基于泡沫图像特征的浮选槽液位智能优化设定方法

赵洪伟 [1] 谢永芳 [1] 蒋朝辉 [1] 徐德刚 [1] 阳春华 [1] 桂卫华 [1]

摘 要 浮选生产过程中浮选槽液位通常根据经验人工设定, 具有主观随意性、液位波动大, 使精/尾矿品位不满足要求. 为此, 提出一种基于浮选泡沫图像多特征的浮选槽液位智能优化设定的方法. 在浮选槽工作原理以及液位与泡沫图像特征间关系的分析基础上, 将基于案例推理的浮选槽液位预设定、基于多泡沫图像特征的改进 LS-SVM (Least squares support vector machine) 品位预测及基于 BP 神经网络的自学习模糊推理智能补偿等模型有机集成, 提出了充分利用泡沫图像特征的液位智能优化设定方法. 将该方法在某铝土矿浮选生产过程进行应用验证, 可使粗选槽液位波动减小, 提高了粗选精/尾矿品位合格率、总精矿品位合格率及回收率.

关键词 浮选液位, 泡沫特征, 案例推理, 品位预测, BP 神经网络模糊推理, 优化设定

引用格式 赵洪伟, 谢永芳, 蒋朝辉, 徐德刚, 阳春华, 桂卫华. 基于泡沫图像特征的浮选槽液位智能优化设定方法. 自动化学报, 2014, **40**(6): 1086−1097

DOI 10.3724/SP.J.1004.2014.01086

An Intelligent Optimal Setting Approach Based on Froth Features for Level of Flotation Cells

ZHAO Hong-Wei[1] XIE Yong-Fang[1] JIANG Zhao-Hui[1] XU De-Gang[1] YANG Chun-Hua[1] GUI Wei-Hua[1]

Abstract In the flotation production process, the liquid level of flotation cells is usually set by on experiences. The liquid level can fluctuate in a large range such that the concentrate grade and tailings grade may not meet the requirement. In this paper, an intelligent optimal setting approach based on forth image features is proposed. On the basis of analysis of flotation cells′ working principle and relationship between level and froth image features, the pre-setting model based on CBR, the improved least squares support vector machine (LS-SVM) grade prediction model based on multiple froth features, and the self-learning fuzzy reasoning intelligent compensation model based on BP neural network are integrated together. This method is tested on a bauxite flotation process. The level fluctuation of rougher flotation cells decreases. The pass rates of concentrate and tailings grade in rougher flotation and the pass rate of the concentrate grade and recovery of the overall flotation increase.

Key words Flotation level, froth feature, case-based reasoning, grade prediction, BP neural network fuzzy reasoning, optimal setting

Citation Zhao Hong-Wei, Xie Yong-Fang, Jiang Zhao-Hui, Xu De-Gang, Yang Chun-Hua, Gui Wei-Hua. An intelligent optimal setting approach based on froth features for level of flotation cells. *Acta Automatica Sinica*, 2014, **40**(6): 1086−1097

选矿是矿产资源加工中的一个重要生产环节, 直接影响矿物资源的利用率和回收率[1]. 泡沫浮选是选矿过程中最重要的矿物分选方法, 广泛应用于冶金、煤炭、化工等生产部门, 我国 90 % 以上有色金属是经泡沫浮选处理的. 由于浮选工艺流程长、机理复杂、矿物品位等生产指标难以在线测量, 且浮选给矿条件经常变化, 长期以来, 主要依靠人工观察浮选槽表面泡沫颜色、大小等视觉特征进行操作, 存在主观随意性, 往往导致工况波动大, 精/尾矿品位不满足要求, 造成浮选药剂和能源消耗大. 因此, 需要深入研究浮选过程操作参数的优化设定方法, 保证浮选生产的自动优化运行. 浮选过程的主要操作参数包括矿浆液位 (泡沫层厚度)、通风量及加药量等, 其中矿浆液位作为重要的操作变量[2−3], 通常是在给矿及药剂添加量给定情况下进行调整, 以获得满足工艺要求的精/尾矿品位.

收稿日期 2013-07-04 录用日期 2013-11-14
Manuscript received July 4, 2013; accepted November 14, 2013
国家自然科学基金重点项目 (61134006), 国家创新研究群体科学基金 (61321003), 高等学校博士学科点专项基金博导类资助课题 (20120162110076), 高等学校博士学科点专项科研基金优先发展领域资助课题 (20110162130011), 中央科研基本业务费中南大学国家杰青培育专项 (2011JQ009) 资助
Supported by National Natural Science Foundation of China (61134006), the Funds for Creative Research Groups of China (61321003), Doctoral Tutor Classes Funded Project of Specialized Research Fund for the Doctoral Program of Higher Education (20120162110076), Priority Areas of Development Funding Issues of Specialized Research Fund for the Doctoral Program of Higher Education (20110162130011), and the Fundamental Research Funds for the Central Universities (2011JQ009)
本文责任编委 文成林
Recommended by Associate Editor WEN Cheng-Lin
1. 中南大学信息科学与工程学院 长沙 410083
1. School of Information Science and Engineering, Central South University, Changsha 410083

浮选现场的液位设定是由操作人员观察泡沫进行调节, 常出现冒槽、液位过低而难以溢流等失控现象, 导致精/尾矿品位波动较大、难以满足生产要求. 针对浮选过程液位控制问题, 国内外很多学者进行了研究. 如文献 [4] 建立了浮选槽及调节阀的数学模型, 获得液位 PI 控制参数, 并以 PI 控制器为基础研究了 SISO 控制器与其他几种 MIMO 控制器的控制效果, 仿真结果表明 MIMO 控制器的液位控制性能优于经典的 SISO 控制器; 文献 [5] 提出了一种 PI 与模型预测相结合的柱式浮选液位控制策略, 仿真表明预测控制器的引入使液位控制过程中其他操作变量的约束限制得到较好的满足, 比传统 PI 控制更能满足实际要求; 文献 [6] 对柱式浮选槽液位控制的多种控制策略进行了综述和对比分析, 指出多数方法仍停留在理论阶段而未经现场验证. 文献 [7] 针对串级浮选槽液位控制问题, 提出了一种 PID 参数整定方法, 利用前馈控制改善了控制性能. 这些研究主要是针对浮选过程液位自动控制策略开展的, 未考虑浮选生产的工艺指标, 由于浮选过程机理复杂, 而且给矿条件经常变化, 浮选生产难以优化运行. 因此, 根据浮选工况, 研究液位自动优化设定方法以改善浮选效果十分必要.

此外, 在矿物选别中浮选泡沫表面视觉特征 (如颜色、大小、流速、纹理等) 不仅可直接反映浮选生产过程工况, 还可以作为工艺指标的直接指示器. 工业机器视觉检测速度快, 可同时监测整个浮选槽的泡沫状态, 实现泡沫表面视觉特征的量化描述与浮选生产状态的客观评价. 基于机器视觉的泡沫浮选监测系统已经应用于浮选过程, 取得了一定的效果[8−12]. 为此, 本文结合多浮选泡沫图像特征, 利用基于案例推理的浮选槽液位预设定模型对浮选槽液位进行预设定, 采用改进型 LS-SVM (Least squares support vector machine) 品位预测模型对浮选矿物品位进行实时预测, 在此基础上, 采用基于 BP 神经网络的自学习模糊推理智能补偿模型对预设定值进行补偿, 得到液位优化设定值. 该优化设定方法能充分利用机器视觉所提供的泡沫图像特征信息对浮选槽液位进行优化设定. 最后, 将所提方法在铝土矿浮选生产现场进行工业验证, 减少了浮选槽精/尾矿品位的波动范围, 改善了浮选效果.

1　浮选槽工作原理及液位分析

浮选是利用有用矿物颗粒与无用脉石颗粒表面物理化学性质不同所导致的亲水性或疏水性差异对矿物进行分选的方法[13]. 在浮选过程中, 矿物颗粒、水及浮选药剂按一定比例在搅拌槽内混合、搅拌、调配成满足浮选要求的矿浆, 并送入浮选槽, 矿浆在浮选槽内与鼓入的空气混合搅拌形成大量气泡, 矿物颗粒与气泡发生充分接触和碰撞. 疏水性的目的矿物颗粒附着于气泡表面, 随气泡上浮至矿浆表面并被刮至溜槽得到精矿产品, 从而实现目的矿物的富集. 而亲水性的脉石矿物颗粒则留在矿浆中, 随矿浆流被排出浮选槽形成尾矿.

浮选槽的工作原理如图 1 所示, 可以看出, 浮选槽中含有固体、液体及气体, 影响因素复杂. 为了使最终精矿品位满足工艺要求, 浮选操作人员根据给矿条件 (给矿流量 G_V、给矿浓度 G_c、给矿粒度 G_d、给矿品位 G_p), 并结合观察的浮选槽表面泡沫状态对浮选槽矿浆液位、通风量及加药量进行控制. 而当给矿条件或其他工况条件发生变化时, 现场操作人员由于经验有限或操作滞后等原因往往不能及时对相关参数进行调节, 常出现 “跑槽” 或者其他失控的状态, 导致精矿品位及回收率不符合要求.

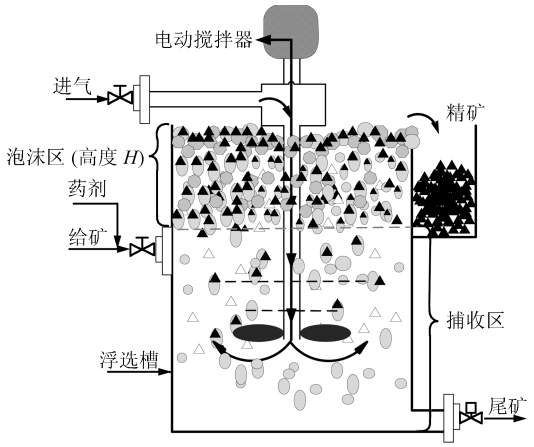

图 1　浮选槽工作原理图

Fig. 1　Working principle diagram of flotation cell

由图 1 可知, 浮选槽内分为两个区域, 即捕收区 (也称作 “矿浆区”, 空气含量 $< 30\,\%$) 和泡沫区 (空气含量 $> 70\,\%$). 浮选槽液位指的是捕收区和泡沫区的接触面位置, 即图 1 中最长虚线标注的位置, 通常用浮选槽顶端至该位置的距离 H 表示. 浮选槽的矿浆液位影响最终精矿产品的质量. 一方面, 若捕收区厚度增加, 有用矿物颗粒有更多时间与气泡接触并粘附于其表面, 而不少非疏水性的脉石颗粒也会随泡沫溢流至溜槽, 从而导致精矿品位下降; 另一方面, 若泡沫区厚度增加, 非疏水性的脉石颗粒在泡沫区有更多时间脱离气泡表面, 使得精矿品位提高, 但会导致回收率下降. 因而对矿浆液位进行合理设定, 对浮选生产过程十分重要. 目前, 我国浮选现场对浮选槽液位的调整主要依靠操作工人观察泡沫, 凭经验手动操作浮选槽尾矿阀门, 劳动强度大, 且难以保证产品质量.

在浮选过程中泡沫层厚度扮演着关键角色, 气泡从泡沫层底部上升运动至泡沫层表面的过程中,

其结构、形态及运动状态都发生变化, 进而引起泡沫表面视觉特征发生变化[14]. 因此可利用泡沫层表面视觉特征评估浮选性能, 并进行操作变量调控以改善浮选性能. 本文利用泡沫图像特征对浮选生产过程中精/尾矿品位进行实时预测, 得到浮选效果评价标准, 结合案例推理、自学习模糊推理等实现液位的预设定和预设定补偿, 以实现浮选槽液位的智能优化设定.

2 浮选槽液位智能优化设定

浮选流程包括粗选、精选及扫选等环节, 粗选为首个生产环节, 对精矿品位及尾矿回收率的提升有重要影响. 这里以浮选流程中粗选槽为例, 提出如图 2 所示的浮选槽液位智能优化设定方法, 主要包括浮选槽液位预设定模型、品位预测模型及智能补偿模型.

2.1 基于案例推理的浮选槽液位预设定模型

案例推理 (Case based reasoning, CBR) 是一种借鉴人类思维方式对问题进行处理的人工智能推理方法[15−16], 它能够从案例中获取经验知识用于解决新问题, 克服了传统基于规则推理 (Rule based reasoning, RBR) 的知识获取困难. 本文基于浮选过程工艺指标及给矿条件采用 CBR 对浮选槽液位进行预设定.

2.1.1 预设定模型结构

基于案例推理的浮选槽液位预设定模型结构如图 3 所示. 该模型首先根据粗选槽目标品位及给矿条件组成的案例在浮选液位调整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判断和重用, 得到当前工况输入特征的案例解作为结果输出, 即浮选槽液位预设定值; 最后, 根据液位预设定值的应用效果, 即作用后的工艺指标进行评价. 若满足要求则直接作为一条新案例存入案例库; 否则, 对其进行修正, 待其满足要求后存入案例库, 从而使案例库得到更新.

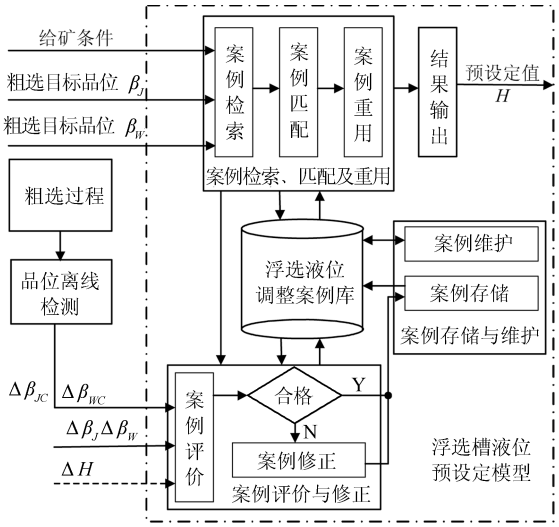

图 3 浮选槽液位预设定模型结构

Fig. 3 Structure of pre-setting model of flotation cells′ level

从图 3 可看出, 该模型的核心是浮选液位调整的案例库. 案例库由很多条历史操作案例组成, 每一条案例由工况描述及其对应的案例解组成. 根据浮选槽工作原理及液位的分析, 将目标精矿品位 β_J、目标尾矿品位 β_W、给矿流量 G_V、给矿浓度 G_c、给

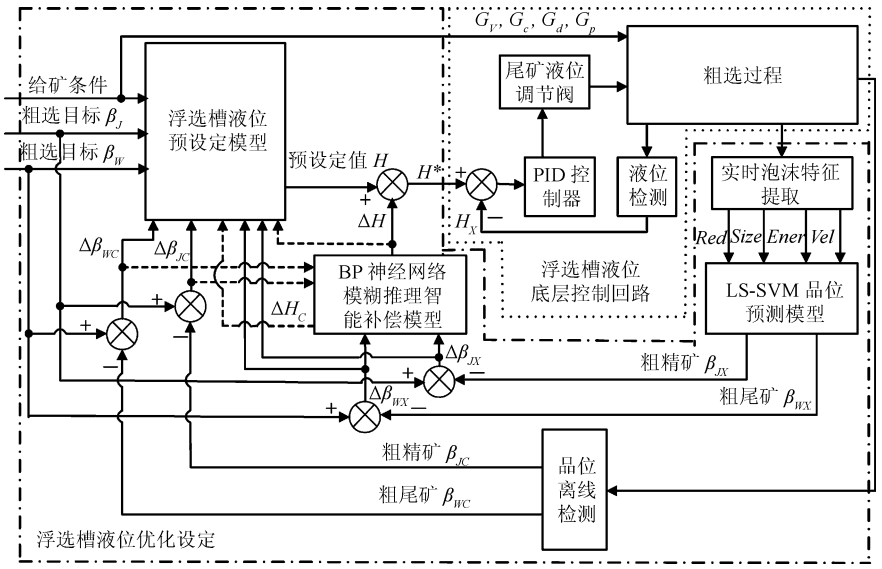

图 2 浮选槽液位优化设定结构图

Fig. 2 Optimal setting structure diagram of flotation cells′ level

矿粒度 G_d、给矿品位 G_p 作为模型的工况描述, 将浮选槽液位的预设定值 H 作为其对应的案例解. 其中第 k 条案例用 $C_k = \{F_k, J_k\}$ 表示, 其对应关系如表 1 所示.

表 1　案例描述

Table 1　Case description

工况描述 F						解 J
f_1	f_2	f_3	f_4	f_5	f_6	j
β_J	β_W	G_V	G_c	G_d	G_p	H

2.1.2　案例检索、匹配与重用

假定浮选生产过程的某实时工况 C_x 的案例描述为 $F_x = \{f_1, f_2, f_3, f_4, f_5, f_6\}$, 它的解 $J = (j_x)$. 案例库中有 n 个案例 $C_1, C_2, \cdots, C_n$, 每条案例 $C_t\,(t = 1, 2, \cdots, n)$ 的描述为 $F_t = \{f_{t,1}, f_{t,2}, f_{t,3}, f_{t,4}, f_{t,5}, f_{t,6}\}$, 对应的解为 $J_t = (j_t)$. 为了得到案例库中与 C_x 匹配的案例, 需要按照一定的规则进行检索. 定义当前浮选工况案例描述 $f_m\,(m = 1, 2, \cdots, 6)$ 与案例库中案例描述 $f_{t,m}$ 的相似度函数为

$$S_A\,(f_m, f_{t,m}) = 1 - \frac{|f_m - f_{t,m}|}{\max\,(f_m, f_{t,m})}, t = 1, 2, \cdots, n \tag{1}$$

其中, $\max\,(f_m, f_{t,m})$ 表示取 f_m 与 $f_{t,m}$ 的较大值, 根据式 (1) 可定义 F_x 与 F_t 的相似度函数为

$$S_W(F_x, F_t) = \sum_{m=1}^{6} \frac{\lambda_m S_A\,(f_m, f_{t,m})}{\sum\limits_{m=1}^{6} \lambda_m} \tag{2}$$

其中, λ_m 为每一种工况特征的加权系数, 其大小由工况数据确定, 即根据各种给矿边界条件及目标品位的相对重要性确定其大小, 通常由经验凑试法得到. F_x 与案例库中的所有案例 $F_t\,(t = 1, 2, \cdots, n)$ 的最大相似度为

$$S_{\max} = \mathrm{Max}\{S_W(F_x, F_t)\},\ t = 1, 2, \cdots, n \tag{3}$$

为判断相似度 $S_W(F_x, F_t)$ 是否满足要求, 需进一步确定相似度阈值并进行判断, 设相似度阈值为 S_{TH}, 其大小由式 (4) 确定:

$$S_{TH} = \begin{cases} 0.85, & S_{\max} \geq 0.85 \\ S_{\max}, & S_{\max} < 0.85 \end{cases} \tag{4}$$

若案例库中案例与当前工况的相似度满足阈值要求, 则将被检索出来作为匹配案例, 假定有 h 个匹配案例 $\{C_1, C_2, \cdots, C_h\}$. 为得到当前浮选工况的最优解, CBR 方法往往通过对 h 个匹配案例 $\{C_1, C_2, \cdots, C_h\}$ 再做相应处理. $C_i\,(i = 1, \cdots, h)$ 与当前工况的相似度分别为 $S_{W,1}, S_{W,2}, \cdots, S_{W,h}$, 其对应的案例解为 $J_i = (j_i)$. 则当前工况下的案例解 J_x 通过式 (5) 得到:

$$J_x = \frac{\sum\limits_{i=1}^{h} \eta_i j_i}{\sum\limits_{i=1}^{h} \eta_i} \tag{5}$$

η_i 为检索到的匹配案例的权值, $\eta_i = S_{W,i}$, 则最终得到的液位预设定值为 J_x, 即 $H = J_x$.

2.1.3　案例修正、评价与存储

首先根据案例重用的结果得到浮选槽需要调整的液位预设定值 H, 并以其作为液位的给定值对浮选过程进行控制. 随着系统运行, 智能补偿模型按照一定补偿周期对浮选液位预设定值进行补偿, 补偿值为 ΔH. 若补偿相对值 $|\Delta H/H| \leq \lambda$ (λ 为补偿量最小阈值, 取 3 % ∼ 5 %), 则说明预设定液位基本满足要求. 若 $|\Delta H/H| > \lambda$, 对当前的品位预测值 β_{JX} 及 β_{WX} 进行评价. 若满足 $|\Delta\beta_{JX}/\beta_J| \leq \delta$ 且 $|\Delta\beta_{WX}/\beta_W| \leq \varepsilon$ (δ 和 ε 为根据工艺要求确定的品位波动阈值, 大小通常为 3 % ∼ 10 %), 则说明此时液位设定值 H^* 满足要求, 将此时 H^* 作为案例解与工况条件组成一条新的案例进行预存储, 可对后续得到的离线检测品位值 β_{JC} 与 β_{WC} 评价. 一般情况下满足 $|\beta_J - \beta_{JC}|/\beta_J \leq \delta$ 且 $\beta_W - \beta_{WC}|/\beta_W \leq \varepsilon$, 则将预存储案例直接存储. 否则, 按照实际品位偏差通过补偿模型对 H^* 进行适当修正 ($H^* + \Delta H_C$, ΔH_C 由 $\Delta\beta_{JC}$ 与 $\Delta\beta_{WC}$ 通过补偿模型计算得到) 并存储. 此外, 若某工况条件下 $S_{\max} \geq 0.95$ 且液位补偿相对值 $|\Delta H/H| \geq 30\%$, 说明案例库中与该工况案例相似度最大的存储案例有误, 需对案例库进行修正. 将其 h 个匹配案例中与其相似度最大的案例 $C_i^{\max}$ 从案例库删除, 从而保证案例库中不出现冗余信息. 然后再由实时工况进行案例推理, 并重复上述过程.

通常情况下, 仅采用基于案例推理的浮选槽液位预设定模型对浮选槽液位进行设定, 可得到一个相对合理的设定值. 由图 2 可看出, 此时相当于对浮选槽液位的开环设定. 由于不能有效克服各种扰动及工况变动的影响, 性能较差. 本文通过实验验证了采用智能补偿模型较单独采用预设定模型浮选生产性能有明显提高.

2.2　基于多泡沫图像特征的品位预测模型

在实际浮选生产过程中, 精矿品位 β_{JX} 及尾矿品位 β_{WX} 通常通过离线检验分析得到, 无法为在线优化设定提供必要的实时数据. 目前, 有学者采用神

经网络方法[17] 对浮选指标进行在线预测, 但该方法在样本量不大时, 易出现过拟合及泛化能力差的问题. LS-SVM 是对 SVM[18] 的改进方法, 主要解决了其在求解二次规划问题时, 遇到的稀疏性及运算复杂问题, 对小样本建模效果较好. 而浮选实际生产过程中, 矿物品位化验时间长、费用高, 难以获得大量离线品位样本数据. 为此, 课题组最早提出利用泡沫图像特征, 采用 LS-SVM 方法对浮选生产指标进行在线预测[10, 19]. 本文在文献 [19] 的基础上, 提出了一种改进的 LS-SVM 预测方法, 利用可直接反映浮选生产状态的多种泡沫图像特征, 实现对精矿品位及尾矿品位的在线预测.

2.2.1 泡沫图像特征与品位相关性分析

由于浮选槽表面泡沫图像特征可有效反映浮选工况状态, 并可作为浮选过程操作的参考量, 泡沫图像特征也常用来对浮选工艺指标 (精矿品位和尾矿品位) 预测. 例如, 浮选泡沫的颜色特征可有效反映气泡所携带目标矿物的多少[10]. 本文以某铝土矿浮选粗选槽为研究对象, 提取了其泡沫图像颜色、尺寸 (大小均值 + 方差)、纹理及动态特征, 研究了这些特征与其对应工艺指标的相关性. 如图 4 (a) ∼ (d) 所示为提取到的 90 幅粗选泡沫图像的 4 种图像特征及与其对应的粗选化验精矿品位的关系图.

由图 4 所示结果可知, 4 种泡沫图像特征与粗选槽精矿品位有较强相关性. 此外, 泡沫图像特征与粗选槽尾矿品位的相关性分析亦发现均有较强的相关性. 这充分表明提取到的各种泡沫图像特征可有效反映矿物品位.

2.2.2 改进型 LS-SVM 预测模型

图 4 表明各种泡沫图像特征与精矿品位之间有较强非线性关系, 但从图 4 中亦可看出有不少样本点远离拟合曲线, 而这些点也与实际工况不符, 误差较大. 这是由于实际浮选生产环境恶劣, 对各种图像采集及传输设备造成影响, 进而导致泡沫特征提取过程中出现误差. 虽然在图像处理过程中进行去噪等一系列预处理操作, 在一定程度上减小了误差, 但仍存在由于各种工况故障导致的错误样本点, 使得建立的 LS-SVM 模型不准确, 易出现较大预测误差.

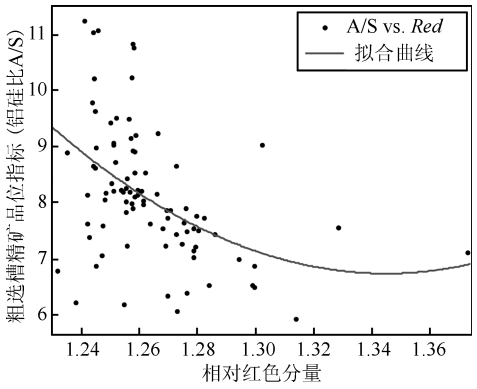

(a) 颜色特征分析

(a) Analysis of color feature

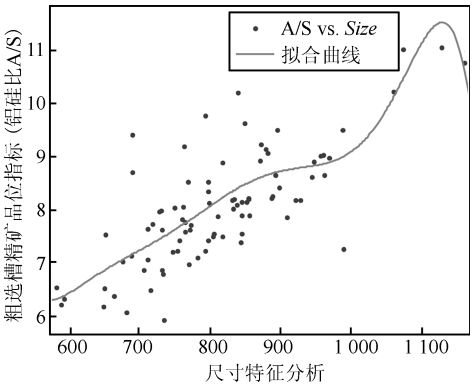

(b) 尺寸特征分析

(b) Analysis of size feature

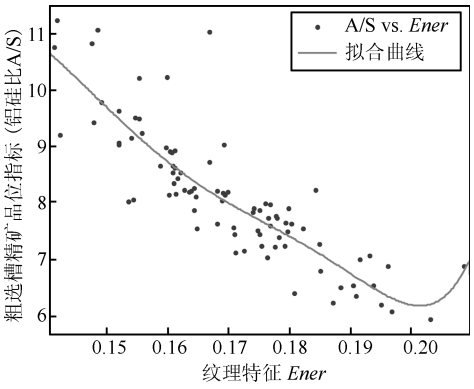

(c) 纹理特征分析

(c) Analysis of textures feature

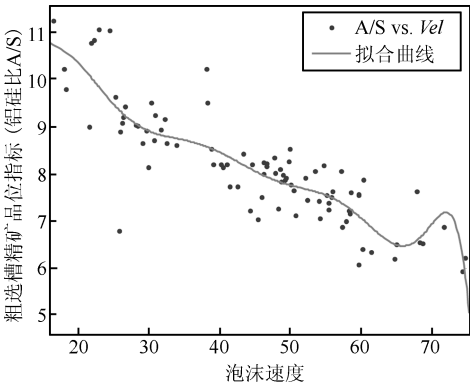

(d) 速度特征分析

(d) Analysis of velocity feature

图 4 泡沫特征与精矿品位关系

Fig. 4 The relationship between froth features and concentrate grad

为此, 提出一种改进型 LS-SVM 预测方法, 以降低在其建模过程中错误样本对模型准确性的影响.

LS-SVM 预测模型是将包含 i $(i=1,2,\cdots,N)$ 组训练样本的样本集 $S=(\boldsymbol{u}_i,\boldsymbol{v}_i)$ (d 维输入 $\boldsymbol{u}_i\in\mathbf{R}^d$, 一维输出 $\boldsymbol{v}_i\in\mathbf{R}$) 的非线性函数估计问题转化为求解式 (6) 所示的高维特征空间中线性函数估计问题[19]:

$$f(x)=\sum_{i=1}^{N}a_i\boldsymbol{K}(x,x_i)+b \tag{6}$$

其中, a_i 为拉格朗日乘子, b 为该模型的另一回归参数, $\boldsymbol{K}(x,x_i)$ 表示核函数. 在模型训练过程中, 由于某些错误训练样本所导致 $|a_i|$ 的剧烈变化影响了模型的估计性能, 而衡量的 LS-SVM 模型的性能指标为其预测均方误差,

$$E_{\mathrm{RMSE}}=\sqrt{\frac{1}{k}\sum_{i=1}^{k}(\hat{v}_i-v_i)^2} \tag{7}$$

其中, k 为预测样本个数, $\hat{v}_i$ 为预测值, v_i 为真实值. E_{RMSE} 越大表明预测误差越大, E_{RMSE} 越小则预测越准确. 因此, 改进型 LS-SVM 的建模过程主要有以下几个步骤:

步骤 1. 构建由泡沫图像特征与对应的浮选指标组成的训练样本集和测试样本集;

步骤 2. 确定核函数类型与核参数, 利用训练样本集数据训练基本 LS-SVM 模型;

步骤 3. 利用基本 LS-SVM 模型对测试样本集进行测试, 计算性能指标 E_{RMSE};

步骤 4. 求取 LS-SVM 模型的拉格朗日乘子 a_i;

步骤 5. 求取 τ=$|a_{i+1}|/|a_i|$, τ 表示 $|a_i|$ 的变化率. 假定 τ 的阈值为 τ_{TH}, τ_{TH} 的大小根据模型训练效果确定. 若 $\tau\geq\tau_{\mathrm{TH}}$, 表明 $|a_i|$ 变化过大, 则删除使 $|a_i|$ 变化过大的样本点;

步骤 6. 将剩余的样本点作为训练样本集对 LS-SVM 模型进行训练, 重新对测试集进行测试并得到其性能指标 E'_{RMSE};

步骤 7. 判断 E'_{RMSE} 与 E_{RMSE} 的大小以衡量改进效果. 若 $E'_{\mathrm{RMSE}}\leq E_{\mathrm{RMSE}}$ 则返回步骤 4, 并以 E'_{RMSE} 取代 E_{RMSE} 作为再次衡量改进效果的标准; 若 $E'_{\mathrm{RMSE}}>E_{\mathrm{RMSE}}$, 则说明剔除样本点未达到优化效果, 不予以剔除. 依次进行, 直到对整个训练样本集中数据点优化完成, 得到改进 LS-SVM 模型.

基于上述建模步骤, 采用如图 5 所示的基于 LS-SVM 的预测模型对精/尾矿品位进行预测. 该模型利用历史工况数据库中的颜色特征 Red、尺寸特征 Size、纹理特征 Ener、速度特征 Vel 及与其对应精矿及尾矿品位构造由特征向量集 $\{\boldsymbol{T}_i\}$ 及品位向量集 $\{\boldsymbol{P}_i\}$ ($i\in\mathbf{N}+$, 表示第 i 组向量) 组成的训练集, 通过训练集对 LS-SVM 模型进行训练. LS-SVM 模型的核函数采用高斯径向基函数, 在训练过程中, 求取该模型的回归参数 a_i 和 b, 并通过网格搜索法及交叉验证法对惩罚参数 C 和核宽 σ 进行搜索和寻优. 训练结束后, 对由实时泡沫特征构造的实时特征向量集 $\{\boldsymbol{T}_i(t)\}$ 进行测试, 通过反预处理得到最终预测精矿和尾矿品位指标 β_{JX}、β_{WX} 作为输出, 并作为智能补偿模型的反馈输入. 同时, 实时泡沫特征及预测结果进入 LS-SVM 历史数据库进行存储.

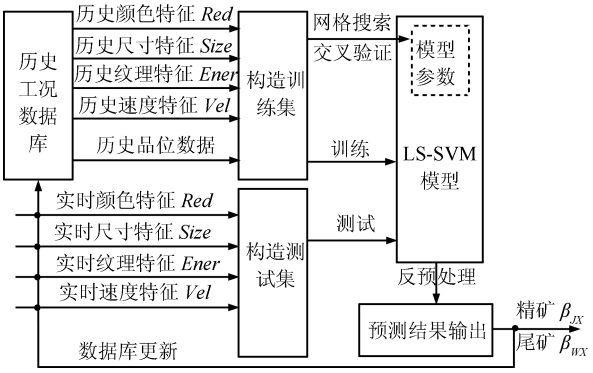

图 5　基于 LS-SVM 的品位预测模型

Fig. 5　Grade prediction model based on LS-SVM

为验证预测模型对粗选槽精/尾矿品位预测的准确性, 利用某铝土矿浮选工业现场得到的 450 组精/尾矿品位数据 (通过离线化验分析得到) 和对应的泡沫图像特征数据对 LS-SVM 模型进行训练. 其中泡沫图像为 40 天内不同时段通过粗选槽监控系统获取, 但由于浮选生产现场环境比较恶劣, 灯光亮度不均及图像数据传输通道误差都会造成得到的泡沫图像具有噪点, 所以首先需要对图像预处理, 然后采用多种泡沫图像特征提取方法[20−23] 得到图像特征数据. 通过训练得到 LS-SVM 的惩罚参数 $C=12$, 核宽 $\sigma=0.65$. 利用另外提取到的 70 组铝土矿粗选槽泡沫图像特征向量在已经训练好的模型上进行测试, 并与人工化验得到的 70 组泡沫特征向量所对应的粗选槽溢流及底流品位进行对比分析, 结果如图 6 所示.

为评价其效果, 按式 (8) 和 (9) 计算了预测相对误差 E 与均方根误差 $RMSE$.

$$E=\frac{|\beta_{YC}(i)-\beta_{HY}(i)|}{\beta_{HY}(i)}\times 100\% \tag{8}$$

$$RMSE=\sqrt{\frac{1}{70}\sum_{i=1}^{70}\left[\beta_{YC}(i)-\beta_{HY}(i)\right]^2} \tag{9}$$

其中, $\beta_{YC}(i)$ 为第 i $(i=1,2,\cdots,70)$ 个预测品位值, $\beta_{HY}(i)$ 为与其对应的实际化验品位值. 以相对

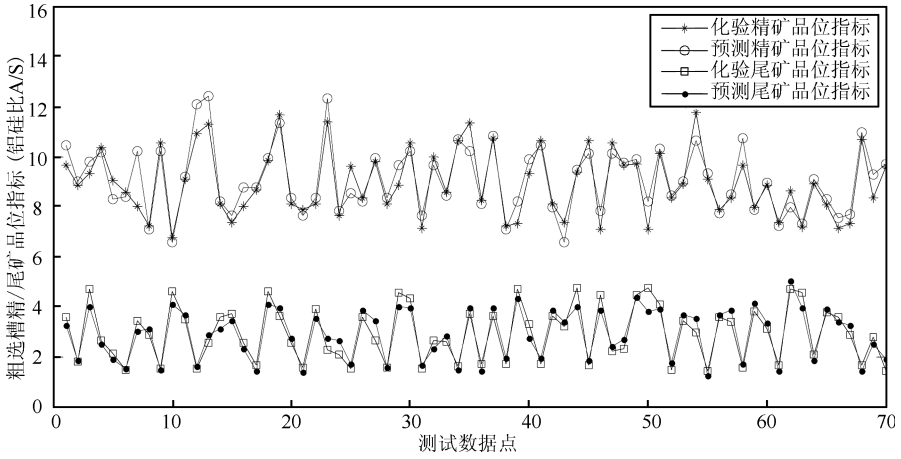

图 6 基于泡沫特征的改进 LS-SVM 品位预测效果

Fig. 6 Grade prediction effect of the improved LS-SVM based on froth features

误差在 15 % 之内的数据点比例 ($E \leq 15\,\%$)、最大相对误差 $E_{\max}$ 及 $RMSE$ 作为预测值的评价指标, 得到结果如表 2 所示.

表 2 改进 LS-SVM 模型预测误差分析

Table 2 Improved LS-SVM model prediction error analysis

预测评价指标	$E \leq 15\,\%$ 数据点所占比例	$E_{\max}$	$RMSE$
精矿品位	97.14 %	17.47 %	0.582
尾矿品位	91.43 %	19.39 %	0.359

由表 2 可以看出, 预测误差 E 较小, 说明预测值较好地跟踪实际值, 同时较小的 $RMSE$ 说明该预测模型可信度较高. 本文还采用基本 LS-SVM 模型对上述测试样本精/尾矿品位进行了预测, 其中精矿品位预测的 $E_{\max}$ 为 26.64 %, $RMSE$ 为 0.758, 尾矿品位预测的 $E_{\max}$ 为 29.16 %, $RMSE$ 为 0.671, 说明改进型 LS-SVM 预测模型的预测效果更好. 由于在特征提取之前进行了图像去噪等操作, 克服了一定的环境干扰, 泡沫图像特征能较好地表征泡沫状态, 且由于在建模过程中剔除了错误样本的影响, 使得预测效果相对稳定.

2.3 基于 BP 神经网络模糊推理的智能补偿模型

浮选生产过程非常复杂, 影响其正常运行的未知干扰因素较多, 而且给矿也发生波动. 这些影响因素都会导致预设定的液位值不满足实时工况要求, 工艺指标不在目标范围内. 因此, 必须根据品位预测模型得到的预测品位对液位预设定值进行适当补偿. 但由于机理复杂, 难以建立精确的数学补偿模型. 为解决这类问题, 文献 [24−25] 提出了基于 RBR 的反馈补偿模型实现对浮选操作变量预设定值的修正. 但应用该方法对浮选液位预设定值进行补偿调整时存在几个主要问题: 1) 由于浮选现场操作人员对浮选槽液位设定值的调整, 往往是先依据经验对品位偏差粗略估计, 再对操作量进行粗略调整, 导致其不能以确切的量化值表示成专家规则; 2) 浮选工况变化范围大, 若将所有工况关系用规则表达, 规则库将十分巨大和复杂, 组织规则困难; 3) 每次进行补偿时, 规则推理都要重新进行搜索和匹配, 效率低, 且不具备自学习能力, 不能自动对规则库进行更新, 需人为修改, 不能对浮选液位设定调整量进行自动优化. 针对以上问题, 本文提出一种基于 BP 神经网络的自学习模糊推理补偿模型实现对浮选液位预设定值的智能补偿, 如图 7 所示.

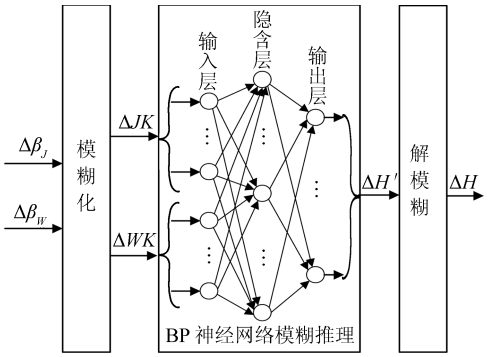

图 7 浮选液位预设定的补偿模型结构

Fig. 7 Structure of the flotation level pre-setting compensation model

该方法将浮选现场根据品位偏差进行液位预设定值调整的模糊专家操作经验按照一定隶属度进行模糊量化处理, 再将实际的品位偏差 $\Delta\beta_J \in [-10, 10]$, $\Delta\beta_W \in [-5, 5]$ (表示目标精/尾矿品位与预测或实际检测精/尾矿品位偏差, 包括 $\Delta\beta_{JX}$, $\Delta\beta_{WX}$, $\Delta\beta_{JC}$ 及 $\Delta\beta_{WC}$, 如图 2 中所示) 及液位设定补偿值 $\Delta H \in$

$[-20, 20]$ 按照一定的比例因子转化到模糊论域, 分别转化为 ΔJK, $\Delta WK \in [-6, 6] \subset Z$ 及 $\Delta H' \in [-4, 4] \subset Z$. ΔJK 与 ΔWK 的模糊子集为 $\{NB, NM, NS, ZO, PS, PM, PB\}$, ΔH 的模糊子集为 $\{NB, NS, ZO, PS, PB\}$. NB、NM、NS、ZO、PS、PM、PB 分别表示负大、负中、负小、零和正小、正中、正大, 其隶属度函数采用三角形. 然后根据浮选现场模糊操作经验建立如表 3 所示的 Mamdani 型[26] 模糊推理规则表. 例如, 根据操作经验, 当精矿品位和尾矿品位基本满足要求时, 即 $\Delta\beta_J$, $\Delta\beta_W$ 均较小时, 液位设定的补偿值 ΔH 取为零; 当精矿品位偏小而尾矿品位偏大 (即 $\Delta\beta_J$ 为正偏大, $\Delta\beta_W$ 为负偏大) 时, 应适当增大 H^* 以增加有用矿石的附着时间和无用脉石的脱离时间, 此时 ΔH 取为正大. 这样就避免了专家知识不能准确获取的问题.

表 3　模糊推理补偿规则表

Table 3　Fuzzy reasoning compensation rules table

ΔH		$\Delta\beta_J$						
		NB	*NM*	*NS*	*ZO*	*PS*	*PM*	*PB*
$\Delta\beta_W$	*NB*	*PS*	*PS*	*PS*	*PS*	*PM*	*PM*	*PB*
	NM	*PS*	*PS*	*PS*	*PS*	*PM*	*PM*	*PB*
	NS	*PS*	*PS*	*PS*	*PS*	*PS*	*PM*	*PB*
	ZO	*ZO*	*ZO*	*ZO*	*ZO*	*PS*	*PS*	*PS*
	PS	*NM*	*NS*	*NS*	*NS*	*NS*	*NS*	*NS*
	PM	*NB*	*NM*	*NM*	*NS*	*NS*	*NS*	*NS*
	PB	*NB*	*NM*	*NS*	*NS*	*NS*	*NS*	*NS*

模糊推理采用 BP 神经网络来实现, 即把推理规则转化为对应的神经网络输入输出样本. 其输入层上的每个节点分别代表 ΔJK 与 ΔWK 的名义值 $[-6, 6] \subset Z$, 输出层节点分别代表 ΔH 的名义值 $[-4, 4] \subset Z$. 每个结点的值为 $[0, 1]$ 内的一个数, 表示该节点所代表的名义值的隶属度. 隐含层节点数由 Kolmogorov 定理确定. 这样该模糊推理网络结构为 26-16-9, 然后随机初始化网络权重, 经过大量离线及在线训练学习便可记忆经验规则. 最终可根据实时浮选工况推理得到液位预设定的补偿调整值并按一定周期对其补偿. 该方法不需要大量计算从而提高了推理效率, 而且当操作经验增加时可通过训练进行自学习.

将优化设定模型得到的浮选槽液位作为底层控制回路的给定值, 由 PID 控制器实现对浮选液位给定值的跟随控制.

3　应用验证

结合如图 8 所示的某铝土矿浮选生产过程, 将提出的基于泡沫图像特征的浮选槽液位智能优化设定方法进行工业实验. 实际浮选流程分为粗选、精选及扫选, 其中粗选作为整个浮选流程的首个生产环节, 它可将矿浆中部分无用脉石矿物分离出, 从而实现有用矿物的一次富集, 为后续二次及三次富集奠定基础, 因而具有重要地位, 且由于其给矿条件容易确定, 所以将所提方法首先应用于粗选槽. 为验证所提方法的应用效果, 试验时在两组并行的浮选生产流程中的一组粗选槽采用智能优化设定方法调整液位, 另一组采用人工设定方法. 两组浮选流程的给矿来自同一给矿搅拌槽, 给矿条件相同. 在一个月 (30 天) 内不同时段每间隔 2 个小时记录一次两组浮选流程中粗选槽的液位值及与其对应的离线化验的粗选精/尾矿 (溢流/底流矿浆) 品位 (以铝硅比衡量), 得到 100 组运行数据, 统计结果如图 9 (a)∼(c) 所示.

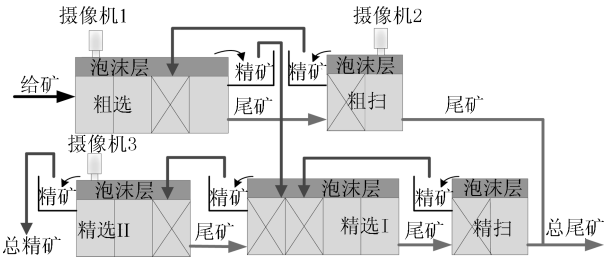

图 8　浮选生产流程图

Fig. 8　Flotation production flow

在一定给矿波动范围内, 根据工艺经验, 要求粗选过程中得到的精矿品位 $\beta_J \geq 9$, 尾矿品位 $\beta_W \leq 3$. 为全面对比评价两种操作方式效果, 分别计算了 100 组运行数据的液位波动最大偏差 $\Delta H_{\max}$ 与标准差 σ_H (反映液位值波动离散程度), 以及精/尾矿品位合格率 η_J 与 η_W, 得到如表 4 所示结果.

表 4　运行效果计算对比

Table 4　Running effect calculation contrast

评价指标	$\Delta H_{\max}$ (cm)	σ_H	η_J (%)	η_W (%)
人工设定	31.7	7.71	71	63
智能设定	18.7	4.58	92	89

由图 9 及表 4 可看出, 人工对液位设定时, 液位波动范围较大, 导致粗选槽精矿品位及尾矿品位不符合工艺目标要求的数据点较多. 而采用本文方法进行液位设定时, 液位波动范围较小, 粗选槽精/尾矿品位合格率分别提高 21 % 和 26 %. 工业应用表明, 所提方法能根据工况变化对粗选槽液位进行优化设定, 具有更好效果. 同时为对比研究粗选过程液位的设定控制效果对整个浮选流程性能的影响, 本

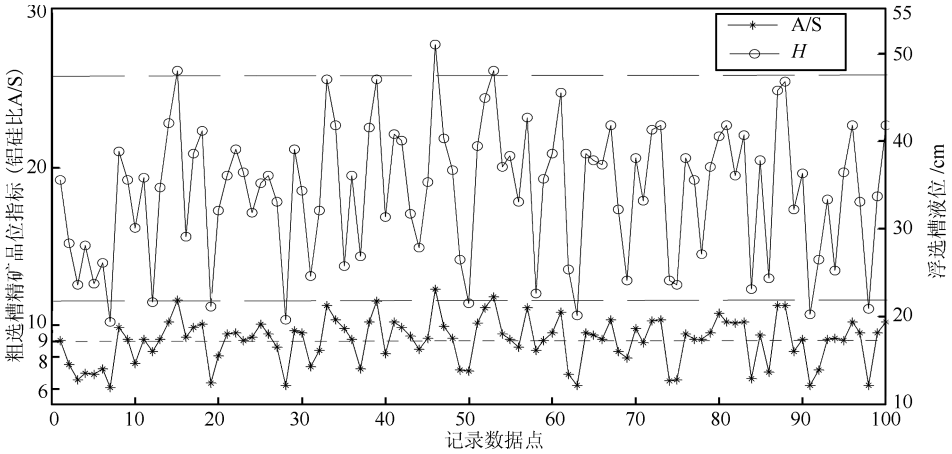

(a) 人工设定时的液位及精矿品位

(a) Level and concentrate grade when setting it manually

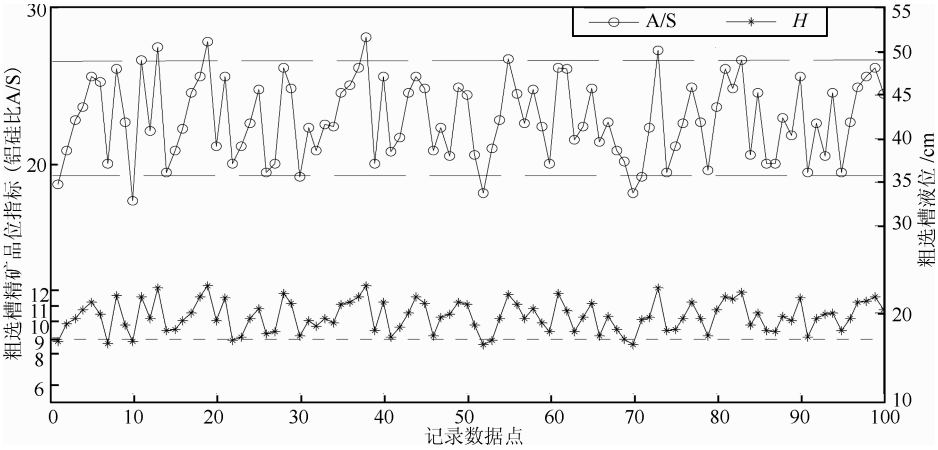

(b) 优化设定时的液位及精矿品位

(b) Level and concentrate grade when setting it optimally

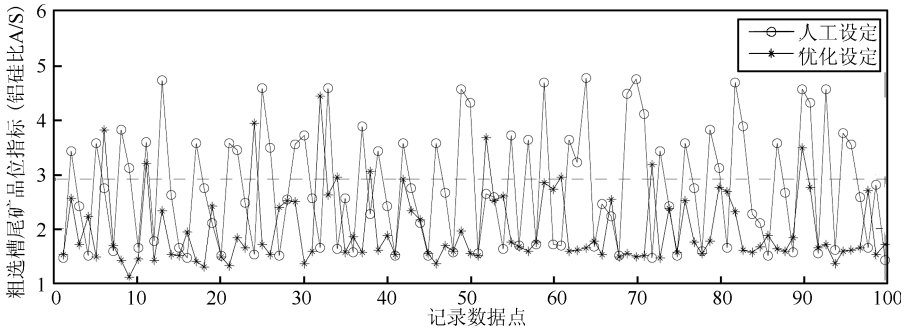

(c) 尾矿品位

(c) Grade of tailings

图 9 粗选过程运行效果对比

Fig. 9 Running effect contrast of rougher flotation process

文分析了现场 1 个月内两种运行模式下 100 组总精矿品位化验值 β_{ZJ}, 如图 10 所示.

根据工艺要求 $\beta_{ZJ} \geq 13$, 人工对粗选槽液位设定时总精矿品位合格率为 77 %, 采用本文方法时总精矿品位合格率为 91 %, 提高了 14 %. 此外本文还根据现场生产统计报表中一个月的累计原矿、总精矿、总尾矿品位数据 θ_{YK}、θ_{ZJ} 及 θ_{ZW} (氧化铝百分含量) 按照式 (10) 计算了总回收率 ξ_{HS}.

$$\xi_{HS} = \frac{\theta_{ZJ}\,(\theta_{YK} - \theta_{ZW})}{\theta_{YK}\,(\theta_{ZJ} - \theta_{ZW})} \times 100\% \qquad (10)$$

其中 ξ_{HS} 表示回收得到的总精矿中氧化铝的质量与原矿中氧化铝的质量之比. 通过式 (10) 通常可估算得到浮选生产流程的总回收率并进行性能评价[1]. 根据计算, 在原矿处理量及给矿品位相同的情况下, 人工对粗选槽液位进行设定调节时的浮选流程总回收率为 91.36 %, 而采用本文方法时总回收率为 93.45 %, 增加 2.09 %. 该结果表明粗选槽液位的合理优化设定对后续浮选流程将产生重要影响并改善了浮选生产过程的总体工艺性能.

应用结果表明本文方法可有效改善浮选性能, 该方法中三个模型为紧密联系的有机整体, 充分利用了机器视觉提供的泡沫特征信息对浮选槽液位进行设定. 但是, 正如第 2.1 节所提, 仅采用案例推理预设定模型是否具有可行性, 而采用智能补偿后的效果又如何? 为此, 本文针对该问题进行了对比实验. 主要将浮选生产流程中由人工进行浮选液位设定的一组仅由基于案例推理的单模型方法进行液位设定, 而另一组仍采用本文的智能设定方法, 统计了一个月的运行时间内不同时段人工化验得到的两组浮选流程的粗选精矿品位及对应的液位值, 得到如图 11 所示结果.

图 11 中方法 1 表示仅采用基于案例推理进行浮选槽液位设定, 方法 2 则表示采用本文提出智能设定方法对其设定. 由图 11 可看出, 采用方法 1 时液位波动较大, 而精矿品位不满足要求的数据点较多. 而采用方法 2 时浮选槽液位波动较小, 精矿品位满足要求的数据点较多. 通过计算, 单独采用预设定模型时精矿品位合格率为 76 %, 而采用本文方法时的合格率为 89 %, 提高了 13 %. 这说明经过智能补偿模型的补偿作用, 所提方法克服了工况变化带来的扰动, 弥补了仅采用基于案例推理的预设定方法的不足.

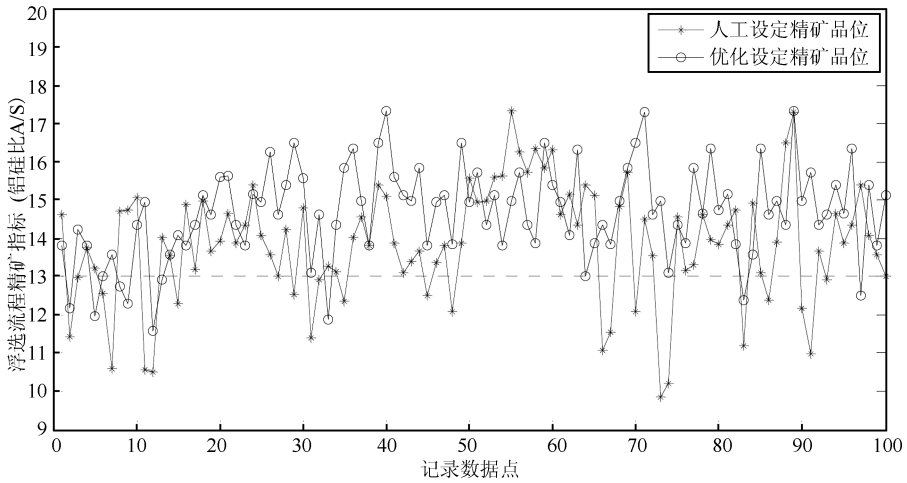

图 10　总精矿品位对比分析

Fig. 10　Comparative analysis of the overall concentrate grade

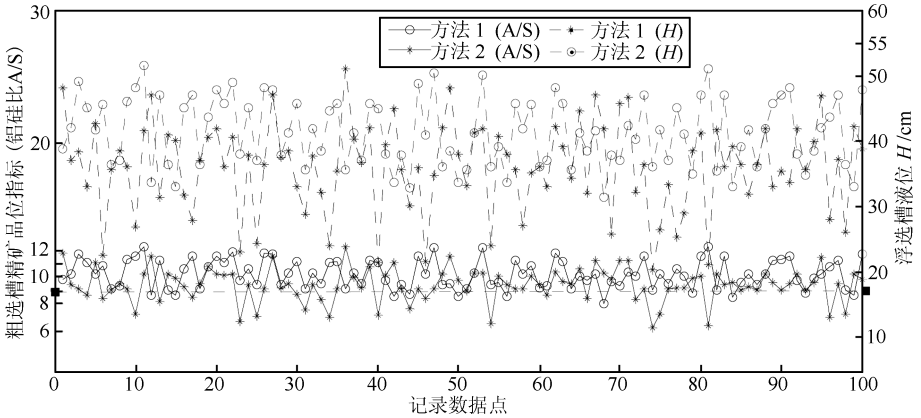

图 11　单模型方法与智能优化设定方法运行效果对比

Fig. 11　Running effect contrast between single-model approach and intelligently optimal setting approach

4 结论

浮选过程机理复杂、具有非线性、准确建模困难, 更难以实现对浮选槽液位的优化设定, 当前采用主观性强的人工设定方式, 易造成液位及工艺指标波动较大. 本文提出了一种基于多泡沫图像特征的浮选槽液位优化设定方法, 实现了浮选槽液位的优化设定, 并通过在铝土矿浮选生产过程的工业实验, 验证了所提方法的有效性. 基于此, 可进一步研究精选、扫选浮选槽的协调优化设定方法, 通过对浮选流程各个槽液位的协调优化, 改善浮选整体性能. 此外, 所提方法对于浮选过程中通风量、加药量的优化设定也具有借鉴意义, 为实现浮选生产全流程协调控制奠定了基础.

References

1 Niu Fu-Sheng, Liu Rui-Qin, Zheng Wei-Min, Yan Man-Zhi. *600 Asks of Mineral Processing Knowledge*. Beijing: Metallurgical Industry Press, 2008. 9−13
(牛福生, 刘瑞芹, 郑为民, 闫满志. 选矿知识 600 问. 北京: 冶金工业出版社, 2008. 9−13)

2 Nakhaeie F, Sam A, Mosavi M R. Concentrate grade prediction in an industrial flotation column using artificial neural network. *Arabian Journal for Science and Engineering*, 2013, **38**(5): 1011−1023

3 Bergh L G, Yianatos J. The long way towards multivariate predictive control of flotation processes. *Journal of Process Control*, 2011, **21**(2): 226−234

4 Kampjarvi P, Jamsa-Jounela S L. Level control strategies for flotation cells. *Minerals Engineering*, 2003, **16**(11): 1061−1068

5 Maldonado M, Desbiens A, Del Villar R. Potential use of model predictive control for optimizing the column flotation process. *International Journal of Mineral Processing*, 2009, **93**(1): 26−33

6 Bouchard J, Desbiens A, Del Villar R. Recent advances in bias and froth depth control in flotation columns. *Minerals Engineering*, 2005, **18**(7): 709−720

7 Wang He, Li Ying-Gen, Wang Huan-Gang, Xu Wen-Li. A design of feed-forward control for flotation cell level. *Non-Ferrous Metals (Mineral Processing)*, 2010, (6): 41−44
(王赫, 李映根, 王焕钢, 徐文立. 串级浮选槽液位的前馈控制设计方法. 有色金属 (选矿部分), 2010, (6): 41−44)

8 Liu J J, MacGregor J F. Froth-based modeling and control of flotation processes. *Minerals Engineering*, 2008, **21**(9): 642−651

9 Nunez F, Cipriano A. Visual information model based predictor for froth speed control in flotation process. *Minerals Engineering*, 2009, **22**(4): 366−371

10 Cao Bin-Fang, Xie Yong-Fang, Gui Wei-Hua, Wei Li-Jun, Yang Chun-Hua. Integrated prediction model of bauxite concentrate grade based on distributed machine vision. *Minerals Engineering*, 2013, **53**: 31−38

11 Marais C, Aldrich C. Estimation of platinum flotation grades from froth image data. *Minerals Engineering*, 2011, **24**(5): 433−441

12 Bartolacci G, Pelletier P, Tessier J, Duchense C, Bosse P, Founier J. Application of numerical image analysis to process diagnosis and physical parameter measurement in mineral processes, Part I: Flotation control based on froth textural characteristics. *Minerals Engineering*, 2006, **19**(6−8): 737−747

13 Ata S. Phenomena in the froth phase of flotation: a review. *International Journal of Mineral Processing*, 2012, **102−103**: 1−12

14 Aldrich C, Marais C, Shean B J, Cilliers J J. Online monitoring and control of froth flotation systems with machine vision: a review. *International Journal of Mineral Processing*, 2010, **96**(4): 1−13

15 Behbahani M, Saghaee A, Noorossana R. A case-based reasoning system development for statistical process control: case representation and retrieval. *Computers and Industrial Engineering*, 2012, **63**(4): 1107−1117

16 Pian Jin-Xiang, Chai Tian-You, Li Jie-Jia. Application of case-based reasoning and iterative learning to laminar cooling process control. *Acta Automatica Sinica*, 2012, **38**(12): 2032−2037
(片锦香, 柴天佑, 李界家. 案例推理及迭代学习在层流冷却控制中的应用. 自动化学报, 2012, **38**(12): 2032−2037)

17 Nakhaei F, Mosavi M R, Sam A, Vaghei Y. Recovery and grade accurate prediction of pilot plant flotation column concentrate: neural network and statistical techniques. *International Journal of Mineral Processing*, 2012, **110**(7): 140−154

18 Wang Yao-Nan, Yuan Xiao-Fang. SVM Approximate-based internal model control strategy. *Acta Automatica Sinica*, 2008, **34**(2): 172−179
(王耀南, 袁小芳. 基于支持向量机逼近的内模控制系统及应用. 自动化学报, 2008, **34**(2): 172−179)

19 Zhou Kai-Jun, Yang Chun-Hua, Mu Xue-Min, Gui Wei-Hua. Flotation recovery prediction based on froth features and LS-SVM. *Chinese Journal of Scientific Instrument*, 2009, **30**(6): 1295−1300
(周开军, 阳春华, 牟学民, 桂卫华. 基于泡沫特征与 LS-SVM 的浮选回收率预测. 仪器仪表学报, 2009, **30**(6): 1295−1300)

20 Gui Wei-Hua, Yang Chun-Hua, Xie Yong-Fang, Tang Zhao-Hui. *Bubble Image Processing and Process Monitoring techniques of Mineral Flotation*. Changsha: Central South University Press, 2013. 95−142
(桂卫华, 阳春华, 谢永芳, 唐朝晖. 矿物浮选泡沫图像处理与过程监测技术. 长沙: 中南大学出版社, 2013. 95−142)

21 Yang Chun-Hua, Zhou Kai-Jun, Mu Xue-Min, Gui Wei-Hua. Froth color and size measurement method for flotation based on computer vision. *Chinese Journal of Scientific Instrument*, 2009, **30**(4): 717−721
(阳春华, 周开军, 牟学民, 桂卫华. 基于计算机视觉的浮选泡沫颜色及尺寸测量方法. 仪器仪表学报, 2009, **30**(4): 717−721)

22 Liu Wen-Li, Lu Mai-Xi, Wang Fan, Wang Yong. Extraction of textural feature and recognition of coal flotation froth. *Journal of Chemical Industry and Engineering (China)*, 2003, **54**(6): 830−835
(刘文礼, 路迈西, 王凡, 王勇. 煤泥浮选泡沫图像纹理特征的提取及泡沫状态的识别. 化工学报, 2003, **54**(6): 830−835)

23 Gui Wei-Hua, Yang Chun-Hua, Xu De-Gang, Lu Ming, Xie Yong-Fang. Machine-vision-based online measuring and controlling technologies for mineral flotation: a review. *Acta Automatica Sinica*, 2013, **39**(11): 1879−1888
(桂卫华, 阳春华, 徐德刚, 卢明, 谢永芳. 基于机器视觉的矿物浮选过程监控技术研究进展. 自动化学报, 2013, **39**(11): 1879−1888)

24 Geng Zeng-Xian, Chai Tian-You. Intelligently optimal index setting for flotation process by CBR. *Journal of Northeastern University (Natural Science)*, 2008, **29**(6): 761−764
(耿增显, 柴天佑. 基于案例推理的浮选过程智能优化设定. 东北大学学报 (自然科学版), 2008, **29**(6): 761−764)

25 Li H B, Chai T Y, Zhang L Y. Hybrid intelligent optimal control for flotation processes. In: Proceedings of the 2012 American Control Conference (ACC). Montreal, Canada: IEEE, 2012. 4891−4896

26 Jiang Yi-Zhang, Deng Zhao-Hong, Wang Shi-Tong. Mamdani-larsen type transfer learning fuzzy system. *Acta Automatica Sinica*, 2012, **38**(9): 1393−1409
(蒋亦樟, 邓赵红, 王士同. ML 型迁移学习模糊系统. 自动化学报, 2012, **38**(9): 1393−1409)

赵洪伟 中南大学信息科学与工程学院硕士研究生. 主要研究方向为工业过程建模与优化控制研究, 智能控制系统.
E-mail: zhaohw@csu.edu.cn
(**ZHAO Hong-Wei** Master student at the School of Information Science and Engineering, Central South University. His research interest covers modeling and optimal control of complex industrial process and intelligent control system.)

谢永芳 博士, 中南大学教授. 主要研究方向为复杂工业过程建模与优化控制.
E-mail: yfxie@csu.edu.cn
(**XIE Yong-Fang** Ph.D., professor at Central South University. His research interest covers modeling and optimal control of complex industrial process.)

蒋朝辉 博士, 中南大学信息科学与工程学院副教授. 主要研究方向为复杂工业过程建模与优化控制, 广义大系统控制理论与应用. 本文通信作者.
E-mail: jzh0903@csu.edu.cn
(**JIANG Zhao-Hui** Ph.D., associate professor at the School of Information Science and Engineering, Central South University. His research interest covers modeling and optimal control of complex industrial process, descriptor large systems control theory and application. Corresponding author of this paper.)

徐德刚 博士, 中南大学信息科学与工程学院副教授. 主要研究方向为复杂工业过程建模与优化控制, 智能控制.
E-mail: dgxu@csu.edu.cn
(**XU De-Gang** Ph.D., associate professor at the School of Information Science and Engineering, Central South University. His research interest covers modeling and optimal control of complex industrial process, and intelligent control.)

阳春华 博士, 中南大学信息科学与工程学院教授. 主要研究方向为复杂工业过程建模与优化控制, 智能自动化系统与装置. E-mail: ychh@csu.edu.cn
(**YANG Chun-Hua** Ph.D., professor at the School of Information Science and Engineering, Central South University. Her research interest covers modeling and optimal control of complex industrial process, intelligent automation systems devices.)

桂卫华 中国工程院院士, 中南大学教授. 主要研究方向为复杂工业过程建模与优化控制, 工业大系统控制理论与应用. E-mail: gwh@mail.csu.edu.cn
(**GUI Wei-Hua** Academician of Chinese Academy of Engineering, professor at Central South University. His research interest covers modeling and optimal control of complex industrial process, and industrial large system control theory and application.)