

基于多尺度 CNN 特征及 RAE-KELM 的 浮选加药状态识别

张进, 廖一鹏*, 陈诗媛, 王卫星

福州大学物理与信息工程学院, 福建 福州 350108

摘要 针对浮选加药状态在线检测困难、识别效率低和主观性强等问题, 提出了一种基于多尺度卷积神经网络 (CNN) 特征及行列自编码核极限学习机 (RAE-KELM) 的浮选加药状态识别方法。首先, 对浮选泡沫图像进行非下采样 Shearlet 多尺度分解, 用 CNN 提取每个尺度图像的深度特征并进行多尺度特征融合; 然后, 构建 RAE-KELM, 将用量子计算改进的细菌觅食算法用于 RAE-KELM 的参数优化; 最后, 通过自建数据集训练得到最优的 RAE-KELM 模型, 实现了浮选加药状态的自适应识别。实验结果表明, 本方法的识别准确率可达到 98.88%; 且本方法减少了人工干预, 有利于提高生产效率。

关键词 图像处理; 卷积神经网络; 非下采样 Shearlet 变换; 行列自编码核极限学习机; 量子细菌觅食算法

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.1215002

Flotation Dosing State Recognition Based on Multiscale CNN Features and RAE-KELM

Zhang Jin, Liao Yipeng*, Chen Shiyuan, Wang Weixing

College of Physics and Information Engineering, Fuzhou University, Fuzhou, Fujian 350108, China

Abstract To address the problems associated with online detection, low recognition efficiency, and strong subjectivity of the flotation dosing state, this paper proposes a flotation dosing state recognition method based on multiscale convolutional neural network (CNN) features and ranks automatic encoder kernel extreme learning machine (RAE-KELM). First, the flotation foam image is subjected to non-subsampled Shearlet multiscale decomposition, and the CNN is used to extract the depth features of each scale image and perform multiscale feature fusion. Then, the RAE-KELM is constructed, and an improved bacterial foraging algorithm based on quantum computing is used to optimize the RAE-KELM parameters. Finally, the optimal RAE-KELM model is obtained through self-built dataset training to realize the adaptive recognition of the flotation dosing state. The experimental results demonstrate that the recognition accuracy of the method can reach 98.88%. Additionally, the method reduces manual interventions, which can improve production efficiency.

Key words image processing; convolutional neural network; non-subsampled Shearlet transform; ranks automatic encoder kernel extreme learning machine; quantum bacterial foraging algorithm

OCIS codes 100.4994; 150.1135; 110.2960

1 引言

浮选是工业中提取矿石矿物质的主要方法, 主

要利用不同物质具有的不同湿润性分离矿物质。其中, 浮选药剂的加药量是影响浮选质量的主要因素, 准确判断加药状态后才能决定加药量。目前, 主要

收稿日期: 2020-09-08; 修回日期: 2020-09-29; 录用日期: 2020-10-14

基金项目: 国家自然科学基金(61471124, 61601126)、福建省自然科学基金(2019J01224)

* E-mail: fzu_lyp@163.com

通过人工识别加药状态,具有在线检测难度大、识别效率低和主观性强等问题,且缺乏统一的评判标准^[1]。因此,针对浮选生成过程中的浮选质量问题,研究科学有效的加药状态识别方法具有重要意义。

国内外学者对浮选生产中的加药状态识别进行了大量研究,刘金平等^[2]通过泡沫大小分布获得气泡大小的概率密度分布函数,采用简单的贝叶斯推理方法识别加药状态,但该方法对复杂模糊的浮选泡沫图像识别精度较低。吴佳等^[3]提出利用支持向量回归方法建立加药量估计模型,并采用区间 II 型模糊系统调整加药状态的识别偏差,进一步提高了加药状态的识别精度,但模型的泛化能力差,且对复杂模糊的浮选泡沫图像识别精度较低。卷积神经网络(CNN)可由图像集直接驱使特征与目标之间的关系,并进行深度学习^[4-6],从而高效提取出图像特征,因此,人们将 CNN 引入浮选加药状态识别方法中。Fu 等^[7-8]提出将 CNN 应用于浮选泡沫图像的特征提取及预测分类,相比传统方法,极大提高了加药状态的识别精度。但该方法提取的是单尺度图像特征,缺乏多尺度图像特征的局部细节和可区分性;且 CNN 的预测分类容易陷入局部最优解,泛化能力差。极限学习机(ELM)的训练速度快、分类准确率高,因此,将 ELM 引入 CNN 分类中^[9]可提高分类识别的效率和精度。但 ELM 是随机生成输入权值和隐含层节点数,分类结果的稳定性差。核极限学习机(KELM)在 ELM 的基础上引入核函数^[10],增加了 ELM 的稳定性。但 KELM 中的惩罚系数和核函数对 KELM 分类结果的影响较大,不同惩罚系数和核函数参数会导致分类精度的波动,可采用引入量子计算的细菌觅食算法(BFA)^[11]优化 KELM 的参数。

针对上述问题,本文提出了一种基于多尺度 CNN 特征及行列自编码 KELM(RAE-KELM)的

浮选加药状态识别方法。首先,通过非下采样 Shearlet 变换(NSST)^[12]将浮选泡沫图像分解成多个尺度的图像,用 CNN 提取多尺度图像的轮廓和细节特征,并将多尺度的特征向量融合成一个特征向量。然后,将融合后的特征向量输入两个 RAE-KELM 中,得到两组随机生成的隐层节点向量。两组隐层节点向量可作为 KELM 的输入形成 RAE-KELM,以降低惩罚系数和核函数参数的影响,增强模型的泛化能力。最后,通过 RAE-KELM 模型对特征向量进行训练分类,同时利用改进的量子细菌觅食算法(QBFA)对 RAE-KELM 的参数进行优化。

2 多尺度 CNN 特征提取及 RAE-KELM 特征分类

2.1 多尺度 CNN 特征提取

根据实际生产状况分析浮选泡沫的大小分布、加药量和矿物质品质之间的关系时,可以定义 4 种加药状态^[13]:1)加药过量状态 s_1 下泡沫呈橡胶状,具有厚、硬和高粘性,存在泡沫崩塌,且会出现少数泡沫极大的现象,该加药状态下的泡沫图像如图 1(a)所示;2)加药正常状态 s_2 下泡沫具有中等的稳定性和粘性,泡沫分布均匀且大小适中,该加药状态下的泡沫图像如图 1(b)所示;3)加药过少状态 s_3 下泡沫较虚,容易破碎且稳定性差,泡沫分布密集且尺寸较小,该加药状态下的泡沫图像如图 1(c)所示;4)生产故障状态(不完全由加药量引起) s_4 下泡沫不明显,很难出现成片的泡沫,该加药状态下泡沫图像如图 1(d)所示。因此,根据浮选泡沫图像的分布和形状,先用 NSST-CNN 模型提取不同状态浮选泡沫图像的特征,然后用 RAE-KELM 对特征进行分类识别,最后用 QBFA 对 RAE-KELM 中的参数进行优化,从而得到最佳的整体框架模型,实现浮选加药状态的识别。




图 1 不同加药状态下的泡沫图像。(a) s_1 ; (b) s_2 ; (c) s_3 ; (d) s_4

Fig. 1 Foam images in different dosing states. (a) s_1 ; (b) s_2 ; (c) s_3 ; (d) s_4

构建 NSST-CNN 模型提取浮选泡沫图像的特征向量时,首先对浮选泡沫图像进行 NSST 多尺度分解,NSST 是一种新兴的图像多尺度几何分析

方法^[14-15],是对 Shearlet 变换的优化改进。通过非下采样金字塔滤波器组去除下采样环节,使图像具有平移不变性并抑制图像中的伪吉布斯效应。

同时,通过剪切滤波器对高频子带信息进行多方向分解。Shearlet 变换是对基本小波函数的扩张、剪切和平移变换,结合仿射系统可形成剪切

波函数。由于 NSST 是对 Shearlet 变换的优化,因此在二维情况下,NSST 中的仿射系统可表示为

$$\begin{cases} M_{AS}(\psi) = \{\psi_{k,l,b}(\mathbf{x}) = |\det \mathbf{A}|^{k/2} \psi(\mathbf{S}^l \mathbf{A}^k \mathbf{x} - \mathbf{b}), k, l \in \mathbf{Z}, \mathbf{b} \in \mathbf{Z}^2\} \\ \mathbf{A} = \begin{bmatrix} 4 & 0 \\ 0 & 2 \end{bmatrix}, \mathbf{S} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \end{cases}, \quad (1)$$

式中, $\psi \in L^2(\mathbf{R})^2$ 为仿射系统的基本元素, \mathbf{x} 为输入矩阵, \mathbf{R} 为实数域, k, l 和 \mathbf{b} 分别为分解的尺度系数、方向系数和平移矩阵, \mathbf{A} 为控制 NSST 尺度分解的各向异性膨胀矩阵, \mathbf{S} 为控制 NSST 方向分解的剪切矩阵。通过 NSST 多尺度分解的浮选泡沫图像可得到一个低频图像和多个高频图像,低频图像能保留泡沫图像的细节,高频图像则保留了泡沫图像的边缘轮廓。图 2 为 NSST-CNN 模型的分解流程图, CNN 网络的参数如表 1 所示。其中, C1、C3、C5 为卷积层, P2、P4、P6 为池化层。将各个尺度全连接层输出的特征向量融合成一个特征向量,既包含低频图像的轮廓特征,又包含高频子带图像的多尺度细节特征。浮选泡沫图像经过 NSST 分解成多个尺度图像后,低频和低频图像可以体现出泡沫图像的细节和轮廓,此时用 CNN 可提取到更多的特征。

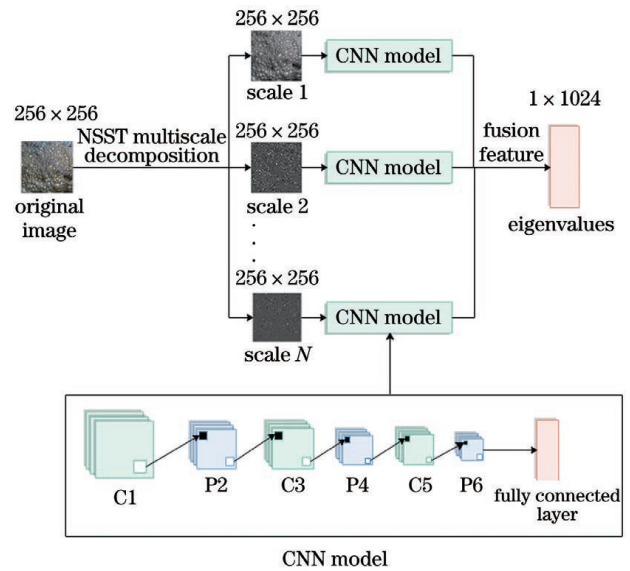


图 2 NSST-CNN 模型的流程图

Fig. 2 Flow chart of the NSST-CNN model

表 1 CNN 模型的参数

Table 1 Parameters of the CNN model

Layer	Scale 1			Scale 2			Scale N (N=3,4,5,...)		
	Step size	Number of cores	Core size	Step size	Number of cores	Core size	Step size	Number of cores	Core size
C1	1	64	5×5	1	64	5×5	1	64	5×5
P2	2	64	2×2	2	64	2×2	2	64	2×2
C3	1	32	3×3	1	64	3×3	1	64	3×3
P4	2	32	2×2	2	64	2×2	2	64	2×2
C5	1	32	2×2	1	32	2×2	1	64	2×2
P6	2	32	2×2	2	32	2×2	2	64	2×2
Fully connected layer	1024 neurons								

若不经 NSST 多尺度分解直接提取不同状态下的浮选泡沫图像特征向量,图像中边缘模糊、细节不清晰的特征不易被提取出来;而经过 NSST 分解后,高低频图像保留的边缘轮廓和细节也不同,边缘模糊、细节不清晰等问题也被削减^[12],因此用 NSST 对浮选泡沫图像进行多尺度分解,可提取更全面、更准确的浮选泡沫图像特征。

2.2 RAE-KELM 特征分类

浮选泡沫图像经 NSST-CNN 模型提取特征向量后,需利用分类算法进行分类。传统 CNN 通过 Softmax 分类器对全连接特征进行分类,并用反向传播训练所有网络参数,容易陷入局部最小值、过拟合等问题。ELM 是一种基于单隐层前馈神经网络的监督学习算法^[16],训练过程中需要调整的参数

少、效率高,泛化性能好,可表示为

$$\mathbf{H}\beta = \mathbf{T}, \quad (2)$$

式中, β 为输出权重, \mathbf{T} 为理想输出, \mathbf{H} 为隐层单元的输出矩阵。ELM 输入权值和隐层节点数的随机性,导致 ELM 的分类性能不稳定。因此,在 ELM 的基础上引入核函数^[10],得到 KELM,可表示为

$$\begin{cases} K(\mathbf{x}, \mathbf{x}_n) = \exp(-\sigma \|\mathbf{x} - \mathbf{x}_n\|^2), \sigma > 0 \\ f(\mathbf{x}) = \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_n) \end{bmatrix}^T \left(\frac{\mathbf{I}}{C} + \boldsymbol{\Omega}_{\text{ELM}} \right)^{-1} \mathbf{T}, \end{cases} \quad (3)$$

式中, \mathbf{x}_n 为第 n 个输入矩阵, $K(\mathbf{x}, \mathbf{x}_n)$ 为 RBF (Radial basis function)核函数, σ 为核函数值, \mathbf{I} 为单位矩阵, C 为惩罚系数, $\boldsymbol{\Omega}_{\text{ELM}} = \mathbf{H}\mathbf{H}^T$, \mathbf{H}^T 为 \mathbf{H} 的转置。虽然 KELM 引入 RBF 核函数和惩罚参数解决了 ELM 输入权值的随机性问题,增强了算法的稳定性,但其性能易受惩罚系数 C 和核函数 σ 的影响。为了降低惩罚系数 C 和核函数 σ 的影响,Cheng 等^[17]提出了多层 KELM(ML-KELM),通过自编码器抽取更多层的特征并作为 KELM 的输入,提高了 KELM 的泛化能力和分类精度。

将单隐层自编码引入 KELM,构建 RAE-KELM,如图 3(a)所示。其中, d 为输入的数量, N 为不同隐层节点的数量。用 CNN 提取、融合后的特征向量作为自编码器的输入,使 ELM 的输入和

输出相等,且随机生成隐层节点的权重 w 和偏置 b ,从而计算得到隐层的输出矩阵 \mathbf{H} ,RAE-KELM 的输出权重矩阵 β 可表示为

$$\beta_i = \mathbf{H}_i^T \mathbf{X}, \quad (4)$$

式中, i 为不同的权重矩阵, \mathbf{X} 为原始输入数据。隐层的输出矩阵 \mathbf{H} 可用输入与输出权重的转置 β^T 相乘得出,用自编码器抽取原始数据,可表示为

$$\mathbf{H}_i = \mathbf{X}\beta_i^T. \quad (5)$$

自编码器的抽取原理如图 3(b)所示,其中, o 为 KELM 的分类决策数量, \mathbf{T} 为 KELM 的分类决策结果。将 CNN 提取、融合的特征向量输入两个不同的自编码器,利用自编码器随机生成两组不同的权重和偏置,得到两组不同的隐层节点。将两组隐层节点的行列矩阵相乘,得到一个包含隐层节点信息的矩阵,可表示为

$$\mathbf{E} = \mathbf{H}_1 \otimes \mathbf{H}_2 = \mathbf{H}_1 \cdot \mathbf{H}_2^T = \begin{bmatrix} h_1^1 \\ h_1^2 \\ \vdots \\ h_1^m \end{bmatrix} \times [h_2^1 \ h_2^2 \ \dots \ h_2^n] = \begin{bmatrix} e_{11} & \dots & e_{1n} \\ \vdots & & \vdots \\ e_{m1} & \dots & e_{mn} \end{bmatrix}, \quad (6)$$

式中, \mathbf{E} 为包含隐层节点信息的矩阵, \mathbf{H}_1 为第一个自编码产生的隐层节点, \mathbf{H}_2 为第二个自编码产生的隐层节点。将 \mathbf{E} 进行全连接,并通过 KELM 进行分类决策,可以有效提高模型的分类精度和泛化能力。

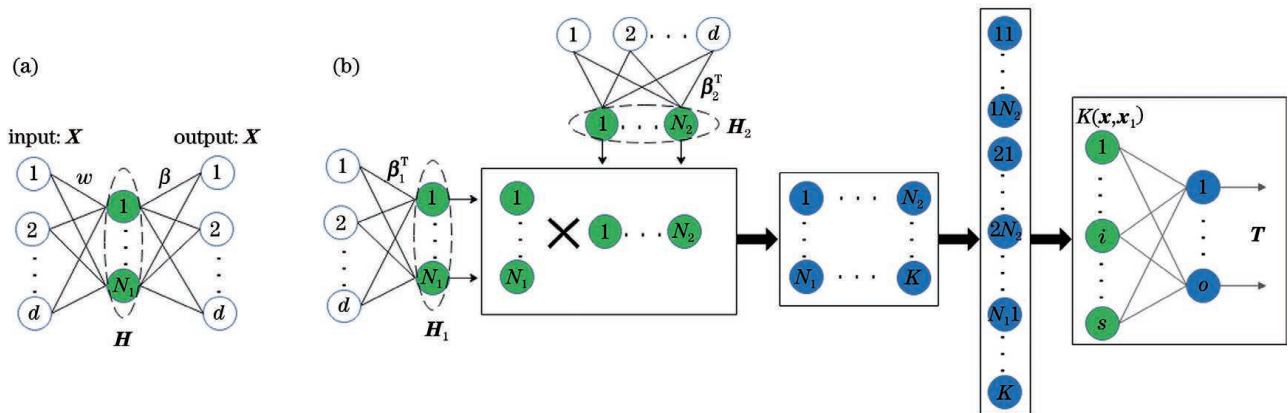


图 3 RAE-KELM 的结构。(a)自编码器;(b) RAE-KELM

Fig. 3 Structure of the RAE-KELM. (a) Self-encoder; (b) RAE-KELM

3 基于量子计算的细菌觅食算法

对于 RAE-KELM 中存在的数值可变参数,需要寻找最优值,以得到最佳参数的算法模型。目前,人们已经提出了多种量子衍生优化算法,如量子和声搜索(QHS)算法^[18]、量子遗传算法(QGA)^[19]。

本方法在 BFA^[11]的基础上引入量子计算,以增强算法的稳定性,提高算法的寻优能力。BFA 是根据大肠杆菌觅食行为提出的一种优化算法,研究发现,细菌具有四个典型的觅食行为,分别为趋向性行为、聚集性行为、复制行为和迁徙行为^[20]。细菌觅食算法具有对初值和参数的选择不敏感、鲁棒性强等优点,

但该算法在复制过程中,采取淘汰一半较差细菌、直接复制一半较优细菌的方式,导致种群缺乏多样性,容易陷入局部最优,同时影响收敛速度。因此,将量子计算引入细菌复制过程中,使其具有量子特性,大幅度提高了算法的空间搜索和寻优能力。具体操作是在细菌觅食复制行为过程中,采取淘汰一半较差细菌,复制一半较优细菌并引入量子计算对其位置

进行偏移,以得到更优的一组细菌。

量子计算中,量子比特是用来储存信息的物理介质,一个量子比特可表示为 $|\phi\rangle = \alpha|0\rangle + \chi|1\rangle$, 其中, (α, χ) 是两个幅常数, $|\alpha|^2 + |\chi|^2 = 1$, $|0\rangle$ 和 $|1\rangle$ 为量子自旋态。一个量子为同时包含 $|0\rangle$ 和 $|1\rangle$ 两个态的信息,一个细菌的量子比特编码可表示为

$$\mathbf{q}_j^t = \begin{bmatrix} \alpha_{11}^t & \alpha_{12}^t & \dots & \alpha_{1k}^t & \alpha_{21}^t & \alpha_{22}^t & \dots & \alpha_{2k}^t & \alpha_{m1}^t & \alpha_{m2}^t & \dots & \alpha_{mk}^t \\ \chi_{11}^t & \chi_{12}^t & \dots & \chi_{1k}^t & \chi_{21}^t & \chi_{22}^t & \dots & \chi_{2k}^t & \chi_{m1}^t & \chi_{m2}^t & \dots & \chi_{mk}^t \end{bmatrix}, \quad (7)$$

式中, \mathbf{q}_j^t 为第 t 代,第 j 个个体的染色体, k 为编码每个基因的量子比特数, m 为染色体的基因个数。

量子旋转门可用来更新染色体的位置,选择不同的旋转角,对算法的收敛速度和寻优能力会产生很大影响。在实际细菌觅食过程中,量子旋转门的旋转角不固定。因此,固定旋转角会影响算法的寻优速度,旋转角太大会使算法容易陷入局部最优解,旋转角太小会导致算法寻优速度变慢。因此提出了一种动态自适应旋转角,可表示为

$$\Delta\theta_z = -\text{sgn}(\mathbf{A}_z)\theta_z, \quad (8)$$

式中, $-\text{sgn}(\mathbf{A}_z)$ 为旋转角方向的正负, $\mathbf{A}_z =$

$$\begin{bmatrix} \alpha_b & \alpha_j \\ \chi_b & \chi_j \end{bmatrix}, \begin{bmatrix} \alpha_b \\ \chi_b \end{bmatrix} \text{ 为当前最优细菌量子比特对应的概率幅,}$$

$\begin{bmatrix} \alpha_j \\ \chi_j \end{bmatrix}$ 为当前细菌量子比特对应的概率幅, θ 为当前细菌旋转角,可表示为

$$\theta_z = \left| \frac{\theta_b - \theta}{M} \right|^\lambda \Delta\theta + 0.08\pi \exp(-t/T), \quad (9)$$

式中, θ_b 为当前最优细菌的旋转角, M 为固定值,一般取为 π , λ 为可动态调整的非线性指数,取值范围为 $(1.0, 2.0)$, $\Delta\theta$ 为动态旋转角,取值范围为 $(0, 0.5\pi)$, t 为当前迭代次数, T 为最大迭代次数。控制 λ 和 $\Delta\theta$ 的大小就可以动态自适应控制旋转角的大小。量子旋转门的调整操作和更新过程可表示为

$$\mathbf{U}(\Delta\theta_z) = \begin{bmatrix} \cos(\Delta\theta_z) & -\sin(\Delta\theta_z) \\ \sin(\Delta\theta_z) & \cos(\Delta\theta_z) \end{bmatrix}, \quad (10)$$

$$\begin{bmatrix} \alpha'_z \\ \chi'_z \end{bmatrix} = \mathbf{U}(\theta_z) \begin{bmatrix} \alpha_z \\ \chi_z \end{bmatrix} = \begin{bmatrix} \cos(\Delta\theta_z) & -\sin(\Delta\theta_z) \\ \sin(\Delta\theta_z) & \cos(\Delta\theta_z) \end{bmatrix} \begin{bmatrix} \alpha_z \\ \chi_z \end{bmatrix}, \quad (11)$$

式中, $(\alpha_z, \chi_z)^T$ 与 $(\alpha'_z, \chi'_z)^T$ 分别为第 z 个量子比特经旋转门更新前后的概率幅。

4 RAE-KELM 的参数优化及加药状态识别

虽然 RAE-KELM 降低了惩罚系数 C 和核函数 σ 的影响,但不同的学习参数组合 (C, σ) 也会影响 RAE-KELM 的拟合性能。为了获取最优的分类性能,用 QBFA 对 RAE-KELM 的惩罚系数 C 和核函数 σ 两个参数进行优化,具体流程如图 4 所示,其中 f_{\max} 为当前目标值的最大值。将惩罚系数和核函数作为 QBFA 中的细菌变量参数,将 RAE-KELM 的分类测试精度作为算法的适应度,不断更新细菌变量参数,并达到一定的迭代次数,从而在找到最佳细菌变量参数的同时得到最佳适应度。

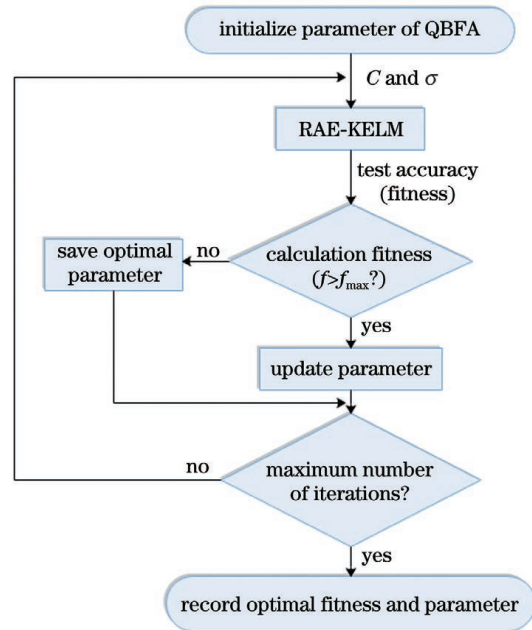


图 4 参数优化流程图

Fig. 4 Flow chart of the parameter optimization

实验提出的基于多尺度 CNN 特征及 RAE-KELM 的浮选加药状态识别方法总体框架图如图 5

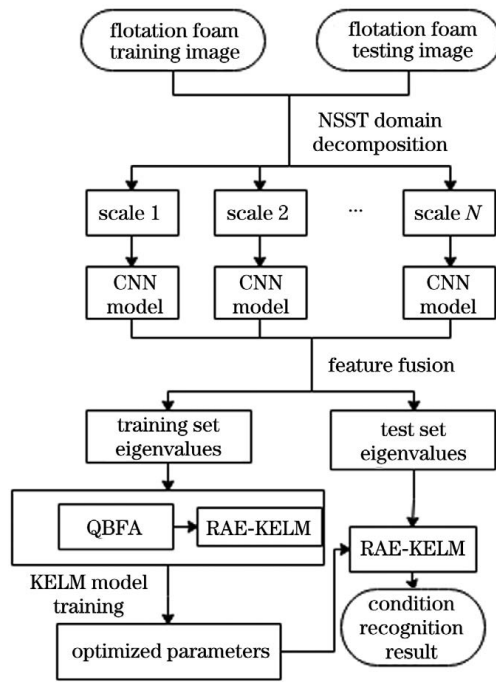


图 5 本方法的总体框架

Fig. 5 Overall framework of our method

所示,其中,输入为浮选泡沫图像,输出为浮选加药状态识别结果,具体步骤如下。

1) 将浮选泡沫图像通过 NSST 多尺度分解,得到一个低频图像和多个高频子带图像。

2) 通过 CNN 模型提取出每个尺度图像的深度特征,并将所有尺度特征融合成一个特征向量。

3) 将浮选泡沫训练图像经过步骤 1) 和步骤 2),得到浮选泡沫训练图像的特征向量;将浮选泡沫测试图像经过步骤 1) 和步骤 2),得到浮选泡沫测试图像的特征向量。

4) 将浮选泡沫训练图像的特征向量作为 RAE-KELM 的输入,利用 RAE-KELM 对浮选泡沫训练图像进行分类,得出浮选泡沫训练图像的测试精度;用 QBFA 对 RAE-KELM 的惩罚系数和核函数进行

优化,得到最佳惩罚系数和核函数,进而得到最佳的 RAE-KELM 模型。

5) 用步骤 4) 得到的最佳 RAE-KELM 模型将浮选泡沫测试图像的特征向量作为 RAE-KELM 的输入,得到浮选泡沫测试图像加药状态的分类结果,实现浮选加药状态的识别。

5 实验结果与分析

为了验证本方法的有效性,分别采用来自美国国家标准与技术研究所的 MNIST 手写数据集和福建金东矿业股份有限公司的铅矿浮选槽浮选泡沫图像作为实验对象。实验的硬件平台:CPU 为 Intel (R) Core (TM) i5-6300HQ、2.30 GHz, GPU 为 NVIDIA GTX960m, RAM 为 12.00 GB, 软件运行环境为 Windows10, Matlab2016a、Python 3.7、tensorflow 1.14。

5.1 量子细菌觅食算法的性能测试

由于本方法用 QBFA 优化 RAE-KELM 中的两个参数,且 RAE-KELM 模型可作为两个位置参数多极值的函数。因此,利用有两个未知参数且多极值的 Rastrigin 函数测试算法的性能,以得到(9)式动态自适应旋转角函数中参数 λ 和 $\Delta\theta$ 的最佳值,可表示为

$$\min f(x) = 20 + x_1^2 + x_2^2 - 10(\cos 2\pi x_1 + \cos 2\pi x_2), \quad (12)$$

式中, $f(x)$ 为函数目标值, x_1, x_2 为函数自变量在二维空间中的横纵坐标。

$f(x)$ 的最小值在 (0,0) 点取为 0, 实验采用的细菌个数 $S = 50$ 、趋向次数 $N_c = 30$ 、复制次数 $N_{re} = 4$ 、迁移次数 $N_{ed} = 4$ 、迁移概率 $P_{ed} = 0.25$ 、量子染色体个数为 20、最大迭代次数为 300。每组实验进行 100 次,同时采用不同的 λ 和 $\Delta\theta$, 实验达到最优值时概率 P_o 和迭代次数 M_o 的平均结果如表 2

表 2 不同参数时 QBFA 的平均最优值概率和迭代次数

Table 2 QBFA's average optimal value probability and number of iterations under different parameters

$\Delta\theta/\pi$	0.1		0.2		0.3		0.4		0.5	
	$P_o/\%$	M_o	$P_o/\%$	M_o	$P_o/\%$	M_o	$P_o/\%$	M_o	$P_o/\%$	M_o
1.1	97.47	213.4	97.91	205.1	98.56	211.1	99.11	196.3	98.79	215.6
1.2	98.21	196.5	97.88	208.8	99.24	204.4	99.20	204.8	99.06	204.6
1.3	97.91	201.6	98.24	199.4	98.78	199.7	99.15	201.6	99.35	198.4
1.4	98.33	208.1	98.56	197.6	98.95	196.4	99.64	198.7	99.64	202.7
1.5	99.11	204.3	99.55	204.5	99.35	196.8	99.70	196.9	99.81	205.3
1.6	98.76	197.4	99.36	210.4	99.12	201.3	99.63	206.2	99.65	203.8
1.7	99.23	196.6	99.87	201.8	99.76	195.2	99.95	190.8	99.75	206.2
1.8	99.05	192.1	99.78	195.3	99.23	198.8	99.63	194.3	99.54	197.5
1.9	98.86	195.8	99.36	199.2	99.34	205.6	99.24	201.8	99.21	198.0
2.0	98.25	202.0	98.95	206.4	98.97	207.1	99.26	202.7	98.99	201.3

所示。可以发现,当 $\lambda = 1.7, \Delta\theta = 0.4\pi$ 时, QBFA 的寻优能力和寻优速度达最佳,可将对应结果作为本方法的最佳参数。

为了进一步验证 QBFA 的参数寻优性能,选取 QGA、QHS、BFA 方法与本方法进行对比,同时用二元非线性函数进行实验,可表示为

$$\begin{aligned} \max f(x, y) &= x \sin(4\pi x) + y \sin(20\pi y), \\ -3.0 \leq x \leq 12.1, 4.1 \leq y \leq 5.8. \end{aligned} \quad (13)$$

式中, $f(x)$ 为函数目标值, x, y 为函数自变量在二维空间中的横纵坐标。实验结果如图 6 所示,可以发现,本方法的寻优能力最强,且在寻优速度上优于 QHS 和 BFA,略强于 QGA,鲁棒性更强。

5.2 CNN 可视化及最佳分解尺度和融合方式的选择

为了验证 CNN 在图像轮廓和细节特征上的提

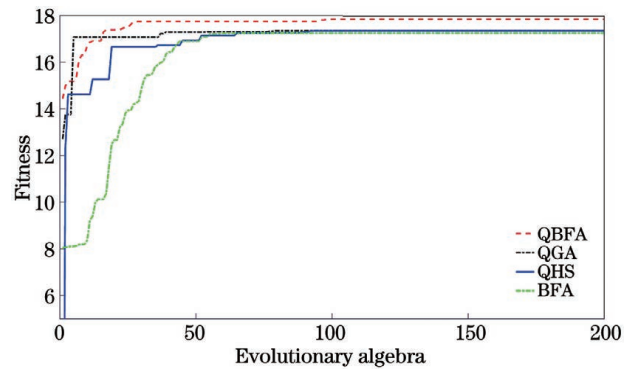


图 6 不同优化算法的性能

取能力,分别选取一张 MNIST 手写数据集中的图像和不同加药状态下的浮选泡沫图像,并将图像用 NSST 多尺度分解成 3 个尺度,经 CNN 模型每一层网络输出的图像如图 7 所示。可以发现,经过卷积

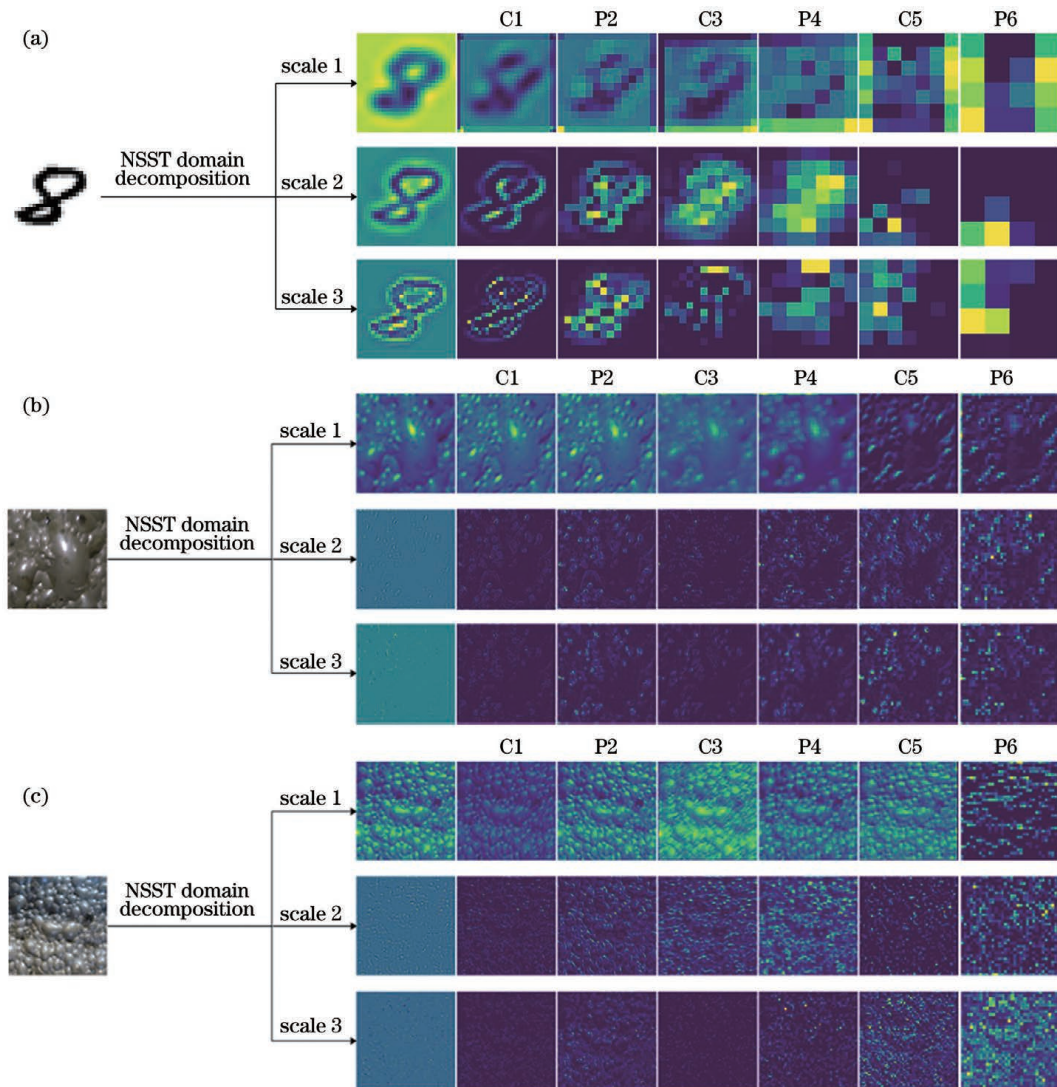


图 7 CNN 特征的可视化结果。(a) MNIST 手写数据集;(b) s_1 状态的浮选泡沫图像;(c) s_2 状态的浮选泡沫图像
Fig. 7 Visualization results of CNN features. (a) MNIST handwritten data set; (b) flotation foam image in state s_1 ; (c) flotation foam image in state s_2

层与池化层的图像呈不断变化趋势,具有分层特征,能提取到图像更多的轮廓和细节特征。由图 7(b)和图 7(c)可知,不同浮选泡沫图像状态经过 NSST 分解和 CNN 特征提取的图像边缘轮廓和细节也是不同的。

为确定最佳的 NSST 分解尺度和特征融合方式,分别采用 MNIST 手写数据集和浮选泡沫图像进行实验。其中, MNIST 手写数据集的训练集包括 55000 张图像、测试集包括 10000 张图像;浮选泡沫图像中有加药状态 s_1 、 s_2 、 s_3 和 s_4 标记的图像各 5000 张, 90% 为训练图像, 10% 为测试图像; NSST

分解尺度用不经过 NSST 和经过 NSST 分解为 2~5 个尺度,融合方式采用取最大值融合、取最小值融合、取平均值融合和取中位数融合。实验结果如图 8 所示,其中, x 、 y 、 z 分别为测试精度最高时对应的坐标值。可以发现, MNIST 手写数据集中的图像和浮选泡沫图像都在 NSST 分解为 3 个尺度和最大值融合时的测试精度最高, MNIST 手写数据集 RAE-KELM 的惩罚系数 C 为 323.6557、核函数 σ 为 67.2123;浮选泡沫图像 RAE-KELM 的惩罚系数 C 为 743.1401、核函数 σ 为 39.2369,因此将分解为 3 个尺度和最大值融合方式作为本方法的最佳选择。

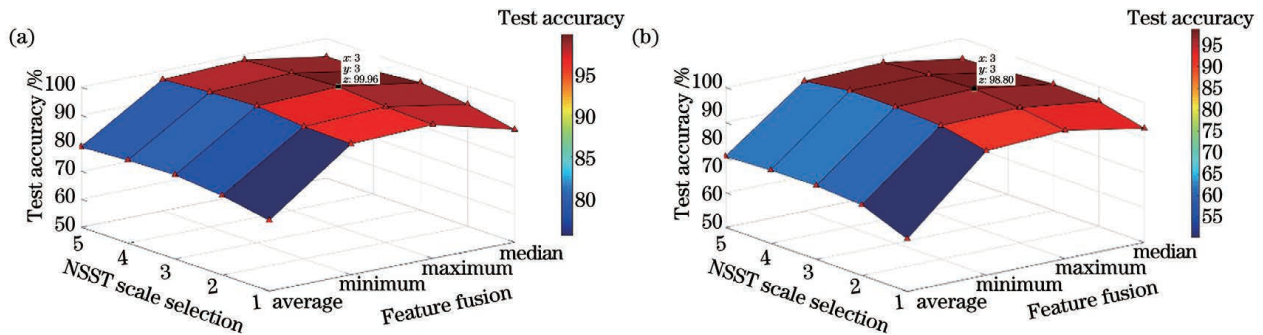


图 8 不同特征提取方式的测试精度。(a) MNIST 手写数据集;(b)浮选泡沫图像

Fig. 8 Testing accuracies of different feature extraction methods. (a) MNIST handwritten data set; (b) flotation foam image

5.3 加药状态识别方法的对比

为了验证本方法采用的 QBFA 和 RAE-KELM 的有效性,选取标记状态 s_1 、 s_2 、 s_3 和 s_4 的图像各 5000 张进行实验,并用 BFA 和 KELM 进行对比,实验结果如

表 3 所示。其中,训练集占 90%,测试集占 10%。可以发现, QBFA 和 RAE-KELM 组合在训练精度和测试精度方面都具有明显的优势,其花费的时间也较长,但总体来说,本方法满足浮选工况中的技术要求。

表 3 不同组合对的浮选加药状态的识别结果

Table 3 Recognition results of flotation dosing states by different combination pairs

Combination pair	QGA+KELM	QGA+RAE-KELM	QBFA+KELM	QBFA+RAE-KELM
Training accuracy / %	97.47	99.55	98.98	99.88
Training time / s	5659.55	5802.57	6050.36	6132.32
Testing accuracy / %	94.58	96.77	96.64	98.89
Testing time / s	5.04	5.08	5.18	5.11

为了验证本方法的实际应用效果,选取 s_1 、 s_2 、 s_3 和 s_4 状态的图像各 500 张进行测试实验,结果如图 9 所示。其中, s_1 、 s_2 、 s_3 和 s_4 状态被预测错误的图像分别为 4 张、0 张、12 张和 6 张,总体测试精度为 98.89%。

部分识别错误的图像如图 10 所示,可以发现, s_1 和 s_3 都是被误判成 s_2 ,原因是这两种状态的浮选泡沫分布均匀且大小接近 s_2 ; s_4 被误判成 s_3 ,原因是 s_4 中的泡沫大小与 s_3 相似。

5.4 不同方法的对比分析

为了验证本方法的优势,选取 s_1 、 s_2 、 s_3 和 s_4 状

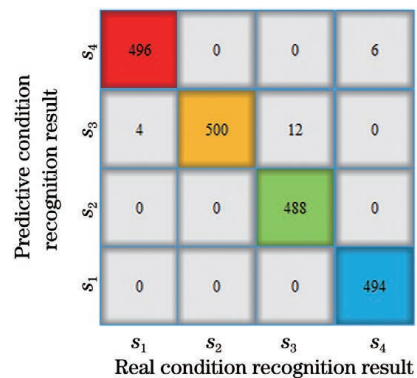


图 9 浮选加药状态的识别结果

Fig. 9 Recognition result of flotation dosing states




图 10 部分识别错误的图像。(a) s_1 被误判成 s_2 ; (b) s_3 被误判成 s_2 ; (c) s_4 被误判成 s_3

Fig. 10 Part of the recognized wrong image. (a) s_1 is misjudged as s_2 ; (b) s_3 is misjudged as s_2 ; (c) s_4 is misjudged as s_3

态的图像各 5000 张进行实验,其中,训练集占 90%,测试集占 10%。选取文献[2]中基于泡沫大小动态分布识别加药状态的方法、文献[3]中基于向量空间模型的浮选泡沫图像分类方法、文献[5]中利用 CNN 进行特征提取及预测分类的方法和文献[7]中的 CNN-ELM 模型分类方法进行实验,并与本方法进行对比。不同方法的识别精度及耗时如

表 4 所示,可以发现,相比其他方法,本方法的浮选加药状态识别准确度更高。原因是文献[2]中的方法难以获取复杂模糊浮选泡沫图像的动态分布情况,文献[3]中的方法泛化能力差,文献[5]中的方法容易出现过拟合等现象,文献[7]中的方法虽然在训练精度和测试精度方面都有较大改进,但稳定性不高。

表 4 不同方法的浮选加药状态识别结果

Table 4 Recognition results of different methods for flotation dosing states

Method	Ref. [2]	Ref. [3]	Ref. [5]	Ref. [7]	Ours
Training accuracy / %	89.67	86.21	98.38	98.89	99.88
Training time / s	1598.41	1444.22	14365.21	6079.52	6132.32
Testing accuracy / %	82.22	76.35	93.25	95.78	98.89
Testing time / s	4.47	4.25	6.43	5.32	5.11

6 结 论

针对目前浮选加药状态在线检测困难、识别效率低和主观性强等问题,提出了一种基于多尺度 CNN 特征及 RAE-KELM 的浮选加药状态识别方法。首先,采用 NSST-CNN 模型提取浮选泡沫图像更多的轮廓和细节特征,以扩大不同加药状态下图像特征的差异;然后,通过改进的 QBFA 提高算法的寻优能力、收敛速度及鲁棒性;其次,用构建的 RAE-KELM 将两组隐层节点行列矩阵相乘,抽取行列二维矩阵特征并将其进行全连接;最后,通过 KELM 进行分类决策,有效提高了模型的分类精度和泛化能力。实验结果表明,本方法的加药状态识别准确率可达到 98.88%,且本方法减少了人工干预,有利于提高生产效率。

参 考 文 献

[1] Kaartinen J, Hätönen J, Hyötyniemi H, et al. Machine-vision-based control of zinc flotation: a case study [J]. Control Engineering Practice, 2006, 14 (12): 1455-1466.
 [2] Liu J P, Gui W H, Tang Z H, et al. Dynamic

bubble-size-distribution-based health status analysis of reagent-addition in froth flotation process [J]. Control Theory & Applications, 2013, 30(4): 492-502.

刘金平, 桂卫华, 唐朝晖, 等. 基于泡沫大小动态分布的浮选生产过程加药量健康状态分析 [J]. 控制理论与应用, 2013, 30(4): 492-502.

[3] Wu J, Xie Y F, Yang C H, et al. Froth-image-features-driven control strategy for addition rates of reagents in stibium rougher flotation [J]. Control Theory & Applications, 2015, 32(12): 1599-1606.
 吴佳, 谢永芳, 阳春华, 等. 泡沫图像特征驱动的锑粗选加药控制策略 [J]. 控制理论与应用, 2015, 32 (12): 1599-1606.

[4] Yao Q L, Hu X, Lei H. Object detection in remote sensing images using multiscale convolutional neural networks [J]. Acta Optica Sinica, 2019, 39 (11): 1128002.

姚群力, 胡显, 雷宏. 基于多尺度卷积神经网络的遥感目标检测研究 [J]. 光学学报, 2019, 39 (11): 1128002.

[5] Yan M J, Su X Y. Hyperspectral image classification based on three-dimensional dilated convolutional residual neural network [J]. Acta Optica Sinica, 2020, 40(16): 1628002.

- 颜铭靖, 苏喜友. 基于三维空洞卷积残差神经网络的高光谱影像分类方法[J]. 光学学报, 2020, 40(16): 1628002.
- [6] Zhu R F, Ma J Y, Li Z Q, et al. Domestic multispectral image classification based on multilayer perception convolutional neural network [J]. Acta Optica Sinica, 2020, 40(15): 1528003.
朱瑞飞, 马经宇, 李竺强, 等. 多层感知卷积神经网络的国产多光谱影像分类[J]. 光学学报, 2020, 40(15): 1528003.
- [7] Fu Y, Aldrich C. Flotation froth image recognition with convolutional neural networks [J]. Minerals Engineering, 2019, 132: 183-190.
- [8] Fu Y H, Aldrich C. Froth image analysis by use of transfer learning and convolutional neural networks [J]. Minerals Engineering, 2018, 115: 68-78.
- [9] Duan M X, Li K L, Yang C Q, et al. A hybrid deep learning CNN-ELM for age and gender classification [J]. Neurocomputing, 2018, 275: 448-461.
- [10] Wang J, Song Y F, Ma T L. Mexican hat wavelet kernel ELM for multiclass classification[J]. Computational Intelligence and Neuroscience, 2017, 2017: 7479140.
- [11] Dass R. Speckle noise reduction of ultrasound images using BFO cascaded with Wiener filter and discrete wavelet transform in homomorphic region [J]. Procedia Computer Science, 2018, 132: 1543-1551.
- [12] Liao Y P, Wang W X, Fu H D, et al. Flotation foam image NSCT multi-scale enhancement with fractional differential[J]. Journal of South China University of Technology (Natural Science Edition), 2018, 46(3): 92-102.
廖一鹏, 王卫星, 付华栋, 等. 结合分数阶微分的浮选泡沫图像 NSCT 多尺度增强[J]. 华南理工大学学报(自然科学版), 2018, 46(3): 92-102.
- [13] Li Z M, Gui W H, Zhu J Y. Fault detection in flotation processes based on deep learning and support vector machine[J]. Journal of Central South University, 2019, 26(9): 2504-2515.
- [14] Easley G, Labate D, Lim W Q. Sparse directional image representations using the discrete Shearlet transform[J]. Applied and Computational Harmonic Analysis, 2008, 25(1): 25-46.
- [15] Wang Y, Lin S. Energy feature finger-knuckle-print recognition based on NSST and Tetrolet [J]. Laser & Optoelectronics Progress, 2021, 58(2): 0210019.
王媛, 林森. 基于 NSST 和 Tetrolet 能量特征的指关节纹识别[J]. 激光与光电子学进展, 2021, 58(2): 0210019.
- [16] Prasad R, Deo R C, Li Y, et al. Soil moisture forecasting by a hybrid machine learning technique: ELM integrated with ensemble empirical mode decomposition[J]. Geoderma, 2018, 330: 136-161.
- [17] Cheng Y S, Zhao D W, Wang Y B, et al. Multi-label learning with kernel extreme learning machine autoencoder[J]. Knowledge-Based Systems, 2019, 178: 1-10.
- [18] Sun W, He Y J, Chang H. Forecasting fossil fuel energy consumption for power generation using QHSA-based LSSVM model [J]. Energies, 2015, 8(2): 939-959.
- [19] Lyu X, Hu Z Q, Zhou H L, et al. Application of improved MCKD method based on QGA in planetary gear compound fault diagnosis [J]. Measurement, 2019, 139: 236-248.
- [20] Li J Q, Yang C H, Zhu H Q, et al. Improved image enhancement method for flotation froth image based on parameter extraction[J]. Journal of Central South University, 2013, 20(6): 1602-1609.