

文章编号: 1001-0920(2009)09-1300-06

## 基于图像特征提取的浮选关键参数智能预测算法

周开军, 阳春华, 牟学民, 桂卫华  
(中南大学 信息科学与工程学院, 长沙 410083)

**摘 要:** 针对矿物浮选过程中回收率参数难以在线检测的问题, 提出了一种智能预测算法. 首先采用相对红色分量提取泡沫颜色特征, 采用改进面积重构变换与分水岭方法分割泡沫图像并提取尺寸特征; 然后在此基础上, 通过斯密特正交化对最小二乘支持向量机(LSSVM)核矩阵进行简约, 利用核偏最小二乘方法进行回归计算, 得到具有稀疏性的LSSVM预测模型. 实验结果表明, 该预测算法能有效地对矿物回收率进行预测.

**关键词:** 矿物浮选; 泡沫图像; 特征提取; 预测模型; 最小二乘支持向量机

中图分类号: TP273.5 文献标识码: A

## Intelligent prediction algorithm for floatation key parameters based on image features extraction

ZHOU Kai-jun, YANG Chun-hua, MOU Xue-min, GUI Wei-hua

(College of Information Science and Engineering, Central South University, Changsha 410083, China.

Correspondent: ZHOU Kai-jun, E-mail: kjzhou@csu.edu.cn)

**Abstract:** For the problem that the mineral recovery is hard to online measure in mineral floatation process, an intelligent prediction algorithm is proposed. The froth color feature is extracted by means of relative redness component. Meanwhile, the froth image is segmented by using an improved area-reconstruction and watershed transform, and the bubble size feature is extracted. On the basis, the kernel matrix of least mean support vector machine (LSSVM) is reduced by Schmidt orthogonalization, and the kernel partial least squares regression calculation is conducted to obtain the sparse LSSVM. The experimental results show that the prediction algorithm can predict the mineral recovery effectively.

**Key words:** Mineral floatation; Froth image; Feature extraction; Prediction model; Least mean support vector machine

### 1 引 言

矿物浮选是指在一定工艺路线下,对矿浆进行加药充气搅拌,使目的矿物粘附于气泡上,通过回收含矿气泡来提高原矿品位,满足还原冶炼的要求.回收率作为关键生产工艺参数之一,直接反映了精矿的质量和产量<sup>[1]</sup>.浮选工艺流程长,影响因素多,现有检测手段难以实时在线检测矿物回收率.因此选厂大多通过离线化验分析回收率,其结果滞后于生产过程3~4个小时,从而无法对生产进行实时控制.

一直以来,选厂工人通过观察泡沫外观特征来判断矿物回收率情况,并以此调节生产操作,这种凭经验的操作方式缺乏定量的标准,操作的主观性和

随意性较大,常出现浮选过程难以处于稳定运行状态、矿物资源浪费严重等问题.为了给浮选操作提供数据支持,保证浮选过程稳定运行,对矿物回收率进行准确预测具有重要的现实意义.

浮选过程中泡沫含有大量与工况相关的视觉信息<sup>[1,2]</sup>,利用图像信息预测矿物回收率,可以为该问题的解决提供一条新的思路.为此,一些学者采用经典图像处理方法,提取了泡沫颜色、尺寸等特征,运用神经网络、模糊模型及最小二乘方法建立了浮选视觉数据模型<sup>[3-6]</sup>.从图像处理角度看,这些特征提取方法易受现场光照的影响;从建模角度看,这些模型需要大量样本数据训练才能取得较好的预测效果.而实际生产中,耗时长的化验分析难以获得足够

收稿日期: 2008-10-15; 修回日期: 2009-01-06.

基金项目: 国家自然科学基金重点项目(60634020); 国家自然科学基金项目(60874069, 60804037).

作者简介: 周开军(1979—),男,湖南常德人,博士生,从事图像信息处理、复杂工业过程建模的研究; 阳春华(1965—),女,湖南娄底人,教授,博士生导师,从事图像信息处理与识别、复杂工业过程建模等研究.

的生产工艺数据,使得模型精度受到影响.

支持向量机适用于小样本数据建模<sup>[7]</sup>,但需求解复杂的二次规划问题.针对该问题,专家们建立了 LSSVM(Least mean support vector machine)模型,避免了求解耗时的 QP 问题<sup>[8]</sup>.在此基础上,进一步解决解的稀疏性,并构造了稀疏 LSSVM<sup>[9-11]</sup>.

本文提出了矿物回收率问题,采用相对红色分量和改进面积重构与分水岭的图像分割方法,提取泡沫颜色及尺寸特征,并与回收率指标进行相关性分析;然后利用 LSSVM 构造预测模型,通过核矩阵约简及参数辨识,得到具有稀疏性的 LSSVM;最后将图像特征信息引入预测模型,实现矿物回收率在线检测,为厂矿企业带来显著的经济效益.

### 2 矿物回收率预测问题描述

矿物浮选过程中,矿浆中加入适量药剂后送入浮选槽,如图 1 所示.矿浆在充入空气和转子搅拌的共同作用下产生气泡,气泡升浮过程中,矿物细粒由于吸附作用粘附在气泡上,通过收集含矿泡沫达到回收矿物的目的,而脉石杂质则滞留于矿浆中排出.全过程工艺流程长,且伴随有气固液三相的复杂物理化学反应.




图 1 系统原理

浮选过程中,能反映回收率指标的  $x(x \in R^d)$  为泡沫的  $d$  维特征参数,包括泡沫颜色、气泡尺寸等;浮选过程输出  $z(z \in R^+)$  为回收率指标.浮选过程的输入输出二元组  $(x, z)$  构成预测模型的样本,构造预测算法的输入输出函数关系为

$$\tilde{z} = f(x, \theta) \quad R^+, \quad (1)$$

其中  $\theta$  为广义参数.

浮选回收率指标预测问题可描述为样本集  $\{(x_i, z_i) \mid 1 \leq i \leq N\}$ ,优化预测函数  $f$  和广义参数  $\theta$ ,使得预测误差  $R(f, \theta)$  最小,即

$$R(f, \theta) = \sum_{i=1}^N (x_i - f(x_i, \theta))^2. \quad (2)$$

本文综合考虑回收率预测函数复杂度及预测误差,通过构造具有稀疏性的 LSSVM 模型,用图像特征与回收率对模型进行训练,得到浮选回收率预测

模型.

### 3 泡沫图像特征提取及稀疏 LSSVM 模型

#### 3.1 泡沫图像特征提取


根据泡沫外观特征与矿物回收率之间的关系,采用泡沫图像特征提取方法,提取泡沫颜色及尺寸特征,以此作为预测模型输入.

##### 3.1.1 泡沫颜色特征提取


泡沫颜色与浮选泡沫矿物含量相关<sup>[12]</sup>.通常,原矿中包含  $SiO_2$  和  $Fe_2O_3$  等物质,自然条件下呈现红色,通过测量泡沫红色值即可反映出目的矿物.但浮选现场环境比较恶劣,光照对泡沫真实颜色产生干扰,为此,提取图像的相对红色分量,分别计算出红色分量和灰度图像的均值,然后计算图像的相对红色分量信息.为了避免全反射点和阴影的影响,去掉最暗和最亮的像素值,根据下式在 RGB 颜色空间提取相对红色分量:

$$\text{Relative redness} = \frac{\text{Red}_{\text{mean}} - \text{Grey}_{\text{mean}}}{\text{Grey}_{\text{mean}}}. \quad (3)$$

该方法有效地消除了光照的影响,提高了系统的鲁棒性,便于工业应用.泡沫颜色特征的提取和分析如图 2 所示,提取的相对红色分量特征与回收率相关性较强.需要指出的是,图 2 中每一个数据点由 10 个原始数据的平均值组成.



(a) 红色分量直方图



(b) 相对红色分量与回收率关系

图 2 泡沫颜色特征提取和分析

##### 3.1.2 气泡尺寸特征提取

气泡尺寸与气泡矿物含量相关<sup>[13]</sup>.在提取尺寸特征前,需要进行泡沫图像分割.由于浮选泡沫尺寸较小,呈不规则形状,且相互粘连,而且浮选过程光

照条件的变化使得浮选泡沫表面亮点不均,边界模糊,传统的图像分割方法在全局阈值的选取上存在困难,易导致泡沫图像过分割或欠分割<sup>[14]</sup>. 本文结合面积重构改进  $H$  顶变换和分水岭方法分割泡沫图像,算法流程如图 3 所示,主要包括提取标识图像及求取拓扑表面.

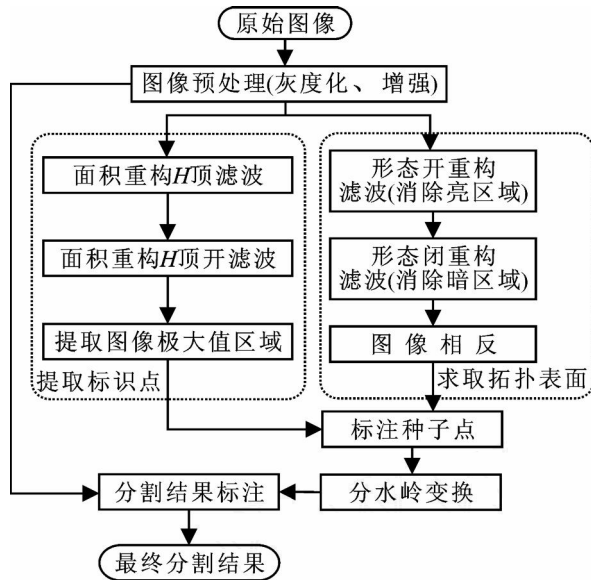


图3 泡沫图像分割流程

人眼对绿色的敏感度最高,对红色的敏感度次之,对蓝色的敏感度最低,而泡沫颜色呈红色,因此赋予  $R, G, B$  不同的权值,得到图像灰度值的加权平均,即

$$Grey = W_R R + W_G G + W_B B. \quad (4)$$

其中:  $W_R, W_G, W_B$  分别为  $R, G, B$  的权值;  $W_G > W_R > W_B$ ;  $W_R + W_G + W_B = 1$ . 经过实验和理论推导证明,当取  $W_R = 0.3, W_G = 0.59, W_B = 0.11$  时,得到的灰度图像最合理.

泡沫图像  $f(x, y)$  的灰度范围为  $[a, b]$ , 经线性变换(对比度扩展)后,图像  $g(x, y)$  的灰度范围为  $[c, d]$ , 则原始图像和变换后的图像关系表示为

$$g(x, y) = c + \frac{d-c}{b-a}(f(x, y) - a). \quad (5)$$

其中:  $a$  和  $b$  由直方图求得,  $c$  和  $d$  为映射灰度范围.

结合形态学中 top-hat 变换和面积形态  $H$  顶重构方法,构造面积重构  $H$  顶变换及其改进变换,为分水岭变换提供标识信息. 定义 top-hat 变换算子为  $HAT(f) = f - (f \circ B)$ . (6) 其中: “ $\circ$ ” 为开运算操作,  $f$  为原图像,  $B$  为  $3 \times 3$  椭圆状结构元素.

面积重构以连通面积大小作为滤波的准则,利用灰度信息对图像进行形态重构,在滤除干扰的同时,较好地保留物体的几何特性<sup>[15]</sup>.  $H$  开重构中标识图像  $g$  满足  $\forall p \in D, g(p) = f(p) - h$ , 其中  $h$  为

指定的常数.  $H$  开重构 top-hat 变换(即  $H$  顶开重构变换)为  $m(p) = f(p) - (p)$ , 其中  $(p)$  为  $H$  开重构的结果. 该变换能依据灰度差  $h$ , 有效地根据面积和对比度大小提取图像的峰值区域,为分水岭算法提供准确的标识<sup>[16]</sup>.

根据 top-hat 变换与面积形态  $H$  重构,定义灰度图像的面积重构  $H$  顶开变换为

$$\forall p \in D, H(g, h, S) = g(p) - (g, h, S)(p). \quad (7)$$

其中:  $g(p)$  为  $p$  点在图像  $g$  中的灰度值,  $(p)$  为面积重构开操作算子,面积阈值  $S = 3$ . 利用对偶特性可得到相应的面积重构  $H$  顶闭算子.

泡沫图像中的小面积细节及小的亮点往往属于噪声,直接用面积重构  $H$  顶变换求取峰值区域易导致过分割,因此提出其改进变换,消除该影响. 面积重构  $H$  顶改进开(闭)变换实现步骤如下:

Step1: 根据指定参数  $h$  和  $S$ , 用面积重构  $H$  开(闭)操作滤除小面积和低对比度的区域.

Step2: 对滤波结果做面积重构  $H$  顶开(闭)变换.

Step3: 将变换结果中所有非零点组成的集合作为特征区域输出,面积重构改进  $H$  顶开变换对图像高亮度区操作,对偶的闭运算对暗区域操作.

采用面积重构改进  $H$  顶开变换提取标识点,对浮选泡沫图像进行求反,其结果为拓扑表面,分水线为气泡边缘. 在求取拓扑表面时,采用双队列方法,具体步骤如下:

Step1: 根据面积重构  $H$  顶改进开变换对浮选泡沫图像反转图中的各项区域赋予不同的编号. 记录各区域边缘点的灰度值并进行排序,得到数列  $L$ .

Step2: 取出数列  $L$  中的最小灰度值 ( $L_{\min}$ ), 取  $L_{\min}$  为当前搜索灰度值  $h$ , 并将图像中的对应点加入到队列  $K$ , 表明有一个新的种子点参加生长.

Step3: 比较  $L_{\min}$  是否等于当前搜索灰度值  $h + 1$ , 如果相等,则转到 Step2; 否则执行 Step4.

Step4: 搜索队列  $K$  中各点 ( $K_p$ ) 的 8 邻域  $N_{K_p}(i)$ , 如果  $N_{K_p}(i)$  的灰度小于等于  $h + 1$ , 则赋予与  $K_p$  相同的编号, 认为与点  $K_p$  属于同一目标. 如果某点同时被赋予不同的编号, 则定为边界点; 如果点  $K_p$  的 8 邻域都已经被编号, 则将点  $K_p$  从对列  $K$  中移出.

Step5: 将新赋值的非边界点加入到队列  $K$  中; 重复执行 Step4, 直到没有新点加入队列  $K$ .

Step6: 如果当前搜索灰度小于图中最高灰度值, 则令  $h = h + 1$ , 并返回执行 Step3; 否则结束搜索.

直接检测分割后的气泡大小为像素单位,而不是实际气泡尺寸,为此,需要对像素进行标定.统计每个分割连通区域的像素数目,再根据工业摄像机分辨率、工作距离及视场确定像素比例,得到气泡尺寸.图 4 给出了气泡分割及尺寸测量结果,气泡面积主要分布在 30 mm<sup>2</sup> 内.从图 4 中可以看出,分割结果准确,提取的气泡尺寸特征能很好地反映回收率.

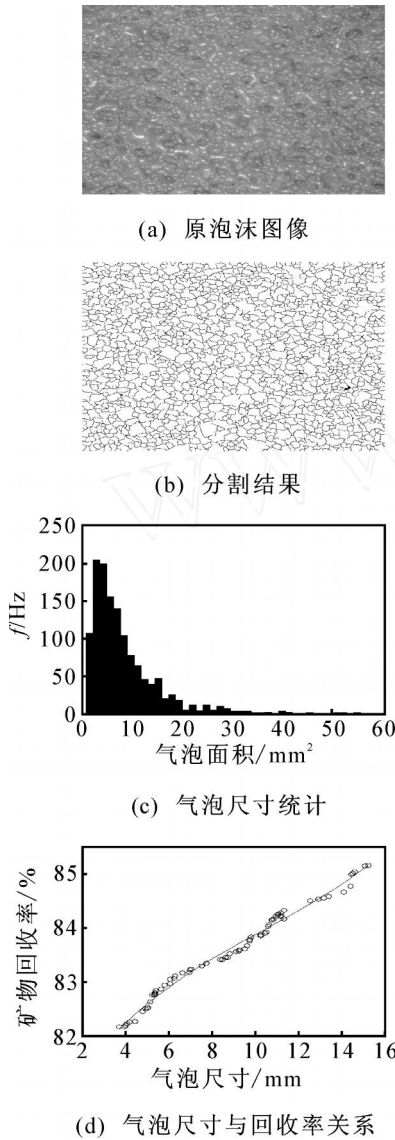


图 4 气泡尺寸特征提取及分析

### 3.2 LSSVM 模型的构造

对于给定的训练样本集  $S = (x_i, z_i), i = 1, 2, \dots, N$ . 其中:  $x_i \in R^d, z_i \in R$ . 在支持向量机回归方法中,利用非线性映射函数  $\phi(x)$  将样本非线性地映射到高维特征空间,可将原样本空间中的非线性函数估计问题转化为高维特征空间中的线性函数估计问题,即

$$f(x) = w^T \phi(x) + b. \quad (8)$$

该回归问题可根据结构风险最小化原理(即综合考虑函数复杂度和预测误差),表示为一个等式约束的

优化问题,即

$$\begin{aligned} \min_{w, b, e} J(w, e) &= \frac{1}{2} w^T w + \frac{C}{2} \sum_{i=1}^N e_i^2; \\ \text{s. t. } z_i &= w^T \phi(x_i) + b + e_i, \\ &i = 1, 2, \dots, n. \end{aligned} \quad (9)$$

通过建立拉格朗日等式,将上述约束优化问题变为无约束优化问题,即

$$L(w, b, e, \alpha) = J(w, e) - \sum_{i=1}^N \alpha_i (w^T \phi(x_i) + b + e_i - z_i), \quad (10)$$

其中  $\alpha_i (i = 1, 2, \dots, N)$  是 Lagrange 乘子.

通过求解将求得的系数  $\alpha_i$  和  $b$  代入式(8),得到支持向量机的输出<sup>[8,9]</sup>为

$$f(x) = \sum_{i=1}^N \alpha_i k(x, x_i) + b. \quad (11)$$

### 3.3 LSSVM 的核矩阵简约及参数辨识

对于每一个样本向量  $x_i$ ,在超空间内的映射可表示为  $\phi(x_i) (i = 1 \dots N)$ ,因此所有样本在特征空间内的映射将组成一个映射矩阵  $\{\phi(x_1), \dots, \phi(x_N)\}$ . 若映射矩阵中存在着一组基  $\{\tilde{x}_1, \dots, \tilde{x}_M\}$ ,则任意一个映射向量都可以由基中的列向量组合而成,即

$$\begin{bmatrix} \phi(x_1) \\ \dots \\ \phi(x_N) \end{bmatrix} = \begin{bmatrix} 11 & \dots & 1M \\ & \ddots & \\ N1 & \dots & NM \end{bmatrix} \begin{bmatrix} \tilde{x}_1 \\ \dots \\ \tilde{x}_M \end{bmatrix}. \quad (12)$$

为了采用该映射矩阵的基代替原映射矩阵,需要通过映射矩阵进行施密特正交化方法,得到线性无关向量组,从而构成映射矩阵的基.

根据施密特正交化理论,对超空间映射矩阵中的列向量  $\phi(x_a)$  进行正交化,即

$$\phi_{t+1}(x_a) = \phi_t(x_a) - (\phi_t(x_a)^T v_t) v_t. \quad (13)$$

其中

$$v_t = \frac{\phi_t(x_i)}{\sqrt{\phi_t(x_i)^T \phi_t(x_i)}},$$

$\phi(x_i) (i = 1 \dots N)$  为通过比较模的大小而挑选出的向量.

对于核矩阵,其格拉姆形式为

$$G(a, b) = \phi(x_a)^T \phi(x_b) = K(x_a, x_b), \quad (14)$$

因此有

$$\begin{aligned} G_{t+1}(a, b) &= \phi_{t+1}(x_a)^T \phi_{t+1}(x_b) = \\ &G_t(a, b) - \frac{G_t(a, x_i) G_t(b, x_i)}{G_t(x_i, x_i)}. \end{aligned} \quad (15)$$

在构造核矩阵简约形式时,采用贪婪算法逐一挑选向量,并对核矩阵剩余部分进行正交化,从而得到核矩阵的基.将核矩阵各列向量中  $G(i, i)$  的大小作为挑选向量的选择依据,每次选择最大.对于原数

据矩阵中的  $x_p$ , 正交算法如下所示<sup>[17]</sup>:

```

Step1: 令  $G_0(p, p) = K(x_p, x_p)$ .
Step2: for  $t = 0$  to  $(d - 1)$ ,
         $G_t(t, p) = K(x_t, x_p)$ ,
    endfor.
Step3: for  $t = 0$  to  $(d - 1)$ ,
    对于挑选出的一个向量  $x_t$ , 令  $\text{index}(t) = i$ ,
    for  $s = (t + 1)$  to  $(d - 1)$ ,
         $G_{t+1}(s, p) =$ 
 $G_t(s, p) - \frac{G_t(t, p) G_t(\text{index}(t), \text{index}(s))}{G_t(\text{index}(t), \text{index}(t))}$ ,
    endfor
 $G_{t+1}(p, p) =$ 
 $G_t(p, p) - \frac{G_t(t, p) G_t(t, p)}{G_t(\text{index}(t), \text{index}(t))}$ 

```

end.

算法中  $d$  为矩阵的秩. 为提高计算的稳定性, 利用 Direct Kernel PLS 核偏最小二乘法辨识出稀疏最小二乘支持向量机的参数. 令  $K^0 = (X)^T (X)$ , 并设  $M$  为预测设定的主元数, 算法表示如下<sup>[18]</sup>:

Step1: 对  $K^0$  进行对中处理后得

$$K^1 = \left( I - \frac{1}{N} \mathbf{1}\mathbf{1}^T \right) K^0 \left( I - \frac{1}{N} \mathbf{1}\mathbf{1}^T \right). \quad (16)$$

Step2: for  $n = 1$  to  $M$ ,

$$t^n = K^n K^{nT} y^n, \quad t^n = t^n / \|t^n\|,$$

$$K^{n+1} = K^n - t^n t^{nT},$$

$$y^{n+1} = y^n - t^n t^{nT} y^n, \quad y^{n+1} = y^{n+1} / \|y^{n+1}\|,$$

endfor.

Step3: 找出  $M$  个主元后, 计算回归系数向量为

$$a = K^1 Y (T^T K^1 K^1 T)^{-1} T^T Y. \quad (17)$$

其中:  $Y = [ \dots y^n \dots ]_{N \times M}$ ,  $T = [ \dots t^n \dots ]_{N \times M}$ ,  $\mathbf{1}$  表示单位阵,  $\mathbf{1}$  为全 1 向量,  $a = [ (\dots i \dots) ]_{1 \times M}^T$ .

由于对核矩阵进行对中处理后, 回归时将不出现偏置量参数, 式(9)可改写为

$$f(x) = \sum_{i=1}^N a_i K(x, x_i). \quad (18)$$

因此核矩阵为

$$K = \left( K^{\text{test}} - \frac{1}{N} \mathbf{1}\mathbf{1}^T K^{\text{rain}} \right) \left( I - \frac{1}{N} \mathbf{1}\mathbf{1}^T \right). \quad (19)$$

### 3.4 LSSVM 模型训练

通过研究浮选工艺流程可知, 矿物回收率 ( $z_i$ ) 可由一系列泡沫图像特征表现出来, 分别为泡沫颜色 ( $x_1$ ) 和泡沫尺寸 ( $x_2$ ). 构造训练集图像数据和测试集图像数据并进行预处理, 将原始样本点按不同的回收率进行分类后, 从每个类别中随机选取比例为  $p$  的样本点作为训练集, 其余样本点作为测试集; 利用泡沫图像原始特征及回收率数据构造 LSSVM

模型的训练样本集 ( $x_i, z_i$ ),  $i$  为采样点; 剔除异常数据并进行归一化处理, 使数据均值为 0, 方差为 1; 用预处理后的训练集训练 LSSVM 模型, 并运用 LSSVM 回归算法对训练样本集进行辨识, 求解回归参数  $a_i$  和  $b$ ; 对预处理后的测试集进行预测; 最后对预测数据进行反预处理, 得到预测结果.

## 4 工业实验结果分析

为了建立准确的预测模型, 在工业现场收集了某浮选厂大量工业运行数据. 其中: 泡沫图像由工业摄像机自动获取; 与之对应的回收率数据由人工取样化验分析获得. 本文使用了时段  $T$  为 70 天的 420 条生产数据, 在采用肖维耐法剔除部分异常样本后, 保留了 400 条数据, 选用比例为  $p = 75\%$  的数据样本作为训练集对预测模型进行训练, 用剩余的 100 条样本数据进行预测.


LSSVM 模型采用 RBF 核函数, 通过数值计算可得径向基核函数参数  $\gamma = 15$ , 调节参数  $C = 1000$ . 为评价预测算法的性能, 使用了最大相对误差 ( $E_{\text{max}}$ ), 均方根误差 (RMSE) 和相对均方根误差 (RRMSE) 对模型的预测准确性和跟踪变化趋势的能力进行了分析, 即

$$E_{\text{max}} = \max \left( \frac{z_i - \hat{z}_i}{z_i} \right), \quad (20)$$


$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (z_i - \hat{z}_i)^2}, \quad (21)$$

$$\text{RRMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{z_i - \hat{z}_i}{z_i} \right)^2}. \quad (22)$$

其中:  $z_i$  为实际数据向量中的第  $i$  个数据,  $\hat{z}_i$  为预测所得数据向量中的第  $i$  个数据. 采用本文算法对回收率指标进行预测, 结果如图 5(a) 所示, 对应的预测误差如图 5(b) 所示.



(a) 矿物回收率预测结果



(b) 相对误差

图5 矿物回收率预测

计算得到的最大相对误差  $E_{\max}$  为 4.15%, 表明了该模型具有较高的预测精度; 均方根误差 RMSE 为 1.117, 符合工业操作要求, 预测可信度较高; 相对均方根误差 RRMSE 为 1.41%, 表明了预测结果整体趋势符合要求, 能较好地预测变化趋势。

## 5 结 论

浮选过程中对关键生产指标的预测非常重要, 为准确预测矿物回收率, 本文建立了 LSSVM 回收率智能预测模型。通过泡沫图像处理方法提取了泡沫颜色与尺寸特征, 并引入回收率预测模型, 有效地解决了预测算法中的信息不完备问题。通过斯密特正交化对核矩阵进行简约, 得到核矩阵的基向量组, 利用 KPLS 方法对 LSSVM 进行回归计算, 了解了的稀疏性问题。工业运行结果表明, 特征提取方法能够准确提取泡沫颜色及尺寸特征, 构造的回收率智能预测模型具有精度高、易于工业应用的特点, 适用于一般浮选工艺条件下的矿物浮选过程。同时, 将图像信息引入矿物回收率预测, 为复杂工业过程的关键生产指标预测提供了一种新的解决方法。

## 参考文献(References)

- [1] 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.
- [2] 刘文礼, 路迈西, 王凡, 等. 煤泥浮选泡沫图像纹理特征的提取及泡沫状态的识别[J]. *化工学报*, 2003, 54(6): 830-835.  
(Liu W L, Lu M X, Wang F, et al. Extraction of textural feature and recognition of coal flotation froth [J]. *J of Chemical Industry and Engineering*, 2003, 54(6): 830-835.)
- [3] Rughooputh H C S, Rughooputh S D D V. Neural network process vision systems for flotation process[J]. *Kybernetes*, 2002, 31(3/4): 529-535.
- [4] Hyotyniemi H, Ylinen R. Modeling of visual flotation froth data [J]. *Control Engineering Practice*, 2000, 8(3): 313-318.
- [5] Holtham P N, Nguyen K K. On-line analysis of froth surface in coal and mineral flotation using JK FrothCam [J]. *Int J of Mineral Processing*, 2002, 64(2/3): 163-180.
- [6] Liu J J, MacGregor J F. Froth-based modeling and control of flotation processes[J]. *Minerals Engineering*, 2008, 21(6): 642-651.
- [7] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers [J]. *Neural Processing Letters*, 1998, 9(3): 293-300.
- [8] Polat K, Akdemir B, Gunes S. Computer aided diagnosis of ECG data on the least square support vector machine[J]. *Digital Signal Processing*, 2008, 11(1): 25-32.
- [9] 甘良志, 孙宗海, 孙优贤. 稀疏最小二乘支持向量机[J]. *浙江大学学报*, 2007, 41(2): 245-248.  
(Gan L Z, Sun Z H, Sun Y X. Sparse least squares support vector machine [J]. *J of Zhejiang University*, 2007, 41(2): 245-248.)
- [10] Hoegaerts L, Suykens J A K, Vandewalle J, et al. Subset based least squares subspace regression in RKHS[J]. *Neurocomputing*, 2005, 63(1): 293-323.
- [11] Heisterkamp D, Peng J, Dai H. An adaptive quasi-conformal kernel metric for image retrieval[C]. *Proc of IEEE Conf on Computer Vision and Pattern Recognition*. Hawaii, 2001: 236-243.
- [12] Bonifazi G, Serranti S, Volpe F, et al. Characterisation of flotation froth colour and structure by machine vision [J]. *Computers and Geosciences*, 2001, 27(9): 1111-1117.
- [13] Lin B, Recke B, Knudsen J K H, et al. Bubble size estimation for flotation processes [J]. *Minerals Engineering*, 2008, 21(7): 539-548.
- [14] 林小竹, 谷莹莹, 赵国庆. 煤泥浮选泡沫图像分割与特征提取[J]. *煤炭学报*, 2007, 32(3): 304-308.  
(Lin X Z, Gu Y Y, Zhao G Q. Feature extraction based on image segmentation of coal flotation froth[J]. *J of China Coal Society*, 2007, 32(3): 304-308.)
- [15] Salembier P, Serra J. Flat zones filtering connected operators and filters by reconstruction[J]. *IEEE Trans on Image Processing*, 1995, 4(8): 1153-1160.
- [16] Vincent L, Soille P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1991, 13(6): 583-598.
- [17] Rosipal R, Trejo L J. Kernel partial least squares regression in reproducing kernel hilbert space[J]. *J of Machine Learning Research*, 2002, 2(2): 97-123.
- [18] Bennett K P, Embrechts M J. An optimization perspective on kernel partial least squares[C]. *Proc of the NATO Advanced Study Institute on Learning Theory and Practice*. Leuven Belgium, 2002: 2-21.
- [19] Mu S J, Zeng Y Z, Liu R L. Online dual updating with recursive PLS model and its application in predicting crystal size of purified terephthalic acid (PTA) process [J]. *Process Control*, 2002, 16(6): 557-566.