

## 基于图像特征的锑浮选矿浆pH值预测控制

王晓丽, 曾子骄, 黄蕾, 谢永芳, 阳春华

(中南大学 信息科学与工程学院, 长沙 410083)

**摘要:** 适宜的矿浆pH值是泡沫浮选高效生产的关键. 针对浮选矿浆pH值无法在线检测和控制滞后的问题, 提取pH关联泡沫表面敏感特征, 建立基于仿射传播聚类的多模型最小二乘支持向量机软测量模型, 提出一种基于差分进化的在线支持向量回归pH值预测控制方法, 离线建立和在线校正pH值预测模型, 采用基于差分进化优化方法求解预测控制决策变量, 从而实现pH值实时控制. 金锑浮选工业数据表明, 所提出的控制策略稳定了矿浆pH值, 减少了药剂消耗.

**关键词:** 图像特征; 差分进化; 仿射传播聚类; 在线支持向量回归; pH值预测控制

**中图分类号:** TP273

**文献标志码:** A

## Predictive control of slurry pH based on froth characteristics for antimony flotation process

WANG Xiao-li, ZENG Zi-jiao, HUANG Lei, XIE Yong-fang, YANG Chun-hua

(School of Information Science and Engineering, Central South University, Changsha 410083, China. Correspondent: WANG Xiao-li, E-mail: xlwang@csu.edu.cn)

**Abstract:** A suitable pH value of the slurry is the key for efficient froth flotation. In the industrial process, it is difficult to measure the pH value online, which causes the control delay. To solve this problem, pH-associated sensitive image features of the froth are obtained, and a soft sensor model-multi-model least squares support vector machine(LSSVM) based on affinity propagation clustering(AP) is introduced. Then, a predictive control strategy based on online support vector regression(OSVR) and differential evolution(DE) optimization for the pH is proposed. The prediction model is built offline and corrected online, and a DE optimization method is used to solve the predictive control problem to find the optimal decision variables, so as to achieve the real-time control of the slurry pH value. The industrial test results in antimony flotation show that the proposed control strategy can stabilize the pH value, and reduce the chemical consumption.

**Keywords:** image features; differential evolution; affinity propagation clustering; online support vector regression; predictive control for pH value

### 0 引言

矿物泡沫浮选是利用有价矿物与脉石矿物表面疏水性质的差异, 将有价矿物与脉石分离的过程. 在浮选过程中, pH值直接影响矿浆离子组成、浮选药剂的活性, 以及矿物的表面性质<sup>[1]</sup>. 不同种类的矿石只有在适宜的pH环境下才能获得最优浮选指标. 但因为浮选矿浆十分容易粘结在分析探头上, 而管理维护跟不上, 造成pH在线检测仪表误差大、稳定性差、易损坏<sup>[2]</sup>. pH值调整剂与水 and 矿石颗粒的作用具有大时滞、强非线性, 增加了pH值控制的难度. 在实际生产中, 众多的选厂仍通过操作工人离线分析并手动调

节pH值调整剂的加入量控制矿浆酸碱度, 离线分析频率低造成控制滞后, 且准确率低, 致使药剂消耗大, 工况波动频繁. 因此, 实时准确测量并控制矿浆pH值对优化浮选生产指标具有重大意义.

由于浮选过程操作变量、生产状态变量耦合严重, pH中和过程具有强非线性、大时滞及不确定性等特点, 难以建立精确的数学模型. 针对此类强非线性系统, 基于智能模型的预测控制是可行的方法. 文献[3-4]提出了基于神经网络预测模型的预测控制策略. Khani等<sup>[5]</sup>提出了基于Wiener或Hammerstein模型的鲁棒模型预测控制策略. 此外还包括采用支持向量

收稿日期: 2015-10-30; 修回日期: 2016-01-24.

基金项目: 国家自然科学基金项目(61304126, 61473318, 61304019); 国家自然科学基金重点项目(61134006).

作者简介: 王晓丽(1981—), 女, 副教授, 博士, 从事工业过程建模与优化等研究; 曾子骄(1988—), 男, 硕士, 从事复杂工业过程优化控制的研究.

机(SVM)<sup>[6]</sup>、全神经网络(ULN)<sup>[7]</sup>建立的预测控制模型.但是,在上述这些方法中,其预测模型都是离线训练模型,不能实现在线校正,而浮选过程具有时变特性,给矿量的频繁波动、浮选液位的变化、温度的扰动都给pH值的控制带来许多不确定因素,离线模型很难适应这种变化.同时,pH值的在线检测精度也急需提高.

随着计算机技术、数字图像处理技术的快速发展,将基于机器视觉的软测量技术应用于浮选过程给浮选指标实时控制带来了新的突破<sup>[8-12]</sup>.因此,本文针对浮选矿浆pH值难以在线测控的问题,以某选厂金锑浮选为研究对象,引入泡沫图像表现特征,建

立基于仿射传播聚类(AP)的多模型最小二乘支持向量机(LSSVM)的pH值软测量模型,并以此为检测手段,提出一种基于差分进化(DE)的在线支持向量回归(OSVR)矿浆pH值预测控制方法.该方法采用在线支持向量回归离线训练和在线学习相结合的方式,增强模型的泛化能力和精确度,并利用DE算法快速、准确求解目标函数,实现矿浆pH值实时控制,减少药剂消耗,提高浮选指标.

## 1 金锑泡沫混合优先浮选过程

某金锑选矿厂采用部分优先——混合浮选新工艺,先在弱碱性环境下选金,后在弱酸性环境下选锑,其工艺流程如图1所示.

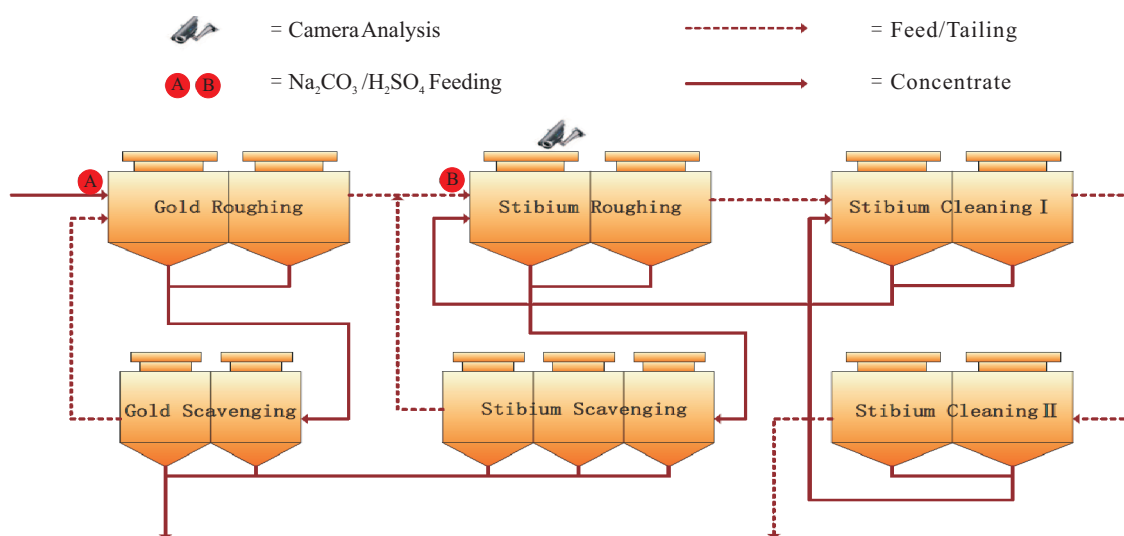


图1 混合浮选回路

在图1浮选回路中:金为一粗选两精选,锑为一粗选两精选两扫选流程,金精矿和锑精矿混合最终形成混合精矿.矿石主要由辉锑矿、毒砂、黄铁矿3类构成.在优先浮选金过程中,需要添加碳酸钠使矿浆pH值为碱性,从而保证较高的金回收率.而锑作为重点浮选目标,适宜于在弱酸性及中性介质中选拔,当pH值在6.5左右时,浮选性能最优.因此,可在锑粗选首槽的入口矿浆中添加H<sub>2</sub>SO<sub>4</sub>溶液,调整锑粗选的pH值.

锑粗选的加药包括黄药、黑药、硫酸铜、硝酸铅和二号油等,这些药的添加顺序和添加方法(溶液或固体)是固定的,添加量主要根据矿石的性质确定一个基准添加量,实时控制是在基准添加量上进行微调.矿浆的pH值直接决定着这些药剂能否发挥其作用,在矿石较稳定的情况下,这些药剂的添加量调节很少,主要是对pH值进行控制,因而使泡沫表面特征与pH值有着密切的关系.因此,在锑粗选槽上方安装工业摄像机,拍摄表层的泡沫图像,对图像处理并基

于泡沫图像的特征对锑粗选矿浆pH值进行软测量,并通过预测控制算法实时计算出H<sub>2</sub>SO<sub>4</sub>的加入量,给定PLC进行反馈闭环控制.

## 2 基于图像特征的矿浆pH值软测量

### 2.1 pH关联敏感图像特征的选取

pH关联敏感图像特征是指能充分反映矿浆pH值变化的最小图像特征子集.深入研究金锑浮选工艺发现:对于一定的矿石,矿浆pH值较高时泡沫颜色偏黑、较虚、尺寸偏大、尺寸分布不均匀、泡沫易破裂;矿浆pH值较低时,颜色呈铅灰色、粘稠度高、泡沫尺寸偏小、分布均匀.

通过浮选泡沫图像监控系统获得泡沫的稳定度  $S_{stable}$ 、灰度  $G_{gray}$ 、红色分量  $R_{red}$ 、绿色分量  $G_{green}$ 、蓝色分量  $B_{blue}$ 、尺寸  $S_{size}$ 、承载率  $L_{load}$ 、色度  $H_{hue}$ 、亮度  $L_{light}$ 、峰度  $K_{kur}$ 、偏斜度  $S_{ske}$ 、尺寸方差  $V_{var}$  等13个泡沫表观特征,都在不同程度上反映了矿浆pH值变化,但这些特征之间存在强耦合,严重影响了

pH 值的测量精度以及计算的复杂度. 因此, 采用关联度分析方法, 计算 13 个图像特征变量和 pH 值的关联度, 最终获得 pH 关联敏感特征集  $[S_{\text{stable}}, G_{\text{gray}}, S_{\text{size}}, L_{\text{load}}, S_{\text{ske}}, V_{\text{var}}]$ .

### 2.2 基于 AP 的多模型 LSSVM 软测量

针对原矿性质多样性的特点, 采用多模型建模分解合成的思想, 能够在各类矿源适应域内, 有效分解系统非线性, 并在每个局部模型中精确逼近真实 pH 值. 建模时, 在 pH 关联敏感特征选取的基础上, 对所有样本采用仿射传播 (AP) 聚类方法进行分类, 然后对每一类建立子模型, 再将所有子模型的结果进行合成, 得到最终的软测量结果. 子模型输入样本表示为

$$X = [x_1, x_2, \dots, x_n]^T.$$

其中:  $x_i = (x_{i1}, x_{i2}, x_{i3}, x_{i4}, x_{i5}, x_{i6})$ ,  $i = 1, 2, \dots, n$ ,  $x_{i1}, x_{i2}, \dots, x_{i6}$  分别为  $S_{\text{stable}}, G_{\text{gray}}, S_{\text{size}}, L_{\text{load}}, S_{\text{ske}}, V_{\text{var}}$ ; 子模型输出样本为  $Y = [y_1, y_2, \dots, y_n]^T$ ,  $y_i$  ( $i = 1, 2, \dots, n$ ) 为 pH 值.

软测量建模具体步骤如下:

Step 1: 基于机器视觉的泡沫图像特征提取, 选取 pH 关联敏感特征;

Step 2: 采用 AP 聚类算法<sup>[13]</sup>将数据样本划分为  $k$  个聚类;

Step 3: 将高斯核函数与多项式核函数加权融合, 分别对每个聚类作 LSSVM 回归, 得到  $k$  个子模型;

Step 4: 按照式  $y(j) = \sum_{i=1}^k \mu_{ij} f_i(x_j)$  对  $k$  个子模型加权融合输出最终 pH 值.

$\mu_{ij}$  表示样本  $j$  隶属于子模型  $i$  的程度, 用样本  $j$  到第  $i$  类样本中心的距离与样本  $j$  到所有类样本中心距离总和的比值表示.

在模型应用时, 实时采集泡沫图像特征并输入各子模型得到子模型输出结果, 再将子模型输出结果进行合成得到一个对应的 pH 值. 图 2 给出了一段时间内的软测量效果.

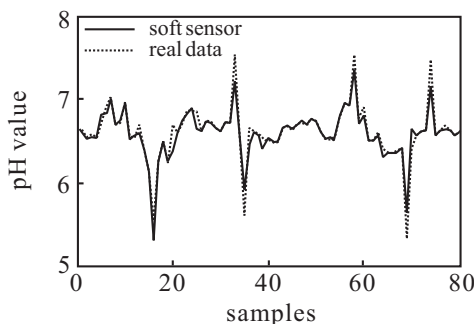


图 2 pH 值软测量结果

在图 2 中: 最大相对误差 (MRE) 为 5.536%, 91% 的绝对误差位于  $\pm 0.3$  之内, 可满足工业生产需求, 为下一步控制奠定了基础.

### 3 基于 DE 优化在线支持向量回归的矿浆 pH 值预测控制

#### 3.1 OSVR 非线性预测模型

浮选矿浆 pH 值预测模型描述为

$$y(k+d) = f[y(k+d-1), \dots, y(k+d-p), u(k), u(k-1), \dots, u(k-q+1)]. \quad (1)$$

其中:  $f$  为非线性方程,  $u$  为控制量,  $k$  为当前时刻,  $y$  为输出量,  $d$  为输出延时,  $p$  和  $q$  分别为系统未知的输入和输出阶次.

由于浮选过程变量多、非线性强, 无法建立精确数学模型, 加上矿源种类多, 工况波动频繁, 故采用 OSVR 建立预测模型, 可在线校正模型增强适应性. 给定训练数据集

$$T = \{x_i, y_{i+d}, i = 1, 2, \dots, l\},$$

$$x_i = (y(i+d-1), \dots, y(i+d-p), u(i), u(i-1), \dots, u(i-q+1)),$$

其中  $l$  为样本数.

非线性映射  $\Phi$  将数据  $x_i$  映射到高维特征空间, 特征空间中 OSVR 的估计模型为  $f(x) = \omega \Phi(x) + b$ . 其中:  $\omega$  为权重系数,  $b$  为偏置.

为了最小化回归方程估计真实风险, 引入松弛变量  $\xi_i$  和  $\xi_i^*$ , 利用结构风险最小化准则构建最小化目标函数

$$\min_{\omega, b} D = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*).$$

$$\begin{cases} y_{i+d} - f(x_i) \leq \varepsilon + \xi_i; \\ f(x_i) - y_{i+d} \leq \varepsilon + \xi_i^*; \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, l. \end{cases} \quad (2)$$

其中:  $\varepsilon$  为不敏感系数,  $C$  为惩罚系数.

构建拉格朗日方程, 此问题转化为对偶问题

$$\min_{\alpha_i, \alpha_i^*} W =$$

$$\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l K(x_i, x_j) (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) +$$

$$\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) - \sum_{i=1}^l y_i (\alpha_i + \alpha_i^*).$$

$$\begin{cases} 0 \leq \alpha_i, \alpha_i^* \leq C; \\ \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0; \\ i = 1, 2, \dots, l. \end{cases} \quad (3)$$

其中:  $\alpha_i$  和  $\alpha_i^*$  为拉格朗日乘子,  $K(x_i, x_j) = \Phi(x_i) \times \Phi(x_j)$  为核函数. 由此可得预测模型

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b. \quad (4)$$

根据拉格朗日乘子和 KKT 条件, 可将训练数据集分为 3 个子集: 误差支持向量集

$$E = \{i | |\theta_i| = C, |h(x_i)| \geq \varepsilon\};$$

支持向量集

$$S = \{i | 0 < |\theta_i| < C, |h(x_i)| = \varepsilon\};$$

保留样本集

$$R = \{I = |\theta_i| = 0, |h(x_i)| \leq \varepsilon\}.$$

其中  $\theta_i = \alpha_i - \alpha_i^*$ ,  $h(x_i) = f(x_i) - y_i$ .

当一个新样本加入训练集  $T$  中, 如果  $h(x_c) < \varepsilon$ , 则直接将样本移入  $R$  集中, 结束训练; 当  $h(x_c) > \varepsilon$  时, 逐渐改变  $\theta_i$  和  $h(x_i)$ , 直到新样本进入 3 个集合中的一个, 对于受新增样本影响的原有样本归属, 将根据  $\Delta\theta$  进行相应移动, 具体参照文献 [14-15].

### 3.2 DE 优化的 OSVR-NMPC 设计

浮选矿浆 pH 值控制系统是一个有  $d$  步延迟的非线性系统, 系统输入为  $u(k)$  时, 输出为  $y(k+d)$ , 根据系统过去的输入输出和当前的输入  $u(k)$ , 通过 OSVR 模型预测当前输出  $\hat{y}(k+d)$ , 获得系统实际输出量与预测输出量之间的误差

$$e(k+d) = y(k+d) - \hat{y}(k+d). \quad (5)$$

反馈校正后得到  $k+1$  时刻预测控制输出

$$y_p(k+d+1) = \hat{y}(k+d+1) + e(k+d). \quad (6)$$

同时, 通过将反馈误差  $e(k+d)$  与设定误差 ErrSet 进行比较决定 OSVR 模型是否进行在线学习, 只对超过设定误差的样本进行在线训练. 即当  $|e(k+d)| > \text{ErrSet}$  时, 说明模型失配, 需要对将样本代入训练集进行在线学习.

对梯粗选 pH 值控制设计预测控制器, 控制性能目标函数为

$$J(k) = \sum_{i=1}^N [y_{ri}(k+d+1) - y_{pi}(k+d+1)]^2 + \sum_{j=1}^M \lambda_j [u_j(k+1) - u_j(k)]^2, \quad (7)$$

其中  $M$  和  $N$  分别为控制时域和预测时域.

差分进化算法是一种随机的并行直接搜索算法, 它可对非线性不可微连续空间函数进行最小化, 具有稳健性和强大的全局寻优能力, 且搜索速度快、效率高. 因此, 本文采用差分进化算法对目标函数求解, 以满足在线优化对求解速度的要求. DE 优化的

OSVR-NMPC 算法框图如图 3 所示.

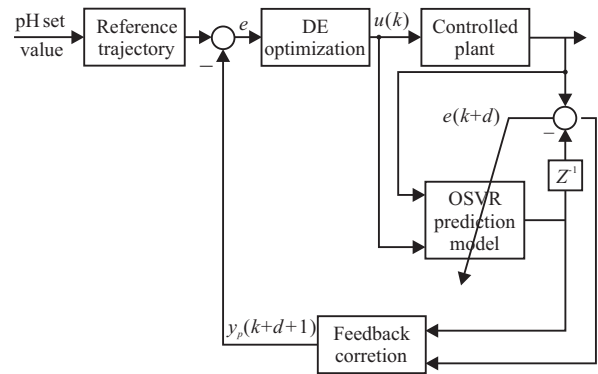


图 3 DE 优化 OSVR-NMPC 算法

优化对象为  $u(k+1)$ , 在 DE 中控制量  $u(k+1)$  的每一个个体表示为  $u_{i,G}$ . 其中:  $i \in [1, 2, \dots, NP]$  为个体在种群中的序列,  $NP$  为种群规模;  $G$  为进化代数. 采用 best/2 变异形式计算变异向量

$$v_{i,G} = u_{\text{Best},G} + F(u_{r_1,G} - u_{r_2,G}) + F(u_{r_3,G} - u_{r_4,G}). \quad (8)$$

其中: 变异算子  $F \in [0, 2]$  为一个实常数因数, 控制偏差变量的放大作用. 随机选择的序号  $r_1, r_2, r_3$  与  $r_4$  互不相同, 且  $r_1, r_2, r_3$  和  $r_4$  与目标向量序号  $i$  也应不相同. 采用如下的交叉操作产生试验向量:

$$x_{i,G} = \begin{cases} v_{i,G}, & \text{rand}(0, 1) \leq \text{CR}; \\ u_{i,G}, & \text{otherwise.} \end{cases} \quad (9)$$

其中:  $\text{rand}(0, 1)$  是一个  $[0, 1]$  之间的随机数;  $\text{CR}$  为交叉因子, 取值范围为  $[0, 1]$ .

按照贪婪准则将试验向量  $x_{i,G}$  与当前种群中的目标向量  $u_{i,G}$  进行比较, 两者中, 利用具有较小目标函数值的向量取代  $u_{i,G}$  的位置, 传递至下一代. 当目标函数小于阈值时, 停止优化, 从而获得最优控制量.

### 3.3 算法步骤

对于式 (1) 所描述的 pH 值非线性系统, DE 优化的 OSVR 预测控制算法步骤如下:

Step 1: 初始化 OSVR 和 DE 参数;

Step 2: 根据现场采样得到控制系统输入输出数据所构成的样本集, 并通过 OSVR 离线训练得到预测模型;

Step 3: 在采样时刻  $k$ , 对于控制量  $u(k)$ , 通过所建立的基于图像特征的软测量模型得到系统的输出  $y(k+d)$ , 通过 OSVR 预测模型得到该时刻输出  $\hat{y}(k+d)$ , 比较预测输出和实际输出得到其预测误差  $e(k+d)$ ;

Step 4: 若  $|e(k+d)| < \text{ErrSet}$ , 则将此样本加入训练集, OSVR 模型保持不变; 若  $|e(k+d)| > \text{ErrSet}$ , 则先将此样本加入训练集进行在线训练调整预测模

型参数;

Step 5: 假设  $k + 1$  时刻待优化输入为  $u(k + 1)$ , 通过预测模型获得  $\hat{y}(k + d + 1)$ , 并修正偏差可以得到  $y_p(k + d + 1)$ ;

Step 6: 通过 DE/Best/2/bin 差分进化算法求解目标函数, 通过 Step 5 进行迭代计算, 从而获得最优控制量  $u(k + 1)$ .

#### 4 结果与分析

结合某厂锑浮选过程连续一个月的实际运行生产数据 456 条对锑粗选 pH 值控制系统进行验证. 结合实际工况剔除部分异常工况样本, 保留 386 条数据, 并对其进行归一化处理, 选定锑粗选 pH 值系统输入输出阶次为  $p = q = 4$ , 时滞  $d = 5$ ,  $C = 500$ ,  $\varepsilon = 0.1$ , 建立形如  $[(y(k), y(k - 1), \dots, y(k - 3)), u(k - 5), \dots, u(k - 8)), y(k + 1)]$  的样本集. 其中:  $u(k)$  为锑粗选过程  $H_2SO_4$  流的流速 (ml/min),  $y(k)$  为输出量 pH 值. 取其中 336 条作为训练数据, 剩余 50 条作为验证数据. 核函数取高斯核函数, 选择参数  $\gamma = 100$ ,  $\sigma^2 = 10$ , 取 ErrorSet = 0.3, 采用 OSVR 进行离线建模和仿真测试, 结果如图 4 所示, OSVR 预测模型绝对误差 87.8% 位于  $\pm 0.3$  之间, 只有 3 次在线学习, 其具有较高的精度且满足了模型在线校正的需要.




图 4 基于 OSVR 预测模型结果

以上述 OSVR 预测模型为基础, 对锑粗选矿浆 pH 值进行预测控制. 采用 DE 算法优化控制量, DE 参数初始值选择  $NP = 100$ ,  $F = 0.5$ ,  $CR = 0.1$ , 阈值为  $10^{-6}$ . 将基于 DE 优化的 OSVR-NMPC 控制结果与最小二乘支持向量机非线性预测控制 (LSSVM-NMPC) 结果进行仿真比较, 结果如图 5 所示.




图 5 SVM-NMPC 与 OSVR-NMPC 控制对比

由此可见, 在模型匹配的条件下, 基于 DE 优化的 OSVR-NMPC 与 LSSVM-NMPC 控制效果基本相同, 系统响应曲线较为平稳, 超调量较小, 但是目标函数寻优精度与计算时间都要略优于 LSSVM-NMPC, 控制量优化时间不超过 1 s. 在首次出现模型不匹配的情况下, OSVR-NMPC 和 LSSVM-NMPC 均出现了较高等度的超调, 但是, OSVR-NMPC 具有在线学习能力, 当模型不匹配 (即误差超过 0.3 时), 将通过该数据样本对预测模型进行在线修正. LSSVM-NMPC 只能通过反馈校正使 pH 值稳定在设定值, 所需时间较长, 并且再次遇到类似工况, LSSVM-NMPC 依然存在模型失配问题, 超调量较大; 而 OSVR-NMPC 超调量明显降低, 控制周期缩短, 能更好地解决浮选过程工况波动频繁以及原矿不稳定所带来的模型失配问题.

将 DE 优化的 OSVR-NMPC 进行现场测试连续运行 1 个月. 实际生产中从 pH 值调整剂加入到其作用显现约需要 5 min, 泡沫图像处理系统的特征提取间隔为 2.5 min, 因此采样周期设为 2.5 min, 预测时域设为 2, 控制时域为 1. 取其中 3 天 pH 值数据与人工控制的 pH 值数据进行比较, 结果如图 6 所示.




图 6 人工控制与 OSVR-NMPC 控制效果对比

图 6 中数据的取样周期为 15 min/个. 由此可知: 人工控制 pH 值调节周期长, 准确率, 振荡较大; 而采用 OSVR-NMPC 的调节周期短, 超调量小, 很好地稳定了锑粗选 pH 值. 取测试前一个月人工调节的  $H_2SO_4$  平均单耗 (每两小时每吨矿物药剂平均消耗量) 与 OSVR-NMPC 调节的  $H_2SO_4$  平均单耗数据进行对比, 如图 7 所示.




图 7 人工控制与 OSVR-NMPC 药剂平均单耗对比

由图 7 可知: OSVR-NMPC 调节药剂单耗波动较

小, 相比于人工调节, 药剂单耗降低了 10.57%, 达到了节约成本、提高浮选效率的目的。

## 5 结 论

金锑浮选泡沫表观特征能够实时反应 pH 值变化。本文基于机器视觉实时提取 pH 关联敏感特征作为辅助变量, 建立了基于 AP 仿射的多模型 LSSVM, 验证了模型的有效性。针对 pH 值的强非线性对象控制问题提出了一种基于 OSVR 的模型预测控制算法。利用实际生产数据离线建立了 OSVR 预测模型, 由于 OSVR 具有在线学习能力, 避免了浮选工况不稳定造成的模型失配, 实现了模型在线自校正。通过差分进化优化算法对目标函数进行求解, 节省了优化时间。仿真和工业现场实验结果表明, 基于该模型的 pH 值预测控制不仅稳定了生产指标, 而且可节约 pH 值调整剂成本。

由于浮选实际生产过程流程长且复杂, 单纯的模型预测控制在工况异常时难以达到期望的控制效果, 因此智能与预测控制相结合的混合控制是需要进一步研究的问题。

## 参考文献(References)

- [1] Ma X, Bruckard W J, Holmes R. Effect of collector, pH and ionic strength on the cationic flotation of kaolinite[J]. *Int J of Mineral Processing*, 2009, 93(1): 54-58.
- [2] 黄宋魏, 张博亚, 胡娟, 等. pH 计及其在浮选中的应用[J]. *有色金属: 选矿部分*, 2008(2): 41-45.  
(Huang S W, Zhang B Y, Hu J, et al. The application of pH apparatus in flotation[J]. *Nonferrous Metals: Mineral Processing Section*, 2008(2): 41-45.)
- [3] Akesson B M, Toivonen H T, Waller J B, et al. Neural network approximation of a nonlinear model predictive controller applied to a pH neutralization process[J]. *Computers and Chemical Engineering*, 2005, 29(2): 323-335.
- [4] Arefi M M, Montazeri A, Poshtan J, et al. Wiener-neural identification and predictive control of a more realistic plug-flow tubular reactor[J]. *Chemical Engineering J*, 2008, 138(1/2/3): 274-282.
- [5] Khani F, Haeri M. Robust model predictive control of nonlinear processes represented by wiener or hammerstein models[J]. *Chemical Engineering Science*, 2015, 129: 223-231.
- [6] Bao Zhejing, Pi Daoying, Sun Youxian. Nonlinear model predictive control based on support vector machine with multi-kernel[J]. *Chinese J of Chemical Engineering*, 2007, 15(5): 691-697.
- [7] Han M, Han B, Xi J, et al. Universal learning network and its application for nonlinear system with long time delay[J]. *Computers and Chemical Engineering*, 2006, 31(1): 13-20.
- [8] 阳春华, 任会峰, 桂卫华, 等. 基于稀疏多核最小二乘支持向量机的浮选关键指标软测量[J]. *中国有色金属学报*, 2011, 21(12): 3149-3154.  
(Yang C H, Ren H F, Gui W H, et al. Soft sensor of key index for flotation process based on sparse multiple kernels least squares support vector machines[J]. *The Chinese J of Nonferrous Metals*, 2011, 21(12): 3149-3154.)
- [9] Zhu Jianyong, Gui Weihua, Yang Chunhua, et al. Probability density function of bubble size based reagent dosage predictive control for copper roughing flotation[J]. *Control Engineering Practice*, 2014, 29(8): 1-12.
- [10] Núñezf Cipriano A. Visual information model based predictor for froth speed control speed control in flotation process[J]. *Minerals Engineering*, 2009, 22(3): 366-371.
- [11] Morara S H, Harris M C, Bradshaw D J. The use of machine vision to predict flotation performance[J]. *Minerals Engineering*, 2012, 36-38(10): 31-36.
- [12] Jahedsaravani A, Marhaban M H, Massinaei M. Prediction of the metallurgical performances of a batch flotation system by image analysis and neural networks[J]. *Minerals Engineering*, 2014, 69(8): 137-145.
- [13] Frey B J, Dueck D. Clustering by passing message between data points[J]. *Science*, 2007, 315(5814): 972-976.
- [14] Ma Junshui, Theiler J, Perkins S. Accurate on-line support vector regression[J]. *Neural Computation*, 2003, 15(11): 2683-2704.
- [15] Shin J, Jin K H, Kim Y. Adaptive support vector regression for UAV flight control[J]. *Neural Networks*, 2011, 24(1): 109-120.

(责任编辑: 闫 妍)