

文章编号 1004-924X(2020)12-2684-16

NSST 域改进 ORB 的泡沫流动特征提取及 加药状态识别

廖一鹏^{1*}, 陈诗媛¹, 杨洁洁¹, 王志刚², 王卫星¹

(1. 福州大学 物理与信息工程学院, 福建 福州 350108;

2. 福建金东矿业股份有限公司, 福建 三明 365101)

摘要:针对浮选泡沫表面图像动态变化、光照影响、噪声干扰导致流动特征难于提取的问题,提出了一种在 NSST 域改进 ORB 的泡沫流动特征提取方法,并应用于浮选加药状态识别。对相邻两帧泡沫图像 NSST 分解,对多尺度高频子带先通过尺度相关系数去除噪声再分为多个内层和外层,在各内层通过方向模极大值检测提取兴趣点,然后在本层和上下层通过非极大值抑制提取特征点,采用多尺度 BRIEF 描述子对特征点描述,结合泡沫的运动趋势动态调整搜索的匹配区域,根据匹配结果计算泡沫流动特征。最后,构建行列自编码极限学习机对泡沫形态、尺寸分布特征和流动特征进行融合,然后通过自适应随机森林对加药状态分类识别。实验结果表明,改进的 ORB 受噪声和光照影响小,流动特征检测精度和效率较现有方法有较大提高,能准确地表征不同加药状态下泡沫表面的流动特性,加药状态的平均识别精度达 97.85%,较现有文献方法有较大提升,为后续的加药量优化控制奠定基础。

关键词:浮选泡沫图像;流动特征提取;ORB;非下采样剪切波变换;行列自编码极限学习机;自适应随机森林
中图分类号:TP391 **文献标识码:**A **doi:**10.37188/OPE.20202812.2684

Dosing status identification and froth flow feature extraction based on improved ORB in NSST domain

LIAO Yi-peng^{1*}, CHEN Shi-yuan¹, YANG Jie-jie¹, WANG Zhi-gang², WANG Wei-xing¹

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China;

2. Fujian Jindong Mining Co. Ltd., Sanming 365101, China)

* Corresponding author, E-mail: fzu_lyp@163.com

Abstract: A froth-flow feature detection method based on an improved ORB in the NSST domain was developed and applied to flotation dosing state recognition to solve the problems of continuous movement, light effects, and noise interference of flotation surface images, which lead to difficulties in flow feature detection. First, two adjacent froth images were decomposed through NSST. Multiscale high-frequency subbands were denoised using a scale correlation coefficient and then divided into multiple inner and outer layers. The points of interest were subsequently extracted through modulus maxima detection in each inner layer, and the feature points were extracted through non-maximum suppression between the upper and low-

收稿日期:2020-05-11;**修订日期:**2020-06-28.

基金项目:国家自然科学基金资助项目(No. 61471124, No. 61601126);福建省自然科学基金资助项目(No. 2019J01224);福建省中青年教育科研项目资助(No. JT180056)

er layers. Second, a multiscale BRIEF descriptor was adopted to describe these feature points, the search matching area was dynamically adjusted according to the movement trend of the bubbles. The froth-flow features were then calculated based on the matching results. Finally, a line-and-column autoencoder extreme learning machine was constructed to fuse the foam shape, size distribution, and flow features, and the dosing state was recognized by the adaptive random forest method. The experimental results showed that the improved ORB was slightly affected by noise and illumination. The flow feature detection efficiency and the detection accuracy were significantly better than those of existing methods. The proposed method could characterize the flow characteristics of the froth surface accurately in different dosing states. The average accuracy of dosing state recognition reached 97.85%, which was significantly higher than those of existing methods. This study lays a foundation for future research on dosing quantity optimization control.

Key words: flotation froth image; flow feature extraction; Oriented Fast and Rotated Brief(ORB); non-subsampled shearlet transform; line and column autoencoder extreme learning machine; adaptive random forest

1 引言

浮选生产是工业上从矿石中提炼出金属矿物的一种有效选矿方法,通过加入特定的化学药剂将金属从矿石中分离,药剂添加的好坏直接影响最终生产指标的高低。目前,浮选厂主要通过人眼观察泡沫表面状态的变化进行相应的药剂剂量调节,这种方式主观性强且实时性差。近年来,研究人员通过机器视觉技术提取泡沫表面特征来进行加药状态预测,取得了一定成果:Zhang 等^[1]通过分水岭算法提取泡沫尺寸分布特征,并建立非线性预测模型实现加药状态的有效识别;Ai 等^[2]提出一种基于泡沫形状加权大小分布特征的加药状态预测方法,进一步提高了预测准确度;Tang 等^[3]提出一种基于泡沫大小累积分布特征的加药状态预测方法,减少了噪声干扰,提高了稳定性;Li 等^[4]提出一种基于泡沫图像深度学习的加药故障状态检测方法,在大数据集条件下具有较高的识别精度。以上方法主要通过提取泡沫尺寸、形态特征进行加药状态预测,Cao 等^[5]通过试验发现泡沫表面的流动特征与药剂添加量之间有较强的相关性,在不同加药状态下呈现不同的流动特性,增加泡沫流动特征作为加药状态识别的驱动,将有助于提高识别精度。

目前,国内外学者主要研究泡沫静态特征的提取,而对流动特征提取方法的研究较少,浮选

过程中泡沫时刻发生着崩塌、合并、新产生等变化,而且浮选槽表面雾气大、粉尘多,采集的图像受光照和噪声影响大,流动特征检测困难。陈良琴等^[6]结合气泡亮点跟踪和相位相关法估计气泡的流动速度,该方法采用 Otsu 分割气泡亮点,分割精度受气泡形变和光照的影响,而且相位相关法计算获取的是两帧图像的相对位移,不能精确描述泡沫的局部运动特征;WANG 等^[7]将 SIFT (Scale Invariant Feature Transform) 算法应用到泡沫流动特征的检测中,根据匹配结果计算流动特征,提取的流动特征在各加药状态下有一定的区分度,但 SIFT 计算复杂,实时性不强;Nakhaei 等^[8-9]采用像素点跟踪技术计算连续帧间的平均流动速度,该方法运行效率高,但是像素值在流动过程容易受噪声和光照影响而产生变化,导致像素点跟踪出错。

Roblee 等^[10]提出的 ORB (Oriented Fast and Rotated Brief) 算法具有旋转不变性和运算效率高的优点,适用于实时性要求高的应用场合,解决了 SIFT 在实时性方面的不足,但该算法提取的特征点容易出现簇集现象,而且抗噪声和尺度变换的能力差,有待改善。近几年,多尺度几何分析的发展为图像处理领域开辟了新的研究方向,非下采样 Shearlet 变换^[11] (NSST, Nonsubsampled Shearlet Transform) 具有多尺度多方向特性,分解后的图像具有平移不变性,而且具备

运算效率高、分解方向不受限制等特质,可将 NSST 引入到 ORB 算法的改进,提高算法整体的鲁棒性。

鉴于上述分析,本文提出一种基于 NSST 域改进 ORB 算法的泡沫流动特征提取方法,并用于加药状态识别。在 NSST 域先采用尺度相关性去除噪声,在各个内层通过方向模极大值检测提取边缘区域的兴趣点,然后在本层和上下层通过非极大值抑制进一步提取特征点,解决特征点的簇集现象和尺度不变性。采用多尺度 BRIEF (Binary Robust Independent Elementary Features) 描述子对特征点进行描述,结合泡沫流动趋势动态调整搜索的匹配区域,以提高匹配效率和精度,根据匹配结果计算泡沫流动特征。最后,构建行列自编码极限学习机对泡沫形态、尺寸分布特征和流动特征进行融合,然后通过自适

应随机森林算法进行加药状态识别。

2 NSST 域改进 ORB 的流动特征提取

2.1 多尺度域噪声去除

NSST 是对剪切波变换的优化改进^[11],去掉了下采样环节使图像具有平移不变性和抑制伪吉布斯效应,泡沫图像通过 k 级分解,得到 1 个低频图像和 k 个不同尺度的高频子带图像,各高频子带图像可再分解为多个方向子带,且所有分解图像大小相同。泡沫图像的 3 级 NSST 多尺度分解如图 1 所示,分解后的低频子带保留泡沫的轮廓信息,而泡沫纹理、边缘细节和噪声点被分解到各高频方向子带,可在多尺度高频子带进行噪声去除和特征点检测。

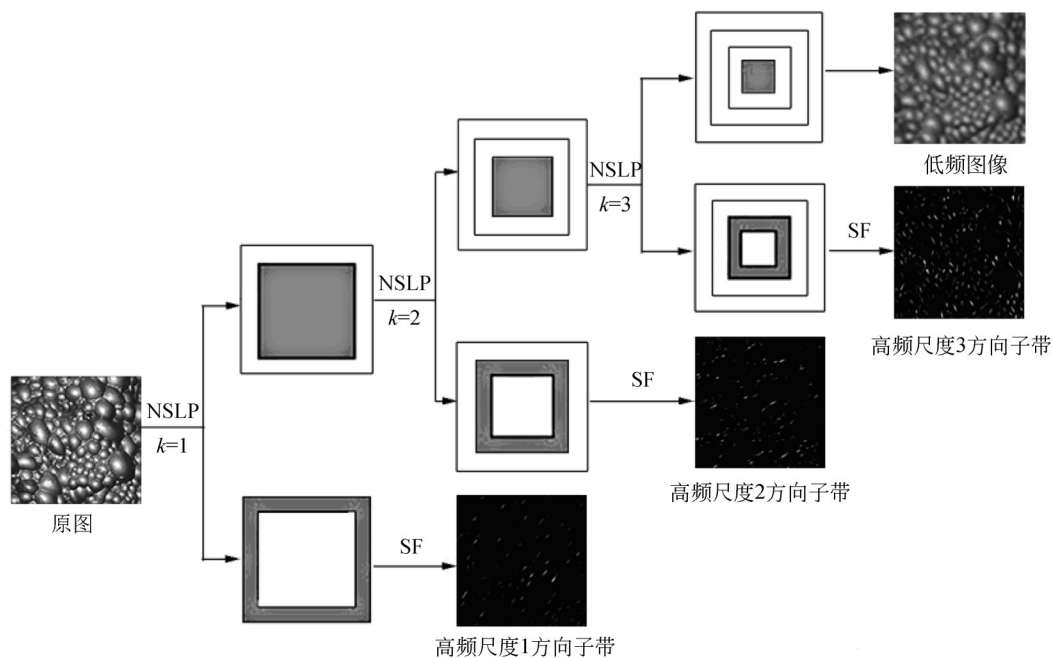


图 1 泡沫图像 NSST 多尺度分解

Fig. 1 Foam image NSST multiscale decomposition

泡沫图像在光源的作用下,每个气泡表面呈现高亮区,流动过程中受光照影响大,而气泡边缘像素点受光照影响小,可将 NSST 域多尺度边缘带作为特征点检测区域,以减少光照影响,同时解决特征点的簇集现象。在进行边缘系数检

测前,先进行噪声去除处理,随着分解尺度的加深,噪声系数在尺度间是弱相关的,会迅速衰减,边缘系数强相关而保持稳定^[12],可根据尺度间系数相关强弱将噪声点从边缘中分离。定义像素点 (i, j) 在 k 尺度 l 方向子带上的系数为 $c_k^l(i, j)$,

尺度相关系数为 $Corr_k^l(i, j)$, K 个尺度间的系数乘积为 $\prod_{k=1}^K c_k^l(i, j)$, E_k^l 为第 k 尺度上第 l 方向子带的能量, 而 $Ecorr_k^l$ 为 $\prod_{k=1}^K c_k^l(i, j)$ 的系数能量, $\sqrt{E_k^l/Ecorr_k^l}$ 是归一化处理, 则像素点 (i, j) 的尺度相关系数为:

$$Corr_k^l(i, j) = \prod_{k=1}^K c_k^l(i, j) \sqrt{\frac{E_k^l}{Ecorr_k^l}}. \quad (1)$$

如果该点的原系数大于尺度相关系数, 则该点为噪声点, 将该系数值置零, 否则系数值保持不变:

$$c_k^l(i, j) = \begin{cases} 0, & Corr_k^l(i, j) < c_k^l(i, j) \\ c_k^l(i, j), & \text{other wise} \end{cases}. \quad (2)$$

2.2 改进 ORB 特征点检测方法

为保证尺度不变性, 在 NSST 域对 ORB 特征点检测方法进行改进, 借鉴 BRISK (Binary Robust Invariant Scalable Keypoints)^[13] 特征点检测方法, 特征点检测在尺度空间上进行, 把 NSST 多尺度高频子带分为多个内层和外层, 在各个内层的边缘区域提取兴趣点, 然后在本层和上下层通过非极大值判断进行特征点检测: 计算内层上 (i, j) 点在各个方向分量的模值, 假设 l 方向的模值 $\text{mod}[c_k^l(i, j)]$ 最大, 以该点为中心, 计算半径为 3 的圆上 16 个系数点在 l 方向的模值, 如果 16 个模值至少有 9 个的值小于 $\text{mod}[c_k^l(i, j)]$, 则该点为潜在的兴趣点。然后该兴趣点在本层和上下层通过非极大值抑制进行特征点判断, 同层中该点的 l 方向的模值 $\text{mod}[c_k^l(i, j)]$ 必须要大于其余八邻域中的点, 上下层对应的 2×9 个点的 l 方向的模值也必须小于 $\text{mod}[c_k^l(i, j)]$, 特征点 $P(i, j)$ 的检测公式如式(3)所示:

$$P(i, j) = \begin{cases} 0, & \text{mod}[c_k^l(i, j)] < \text{mod}[c_k^l(i+m, j+n)] \\ 0, & \text{mod}[c_k^l(i, j)] < \text{mod}[c_{k+1}^l(i+m, j+n)] \\ 0, & \text{mod}[c_k^l(i, j)] < \text{mod}[c_{k-1}^l(i+m, j+n)] \\ 1, & \text{other wise} \end{cases} \quad (3)$$

其中: $m \in [-1, 1]$, $n \in [-1, 1]$ 。

2.3 多尺度 BRIEF 特征描述方法

为使特征点描述具有旋转不变性, 必须先规

定特征点的主方向, ORB 将特征点与邻域质心的夹角定义为主方向^[14], 特征点邻域图像矩定义为:

$$m_{pq} = \sum_{i, j} i^p j^q I(i, j), \quad (4)$$

其中: $I(i, j)$ 为像素点 (i, j) 的灰度值, m_{pq} 为 $p+q$ 阶矩。特征点邻域图像质心为:

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right). \quad (5)$$

特征点与质心的夹角为特征点的主方向:

$$\sigma = \arctan(m_{01}, m_{10}). \quad (6)$$

获取特征点主方向后, 本文采用多尺度系数进行特征描述, 在特征点周围选取 M 对随机点, 将 M 对随机点旋转 σ 角度后, 对每对点的低频子带梯度以及高频子带系数进行比较, 将比较结果组合起来作为描述子, 定义比较准则:

$$\tau(P; a, b) = \begin{cases} 1, & P(a) > P(b) \cap I(a) > I(b) \\ 0, & \text{other wise} \end{cases}, \quad (7)$$

$$P(a) = \sum_{l=1}^L \prod_{k=1}^K c_k^l(a), P(b) = \sum_{l=1}^L \prod_{k=1}^K c_k^l(b), \quad (8)$$

其中: $I(a)$ 和 $I(b)$ 为随机点对 a 和 b 的低频子带梯度, $P(a)$ 和 $P(b)$ 为全方向的 K 个尺度系数乘积之和。通过 M 对随机点的比较, 构成 M 维的二进制特征描述子:

$$B = \sum_{i=1}^M 2^{i-1} \tau(P; a_i, b_i). \quad (9)$$

2.4 结合运动趋势的特征点匹配

每个特征点对应的描述符 B 均为 M 位的二进制比特串, 匹配时采用异或操作计算对应描述符 B_1 和 B_2 之间的汉明距离 HD, 用于衡量两个特征点间的近似度, 值越大代表相似度越小, 反之越大:

$$\text{HD}(B_1, B_2) = B_1 \oplus B_2. \quad (10)$$

浮选槽表面的泡沫受刮板的作用其流动方向和速度在短时间内相对稳定, 相对于前一帧图像中的特征点, 后一帧图像的匹配点应落于沿泡沫流动方向的一定范围内, 可根据这特性缩小匹配的搜索区域, 假设 v_x 和 v_y 分别为前两帧图像所有匹配点的水平速度和竖直速度的均值, 其合成速度为 v 。定义搜索区域为以当前特征点 p 为圆心, 以 r 为半径的圆, 搜索区域的半径公式为:

$$r = (1.5 + n_r)|v|, n_r = 1, 2, 3, \dots, n, \quad (11)$$

其中: n_r 为区域扩大系数, 初始值为 1, 在搜索区域中找到与该点汉明距离最近的关键点 p_1 和近次的关键点 p_2 , 并将 p_1, p_2 与 p 的汉明距离分别记为 HD_1 和 HD_2 , 如果满足 $HD_1/HD_2 < 0.5$, 则接受 p_1 为匹配点, 反之依据式(11)循环扩大搜索范围直至找到匹配点或搜索至全图。最后计算匹配点对间线段的长度和斜率, 将一定长度和斜率范围的点作为 RANSAC^[15] 内点, 剔除误匹配点, 提高匹配精度。

2.5 泡沫流动特征计算

假设时间间隔为 Δt 的连续两帧图像 I_t 和 I_{t+1} 共有 N 对匹配点, 它们在 I_t 和 I_{t+1} 的位置分别为 (x_t^n, y_t^n) 和 (x_{t+1}^n, y_{t+1}^n) , 通过式(12)计算该点的水平流动速度 v_x^n 和垂直流动速度 v_y^n , 通过式(13)计算平均水平流动速度 v_x 和平均垂直流动速度 v_y :

$$v_x^n = \frac{x_{t+1}^n - x_t^n}{\Delta t}, v_y^n = \frac{y_{t+1}^n - y_t^n}{\Delta t}, \quad (12)$$

$$v_x = \frac{1}{N} \sum_{n=1}^N v_x^n, v_y = \frac{1}{N} \sum_{n=1}^N v_y^n. \quad (13)$$

通过式(14)计算当前的泡沫平均流动速度和方向, 假设前一时间刻检测的水平流动速度为 v_x' , 垂直流动速度为 v_y' , 通过式(15)计算当前的水平流动加速度 a_x 和垂直流动加速度 a_y , 通过式(16)计算流动速度和方向的无序度 \bar{v} 和方向 $\bar{\theta}$ 为前一段时间的平均流动速度和方向。

$$v = \sqrt{v_x^2 + v_y^2}, \quad \theta = \arctg \frac{v_y}{v_x}, \quad (14)$$

$$a_x = \frac{v_x - v_x'}{\Delta t}, \quad a_y = \frac{v_y - v_y'}{\Delta t}, \quad (15)$$

$$\rho_v = \frac{\sqrt{(v - \bar{v})^2}}{\bar{v}}, \quad \rho_\theta = \frac{\sqrt{(\theta - \bar{\theta})^2}}{\bar{\theta}}. \quad (16)$$

假设摄像机镜头到目标物体的物距为 S , 镜头焦距为 f , 摄像机的光学放大倍率为 μ , 焦距和物距的关系为:

$$f = \frac{S\mu}{\mu + 1}, \quad \mu = \frac{v}{v_T}, \quad (17)$$

式中: v_T 为泡沫表面流动速度实际值, 由此可推出泡沫流动速度与摄像机高度及镜头焦距的关系式为:

$$v_T = \frac{S - f}{f} v. \quad (18)$$

3 浮选加药状态识别

根据精矿品位和尾矿品位的等级, 将浮选加药状态分为正常、过量、欠量、故障等 4 种状态^[4]。泡沫表面的形态、尺寸分布特征是加药状态评判的重要依据, 研究发现泡沫表面流动特征与药剂添加状态也有较强的相关性^[5], 本文综合考虑两类特征作为加药状态评判的依据。黄凌霄等^[16]在多尺度域提取泡沫的亮点个数、平均面积、标准差、椭圆率和分形维数作为等效形态、尺寸特征, 提取的特征与泡沫类别的相关性较高, 本文采用这 5 个特征作为泡沫表面的形态、尺寸分布特征, 结合提取的 6 个流动特征作为加药状态评判的依据。

随机森林(Random Forest, RF)^[17]是基于多决策树的集成学习算法, 对异常值不敏感, 抗噪声能力强, 具有很好的分类性能。为了提升决策树的多样性, 降低树之间的相似性, 避免产生过拟合现象, 先对形态、尺寸分布特征和流动特征进行融合和维度扩展。自编码极限学习机^[18]令输入与输出相等, 通过前馈神经网络来完成高层次的特征提取, 具有较高的特征抽取和学习能力:

$$H\beta = X, \quad (19)$$

式中: β 是隐含层和输出层间的连接权值矩阵, X 表示与输入相等的输出值, H 表示隐层单元的输出矩阵。随机生成输入与隐层间的权重和偏置可得隐层输出矩阵 H , 通过式(20)求得输出权重矩阵 β :

$$\beta = H^+ X. \quad (20)$$

经过训练后, 隐层节点 H 的输入是输出权重的转置 β^T , 通过式(21)对原始特征进行高维特征抽取:

$$H = X\beta^T. \quad (21)$$

为实现特征融合和高维扩展, 如图 2 所示, 先通过两个自编码极限学习机分别对形态、尺寸分布特征和流动特征进行学习和抽取, 得到 N_1 维特征向量 H_1 和 N_2 维特征向量 H_2 , 然后通过式(22)将向量 H_1 和向量 H_2 的转置进行叉乘, 将两类特征融合在一起, 得到 N_3 ($N_3 = N_1 \times N_2$) 维特征向量 E , 有助于扩大不同决策树间样本采样和特征选取的差异程度, 提升决策准确率。

$$E = H_1 \otimes H_2 = H_1 \cdot H_2^T. \quad (22)$$

随机森林采用有放回抽样的方式随机从训练样本中抽取 N_i 个样本子集建立 N_i 棵决策树,在决策树的创建过程中,从所有特征中随机选取比例为 P_m 的特征变量创建决策树, N_i 和 P_m 在模型中都是超参数,不同组合对最终的分类效果产生重要影响。本文以测试样本集的分类精度作为适应度,采用量子菌群算法^[19]对两个超参数进行优化。浮选加药状态识别的具体步骤如下:

Step 1: 采集不同加药状态下浮选槽表面的泡沫图像,并将视频图像分类存储。

Step 2: 对不同加药状态下的泡沫视频图像,在 NSST 域提取泡沫的 6 个等效形态、尺寸分布特征,以及 5 个流动特征。

Step 3: 对不同加药状态下视频图像提取的等效形态、尺寸分布特征和流动特征,分别通过自编码极限学习机进行学习和抽取,然后将两组特征行列矩阵相乘进行特征融合,创建样本数据集。

Step 4: 通过样本数据集训练随机森林多分类器,并采用量子菌群算法^[19]对 N_i 和 P_m 两个超参数进行自适应优化。

Step 5: 实时采集浮选槽表面的泡沫图像,提取泡沫的形态、尺寸分布特征和流动特征,然后通过行列自编码极限学习机对特征进行抽取和融合,最后采用训练的自适应随机森林进行决策分类。

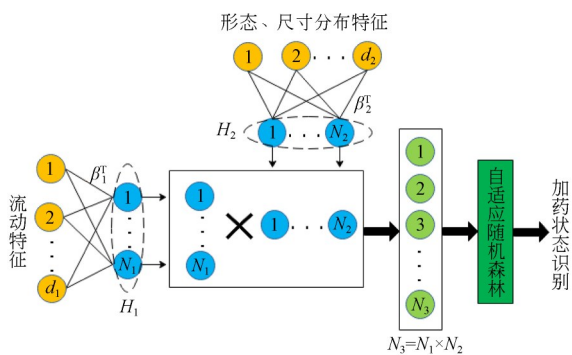


图 2 加药状态识别模型

Fig. 2 Flotation dosing state recognition model

4 实验结果与分析

为验证本文方法的性能,以福建金东矿业股份有限公司的铅矿浮选槽作为实验对象,在精选槽泡沫表面溢流口上方 80 cm 处安装工业 CCD

摄像机及光源,实验硬件平台为 Intel(R) Core (TM) i7-9700 CPU@3 GHz, 8 GB(RAM),软件运行环境为 Windows 7 Matlab 2014a。

4.1 NSST 域 ORB 算法改进效果

在 NSST 域进行 ORB 算法改进实验,并与 SIFT 算法、ORB 算法的实验结果比较,结果如图 3 所示。抽取间隔 $\Delta t=0.5$ s 的连续两帧 256×256 图像 I_t 和 I_{t+1} , NSST 分解得到 1 个低频图像和 5 个尺度高频子带,把第 2, 4 尺度高频子带定为内层,而第 1, 3, 5 尺度高频子带定为外层。两个内层提取的特征点如图 3(b), (c), (f) 和 (g) 所示,融合后得到特征点检测结果如图 3(d) 和 (h) 所示,大部分特征点都均匀分布在泡沫边缘区域,有效解决了簇集现象。对各特征点采用多尺度 BRIEF 描述子进行特征描述,并结合前两帧图像检测的流动速度 (33.99 pixel/s) 和方向 (21.54°) 动态调整搜索的匹配区域,匹配结果如图 3(i) 所示,因循环扩大搜索的匹配范围而出现了误匹配点,通过 RANSAC 算法进一步剔除了所有误匹配点。传统 SIFT 算法的检测结果如图 3(k) 所示,匹配点对较多且分布均匀,但出现了误匹配点。传统 ORB 算法的检测结果如图 3(l) 所示,匹配点对较少且簇集,也出现了少量误匹配点。

为验证本文改进 ORB 算法的抗噪声和尺度变换性能,分别对 100 对叠加均值为 0、不同方差的高斯白噪声图像和 100 对不同尺度比例的图像进行匹配实验,并与近年所提出的改进 SIFT^[20] 和 ORB^[14] 算法进行结果比较分析,平均匹配精度 (正确匹配点对数与总匹配点对数的比率) 和运行时间如表 1 所示,在噪声方差为 10%、尺度比为 1:2 情况下:改进的 SIFT 较原 SIFT 的运算时间较少了一半,抗噪声和尺度变换性能较好,平均匹配精度较高,但是运算效率有待进一步提高;改进的 ORB 算法的抗噪声和尺度变换性大大提升,而且保持较高的运算效率;本文改进 ORB 算法的抗噪声和尺度变换能力大大提升,抗噪声性能优于改进的 SIFT 和 ORB 算法,抗尺度变换性能与改进 SIFT 相当,但是运算效率高于改进的 SIFT 算法。当噪声方差增加到 30%、尺度比增大到 1:8 情况下:3 种算法的匹配性能都大幅度下降,但是本文改进 ORB 算法保持高于 85% 的匹配精度,具有较优的抗噪声和尺度变换能力。

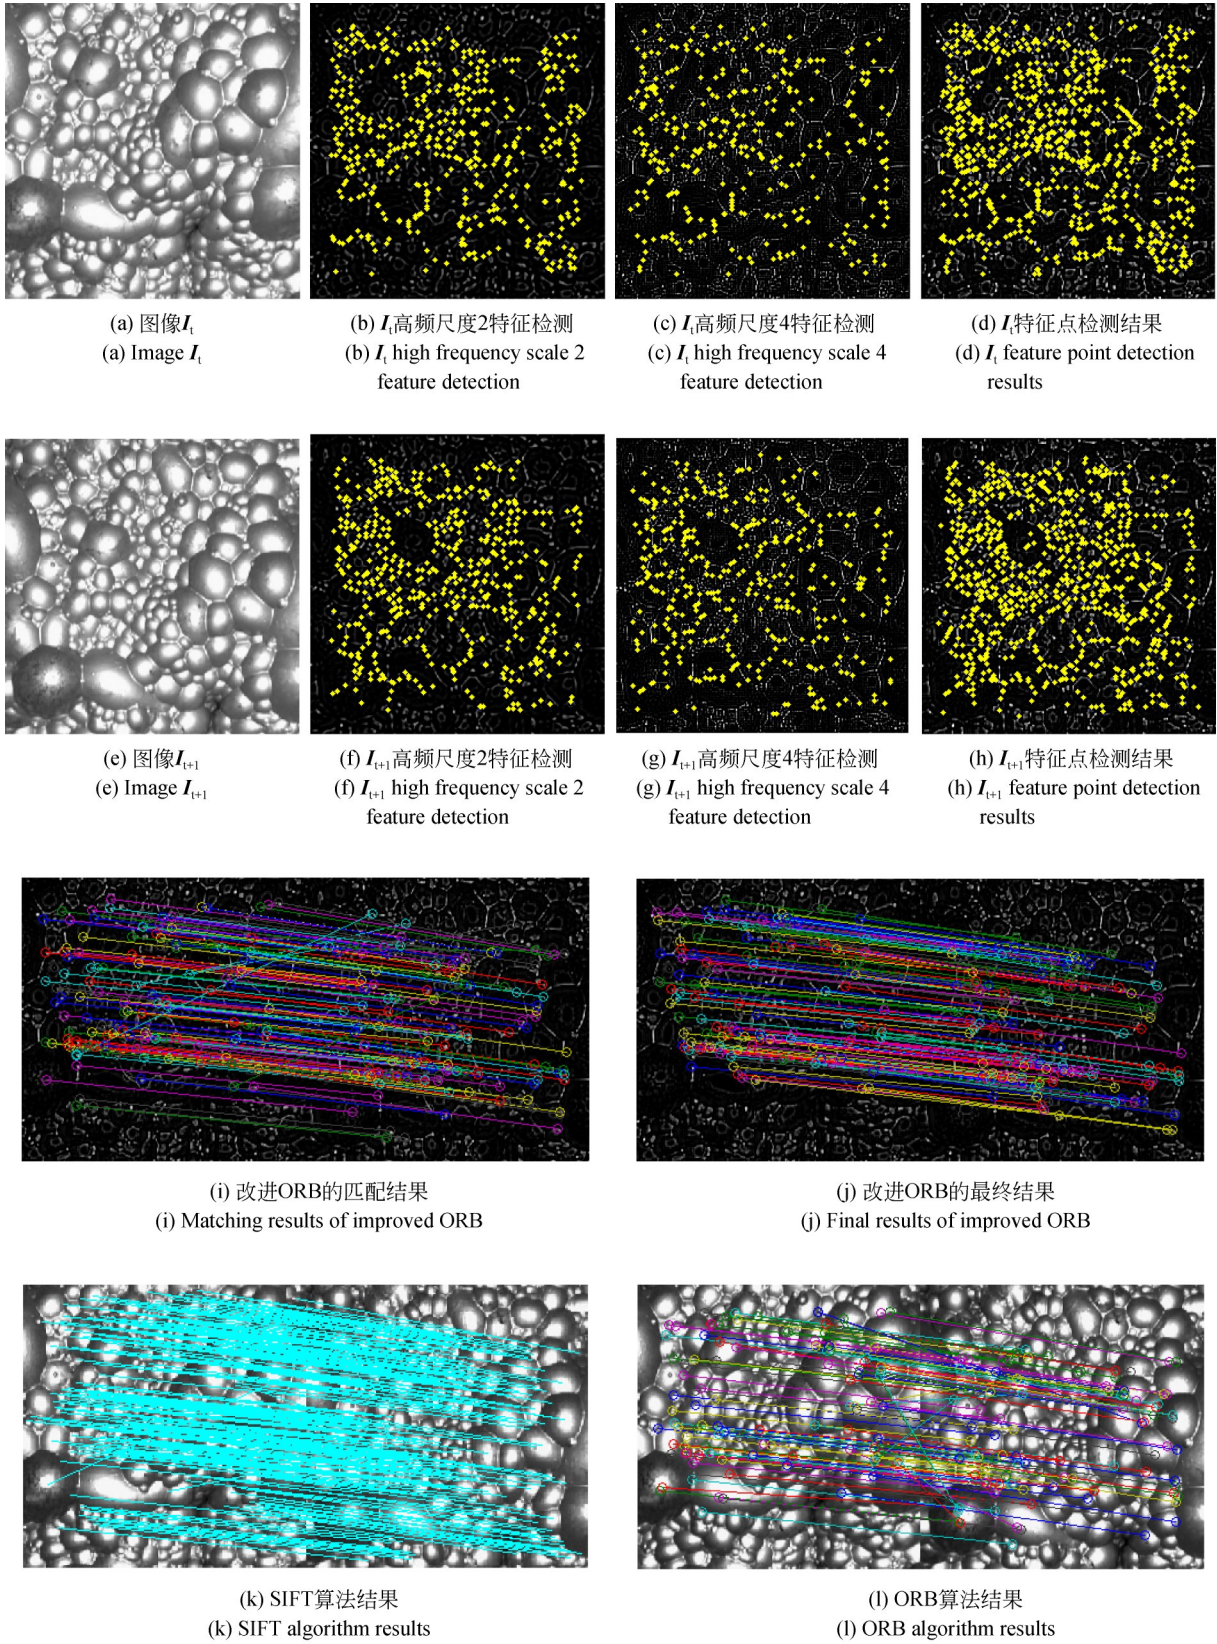


图 3 改进 ORB 的实验结果及比较

Fig. 3 Improved ORB algorithm experimental results and comparison

表 1 匹配精度及运行时间比较

Tab. 1 Comparison of matching accuracy and running time

方法	噪声方差 10%		尺度 1:2		噪声方差 30%		尺度 1:8	
	匹配精度/%	时间/s	匹配精度/%	时间/s	匹配精度/%	时间/s	匹配精度/%	时间/s
改进的 SIFT	94.91	0.982 5	98.72	0.904 1	82.23	1.135 4	81.25	0.854 7
改进的 ORB	92.76	0.250 4	96.34	0.204 3	78.54	0.302 1	74.58	0.186 9
本文方法	95.12	0.405 8	98.56	0.301 2	87.12	0.501 3	85.27	0.279 8

4.2 流动特征提取性能及比较

为验证本文流动特征检测的精度,从采集的图像库中,人工截取实际位移为(20,20)的两帧 256×256 图像 I_t 和 I_{t+1} 进行仿真实验,计算速度大小 v 、方向 θ 、相对误差 $E_v = |v - v_0|/v_0 \times 100\%$ 和 $E_\theta = |\theta - \theta_0|/\theta_0 \times 100\%$ (v_0 和 θ_0 为实际值),以及运行时间,并与现有文献方法进行比较分析,实验结果如图 4 所示,结果数据统计如表 2 所示:文献[6]方法的实验结果如图 4(f),对大津阈值分割的气泡图像进行相位相关计算,运算

效率高,但获取的是两帧图像的整体相对位移,检测精度低;文献[7]方法的匹配结果和速度矢量图如图 4(g)所示,速度矢量图上的带箭头线段代表各个特征点的速度矢量,检测范围广且分布均匀,但是 SIFT 算法的运算效率低。文献[8-9]方法的像素跟踪结果和速度矢量图如 4(h)所示,跟踪错误率低、检测效率高,但是跟踪点较少、分布不均匀。本文方法的实验结果如图 4(e)所示,匹配点多且分布较为均匀, $E_v=0.012 0\%$, $E_\theta=0.045 3\%$,检测精度高,而且运算效率较文献[7]方法有较大提高。

表 2 特征检测结果及比较

Tab. 2 Feature detection results and comparison


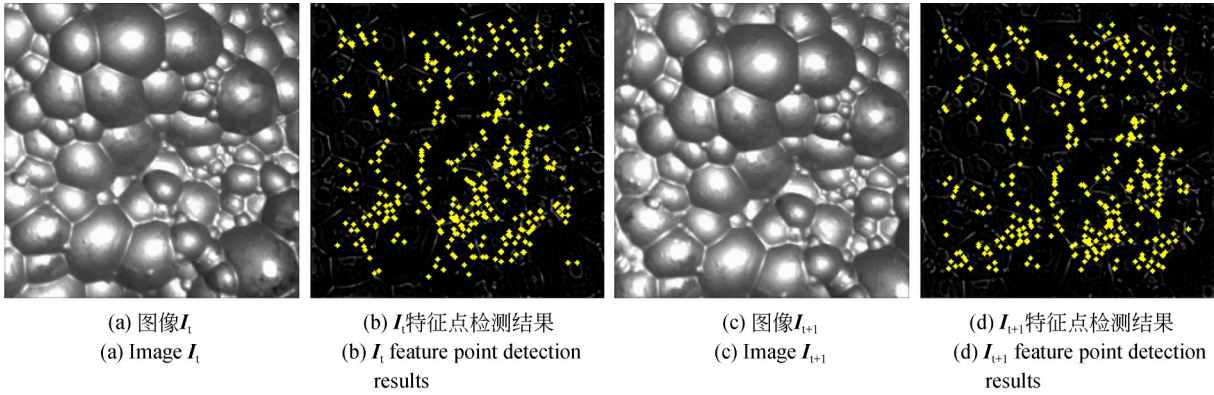
类别	方法	$v_x/(\text{pixel}\cdot\text{s}^{-1})$	$v_y/(\text{pixel}\cdot\text{s}^{-1})$	$v/(\text{pixel}\cdot\text{s}^{-1})$	$\theta/(\text{°})$	$E_v/\%$	$E_\theta/\%$	时间/s
原始图像	文献[6]	19.000 0	20.000 0	27.583 2	46.467 9	1.463 2	3.262 0	0.163 8
	文献[7]	19.989 0	19.649 4	28.536 9	44.753 0	0.252 7	0.247 0	2.314 3
	文献[8]	20.194 2	20.043 3	28.458 3	44.778 5	0.615 3	0.492 2	0.259 6
	本文方法	19.993 6	20.009 7	28.287 7	45.020 4	0.012 0	0.045 3	0.407 2
噪声图像	文献[6]	19.000 0	20.000 0	27.586 2	46.467 9	1.463 2	3.262 0	0.171 9
	文献[7]	19.856 8	19.561 5	28.609 8	45.194 8	1.151 0	0.432 9	2.384 2
	文献[8]	17.852 3	17.138 4	33.482 5	42.357 5	5.198 3	2.642 5	0.305 8
	本文方法	20.021 2	20.028 2	28.324 3	45.002 1	0.141 4	0.004 7	0.442 2
亮度变化图像	文献[6]	19.000 0	19.000 0	26.870 1	45.000 0	5.000 7	0.000 0	0.163 3
	文献[7]	18.651 3	19.741 0	29.410 1	44.394 2	3.981 3	1.346 4	2.134 1
	文献[8]	18.806 2	21.434 3	30.134 4	43.394 9	1.850 1	1.605 1	0.281 2
	本文方法	19.958 1	20.076 7	28.318 3	45.164 8	0.120 6	0.366 2	0.380 2

为验证本文方法的抗噪声和光照影响的性能,对图像叠加均值为 0、方差为 20% 的高斯白噪声,如图 5(a)和(b)所示,对 I_{t+1} 通过伽马校正进行亮度非线性调整,如图 5(c)所示。采用不同方法对两种图像进行实验,结果如图 5(d)~图 5(g)所示,数据统计如表 2 所示:文献[6]方法的功率谱峰值图如 5(d)所示,获取的是两

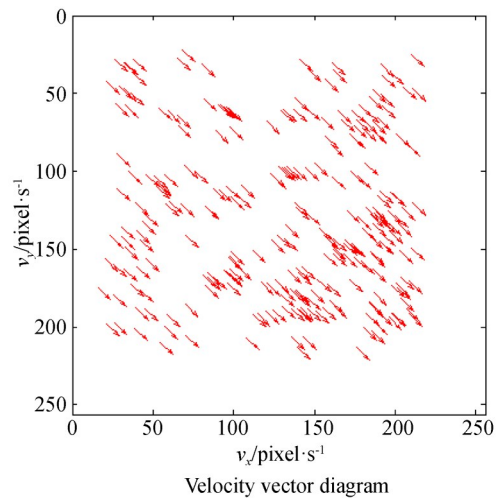
帧图像的整体相对位移,运算效率高,但气泡分割结果受噪声和光照变化影响大,导致检测精度不高;文献[7]方法的速度矢量图如 5(e)所示,检测范围广且分布均匀,抗噪声性能好,但是运算效率低,光照影响下的检测精度不高;文献[8-9]方法的像素跟踪矢量图如 5(f)所示,检测效率高,但是跟踪点较少、分布不均匀,在噪声

和光照变化的干扰下跟踪容易出错,导致检测精度低。本文方法的结果如图 5(g)所示,匹配点多且分布均匀,在噪声和光照变化影响下匹


配点减少但分布均匀,相对误差 E_v 和 E_θ 都较小,仍然保持较高的检测精度,抗噪声和光照影响能力强。



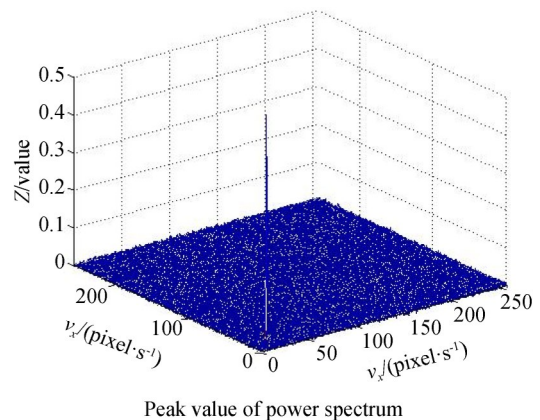
Improved ORB matching results of NSST threshold



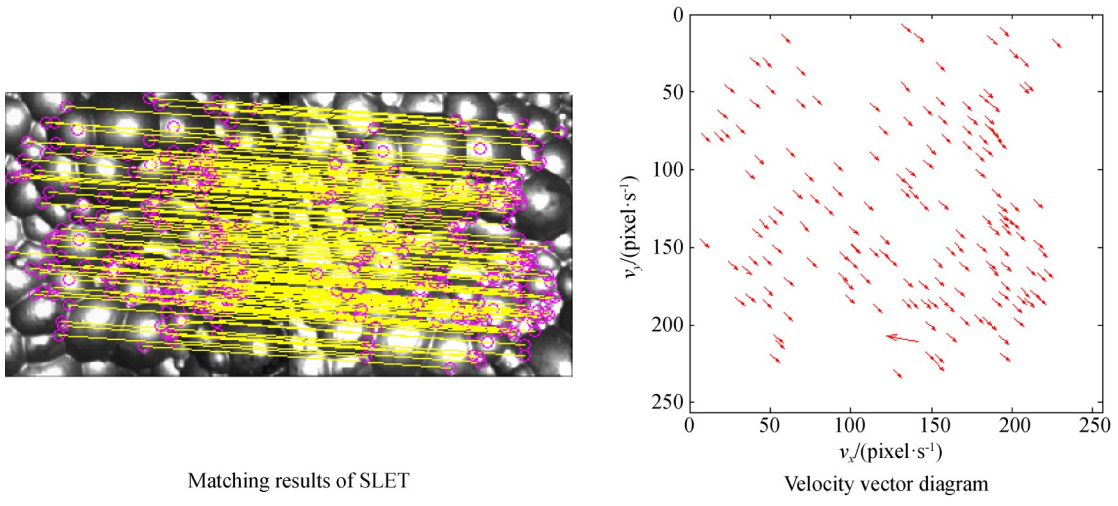
(e) 本文方法结果
(e) Results of proposed method



Results of otsu threshold segmentation

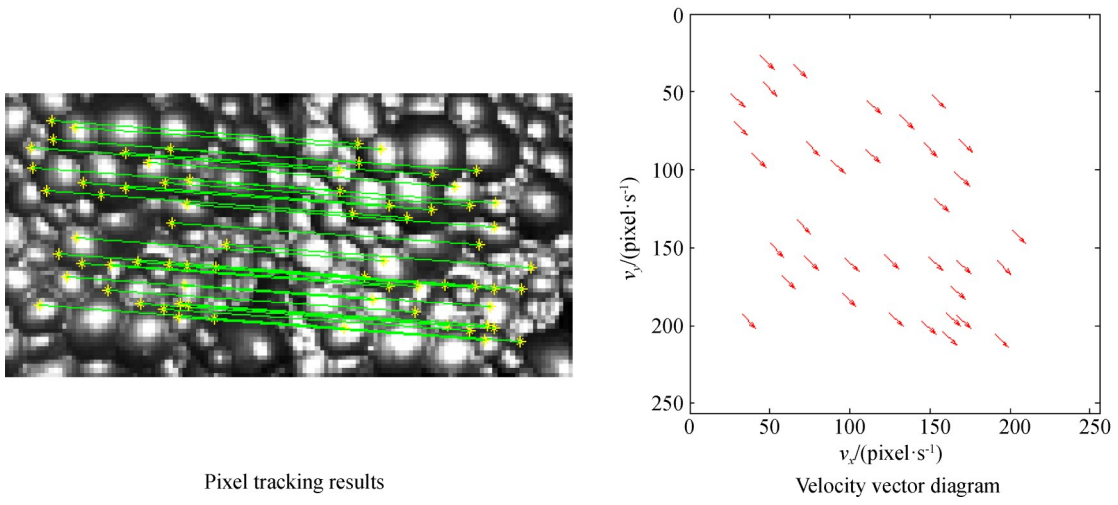


(f) 文献[6]方法结果
(f) Result of Ref.[6]



Matching results of SLET

(g) 文献[7]方法结果
(g) Result of Ref.[7]




Pixel tracking results


(h) 文献[8-9]方法结果
(h) Result of Ref.[8-9]

图 4 特征检测效果及比较


Fig. 4 Feature detection effect and comparison



(a) 噪声图像 I_t
(a) Noise image I_t



(b) 噪声图像 I_{t+1}
(b) Noise image I_{t+1}



(c) I_{t+1} 亮度非线性调整
(c) I_{t+1} brightness nonlinear adjustment

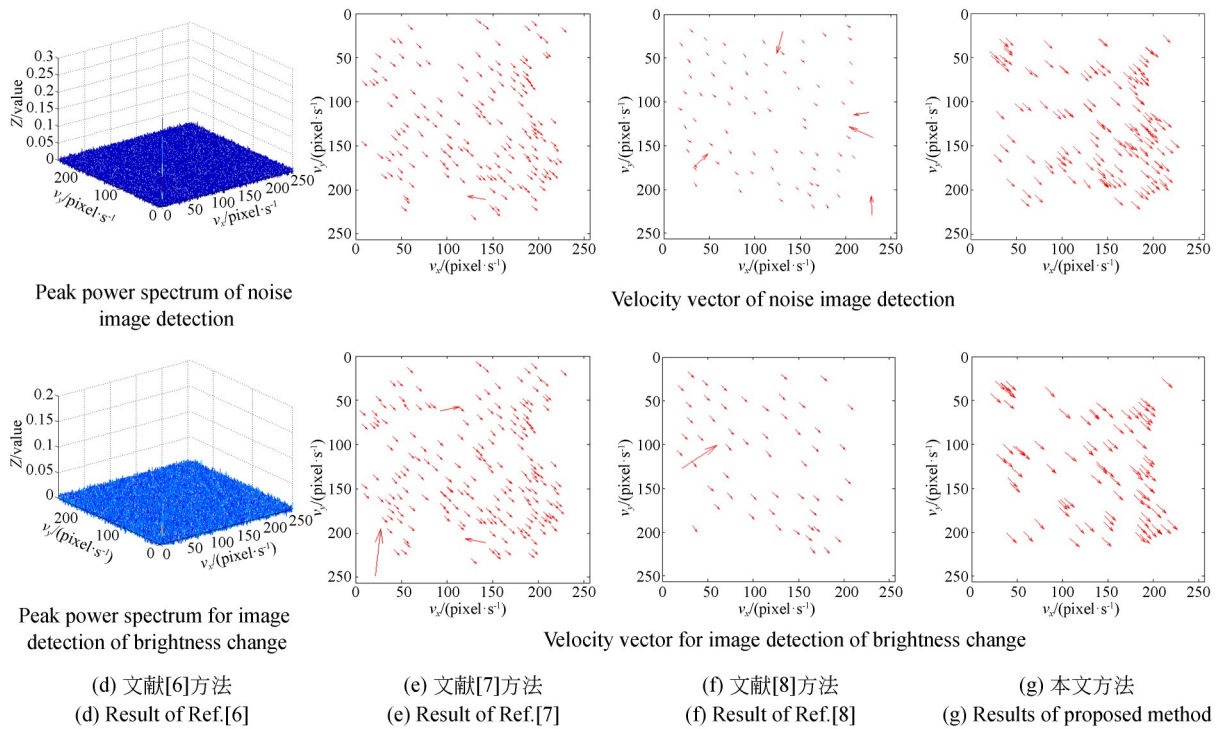



图 5 抗噪声和光照影响性能

Fig. 5 Noise and light resistance affect performance

4.3 浮选加药状态识别

为了使相机镜头不受其气泡飞溅矿浆的影响,浮选表面离相机镜头的距离为 80 cm,匹配镜头为 CMP 百万级工业镜头 M0814-MP,调节镜头的焦距距 8 mm。采集铅矿精选槽在正常加药、欠量、过量、故障等 4 种状态下的泡沫视频图像,然后进行泡沫形态、尺寸分布特征和流动特征提取,以平行刮板转轴的方向为 X 轴方向、流溢口的方向为 Y 轴方向,实验结果如图 6 所示:正

常加药下泡沫流动速度保持在 20 ~ 50 pixel/s 之间且变化缓慢,流动方向为 75° ~ 100°,大部分朝着流溢口的方向流动,加速度较小且变化不大,流动速度和方向有一定无序度;加药过量下泡沫流动速度处在 5 ~ 25 pixel/s,流动缓慢且曲线呈现周期性的上下波动,流动方向稳定在 90°附近,加速度较小且波动不大,但速度呈现极大的无序性;欠药量下泡沫流动速度在 40 ~ 60 pixel/s 之间且上下波动较大,流动方向稳定在 70°左右,加



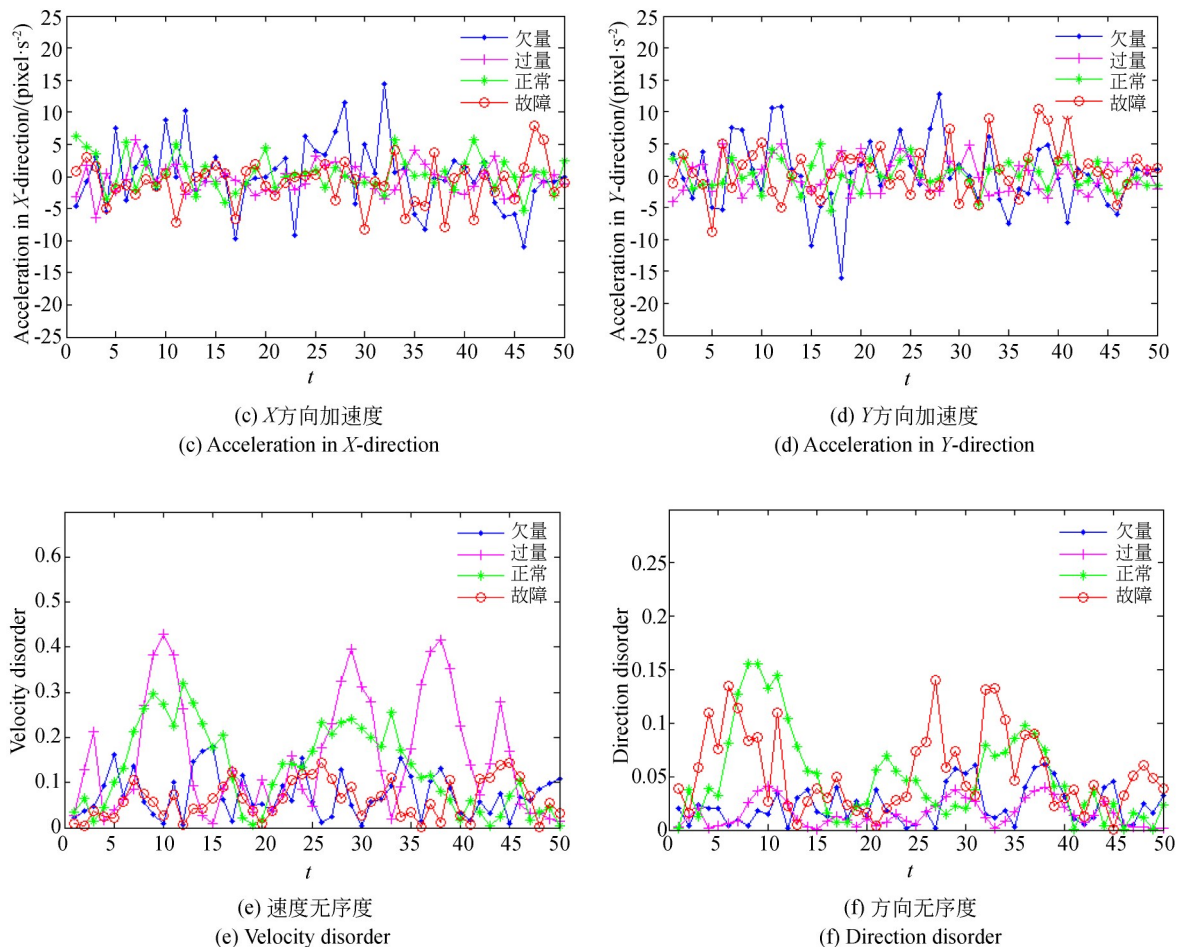


图 6 不同加药状态下的流动特征提取结果

Fig. 6 Extraction results of flow characteristics under different dosing states

速度较大且变化幅度大,速度和方向的无序度小;故障状态下泡沫流动速度在 50~70 pixel/s 之间,流动快且上下波动较大,流动方向在 $50^\circ \sim 70^\circ$ 之间来回变化,加速度较大且变化幅度大,流动方向呈现较大的无序性。实验数据表明:提取的流动特征与实际加药状态下的泡沫流动趋势吻合,实现了流动特征的定量描述,能准确表征各加药状态下泡沫的流动特性,且在各状态下具有一定的区分度,可作为加药状态预测的有效特征。

采集 4 种加药状态下各 2 500 组泡沫图像,其中 $2\,000 \times 4$ 组作为训练集,其他 500×4 组作为测试集,提取各组图像的 5 个形态、尺寸分布特征和 6 个流动特征,然后通过行列自编码极限学习机对这些特征学习和抽取,设置自编码极限学习机

的隐含节点与输入节点数相同($N_1=6, N_2=5$),两组特征行列矩阵相乘后得到 30 维的特征向量。为验证本文行列自编码极限学习机的性能,分别采用原始的 11 个特征和融合后的 30 个特征对随机森林进行训练和测试,参数 N_l 取值范围:100~900, P_m 取值范围:0.1~0.9,在取值范围内调整两个参数进行实验,两种方法的测试准确率曲面图如图 7(a),(b)所示:本文通过行列自编码极限学习机的特征学习和抽取,将两类特征进行融合及维度扩展,有助于扩大不同决策树间样本采样和特征选取的差异程度,避免产生过拟合现象,整体准确率大大提升,分类精度受 N_l 和 P_m 的影响而产生的波动小,稳定性好。为验证本文加药状态识别效果,训练过程中采用量子菌群算法自适应获取随机森林算法的最优参数 $N_l=$




图7 测试准确率曲面图

Fig. 7 Surface diagram of test accuracy

503, $P_m=0.6$, 各加药状态的识别结果如表3所示, 本文方法能有效识别4种不同的加药状态, 平均识别准确率达到97.85%。

表3 加药状态识别结果

Tab. 3 Identification results of dosing status

实际状态	识别状态				识别率/%
	正常	过量	欠量	故障	
正常	483	10	7	—	96.6
过量	6	491	3	—	98.2
欠量	5	—	488	7	97.6
故障	—	—	5	495	99.0

表4 噪声与光照变化测试结果

Tab. 4 Test results of noise and light change

高斯噪声方差/%	5	10	15	20	25	30	40
伽马校正系数	0.7	0.8	0.9	1.1	1.2	1.3	1.5
平均识别率/%	97.81	97.75	96.25	94.86	90.03	83.02	71.14
平均识别率/%	88.63	93.56	97.06	97.23	96.72	92.35	85.12

为进一步验证本文方法的优势, 采用相同的数据集对现有文献方法进行试验, 统计各方法的平均识别精度、标准差以及平均运行时间, 实验结果如表5所示: 文献[1]采用分水岭分割方法提取泡沫大小分布特征, 建立 Hammerstein-Wiener 非线性模型对泡沫加药状态进行预测, 运算效率高, 识别精度达到90%以上, 但是提取的特征单一, 且识别精度受分割精度影响大, 识别精度有

待进一步提高, 稳定性差; 文献[2]采用形状加权大小分布来表征泡沫特征, 通过最小二乘支持向量机对泡沫加药状态进行识别, 进一步提高了识别精度, 标准差也较小; 文献[3]基于时间序列图像提取泡沫大小累积分布特征, 采用形状加权大小分布来表征泡沫特征, 建立 XGBoost 非线性模型实现泡沫加药状态识别, 具有较高的识别精度, 稳定性好, 但是运算效率低; 文献[4]构建

CNN 网络提取泡沫图像特征,通过训练的 SVM 进行筛选加药状态判别,大规模数据集训练下具有较高的识别率,但是在等同的小样本数据集下识别精度较低;本文方法的流动特征提取精度高,构建行列自编码极限学习机对泡沫形态、尺寸分布特征和流动特征进行融合,然后通过自适

应随机森林对加药状态识别,扩大了决策树间样本采样和特征选取的差异程度,泛化性能好,平均识别率达 97.85%,标准差为 1.01%,识别精度和稳定性较文献[1,2,4]方法有较大提升,与文献[3]方法的识别精度相当,但提高了运算效率。

表 5 不同方法的识别效果

Table 5 Recognition effect of different methods

方法	特征提取方法	识别算法	准确率/%	标准差/%	时间/s
文献[1]	泡沫尺寸分布特征	Hammerstein—Wiener	92.75	3.36	1.054 6
文献[2]	泡沫形状加权大小分布特征	最小二乘支持向量机	94.75	1.59	1.987 0
文献[3]	泡沫大小累积分布特征	XGBoost	97.89	1.13	3.454 6
文献[4]	CNN 特征	SVM	87.93	2.52	1.865 1
本文方法	泡沫等效形态、尺寸分布特征 泡沫流动特征	行列自编码极限学习机 自适应随机森林	97.85	1.01	2.396 2

5 结 论

本文提出了一种基于 NSST 域改进 ORB 算法的泡沫流动特征提取及加药状态识别方法。对各高频方向子带采用尺度相关性去除噪声系数,有效提高了算法的抗噪性能。在多尺度域结合方向模板极大值检测和非极大值抑制在边缘区域提取特征点,采用多尺度 BRIEF 描述子对特征点描述,解决了特征点的簇集现象和尺度不变性,使特征点描述具有旋转不变性,改进的 ORB 算法的抗噪声和尺度变换性能增强。构建行列

自编码极限学习机对泡沫形态、尺寸分布特征和流动特征进行融合,然后通过自适应随机森林对加药状态识别,扩大了决策树间样本采样和特征选取的差异程度,以减少过拟合现象,提升决策准确率。本文方法实现了泡沫流动特征的定量描述,受噪声和光照影响小,检测精度和运算效率较现有方法有较大提高,能准确地表征不同加药状态下泡沫表面的流动特性,并应用于加药状态识别,平均识别精度达 97.85%,较现有文献方法有较大提升,为后续的加药量优化控制奠定基础。

参考文献:

- [1] ZHANG J, TANG Z H, AI M X, *et al.*. Nonlinear modeling of the relationship between reagent dosage and flotation froth surface image by Hammerstein-Wiener model[J]. *Minerals Engineering*, 2018, 120(5):19-28.
- [2] AI M X, XIE Y F, XIE S W, *et al.*. Shape-weighted bubble size distribution based reagent predictive control for the antimony flotation process [J]. *Chemometrics & Intelligent Laboratory Systems*, 2019, 192(8):103821.

- [3] TANG Z H, TANG L Y, ZHANG G Y, *et al.*. Intelligent setting method of reagent dosage based on time series froth image in zinc flotation process [J]. *Processes*, 2020, 8(536):8050536.
- [4] 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.
- [5] CAO B F, XIE Y F, GUI W H, *et al.*. Coordinated optimization setting of reagent dosages in roughing-scavenging process of antimony flotation [J]. *Jour-*

- nal of Central South University*, 2018, 25 (1) : 95-106.
- [6] 陈良琴,王卫星. 基于气泡跟踪与相位相关的浮选表面气泡平移运动估计[J]. 四川大学学报(工程科学版),2016,48(5):143-152.
CHEN L Q, WANG W X. Flotation surface bubble displacement motion estimation based on bubble tracking and phase correlation[J]. *Journal of Sichuan University(Engineering Science Edition)*, 2016, 48(5):143-152. (in Chinese)
- [7] WANG Y L, SUN B, ZHANG R Q, *et al.*. Sulfur flotation performance recognition based on hierarchical classification of local dynamic and static froth features [J]. *IEEE Access*, 2018, 6 (3) : 14019-14029.
- [8] NAKHAEI F, IRANNAJAD M, MOHAMMAD-NEJAD S. Evaluation of column flotation froth behavior by image analysis: effects of operational factors in desulfurization of iron ore concentrate[J]. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 2018, 40(19) : 2286-2306.
- [9] NAKHAEI F, IRANNAJAD M, MOHAMMAD-NEJAD S. Column flotation performance prediction: PCA, ANN and image analysis-based approaches [J]. *Physicochemical Problems of Mineral Processing*, 2019, 55(5) : 1298-1310.
- [10] RUBLEE E, RABAUND V, KONOLIGE K, *et al.*. ORB: An efficient alternative to SIFT or SURF [C]. *Int Conf on Computer Vision. Barcelona:IEEE*, 2011: 2564-2571.
- [11] GANASALA P, PRASAD A D. Contrast enhanced multi sensor image fusion based on guided image filter and NSST [J]. *IEEE Sensors Journal*, 2020, 20(2) : 339-346.
- [12] 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.
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. (in Chinese)
- [13] DONG Q, LIU J H, WANG C, *et al.*. Image mosaic algorithm based on improved BRISK [J]. *Journal of Electronics & Information Technology*, 2017, 39(2) : 444-450.
- [14] 樊彦国,柴江龙,许明明,等. 基于 ORB 与 RANSAC 融合改进的图像配准[J]. 光学精密工程, 2019, 27(3) : 702-717.
FAN Y G, CHAI J L, XU M M, *et al.*. Improved fast Image registration algorithm based on ORB and RANSAC fusion [J]. *Opt. Precision Eng.*, 2019, 27(3) : 702-717. (in Chinese)
- [15] SONG J L, YANG J H, LIU F J, *et al.*. High temperature strain measurement method by combining digital image correlation of laser speckle and improved RANSAC smoothing algorithm [J]. *Optics and Lasers in Engineering*, 2018, 111: 8-18.
- [16] 黄凌霄,廖一鹏. 浮选气泡 NSCT 域多尺度等效形态特征提取及识别[J]. 光学精密工程, 2020, 28(3) : 704-716.
HUANG L X, LIAO Y P. Recognition and multi-scale equivalent morphological features extraction of flotation bubbles in nsct domain [J]. *Opt. Precision Eng.*, 2020, 28(3) : 704-716. (in Chinese)
- [17] 吴海滨,陈寅生,张庭豪,等. 改进多尺度幅值感知排列熵与随机森林结合的滚动轴承故障诊断[J]. 光学精密工程, 2020, 28(3) : 621-631.
WU H B, CHEN Y S, ZHANG T H, *et al.*. Rolling bearing fault diagnosis by improved multiscale amplitude-aware permutation entropy and random forest [J]. *Opt. Precision Eng.*, 2020, 28 (3) : 621-631. (in Chinese)
- [18] 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.
- [19] 廖一鹏,张进,王志刚,等. 结合双模多尺度 CNN 特征及自适应深度 KELM 的浮选工况识别[J]. 光学精密工程, 2020, 28(8) : 1785-1798.
LIAO Y P, ZHANG J, WANG ZH G, *et al.*. Flotation performance recognition based on dual-

modality multiscale CNN features and adaptive deep learning KELM [J]. *Opt. Precision Eng.*, 2020, 28(8): 1785-1798. (in Chinese)

- [20] 牛燕雄,陈梦琪,张贺. 基于尺度不变特征变换的快速景象匹配方法[J]. 电子与信息学报, 2019,


41(3): 626-631.

NIU Y X, CHEN M Q, ZHANG H. Fast scene matching method based on scale invariant feature transform [J]. *Journal of Electronics & Information Technology*, 2019, 41(3): 626-631. (in Chinese)

作者简介:



廖一鹏(1982—),男,福建泉州人,博士生,讲师,2005年于福州大学获得学士学位,2008年于福州大学获得硕士学位,现为福州大学物理与信息工程学院教师,主要从事图像处理与模式识别方面的研究。E-mail: fzu_lyp@163.com



王卫星(1959—),男,湖南人,博士,教授,博士生导师,1982年和1985年分别在国内获得学士学位和工程硕士,1997年于瑞典皇家工学院获得博士学位,主要从事图像处理与模式识别、机器视觉应用等方面研究。E-mail: wxw@fzu.edu.cn