

数据驱动的锑粗选泡沫图像特征优化设定

吴佳, 谢永芳, 阳春华, 桂卫华

(中南大学信息科学与工程学院, 长沙 410083)

摘要: 针对锑浮选过程中精、尾矿品位难以在线检测, 浮选性能不稳定的问题, 提出一种数据驱动的泡沫图像特征优化设定方法. 该方法根据入矿品位类型对泡沫图像特征进行优化设定, 并针对不同入矿品位类型的样本分布特点, 先尝试采用案例推理的方法从历史数据中寻找浮选性能优良的泡沫状态. 若经验知识不足, 则采用基于多中心模糊C均值聚类与概率支持向量回归的区间II型模糊系统建模方法建立精、尾矿品位指标模型, 并在此基础上利用智能优化方法寻优泡沫图像特征值. 某锑浮选工业实验结果表明了所提出方法的有效性.

关键词: 数据驱动; 锑浮选; 案例推理; 模糊C均值聚类; 支持向量回归

中图分类号: TP273

文献标志码: A

Data-driven optimal setting for froth image features of stibium rougher flotation

WU Jia, XIE Yong-fang, YANG Chun-hua, GUI Wei-hua

(School of Information Science and Technology, Central South University, Changsha 410083, China. Correspondent: XIE Yong-fang, E-mail: yfxie@csu.edu.cn)

Abstract: Due to the difficulties of measuring concentrate and tailing grade online and unstability of the flotation performance, a data-driven optimal setting for froth image features is proposed. The froth image features are optimal set according to the type of feed ore grade. Considering the distribution nature of samples of each feed grade type, it is tried to use case-based reasoning method for obtaining the froth status with optimal flotation performance from history data. When lack of enough experiential knowledge, the interval type II fuzzy system modeling method based on the multi-centers fuzzy C-means clustering and probabilistic support vector regress method is adopted to build the concentrate and tailing grade model. Then intelligent optimization algorithm is applied to search the optimal values for the froth image features. The application to the stibium flotation process shows the effectiveness of the proposed method.

Keywords: data-driven; stibium flotation; case-based reasoning; fuzzy C-means clustering; support vector regress

0 引言

锑粗选是锑浮选流程中的一道关键工序, 绝大部分含锑矿物在粗选中被分离出来, 这对于精、尾矿品位指标具有决定性作用. 为了改善含锑矿物的可浮性, 在锑粗选加入黄药、二号油等多种药剂. 精、尾矿品位难以在线检测, 浮选工只能通过肉眼观察泡沫调整药剂. 由于对泡沫状态的认知主观性强, 将泡沫状态作为加药调整的依据易导致浮选性能不稳定, 甚至恶化. 因此, 如何确定泡沫图像特征优化状态以指导浮选过程控制具有重要意义.

近年来, 采用机器视觉代替肉眼观察泡沫来实现

浮选过程监控已成为国内外学者研究的热点^[1-2]. 为使浮选性能满足生产要求, 基于机器视觉的浮选过程控制器通过调整操作量(加药量、液位等)使得泡沫图像特征稳定在一个期望状态. Liu等^[3]首先建立基于PLS的泡沫图像特征与加药量的关系模型, 然后基于该模型给出硫酸铜的调整量, 使得锌浮选泡沫图像特征达到给定值; Zhu等^[4]采用模型预测方法实施加药量控制, 使得铜浮选泡沫尺寸概率密度分布达到期望状态; Gianni等^[5]通过调整加药量使得泡沫尺寸大小达到设定值. 这些研究极大地促进了浮选性能的提高和浮选工况的稳定, 但也引出了另外一个关键问题,

收稿日期: 2015-05-10; 修回日期: 2015-10-11.

基金项目: 国家自然科学基金重点项目(61134006); 国家自然科学基金项目(61473318, 61304126).

作者简介: 吴佳(1982-), 男, 博士生, 从事复杂有色冶金过程建模、数据挖掘的研究; 谢永芳(1972-), 男, 教授, 博士生导师, 从事分散鲁棒控制、故障诊断等研究.

即图像特征的期望值如何设定.为了获取泡沫图像特征的最优模式,常用的方法是归纳总结经验知识和分析泡沫图像特征与浮选性能指标(精矿品位、回收率等)的相关性,如Moolman等^[6]基于经验将泡沫分为理想泡沫、水泡和干泡,Kaartinena等^[7]采用相关分析法得到钽浮选泡沫的最优模式.以上方法在矿源性质相对稳定和不考虑样本数据存在不确定性时才能取得较好的效果.而钽浮选中入矿品位时常变化,根据经验,当入矿品位类型变化时,矿浆性质也会随之变化,泡沫图像特征亦会呈现较大的差别.因此,泡沫图像需要根据入矿品位类型进行优化设定.不同的入矿品位样本数据分布存在差异,入矿品位作为独立变量,呈近似高斯分布,低入矿品位和高入矿品位类型的样本数据相对于中入矿品位类型要少很多,且高入矿品位类型往往导致尾矿品位要求难以达到,低入矿品位类型也易导致精矿品位难以满足生产要求.因此,在高入矿品位和低入矿品位类型下满足生产要求的历史数据相对较少,导致可依据的经验知识不足.另外,在浮选过程中剧烈的搅拌和鼓风作用下,泡沫具有动态波动特性,使得泡沫图像特征数据具有不确定性.因此,在经验知识不充分的情况下,通过分析泡沫图像特征与浮选性能指标之间的关系获取泡沫的优良状态就更加困难.

为此,研究基于经验与建模相结合的数据驱动方法,以寻优钽粗选泡沫图像特征设定值.数据驱动的方法首先尝试从历史经验中搜索与当前工况相匹配的解,如果能得到满足要求的解,则直接输出;否则建立性能指标模型,并采用智能搜索算法得到新问题的解.文献[8]采用操作模式匹配与基于神经网络模型寻优的数据驱动方法来优化设定铜闪速熔炼的氧气量与热风量;文献[9]采用操作模式与基于投影寻踪回归模型寻优的数据驱动方法来优化设定铜闪速熔炼的风量、氧量及造渣剂.借鉴以上研究工作经验,结合钽粗选过程特点,提出一种基于案例推理(CBR)、多中心模糊C均值聚类和概率支持向量回归(MCFCM_PSVR)的区间II型模糊模型的泡沫图像特征优化设定方法.案例推理是一种通过学习过去经验知识来解决新问题的技术^[10],例如文献[11]提出了一种基于案例推理的浮选过程液位、进气量以及加药量的优化控制方法,因此首先尝试采用案例推理的方法从历史经验中获取泡沫图像特征的优化设定值.而当案例推理无法获取满意解时,首先建立基于MCFCM_PSVR的区间II型模糊的指标模型.区间II型模糊系统是近年来处理数据不确定性问题而快速发展的一种技术^[12],例如文献[13]针对噪声污染的数

据提出一种区间II型模糊神经网络-支持向量机的建模方法.在钽粗选中,外部干扰(例如给矿量波动)与过程的动态波动特性使得泡沫图像即使在相对稳定的阶段也会在一个区间内不确定.若采用I型模糊方法建模,将无法处理泡沫图像数据与浮选性能指标关系间的不确定性;而II型模糊系统将数据的隶属度进一步模糊化,增强了系统处理数据不确定性的能力.为了建立基于区间II型模糊系统的精、尾矿品位软测量模型,采用多中心FCM聚类法对样本进行聚类,使输入数据的隶属度进一步模糊化,并采用能够处理噪声数据的PSVR建模方法^[14]建立子模型,最后基于指标模型采用状态转移算法^[15]寻优泡沫图像特征值.工业实验表明,所提方法能够有效指导浮选生产,为稳定浮选生产和改善浮选性能起到了重要作用.

1 钽粗选图像特征优化设定策略

为改善浮选性能,利用泡沫图像特征来指导加药量控制.分别采用改进的谷底边缘检测、亮点修复和多颜色空间泡沫颜色特征提取,以及尺度不变特征点配准等方法^[16-18]提取钽粗选的泡沫尺寸、颜色、速度等13种图像特征.采用敏感性指数和属性重要度^[19]的方法对泡沫图像特征集进行约简,得到蓝色分量均值(0~255阶)、泡沫平均尺寸(泡沫包含的像素点)、承载率(颜色偏黑的占比)和色度(0~360°)等4种能够充分反映浮选工况信息的关键泡沫图像特征.所提出的钽粗选泡沫图像特征优化设定的框架如图1所示, I 、 O 分别代表离线化验得到的入矿品位、精矿和尾矿品位数据, P 、 S 分别代表可在线获取的加药量和图像特征参数, i^C 代表当前入矿品位类型, O^* 代表浮选性能指标(精、尾矿品位)要求, S^* 代表泡沫图像特征优化设定值.

泡沫图像特征优化设定分为两个阶段.

阶段1:基于案例推理的泡沫图像特征优化设定.如果符合当前生产要求的泡沫状态能从历史经验中匹配得到,则可快速地用于泡沫图像特征优化设定.因此,首先尝试采用案例推理的方法从历史经验中寻优泡沫图像特征的设定值.

阶段2:基于浮选指标模型寻优的泡沫图像特征优化设定.由于矿源性质、外界扰动等不可避免地带来工况的改变,再加上在高入矿品位和低入矿品位类型的案例子库中案例相对较少,并不能保证历史经验中存在符合当前生产要求的泡沫状态.为此,根据入矿品位类型建立基于MCFCM_PSVR的区间II型模糊的浮选指标估计模型,然后采用状态转移算法寻优泡沫图像特征值.

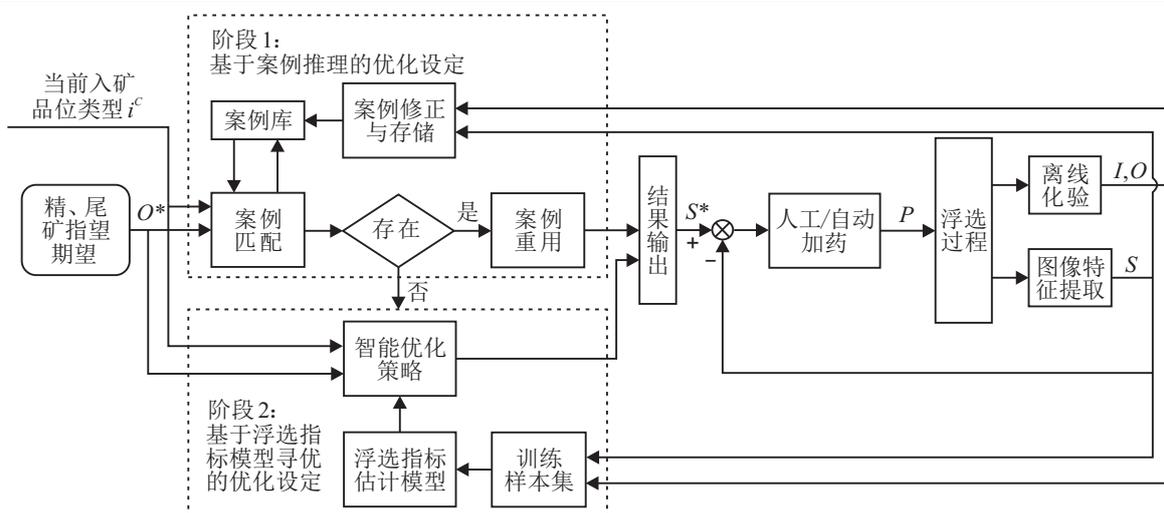


图 1 锡粗选图像特征优化设定策略

2 基于案例推理的图像特征优化设定

如果历史数据丰富,则可以采用案例推理的方法对图像特征进行优化设定.首先,根据粗选槽精、尾矿品位的期望及给矿品位类型组成的案例在案例库中检索到与之相似的案例;然后,根据设定的相似度阈值对其进行匹配和重用,得到当前工况输入特征的案例解作为结果输出,即泡沫图像特征设定值;最后,根据泡沫图像特征设定值的应用效果,判定是否需要对其进行修正,从而使案例库得到更新.案例库存储的是浮选过程运行的历史数据.对于锡粗选,每个案例的工况描述由入矿品位类型 i_1^C 、精矿品位 o_1 和尾矿品位 o_2 组成.案例解由4个关键泡沫图像特征组成,分别为蓝色分量均值 s_1 、泡沫平均尺寸 s_2 、承载率 s_3 、色度 s_4 .第 k 个案例用 $C_k = F_k, J_k$ 表示,其对应关系如表1所示.

表 1 案例描述

工况描述			解			
i_1^C	o_1	o_2	s_1	s_2	s_3	s_4
f_1	f_2	f_3	j_1	j_2	j_3	j_4

假设当前运行工况 C_t 的工况描述为 $F = \{f_1, f_2, f_3\}$,它的解为 $J = \{j_1, j_2, j_3, j_4\}$;案例库中有 m 个案例 C_1, C_2, \dots, C_m ,案例 C_k 的工况描述为 $F_k = \{f_{k,1}, f_{k,2}, f_{k,3}\}$,对应的解为 $J_k = \{j_{k,1}, j_{k,2}, j_{k,3}, j_{k,4}\}$.为了得到 C_t 的解,案例推理包含如下几个步骤.

Step 1 案例匹配.根据入矿品位类型 i_1^C 将案例库中的所有案例进行分类,并以当前运行工况的入矿品位类型 f_1 作为匹配对象确定与 C_t 匹配的案例库子集.定义当前工况案例描述 f_i ($i = 2, 3$)与案例库子集中的案例描述 $f_{k,i}$ 的相似度为

$$\text{sim}(f_i, f_{k,i}) = 1 - |f_i - f_{k,i}| / \max(f_i, f_{k,i}), \quad (1)$$

其中 $\max(f_i, f_{k,i})$ 表示取 f_i 与 $f_{k,i}$ 的较大值.则 F 与案例子集中 F_k 的相似度为

$$\text{Sim}(F, F_k) = \frac{\sum_{i=1}^2 (w_i \times \text{sim}(f_{i+1}, f_{k,i+1}))}{\sum_{i=1}^2 w_i}. \quad (2)$$

其中: $\sum_{i=1}^2 w_i = 1$, w_i 为权系数,其大小由入矿品位类型 i_1^C 确定,当入矿品位类型低时更注重精矿品位是否满足要求;而入矿品位类型高时,会更加重视尾矿品位指标.因此, w_1 的取值会随着入矿品位的提高而减小,而 w_2 则会随着入矿品位的提高而增大.从低入矿品位到高入矿品位类型的 w_1 的取值分别为0.7、0.6、0.5、0.4、0.3, $w_2 = 1 - w_1$.设定相似度阈值(经验取值0.9),当相似度值 $\leq \alpha$ 时,则认为案例符合要求的匹配案例.如果匹配案例存在,则进入案例重用阶段;否则进入基于模型寻优的泡沫图像特征优化设定过程.

Step 2 案例重用.假定从案例库中匹配出 h 个案例 $\{C_1, C_2, \dots, C_h\}$,为得到当前浮选工况 C_t 的最优解,需对 h 个案例 $\{C_1, C_2, \dots, C_h\}$ 进行重用.在锡粗选的案例库中,差异较大的泡沫图像特征可能对应相同的精、尾矿品位.为使重用得到更好的解,必须估算每个匹配案例的密度分布.采用下式计算案例 C_i ($i = 1, 2, \dots, h$)的密度估计^[20]:

$$\rho(C_i) = \frac{1}{h} \sum_{j=1}^h \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{\|J_i - J_j\|^2}{2\sigma^2}\right). \quad (3)$$

其中: $\|J_i - J_j\|^2 = \sum_{l=1}^4 \lambda_l (j_{i,l} - j_{j,l})^2$, λ_l 为第 l 个泡沫图像特征的权系数, λ_l ($l = 1, 2, \dots, 4$)的取值分别为0.35、0.3、0.25、0.1; σ 为 $\{\|F_h\|\}_{i=1}^h$ 的标准差. $\rho(C_i)$ 越大,表示 C_i 越可靠.记分布密度最大的案例 $C_q = \{F_q, J_q\}$,直接重用 C_q 的泡沫图像特征值 J_q 作为 C_t 的解,即 $J = J_q$.

Step 3 案例修正及保存. 将重用结果 J 用于指导梯浮选过程控制后, 根据离线化验结果对原有案例库进行修正. 将得到的新的案例记为 $C_{\text{new}} = \{F_{\text{new}}, J_{\text{new}}\}$, 根据式(2)计算 C_q 与 C_{new} 的相似度 $\text{Sim}(F_q, F_{\text{new}})$, 并根据下式计算泡沫图像特征偏差:

$$J_{e_{q,\text{new}}} = \sum_{l=1}^4 \lambda_l (|j_{q,l} - j_{\text{new},l}| / j_{q,l}). \quad (4)$$

当 $J_{e_{q,\text{new}}} < \beta$ (经验取值 0.15) 且 $\text{Sim}(F_q, F_{\text{new}}) < \alpha$ 时, 说明案例库中与该工况案例相似度最大的存储案例有误, 需对相似度最大的案例进行删除修正. 若案例库中的案例 C_k 满足 $J_{e_{q,k}} < \beta$ 且 $\text{Sim}(F_q, F_k) \geq \alpha$, 则可将 C_k 删除后, 存储新的案例 C_{new} ; 否则可直接存储 C_{new} .

3 基于浮选指标模型寻优的图像特征优化设定

泡沫图像特征能够有效反应浮选性能. 在以往经验难以有效解决新问题的情况下, 首先通过建立基于泡沫图像特征的精、尾矿品位的软测量模型, 然后基于指标模型寻优设定泡沫图像特征, 是一个行之有效的方法. 由于浮选泡沫具有动态波动性, 即使工况相对稳定, 泡沫图像特征数据的取值仍会在一个区间内不确定. 为降低样本数据不确定性带来的不利影响, 采用区间 II 型模糊的多 TS 模型结构, 通过 MCFCM 方法得到模糊规则前件, 并建立基于 PSVR 的后件子模型. 根据入矿类型建立指标模型, 设某类入矿类型下的样本集为 $\{x_i, y_i\}_{i=1}^M$, $x_i = [s_{i,1}, s_{i,2}, \dots, s_{i,4}]$ 表示第 i 个样本的输入部分 (泡沫图像特征), $y_i = [o_{i,1}, o_{i,2}]$ 表示第 i 个样本的输出部分 (精、尾矿品位), M 表示样本个数. 基于模型寻优的过程如下.

Step 1 基于 MCFCM 的前件模糊化. 采用 FCM 方法对样本的输入部分进行聚类, 聚类的目标函数为

$$J(U, C) = \sum_{i=1}^c \sum_{j=1}^M u_{ij}^m d_{ij}^2; \quad (5)$$

$$\text{s.t. } \sum_{j=1}^c u_{ij} = 1, 0 \leq u_{ij} \leq 1.$$

其中: $U = [\mu_{ij}]$ 为隶属度矩阵, $C = \{c_i\}$ 为聚类中心, c 为聚类数, m 为加权指数 (经验值取 $m = 2$), d_{ij} 为样本 j 到聚类中心 i 的距离. FCM 的迭代算式为

$$u_{ij} = \left((d_{ij})^{2/(m-1)} / \sum_{k=1}^c (d_{kj})^{2/(m-1)} \right)^{-1}, \quad (6)$$

$$c_i = \sum_{j=1}^M u_{ij}^m x_j / \sum_{j=1}^M u_{ij}^m, \quad (7)$$

$$d_{ij}^2 = \|x_j - c_i\|^2 = \sum_{k=1}^4 \lambda_k \times \|s_{i,k} - c_{j,k}\|^2. \quad (8)$$

对于区间 II 型模糊系统, 在推理时需要将隶属

度进行区间化. 为此, 在 FCM 聚类完成得到聚类中心 $C = \{c_i\}$ 后, 一次随机删除每类中的一个或多个样本, 再重新计算聚类中心. 设 c_i^k 表示第 k 次循环中第 i 类样本的中心, 经过 K 次循环后, 第 i 类样本的中心集可记为 $C_i = \{c_i^1, c_i^2, \dots, c_i^K\}$. 对于输入 x , 根据式(8), $d_i^2(x)$ 可区间化为 $[\underline{d}_i^2, \bar{d}_i^2] = [\min_{k=1,2,\dots,K} \|x - c_i^k\|^2, \max_{k=1,2,\dots,K} \|x - c_i^k\|^2]$; 根据式(6), x 隶属于第 i 类的程度 $f^i(x)$ 可区间化为 $[\underline{f}^i, \bar{f}^i]$, 有

$$\begin{cases} \underline{f}^i = \left(\frac{(\bar{d}_i)^{2/(m-1)}}{(\bar{d}_i)^{2/(m-1)} + \sum_{k=1, k \neq i}^c (d_k)^{2/(m-1)}} \right)^{-1}, \\ \bar{f}^i = \left(\frac{(d_i)^{2/(m-1)}}{(d_i)^{2/(m-1)} + \sum_{k=1, k \neq i}^c (\bar{d}_k)^{2/(m-1)}} \right)^{-1}. \end{cases} \quad (9)$$

Step 2 基于 PSVR 后件子模型. 当样本聚类完成后, 针对各类样本子集建立 PSVR 回归模型. 假设第 l 子类训练样本集为 $\{x_i, y_i\}_{i=1}^{N_l}$, $x_i \in R^p$. 其中: $p = 4$ 为样本空间维数, N_l 为样本数, $y_i \in R$. 在特征空间中, 最优超平面需要求解如下优化问题:

$$\min J(\omega, b, \varepsilon_i) = \frac{1}{2} \omega^T \omega + \frac{\varsigma}{2} \sum_{i=1}^{N_l} \varepsilon_i^2; \quad (10)$$

$$\text{s.t. } y_i = \omega^T \Phi(x_i) + b + \varepsilon_i.$$

其中: ς 为惩罚系数, ε_i 为松弛变量, $\Phi(\cdot)$ 为非线性映射函数. 由于数据存在不确定性, 导致最优超平面也有不确定性^[14], 即式(10)中 $\|\omega\|$ 取值会在一定范围内随机分布. 因此, 将式(10)转换为求解最优超平面的期望

$$\min J(\omega, b, \varepsilon_i) = \frac{1}{2} \int_{\|\omega\|} \|\omega\|^2 \rho(\|\omega\|) d(\|\omega\|) + \frac{\varsigma}{2} \sum_{i=1}^{N_l} \varepsilon_i^2; \quad (11)$$

$$\text{s.t. } y_i = \omega^T \Phi(x_i) + b + \varepsilon_i.$$

其中 $\rho(\|\omega\|)$ 为 $\|\omega\|$ 的概率密度分布函数. 第 l 条规则的后件子模型为

$$f_l(x) = \sum_{i=1}^{N_l} \alpha_i k(x_i, x) + b. \quad (12)$$

其中: $k(x_i, x) = \Phi(x_i) \cdot \Phi(x)$ 为核函数, α_i 为 Lagrange 乘子, 本文中采用高斯核函数. 在求解式(11)的过程中, 需对样本进行随机抽样, 然后对 $\rho(\|\omega\|)$ 进行估计, 最后采用状态转移算法求解式(11).

Step 3 输出处理. 假设模型输入为 x , 第 i 个子模型的输出为 y^i , 则模型输出为

$$y(x) = \frac{y_l(x) + y_r(x)}{2}. \quad (13)$$

$[y_l(x), y_r(x)]$ 为模糊推理输出经过下式降型处理得到的结果.

$$\begin{cases}
y_l^{(0)}(x) = \sum_{i=1}^c \underline{f}^i y^i / \underline{f}^i, \\
y_r^{(0)}(x) = \sum_{i=1}^c \bar{f}^i y^i / \sum_{i=1}^c \bar{f}^i, \\
\bar{y}_l(x) = \min\{y_l^{(0)}(x), y_r^{(0)}(x)\}, \\
\underline{y}_r(x) = \max\{y_l^{(0)}(x), y_r^{(0)}(x)\}, \\
\underline{y}_l(x) = \bar{y}_l(x) - \left[\frac{\sum_{i=1}^c (\bar{f}^i - \underline{f}^i)}{\sum_{i=1}^c \bar{f}^i \sum_{i=1}^c \underline{f}^i} \times \frac{\sum_{i=1}^c \underline{f}^i (y^i - y^1) \sum_{i=1}^c \bar{f}^i (y^c - y^i)}{\sum_{i=1}^c \underline{f}^i (y^i - y^1) + \sum_{i=1}^c \bar{f}^i (y^c - y^i)} \right], \\
\bar{y}_r(x) = \underline{y}_r(x) + \left[\frac{\sum_{i=1}^c (\bar{f}^i - \underline{f}^i)}{\sum_{i=1}^c \bar{f}^i \sum_{i=1}^c \underline{f}^i} \times \frac{\sum_{i=1}^c \bar{f}^i (y^i - y^1) \sum_{i=1}^c \underline{f}^i (y^c - y^i)}{\sum_{i=1}^c \bar{f}^i (y^i - y^1) + \sum_{i=1}^c \underline{f}^i (y^c - y^i)} \right], \\
[y_l(x), y_r(x)] = \left[\frac{(\underline{y}_l(x) + \bar{y}_l(x))}{2}, \frac{(\underline{y}_r(x) + \bar{y}_r(x))}{2} \right].
\end{cases} \quad (14)$$

Step 4 基于指标模型的泡沫图像特征智能寻优. 设浮选指标要求为 $y^* = [o_1^*, o_2^*]$, 当前入矿品位类型下的精尾矿模型为 $y_1^{ic} = f_1(x)$, $y_2^{ic} = f_2(x)$, 则优化目标函数为

$$\begin{aligned}
\min y &= w_1 |(1 - y_1^{ic}/o_1^*)| + w_2 |(1 - y_2^{ic}/o_2^*)|; \\
\text{s.t. } &70 \leq s_1 \leq 170, \\
&400 \leq s_2 \leq 1600, \\
&20 \leq s_3 \leq 100, \\
&40 \leq s_4 \leq 230.
\end{aligned} \quad (15)$$

采用状态转移算法寻优式 (15), 获得泡沫图像特征的优化设定值.

4 工业实验验证

为了验证本文所提方法的有效性, 在一条日处理 800t 的锑浮选生产线上进行为期一周的工业实验. 实验期内工人根据泡沫图像特征优化设定值调整加药量. 显然, 如果通过调整加药使得泡沫图像特征能够保持在优化设定值附近, 且精、尾矿品位与生产要求相近, 则表示泡沫图像特征优化设定值有效. 由于入矿品位时常变化, 每 30min 设定一次入矿品位

类型, 并采用本文方法对泡沫图像特征进行优化设定. 设在 t_k 时刻设定入矿品位类型, 则在 $t_k \text{ min} \sim (t_k + 12) \text{ min}$ 内完成加药量的调整, 在 $(t_k + 12) \text{ min} \sim (t_k + 15) \text{ min}$ 内检测泡沫图像特征值与优化设定值的偏差, 在 $(t_k + 15) \text{ min} \sim (t_k + 30) \text{ min}$ 内维持加药量不变以防止过度频繁调整药剂引起流程不稳定.

在实验期间内, 粗精、尾矿品位设定为 16% 和 0.45%, 对于偏高、中和偏低入矿类型, 样本相对丰富, 采用案例推理的方式获取最优泡沫图像特征设定值; 而对于高入矿品位和低收入矿品位类型, 首先根据入矿品位类型选择样本数据建立基于 MCFCM_PSVR 的精、尾矿品位软测量模型, 然后采用智能寻优方法获取泡沫图像特征的最优设定值. 例如在低收入矿品位类型下, 补充部分偏低品位类型样本后, 可选择的样本数据为 340 个, 将其分成 230 个训练样本和 110 个检验样本, 并分别采用 FCM_NN 和 MCFCM_PSVR 方法建立精、尾矿品位软测量模型. 图 2 为低收入矿品位类型下精、尾矿品位的实测值与软测量模型的结果对比. 采用平均绝对误差和误差标准差衡量软测量模型性能, 计算结果如表 2 所示.

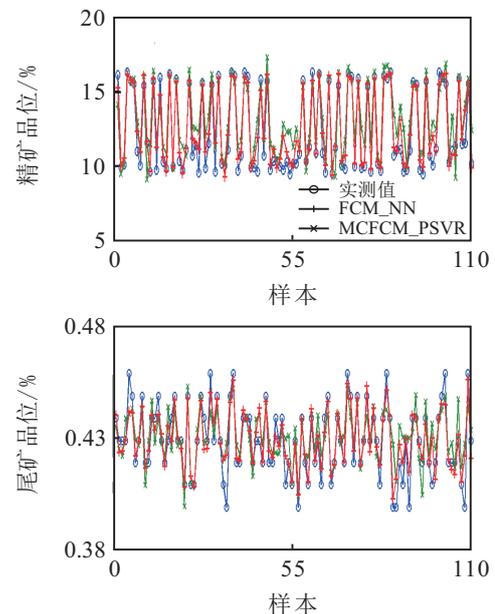


图 2 低收入矿品位下的精、尾矿品位实测值与软测量结果对比

表 2 软测量模型性能 %

品位估计模型	FCM_NN		MCFCM_PSVR	
	平均误差均值	误差标准差	平均误差均值	误差标准差
锑精矿	1.06	1.29	0.52	0.74
锑尾矿	0.09	0.11	0.05	0.08

由表 2 可知, 采用 MCFCM_PSVR 方法建立的精、尾矿品位软测量模型, 其平均绝对误差和误差均值都比 FCM_NN 更小, 表明采用 MCFCM_PSVR 方法建模性能更好. 同样采用 MCFCM_PSVR 方法建立高

入矿品位类型下的精、尾矿品位软测量模型, 并采用状态转移优化算法寻优泡沫图像特征值, 得到如表3所示的泡沫图像特征优化设定值。

表3 泡沫图像特征优化设定值

入矿类型	蓝色分量均值	泡沫尺寸均值	负载率	色度
低品位	97.4	452.5	50	112.1
偏低品位	88.4	478.9	41.8	103.6
中品位	96	516.2	42	139.6
偏高品位	102.7	1133.7	51.6	176.4
高品位	95.6	1043.5	41.4	154.4

工业验证结果. 首先计算每个周期中的12~15 min内泡沫尺寸大小、承载率、色度和蓝色分量均值4个图像特征均值落入优化设定值容许区间的概率, 可得一周的实验期内4个图像特征对应的概率分别为61.6%、50%、79.2%、56.6%。图3为4个泡沫图像特征在优化设定值周围的波动图。由此可见, 泡沫图像特征多数时间内能被控制在优化设定值附近。

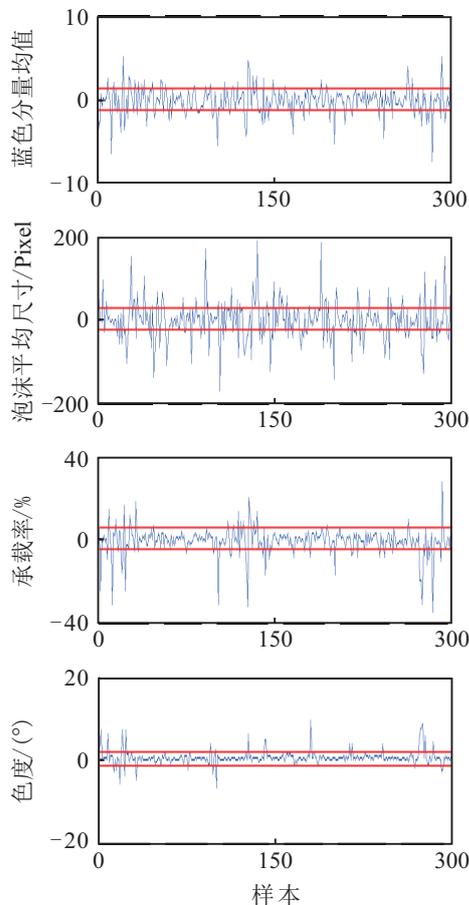


图3 泡沫图像特征的偏差

然后, 检验实验期间内梯粗选的精、尾矿品位。粗精、尾矿浆样品的采样周期为20 min, 每8 h(一个班)将样品进行混合, 分别得到粗精和粗尾矿浆的综合样品后再进行化验。图4显示了工业实验期间的浮选性能, 其中两条直线的交点为浮选性能期望值, 可以看出工业实验期间浮选性能指标在期望性能指标附近更为集中, 显示出浮选性能更为稳定。

计算可知, 实验期前一个月(无泡沫图像特征优化设定值指导浮选过程控制)的精矿品位的均值和标准差分别为14.1和3.35, 尾矿品位的均值和标准差分别为0.47和0.03; 而工业实验期间精矿品位的均值和标准差分别为15.81和1.99, 尾矿品位的均值和标准差分别为0.45和0.02。结果表明, 实验期间浮选性能能够更好地稳定在期望值附近。综上所述, 采用本文方法优化设定梯粗选泡沫图像特征值是有效的。

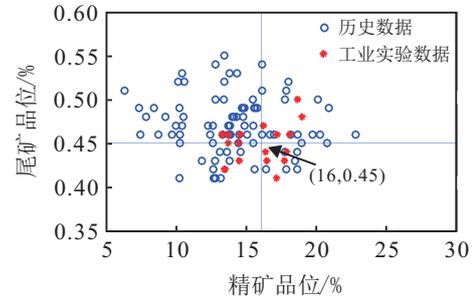


图4 浮选性能指标

5 结论

为了有效利用泡沫图像特征指导梯粗选过程加药控制, 提出了数据驱动的梯粗选泡沫图像特征的优化设定方法。针对梯粗选矿石性质随入矿品位变化的特点, 根据入矿品位类型对泡沫图像特征进行优化设定。将经验与建模相结合, 采用案例推理从历史数据中尝试获取每类入矿品位类型下精、尾矿品位符合生产要求的泡沫状态。当历史经验不足时, 采用基于MCFCM.PSVR的区间II型模糊建模方法建立浮选指标估计模型, 并采用状态转移算法寻优泡沫图像特征值。工业实验结果表明, 所提方法有效实现了梯粗选泡沫图像特征的优化设定, 稳定了浮选工况, 并改善了浮选性能。

参考文献(References)

- [1] 桂卫华, 阳春华, 徐德刚, 等. 基于机器视觉的矿物浮选过程监控技术研究进展[J]. 自动化学报, 2013, 39(11): 1879-1888. (Gui W H, Yang C H, Xu D G, et al. Machine-vision-based online measuring and controlling technologies for mineral flotation a review[J]. Acta Automatica Sinica, 2013, 39(11): 1879-1888.)
- [2] Shean B J, Cilliers J J. A review of froth flotation control[J]. Int J of Mineral Processing, 2011, 100(3/4): 57-71.
- [3] Liu J J, MacGregor J F. Froth-based modeling and control of flotation processes[J]. Minerals Engineering, 2008, 21(9): 642-651.
- [4] Zhu Jianyong, Gui Weihua, Yang Chunhua, et al. Probability density function of bubble size based reagent dosage control for flotation process[J]. Asian J of Control, 2014, 16(4): 1-13.

- [5] Bartolacci Gianni, Pelletier Patrick, Tessier Jayson, et al. Application of numerical image analysis to process diagnosis and physical parameter measurement in mineral processes-Part I: Flotation control based on froth textural characteristics[J]. Minerals Engineering, 2006, 19(6): 734-747.
- [6] Moolman D W, Eksteen J J, Aldrich C, et al. The significance of flotation froth appearance for machine vision control[J]. Int J of Mineral Processing, 1996, 48(3): 135-158.
- [7] Kaartinen J, Hatonen J, Hyotyniemi H, et al. Machine-vision-based control of zinc flotation — A case study[J]. Control Engineering Practice, 2006, 14(12): 1455-1466.
- [8] 桂卫华, 阳春华, 李勇刚, 等. 基于数据驱动的铜闪速熔炼过程操作模式优化及应用[J]. 自动化学报, 2009, 35(6): 717-724.
(Gui W H, Yang C H, Li Y G, et al. Data-driven operational-pattern optimization for copper flash smelting process[J]. Acta Automatica Sinica, 2009, 35(6): 717-724.)
- [9] 桂卫华, 刘建华, 谢永芳. 铜闪速熔炼过程操作模式分级匹配技术与演化策略[J]. 系统工程理论与实践, 2013, 33(10): 2714-2720.
(Gui W H, Liu J H, Xie Y F. Operational pattern hierarchical matching and evolution strategy for copper flash smelting process[J]. Systems Engineering — Theory & Practice, 2013, 33(10): 2714-2720.)
- [10] Guishan Xing, Jinliang Ding, Tianyou Chai, et al. Hybrid intelligent parameter estimation based on grey case-based reasoning for lamina cooling process[J]. Engineering Applications of Artificial Intelligence, 2012, 25: 418-429.
- [11] 耿增显, 柴天佑. 基于案例推理的浮选过程智能优化设定[J]. 东北大学学报: 自然科学版, 2008, 29(6): 761-764.
(Geng Z X, Chai T Y. Intelligently optimal index setting for flotation process by CBR[J]. J of Northeastern University: Natural Science, 2008, 29(6): 761-764.)
- [12] Oscar Castillo, Patricia Melin. A review on the design and optimization of interval type-2 fuzzy controllers[J]. Applied Soft Computing, 2012, 12(4): 1267-1278.
- [13] Juang C, Huang R, Cheng W. An interval type-2 fuzzy-neural network with support-vector regression for noisy regression problems[J]. IEEE Trans on Fuzzy Systems, 2010, 18(4): 686-699.
- [14] Li H X, Yang J L, Zhang G, et al. Probabilistic support vector machines for classification of noise affected data[J]. Information Sciences, 2013, 221: 60-71.
- [15] Zhou X, Yang C, Gui W. State transition algorithm[J]. J of Industrial and Management Optimization, 2012, 8(4): 1039-1056.
- [16] Chunhua Yang, Canhui Xu, Xuemin Mu, et al. Bubble size estimation using interfacial morphological information for mineral flotation process monitoring[J]. Trans of Nonferrous Metals Society of China, 2009, 19(3): 694-699.
- [17] Chunhua Yang, Canhui Xu, Weihua Gui, et al. Application of highlight removal and multivariate image analysis to color measurement of flotation bubble images[J]. Int J of Imaging Systems and Technology, 2009, 19(4): 316-322.
- [18] Jinping Liu, Weihua Gui, Zhaohui Tang. Flow velocity measurement and analysis based on froth image SIFT features and Kalman filter for froth flotation[J]. Turkish J of Electrical Engineering and Computer Science, 2013, 21(2): 2378-2396.
- [19] 吴佳, 谢永芳, 阳春华, 等. 一种无监督约简的浮选泡沫图像特征选择方法及应用[J]. 信息与控制, 2014, 43(3): 314-317.
(Wu J, Xie Y F, Yang C H, et al. An unsupervised reduction method for selection of flotation froth image characters and its application[J]. Information and Control, 2014, 43(3): 314-317.)
- [20] Girolami M, Chao H. Probability density estimation from optimally condensed data samples[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2003, 25(10): 1253-1264.

(责任编辑: 齐 霖)