它们与PCA-PSO-SVM分类模型进行矿石分类识别对比实验。结果表明,LIBS技术结合PCA-PSO-SVM分类方法可对矿石进行快速且高准确度的识别。

2 PSO-SVM算法原理

2.1 PSO算法

PSO算法是一种基于种群搜索的优化算法,最早由Reynolds提出,Kennedy和Eberhart^[10]在1995年对该算法进行改进。PSO算法用粒子的速度、位置、适应度值代表粒子的特征,适应度值由适应度函数计算得到^[11]。粒子在多维搜索空间中运动,每次运动后获取个体所经历位置的最优适应度位置作为个体极值 p_{best} ,将群体中所有粒子搜索到的最优适应度位置作为群体极值 g_{best} ,通过个体极值 p_{best} 与群体极值 g_{best} 更新个体的速度与位置,不断迭代,从而在解空间中获取最优解。PSO算法更新速度与位置的方程式为^[12]

$$\mathbf{v}_k(t+1) = \omega \mathbf{v}_k(t) + c_1 \text{rand}_1 [\mathbf{p}_{best_k} - \mathbf{x}_k(t)] + c_2 \text{rand}_2 [\mathbf{g}_{best} - \mathbf{x}_k(t)], \quad (1)$$

$$\mathbf{x}_k(t+1) = \mathbf{x}_k(t) + \mathbf{v}_k(t+1), \quad (2)$$

式中: $\mathbf{x}_k = [x_{k1}, x_{k2}, \dots, x_{kn}]^T$ 为第 k 个粒子在 n 维搜索空间中的位置; $\mathbf{v}_k = [v_{k1}, v_{k2}, \dots, v_{kn}]^T$ 为第 k 个粒子的速度; \mathbf{p}_{best_k} 表示第 k 个粒子的最优位置; \mathbf{g}_{best} 表示群体中所有粒子的最优位置; c_1 与 c_2 为加速度因子; rand_1 与 rand_2 是 $[0, 1]$ 区间内两个独立的随机数^[13]; t 为当前迭代次数; ω 为惯性权重,该值较大时,全局搜索能力强,该值较小时更利于局部搜索,且该值的不合理设置容易导致算法陷入局部最优。为平衡PSO算法的全局与局部搜索能力和避免陷入局部最优,通常采用动态惯性权重,本文采取线性递减惯性权重^[14-15],即

$$\omega = \frac{(\omega_{start} - \omega_{end})(t_{max} - t)}{t_{max}} + \omega_{end}, \quad (3)$$

式中: ω_{start} 与 ω_{end} 分别为 ω 的起始值与终止值; t_{max} 为最大迭代次数。通常取 $\omega_{start} = 0.9$ 和 $\omega_{end} = 0.4$ 获得最优的搜索能力^[12]。

2.2 SVM

SVM是由 Vapnik 于 1995 年提出,是一种基于统计学习理论的机器学习方法,最初是为解决二值分类问题而设计^[16]。SVM 的构造需要设计最优分类超平面并获得其决策函数,设输入数据集为 $I = \{(\mathbf{x}_i, y_i), \mathbf{x} \in \mathbf{R}^d, y \in \mathbf{R}\} (i = 1, 2, \dots, n)$, 其中 \mathbf{x}_i 为包含 d 个特征的输入特征向量, y_i 为期望输出,即类别标签; SVM 分类器模型可表示为 $f(\mathbf{x}) = \boldsymbol{\eta}\varphi(\mathbf{x}) + b$, 其中 $\varphi(\mathbf{x})$ 为非线性函数, $\varphi(\mathbf{x})$ 将输入数据映射到高维特征空间中, $\boldsymbol{\eta}\varphi(\mathbf{x}) + b = 0$ 可表示最优分类超平面; 决策函数可表示为 $f(\mathbf{x}) = \text{sign}[\boldsymbol{\eta}\varphi(\mathbf{x}) + b]$; 由于分类器会有一定的容错率, 故通常采用软边距 SVM 分类器, 其定义式为^[17-19]

$$R(\boldsymbol{\eta}, \boldsymbol{\xi}) = \frac{1}{2} \boldsymbol{\eta}^T \boldsymbol{\eta} + C \sum_{i=1}^n \xi_i, \quad (4)$$

$$\text{s.t. } y_i(\boldsymbol{\eta}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0, \quad (5)$$

式中: $\boldsymbol{\eta}$ 为超平面斜率, 是一个 n 维向量; $\boldsymbol{\xi}$ 为松弛变量; C 为惩罚因子。采用拉格朗日乘子法求解优化

可以得到最优分类决策函数^[18]

$$f(\mathbf{x}) = \text{sign} \left[\sum_{i=1}^n y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b \right], \quad (6)$$

式中: α_i 为拉格朗日乘子, 其取值范围为 $0 \leq \alpha_i \leq C$; $K(\mathbf{x}_i, \mathbf{x})$ 为核函数。本文采用径向基函数作为核函数, 该函数可表示为^[20-21]

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2), \gamma > 0. \quad (7)$$

2.3 PSO 优化 SVM 算法

本文的 SVM 算法采用径向基函数作为核函数, 该 SVM 分类器的性能主要受惩罚因子 C 与参数 γ 的影响。太大的 C 将导致模型在训练集上的分类准确率较高, 在测试集上的分类准确率较低, 太小的 C 将导致模型在训练集与测试集上的分类准确率都较低; 参数 γ 太大会导致模型输出过拟合, 太小则会导致欠拟合。为了得到合适的惩罚因子 C 与参数 γ , 本实验采用 PSO 算法对这两个参数进行寻优, 从而到达优化 SVM 分类器的目的。PSO 优化 SVM 算法的流程如图 1 所示。

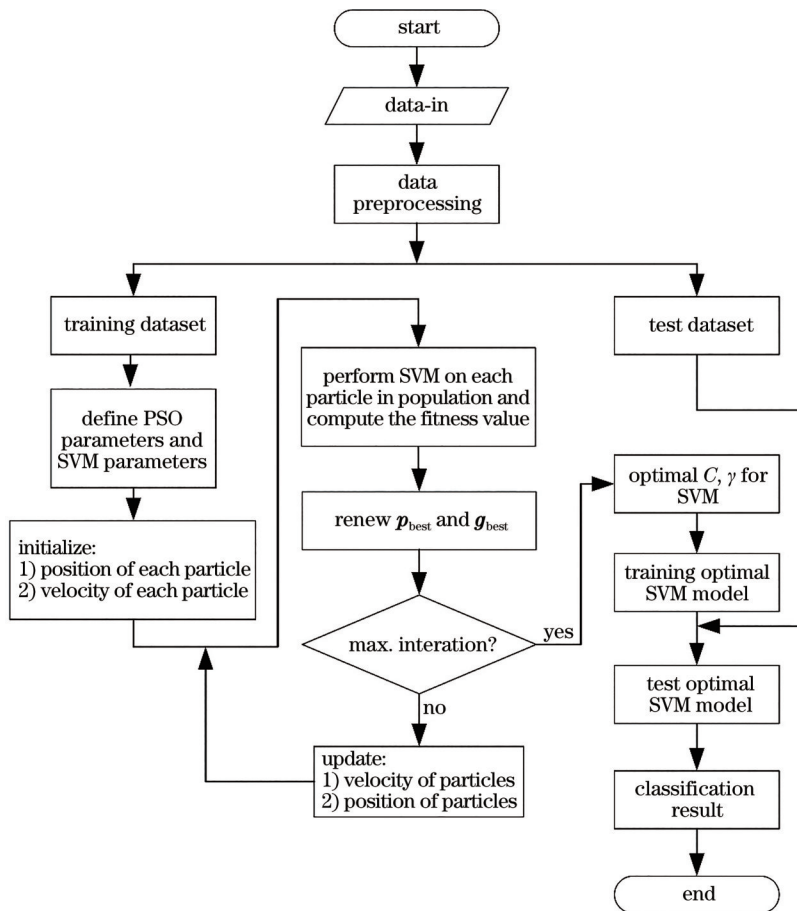


图 1 PSO-SVM 分类模型流程

Fig. 1 Flow of PSO-SVM classification model

3 实验数据获取与预处理

3.1 矿石数据集的获取

本实验的 LIBS 矿石数据集来源于 Képeš 等^[9]提供的 LIBS 基准分类数据集,该数据集由 138 个样品的 LIBS 光谱组成,这些样品属于 12 个矿石类别,这 12 类矿石的信息如表 1 所示。本实验从该数据

集的每个类别中随机取出 100 条光谱对应的数据,组成包含 12 个矿石类别、共 1200 条光谱的实验数据集。

图 2 为 12 类矿石的 LIBS 全谱图,可以看到 12 类矿石的光谱形貌相似,主要元素的强度不同,但难以从光谱图直接区分这 12 类矿石,需要对光谱数据作进一步处理,才能达到光谱识别的目的。

表 1 数据集中的矿石类别信息

Table 1 Ore category information in the dataset

Ore category label	Ore name	Ore category label	Ore name	Ore category label	Ore name
Ore 1	U ore	Ore 5	Au-Cu ore	Ore 9	Hematite ore
Ore 2	Zn-Pb-Ag sulfide ore	Ore 6	Mn ore	Ore 10	Anomalous ferruginous ore
Ore 3	Ni-Cu ore	Ore 7	Gold oxide ore	Ore 11	Silver copper gold ore
Ore 4	Sn ore	Ore 8	Zinc sulfide ore	Ore 12	Skarn tungsten magnetite ore




图 2 12 类矿石样品的 LIBS 全谱图

Fig. 2 LIBS spectra of 12 types of ore samples

3.2 数据预处理

由于不同波长对应的强度值相差较大,且 LIBS 光谱测量存在连续背景与随机误差,故需要对测量的光谱数据进行归一化与平滑、基线校正等预处理,以提高模型分类识别的准确率。以 U ore 的任一组光谱数据为例,首先将光谱强度值中小于 0 的异常值全部用 0 替换,并采用 Savitzky Golay 滤波对光谱数据进行平滑滤波处理;然后对光谱数据进行

基线校正,本实验采用分段特征值提取法进行基线校正,其主要过程如下^[5-7]。

1) 将光谱数据平均分为 N 个数据点群,即

$$N = \frac{\lambda_{wl}}{N_{num}}, \quad (8)$$

式中: λ_{wl} 为光谱数据的波长范围; N_{num} 为每个数据点群的像素点数量。

2) 分段求取特征值点,即每个数据点群中光谱

强度的最小值 I_{\min} :

$$I_{\min} = \min\{A(\alpha_j)\}, j = 1, 2, 3, \dots, N. \quad (9)$$

3) 基线校正, 将每个数据点群的光谱强度值减去对应点群的特征值点, 并拼接 N 个数据点群, 得到基线校正后的光谱数据。

4) 将该组光谱数据归一化到 $[0, 1]$, 归一化的公式为

$$y = \frac{y - y_{\min}}{y_{\max} - y_{\min}}, \quad (10)$$

式中: y 为该组光谱在各个波长的强度值; y_{\min} 为该组光谱数据强度值中的最小值; y_{\max} 为该组光谱数据强度值中的最大值。

图 3(a) 为 U ore 的一组原始光谱图, 图 3(b) 为预处理后的光谱图。




图 3 U ore 的 LIBS 光谱。(a) 原始光谱; (b) 预处理后的光谱

Fig. 3 LIBS spectra of U ore. (a) Original spectrum; (b) spectrum after preprocessing

4 结果与分析

4.1 PCA

PCA 是一种广泛使用的统计方法, 可实现数据压缩与特征提取。本实验使用的数据集中每条光谱包含 40002 个波长点, 若将全谱的强度值作为分

类模型的输入数据, 将出现输入维度高、训练时间长、模型难以收敛等问题, 故本实验将预处理后得到的 1200×40002 光谱矩阵作为 PCA 的输入, 从而降低分类模型的输入维度。

图 4(a) 所示为经过预处理的数据在 PCA 处理后的前 10 个主成分得分与累计得分, 左纵轴表示各

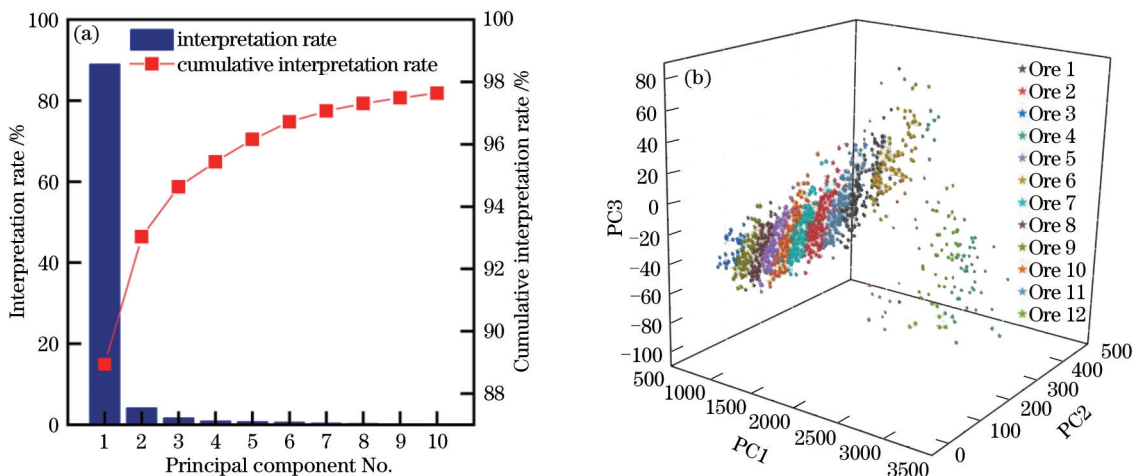


图 4 12 类矿石 LIBS 数据的 PCA 分析结果。(a) 各主成分得分和主成分累计得分; (b) 前 3 个主成分的三维散点图

Fig. 4 PCA analysis results of LIBS data for 12 types of ores. (a) Each principal component score and the cumulative score of principal components; (b) three-dimensional scatter plot of the first three principal components

个主成分的解释率,右纵轴表示主成分的累计解释率。可以看到,前 10 个主成分的累计得分达到 97.5%,可以代表矿石光谱的主要信息。图 4(b)为预处理后的矿石数据经过 PCA 降维后,对前 3 个主成分通过聚类分析得到的三维散点图,每个散点代表一个样本。可以看出,样本的聚类效果较好,同类样本呈区域性聚集,达到了明显的区域划分效果,但不同类样本的间隔较小,Ore 11 与 Ore 12 样本的分布较为稀疏,且个别样本与其他样本混杂在一起,因此需要借助其他分类算法对经过预处理和 PCA 降维的矿石数据作进一步处理。

4.2 PCA-PSO-SVM 对 12 类矿石的分类识别

本实验将经过 PCA 降维的不同数量的主成分作为 PSO-SVM 分类模型的输入,12 类矿石中每类矿石包含 100 组 LIBS 光谱数据,共 1200 组 LIBS 光谱数据。从每类矿石的 100 组光谱数据中随机取 60 组光谱数据用于训练,即训练集包含 720 组光谱数据;每类样本剩余的 40 组光谱数据用于测试,即测试集包含 480 组光谱数据。将分类准确率 (ACC; R_{Acc}) 作为分类模型的性能评价指标,其定义为

$$R_{\text{Acc}} = \frac{\sum_{i=1}^n T_i}{\left(\sum_{i=1}^n T_i + \sum_{i=1}^n F_i \right)}, \quad (11)$$

式中: T_i 表示第 i 类矿石样本中正确分类的样本数量; F_i 表示第 i 类矿石样本中错误分类的样本数量; n 表示矿石的类别数。

实验中的 SVM 算法基于台湾大学林智仁等提供的 libsvm 3.1 软件库实现。将分类模型的性能评价指标作为 PSO 的适应度函数,即 PSO 的目标函数,其定义如(11)式所示; PSO 的关键影响参数——惯性权重 ω 采用线性递减惯性权重,其定义见(3)式,惯性权重 ω 的取值范围为 $0.4 \leq \omega \leq 0.9$; 实验中将加速度因子、粒子群规模与最大迭代次数作为 PSO 寻优 SVM 分类模型的参数,并对比寻优得到的对应 SVM 模型分类准确率与分类时间,选定加速度因子 c_1 与 c_2 分别为 0.6 与 0.7, 粒子群规模为 10, 最大迭代次数为 20; 将 SVM 中惩罚因子 C 的搜索范围设置为 $0.01 < C < 10000$, 参数 γ 的搜索范围设置为 $0.001 < \gamma < 100$ 。

表 2 所示为将不同数量的主成分作为 PSO-SVM 分类模型的输入变量时得到的测试集分类识别结果,其中对同一种输入变量的数量重复进行 10 次分类识别实验,取 10 次实验识别准确率的平均

表 2 不同输入变量对应的 PSO-SVM 识别结果
Table 2 PSO-SVM recognition results with different input variables

Numbers of variables	Cumulative interpretation rate / %	Average accuracy rate / %
3	94.63	41.46
5	96.16	76.88
10	97.64	98.54
15	98.03	99.79
25	98.23	99.92
50	98.47	99.77

值作为该种变量数量的识别准确率。从表 2 可以看到:随着输入变量的主成分数量增加,PSO-SVM 模型的识别准确率不断提高,当主成分数量为 25 时,PSO-SVM 模型的平均准确率可达 99.92%;但是当主成分数量过大时,会导致模型的识别准确率有所下降。

通过以上实验对比分析,本实验选定矿石光谱数据经 PCA 降维后的前 25 个主成分作为模型的输入来训练 PSO-SVM 模型,对测试集进行分类识别的结果如图 5 所示。图 5(a)所示为 PSO 寻优的适应度曲线,其中纵坐标的适应度为十折交叉验证的平均识别准确率,PSO 寻得的 SVM 最优参数分别为 $C = 1891.93$ 、 $\gamma = 0.001$ 。从图 5(a)可以看到,在第 2 次迭代后,最佳适应度达到 100%,即 PSO-SVM 模型对训练集的交叉验证识别准确率达到 100%,模型收敛速度非常快,达到了快速优化 SVM 模型参数的目的。图 5(b)所示为该分类模型对测试集的最优分类识别结果,可以看到所构建的 PSO-SVM 模型对 12 类矿石的识别准确率可以达到 100%。

为了验证 PCA-PSO-SVM 分类模型对矿石识别的有效性,将 PCA-PSO-SVM 与其他分类算法的识别结果进行比较。本实验分别建立 PCA-LDA 分类模型、PCA-PSO-BP 分类模型,并对建立的模型进行参数优化调整。其中,PCA-PSO-BP 分类模型中 BP 神经网络的输入层神经元数为 25,隐含层神经元数为 15,输出层的神经元数为 12,隐含层的激励函数为 tansig 函数,输出层的激励函数为 purelin 函数,学习率为 0.1,网络训练的最大训练次数为 2000,网络训练目标误差为 0.01。采用 PSO 对 BP 神经网络中神经元间的权值与阈值进行优化,PSO 的参数取值如下:加速度因子 c_1 与 c_2 分别为 0.6 与 0.7,粒子群规模为 50,最大迭代次数为 80,线性递

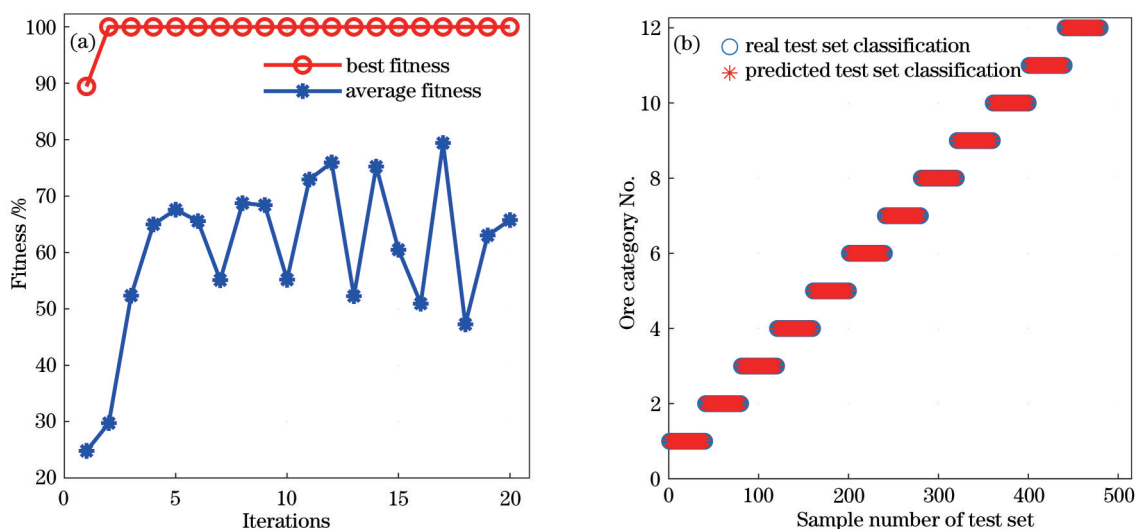


图 5 PCA-PSO-SVM 对 12 类矿石的识别结果。(a) PSO 寻优结果; (b) PCA-PSO-SVM 识别结果
Fig. 5 PCA-PSO-SVM recognition results on 12 types of ores. (a) PSO optimizing results; (b) PCA-PSO-SVM recognition results

减惯性权重的取值范围为 $0.4 \leq \omega \leq 0.9$ 。使用这 3 种模型分别对预处理后的矿石数据进行 50 次独立的识别实验,并记录每次实验的误差识别数量。将 50 次实验的算术平均识别准确率作为该模型的识别准确率,分别统计 50 次实验的分类识别时间(含建模时间),将 50 次实验的算术平均分类识别时间作为该模型分类识别时间。图 6 所示为 3 种分类模型分别进行 50 次独立识别实验的识别误差数量对比,表 3 所示为 3 种分类模型分别进行 50 次独立识别实验的结果统计。从图 6 与表 3 可以看到: PCA-LDA 模型的识别性能最稳定且识别时间最短,但其识别率只能达到 98.54%,为 3 种模型的最低值; PCA-PSO-BP 模型的识别性能不稳定且识别

表 3 三种分类模型的识别结果

Table 3 Recognition results of three classification models

Model	Mean error	Average classification time / s	Average classification accuracy / %
PCA-LDA	7.00	1.60	98.54
PCA-PSO-BP	5.58	3.03	98.84
PCA-PSO-SVM	0.46	10.76	99.90

误差较大; PCA-PSO-SVM 的分类识别虽然时间较长,但其准确率最高,最佳分类准确率可高达 100%,且平均分类准确率可达 99.90%。可见,所提出的 PCA-PSO-SVM 分类模型在矿石分类识别应用中具有较高的准确性。

5 总 结

采用 LIBS 技术结合 PCA-PSO-SVM 分类模型对 12 类矿石进行分类识别。对 12 类矿石的 LIBS 光谱数据的预处理包括采用 Savitzky Golay 进行平滑滤波,采用分段特征值提取法进行基线校正、归一化等。利用 PSO 算法对 SVM 的参数进行寻优,使得 PCA-PSO-SVM 模型得以快速收敛。采用 PCA 对预处理后的光谱数据进行降维,并对比将不同的主成分数量作为 PCA-PSO-SVM 分类模型的输入变量时得到的识别准确率,发现分类模型的识别准确率随着主成分数量的增加而增大,但主成分数量较大时,分类模型的识别准确率反而有所下降。因此,本实验选择前 25 个主成分作为分类模型

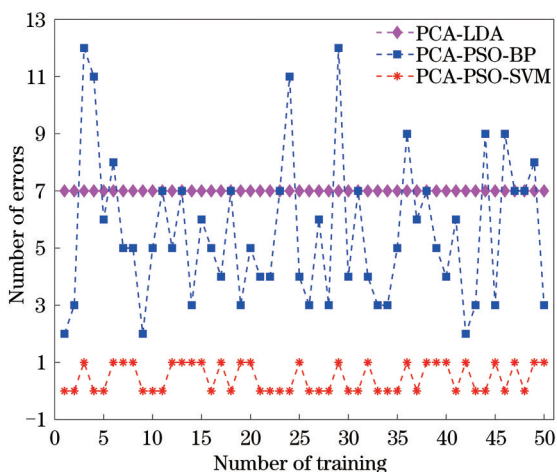


图 6 三种分类模型下对矿石分类识别的误差数量对比
Fig. 6 Comparison of number of errors in ore classification by three classification models

的输入变量,此时 PCA-PSO-SVM 模型的最佳识别准确率可达 100%。采用 PCA-LDA、PCA-PSO-BP、PCA-PSO-SVM 三种分类模型分别对 12 类矿石进行识别,三种模型的平均识别准确率分别为 98.54%、98.84%、99.90%。实验结果表明,采用 LIBS 技术结合 PCA-PSO-SVM 分类模型可对矿石类别进行高准确度识别,为矿石类型鉴别提供了一种有效的技术手段。

参 考 文 献

- [1] Deng T, Yu Y. Research on ore identification and separation based on improved PSO-Faster R-CNN algorithm[J]. Mining Research and Development, 2021, 41(2): 178-182.
邓田, 余翼. 基于 PSO-Faster R-CNN 改进算法的矿石识别分类研究[J]. 矿业研究与开发, 2021, 41(2): 178-182.
- [2] Yang Y W, Li C, Liu S, et al. Classification and identification of brands of iron ores using laser-induced breakdown spectroscopy combined with principal component analysis and artificial neural networks[J]. Analytical Methods, 2020, 12(10): 1316-1323.
- [3] Hu Y, Fan Z W, Li C, et al. Laser-induced breakdown spectroscopy combined with extreme learning machine mineral identification analysis research[J]. Spectroscopy and Spectral Analysis, 2016, 36(S1): 471-472.
胡勇, 范增伟, 李超, 等. 激光诱导击穿光谱结合极限学习机的矿物识别分析研究[J]. 光谱学与光谱分析, 2016, 36(S1): 471-472.
- [4] Dong P K, Zhao S Y, Zheng K X, et al. Rapid identification of ginseng origin by laser induced breakdown spectroscopy combined with neural network and support vector machine algorithm[J]. Acta Physica Sinica, 2021, 70(4): 040201.
董鹏凯, 赵上勇, 郑柯鑫, 等. 激光诱导击穿光谱技术结合神经网络和支持向量机算法的人参产地快速识别研究[J]. 物理学报, 2021, 70(4): 040201.
- [5] Li A Z, Wang X S, Xu X J, et al. Fast classification of tobacco based on laser-induced breakdown spectroscopy[J]. Chinese Optics, 2019, 12(5): 1139-1146.
李昂泽, 王宪双, 徐向君, 等. 激光诱导击穿光谱技术对烟草快速分类研究[J]. 中国光学, 2019, 12(5): 1139-1146.
- [6] Zhou Z H, Tian X Y, Sun L X, et al. Identification of aluminum alloy grades by fiber-laser induced breakdown spectroscopy combined with support vector machine[J]. Laser & Optoelectronics Progress, 2018, 55(6): 063002.
周中寒, 田雪咏, 孙兰香, 等. Fiber-LIBS 技术结合 SVM 鉴定铝合金牌号[J]. 激光与光电子学进展, 2018, 55(6): 063002.
- [7] Yang C R. Study of the spectral data processing in laser induced breakdown spectroscopy technology [D]. Beijing: Beijing Jiaotong University, 2014: 26-31.
杨崇瑞. 激光诱导击穿光谱数据处理方法研究[D]. 北京: 北京交通大学, 2014: 26-31.
- [8] Sheng L W, Zhang T L, Niu G H, et al. Classification of iron ores by laser-induced breakdown spectroscopy (LIBS) combined with random forest (RF)[J]. Journal of Analytical Atomic Spectrometry, 2015, 30(2): 453-458.
- [9] Képeš E, Vrábek J, Střítežská S, et al. Benchmark classification dataset for laser-induced breakdown spectroscopy[J]. Scientific Data, 2020, 7(1): 53.
- [10] Kennedy J, Eberhart R. Particle swarm optimization [C]//Proceedings of ICNN'95-International Conference on Neural Networks, November 27-December 1, 1995, Perth, WA, Australia. New York: IEEE Press, 1995: 1942-1948.
- [11] García-Gonzalo E, Fernández-Martínez J L. A brief historical review of particle swarm optimization (PSO) [J]. Journal of Bioinformatics and Intelligent Control, 2012, 1(1): 3-16.
- [12] Marini F, Walczak B. Particle swarm optimization (PSO). A tutorial[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 149: 153-165.
- [13] Tang Y Q, Li C H, Song Y F. Network security situation prediction based on improved particle swarm optimization and extreme learning machine[J]. Journal of Computer Applications, 2021, 41(3): 768-773.
唐延强, 李成海, 宋亚飞. 基于改进粒子群优化和极限学习机的网络安全态势预测[J]. 计算机应用, 2021, 41(3): 768-773.
- [14] Su Y X. Sound event recognition based on adaptive particle swarm optimized matching tracking[J]. Laser & Optoelectronics Progress, 2020, 57(10): 101502.
苏映新. 自适应粒子群优化匹配追踪声音事件识别算法[J]. 激光与光电子学进展, 2020, 57(10): 101502.
- [15] Shi Y, Eberhart R C. Empirical study of particle swarm optimization[C] //Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat.

- No. 99TH8406), July 6-9, 1999, Washington, D.C., USA. New York: IEEE Press, 1999: 1945-1950.
- [16] Yang Y L, Wang P, Ma C H. Quantitative analysis of Mn element in liquid steel by LIBS based on particle swarm optimized support vector machine[J]. *Laser & Optoelectronics Progress*, 2015, 52(7): 073004.
杨友良, 王鹏, 马翠红. 基于粒子群优化支持向量机的 LIBS 钢液 Mn 元素定量分析[J]. *激光与光电子学进展*, 2015, 52(7): 073004.
- [17] Subasi A. Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders[J]. *Computers in Biology and Medicine*, 2013, 43(5): 576-586.
- [18] Yang Y S, Zhang Y, Yang Y L, et al. Qualitative analysis of molten steel based on support vector machine by LIBS[J]. *Laser & Optoelectronics Progress*, 2015, 52(5): 053001.
杨友盛, 张岩, 杨友良, 等. 基于支持向量机的钢水 LIBS 定性分析[J]. *激光与光电子学进展*, 2015, 52(5): 053001.
- [19] Sha W, Li J T, Lu C P. Quantitative analysis of Mn in soil based on laser-induced breakdown spectroscopy optimization[J]. *Chinese Journal of Lasers*, 2020, 47(5): 0511001.
沙文, 李江涛, 鲁翠萍. 基于激光诱导击穿光谱技术寻优定量分析土壤中 Mn 元素[J]. *中国激光*, 2020, 47(5): 0511001.
- [20] Liu J X, Du B, Deng Y Q, et al. Terahertz-spectral identification of organic compounds based on differential PCA-SVM method[J]. *Chinese Journal of Lasers*, 2019, 46(6): 0614039.
刘俊秀, 杜彬, 邓玉强, 等. 基于差分-主成分分析-支持向量机的有机化合物太赫兹吸收光谱识别方法[J]. *中国激光*, 2019, 46(6): 0614039.
- [21] Wang S T, Wu X, Zhu W H, et al. Fluorescence detection of polycyclic aromatic hydrocarbons by parallel factor combined with support vector machine[J]. *Acta Optica Sinica*, 2019, 39(5): 0530002.
王书涛, 吴兴, 朱文浩, 等. 平行因子结合支持向量机对多环芳烃的荧光检测[J]. *光学学报*, 2019, 39(5): 0530002.