

一种新的浮选泡沫图像识别方法

郝元宏¹, 韩静², 齐春¹

(1. 西安交通大学电子与信息工程学院, 710049, 西安; 2. 山西大学商务学院理学系, 030031, 太原)

摘要: 针对灰度共生矩阵法提取的浮选泡沫图像纹理特征相互混叠, 不利于聚类 and 识别的问题, 提出一种基于正交保局投影和支持向量机的浮选泡沫图像识别新方法. 该方法利用正交保局投影法对原始纹理特征参数进行变换处理, 有效改变了不同类别特征参数的聚集程度, 并利用支持向量机进行分类. 实验结果表明, 所提方法的正确识别率能够达到 93.5%, 与基于最近邻分类器的主元分析法相比, 其性能更好.

关键词: 浮选; 泡沫图像; 机器视觉; 正交保局投影; 支持向量机

中图分类号: TD928.9 **文献标志码:** A **文章编号:** 0253-987X(2011)04-0104-05

A New Recognition Method for Flotation Froth Images

HAO Yuanhong¹, HAN Jing², QI Chun¹

(1. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. Faculty of science, Business College of Shanxi University, Taiyuan 030031, China)

Abstract: A novel approach to classify the flotation froth images based on OLPP and support vector machine is presented to deal with the problem that the texture feature vectors of digitized images of the froth obtained from the use of gray-level dependence matrix method can not provide a compact representation of froth properties. The texture feature vectors from OLPP is transformed, and then, classification is investigated by using a multi-class SVM. Results obtained encourage to apply the approach to develop a classification system for flotation froth images. Comparison between OLPP with SVM and PCA with nearest neighbor classifier shows that the proposed recognition technology has higher precision and robustness.

Keywords: flotation; froth image; machine vision; orthogonal locality preserving projection; support vector machine

浮选泡沫体是由大量的大小不一、形状各异、灰度值不同的矿化气泡组成的, 包含大量与浮选过程变量及浮选结果有关的信息. 由于受到矿物等级、粒径大小分布, 以及表面属性等因素的影响, 对浮选的控制过程十分复杂. 虽然已经有了不少这方面的研究, 但所获得的数学模型并不能很好地和实际吻合^[1]. 在实际生产过程中, 一般由操作人员根据对浮选泡沫状态的视觉观察来调整加药量, 以使浮选控制过程处于一个较好的状态下. 因此, 浮选的性能在很大程度上依赖于操作人员的经验和能力, 实际操

作的主观随意性较大.

在浮选过程中, 矿化水泡上携带的矿物微粒是不断变化的, 水泡的纹理呈现出一定的规律性. 计算机图像处理技术能够既精确又快速地从浮选泡沫图像中提取出泡沫的自然属性, 从而提供给系统操作者更加客观的参考信息用于控制浮选. 因此, 20 多年来, 机器视觉技术在泡沫浮选控制系统中的研究与应用日益受到人们的关注. 国外早在 20 世纪 80 年代就开始将计算机技术、图像处理技术和人工神经网络等方法引入到浮选过程的测量控制中^[2-3], 用

收稿日期: 2010-11-05. 作者简介: 郝元宏(1982—), 男, 博士生; 齐春(联系人), 男, 教授, 博士生导师. 基金项目: 陕西省自然科学基金资助项目(2003E212).

网络出版时间: 2011-02-21 网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20110221.1605.006.html>

以增强浮选控制的准确性与可靠性. 浮选泡沫图像识别系统的目的是将图像处理和图像分类的方法应用到浮选过程中泡沫状态的检测, 直接模拟现场的人工操作, 避免人工干预的主观性, 为矿物浮选的控制过程提供更加精确、可靠的方法. 文献[3-4]分别针对铜矿石和铁锰合金矿的浮选泡沫图像, 给出了利用数字图像分析和人工神经网络方法的识别系统, 正确识别率分别达到了 80% 左右和接近 90%. 2000 年以后, 该领域的研究逐渐成为热点^[4-6], 国内也有相关研究与报道^[7-8].

图像分割方法在矿物浮选过程中应用较为广泛, 而图像识别方法在该领域中的应用研究还处于起步阶段, 并且多采用神经网络进行分类. 从实验结果来看, 采用以上方法对浮选泡沫图像的分类效果不是很理想, 正确识别率一般在 90% 以下^[3-4, 8]. 本文针对这个问题, 利用正交保局投影分析法 (Orthogonal Locality Preserving Projections, OLPP) 对纹理特征参数进行变换处理, 首先改变不同类别特征参数的相对聚集程度, 然后利用支持向量机 (Support Vector Machines, SVM)^[9] 进行分类, 能够达到较高的正确识别率. 实验处理对象为铅锌矿现场采集的实际浮选泡沫图像.

1 浮选泡沫图像特征参数的提取

纹理信息是泡沫图像的一个重要特征. 不同类别等级泡沫图像比较相似, 如图 1 所示, A、B、C 和 D 是典型的 4 类浮选泡沫图像 (全部来自于铅锌矿现场采集的实际浮选泡沫图像). Haralick 等^[10]提出用灰度共生矩阵所产生的一些统计量作为纹理特征来表示图像像素的空间关系, 是一种有效的测度图像纹理的数学方法. 本文采用灰度共生矩阵法提取泡沫图像的原始特征参数.




图 1 4 类泡沫的典型结构

Haralick 等由灰度共生矩阵提取了 14 个特征, 由于灰度共生矩阵的计算量很大, 为简便起见, 本文采用下面最常用的 4 个纹理特征来提取图像: 角二阶矩 M 、对比度 N 、熵 E 、相关性 R .

若 $f(x, y)$ 表示一幅尺寸为 $L_r \times L_c$ 的图像, N_G 表示该图像灰度级, 则共生矩阵可表示为

$$\begin{aligned} P(i, j, d, \theta) &= O\{((x_1, y_1), (x_2, y_2)) \mid \\ &\quad (x_1, y_1), (x_2, y_2) \in (L_r \times L_c), \\ &\quad (x_2, y_2) = (x_1, y_1) + (d \cos \theta, d \sin \theta), \\ &\quad f(x_1, y_1) = i, f(x_2, y_2) = j, 0 \leq i, j < N_G\} \end{aligned} \quad (1)$$

式中: $O(\cdot)$ 为集合中满足条件的像素对的数量; d 为像素对间的距离; θ 为共生矩阵的生成方向. 本文采用如下 4 个特征作为泡沫图像的原始纹理特征

$$M = \sum_{i=0}^{N_G-1} \sum_{j=0}^{N_G-1} P^2(i, j) \quad (2)$$

$$N = \sum_{n=0}^{N_G-1} n^2 \left(\sum_{i=0}^{N_G-1} \sum_{j=0}^{N_G-1} P(i, j) \right), \quad |i - j| = n \quad (3)$$

$$E = - \sum_{i=0}^{N_G-1} \sum_{j=0}^{N_G-1} P(i, j) \cdot \ln[P(i, j)] \quad (4)$$

$$R = \frac{1}{\sigma_x \sigma_y} \left\{ \sum_{i=0}^{N_G-1} \sum_{j=0}^{N_G-1} ij P(i, j) - \mu_x \mu_y \right\} \quad (5)$$


式中: μ_x, σ_x 分别是 $\{p_x(i); i=1, 2, \dots, N_G\}$ 的均值和方差; μ_y, σ_y 分别是 $\{p_y(j); j=1, 2, \dots, N_G\}$ 的均值和方差.

2 浮选泡沫图像特征参数的正交保局投影


按照灰度相关矩阵方法提取浮选泡沫图像的特征参数后, 直接使用分类器进行分类的效果不太理想. 在研究中, 我们想知道数据的几何分布情形, 然而数据往往是高维的, 例如本文的特征向量为 8 维, 无法对数据的几何分布结构可视化. Sammon^[11]投影是一种多元数据分析方法, 它为我们提供了一种数据可视化的途径. 该方法能够将高维数据降到低维空间 (一般为 2 或 3 维), 并近似地保持数据原有的几何分布结构. 于是, 在实验过程中, 我们采用 Sammon 投影将泡沫图像的灰度共生纹理特征在 2 维空间下进行了可视化. 由图 2a 可以看出: A 类泡沫图像和 B 类泡沫图像的分类效果比较差, 相互混叠在一起, 可以认为是线性不可分的; 同样, C 类图像和 D 类图像也相互混叠, 不容易分开. 针对上述

问题,本文采用基于流行学习的方法对浮选泡沫图像的特征参数作了进一步的变换处理,经过变换后,模式的分布具有可分性,见图2b.

He等^[12]提出了保局投影(Locality Preserving Projections, LPP),并将其应用于人脸识别. LPP的本质就是对拉普拉斯特征映射的线性逼近,然而通过LPP算法获取的图像子空间的基向量是非正交的,这使得图像重建变得困难. 鉴于此, Cai等^[13]提出正交LPP(OLPP)算法,其核心思想是在特征值求解过程中增加正交约束. 本文采用正交保局投影对提取到的纹理特征进行变换处理,得到新的浮选泡沫图像特征参数模式分布,最后利用非线性支持向量机对其进行分类. 下面简述正交保局投影过程.



(a)原始纹理特征的 Sammon 投影



(b)采用新方法得到的 Sammon 投影

图2 原始特征与新特征的 Sammon 投影效果比较

OLPP 算法的步骤如下.

步骤1 主元分析法(Principal Component Analysis, PCA)将图像数据集 $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ 投影到 PCA 子空间, 丢弃数值较小的特征值对应的特征向量. PCA 投影矩阵记为 $\mathbf{W}_{\text{PCA}}$.

步骤2 构造近邻图, 设 $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ 为浮选泡沫图片集. 记 G 为一个 N 节点的图, 第 i 个节点对应于图像 x_i . 如果第 i 个节点 x_i 与第 j 个节点 x_j 满足近邻条件(K 近邻, 实验中取 $K=5$), 就在二者之间连一条边.

步骤3 选择边权值, 如果图像 x_i 与 x_j 相连, 就置二者之间的边权值为

$$S_{ij} = e^{-||x_i - x_j||^2/t} \quad (6)$$

t 为合适的实数(实验中采用经验值 $t=5$). 否则, 置二者的边权值 $S_{ij}=0$.

步骤4 特征映射, 设 $\mathbf{D}$ 是一个对角阵, 且 $D_{ii} = \sum_j S_{ij}$. 定义 $\mathbf{L} = \mathbf{D} - \mathbf{S}$ 为拉普拉斯矩阵. $\mathbf{X}$ 的行向量是图像 x_i .

令 $\{a_1, \dots, a_k\}$ 是正交基向量组, 令

$$\mathbf{A}^{k-1} = [a_1, \dots, a_{k-1}] \quad (7)$$

$$\mathbf{B}^{k-1} = [\mathbf{A}^{k-1}]^T (\mathbf{X} \mathbf{D} \mathbf{X}^T)^{-1} \mathbf{A}^{k-1} \quad (8)$$

正交基向量组 $\{a_1, \dots, a_k\}$ 可以通过如下步骤得到.

第1步: 计算 $(\mathbf{X} \mathbf{D} \mathbf{X}^T)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 最小的特征值对应的特征向量作为 a_1 ;

第 k 步: 计算如下矩阵最小的特征值对应的特征向量作为 a_k , 直至求出所有 k 个特征向量

$$\mathbf{M}^k = \{ \mathbf{I} - (\mathbf{X} \mathbf{D} \mathbf{X}^T)^{-1} \mathbf{A}^{k-1} [\mathbf{B}^{k-1}]^{-1} [\mathbf{A}^{k-1}]^T \} \cdot (\mathbf{X} \mathbf{D} \mathbf{X}^T)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T \quad (9)$$

步骤5 最终嵌入函数为

$$\mathbf{x} \rightarrow \mathbf{y} = \mathbf{W}^T \mathbf{x}$$

$$\mathbf{W} = \mathbf{W}_{\text{PCA}} \mathbf{W}_{\text{OLPP}}$$

$$\mathbf{W}_{\text{OLPP}} = [a_1, a_2, \dots, a_{k-1}] \quad (10)$$

式中: $\mathbf{y}$ 是一个 k 维的向量.

经过上述正交变换处理, 得到新的浮选泡沫图像特征参数模式分布 $\mathbf{Y}$, 作为接下来支持向量机的输入.

3 识别方法

对现场采集图像的摄取是在一种自然光环境下进行的, 不可避免地会出现照度随照相时间和光环境不断变化, 因此数据可以认为是非线性可分的, 而 OLPP 是一种非线性的流行学习方法, 适合于描述呈非线性分布的数据属性. 基于核函数的支持向量机, 将原始数据通过核映射到高维数据空间, 使得数据在高维空间变得可分, 而计算却在原始空间进行. 因此, 将 OLPP 与 SVM 结合, 适合于浮选泡沫图像分类的实际情况.

经典统计学研究的是当样本数目趋近于无穷多

时的渐近理论.然而,由于观测能力和观测成本的限制,实际问题可用的样本往往是很有限的,甚至非常少,从而使经典统计学面临实际风险与期望风险不一致的严重困难. Vapnik 等研究了小样本学习问题的统计规律——统计学习理论(Statistical Learning Theory, SLT). SLT 一方面建立了一套较为完整的数学体系,同时提出了有效的学习算法——SVM. 传统的神经网络结构的选择往往凭经验,而且经常不能获得很好的效果,而 SVM 是基于结构风险最小化原则来实现期望风险最小化的机器学习算法. 与神经网络相比较而言, SVM 方法具有许多独特的优点,例如 SVM 利用最大化间隔控制分类器的推广能力,利用 Mercer 核实现线性算法的非线性化,具有全局唯一最优解并且解是稀疏的.

SVM 算法的思想是:对于两类分类问题,当两类样本线性可分时,选择一个最优线性超平面,使得两类样本不仅线性可分,而且两类分开的间隔最大;当两类样本线性不可分时,首先通过某种事先选择的非线性映射(核方法)将原空间的数据映射到一个高维特征空间(可以是无穷维)中,然后在这个高维的特征空间中构造最优的分类超平面. 本文针对浮选泡沫识别问题的特点,利用支持向量机对其进行分类,分类效果得到很大改善.

将 SVM 用于多元分类问题时,必须由二元分类器构造多元分类器,常用的组合策略有“一对一”组合策略和“一对多”组合策略. 对于给定的 n 个类别,“一对一”策略需要 $n(n-1)/2$ 个两类分类器,而“一对多”策略仅仅需要构造 n 个两类分类器. 为了降低问题的复杂性,本文采用“一对多”组合策略构造了一个多分类器.

下面,给出将 OLPP 特征提取方法和 SVM 多分类器结合,以用于浮选泡沫图像分类的步骤.

步骤 1 选择支持向量机的核函数 k , 确定训练样本集的规模;

步骤 2 按照灰度相关矩阵方法提取浮选泡沫图像训练样本以及测试样本的特征参数,组成 2 个集合,分别记为 $\{s\}$ 、 $\{T\}$;

步骤 3 采用 OLPP 对 $\{s\}$ 进行变换处理得到投影方向,分别将 $\{s\}$ 和 $\{T\}$ 在投影方向上投影,得到 2 组投影系数集合 $\{P_s\}$ 、 $\{P_T\}$;

步骤 4 将 $\{P_s\}$ 作为训练样本输入多元支持向量机进行训练;

步骤 5 将 $\{P_T\}$ 作为测试样本输入多元支持向量机进行测试,统计正确识别率.

4 实验结果及分析


为了验证本文方法的有效性,共选取典型的 4 类铅锌矿浮选泡沫图像,见图 1,每类选取 80 个样本. 首先使用灰度共生矩阵法提取图像的特征参数,构造 4 个方向(0° 、 45° 、 90° 、 135°)的灰度共生矩阵,然后分别计算每个共生矩阵的二阶矩、熵、对比度及相关性特征这 4 个指标,并分别求 4 个矩阵各自对应的 4 个指标的均值以及标准差,得到 8 个参数. 最后,这 8 个参数组合成一个特征向量,即为原始纹理特征.

得到 8 维原始纹理特征后,使用正交保局投影变换对其进行特征变换,然后使用支持向量机进行分类. 利用支持向量机分类时分别选取了不同的训练样本个数,以检验本系统对于小样本问题的处理能力. 支持向量机分类器的惩罚系数 C 取为 1,核函数取径向基核函数($k(x, y) = \exp(-\|x - y\|^2 / \sigma)$),其中 σ 取值为 0.002.


图 2a 和图 2b 分别是原始纹理特征以及经本文方法变换后,每类的 20 个测试样本的特征参数在二维空间中的 Sammon 投影. 从图 2a 可以看出,虽然 A、B 类和 C、D 类的中心相距较远,但是 A 与 B、C 与 D 各类中心混叠在一起,各自的聚类中心难以区分,给分类造成困难,正如第 3 节提到的,现场采集图像不可避免地受到光环境变化的影响,因此数据可以认为是非线性可分的,仅仅采用灰度相关矩阵法不足以描述该非线性问题. 图 2b 是经正交保局投影变换处理后,每类的 20 个测试样本的特征参数在二维空间中的 Sammon 投影,可以看出,各类的聚类中心离的较远,容易区分.

同时,为了验证本文所提出方法的有效性,我们在计算机上作了如下仿真:图 3a 和图 3b 是训练样本数目分别为 10 和 20 时,本文提出的识别方法与其他两种识别方法(一种是基于 PCA 与最近邻分类器的识别方法,另一种是基于 OLPP 与最近邻分类器的识别算法)的效果对比图. 我们给出的正确识别率是一个平均的识别率. 本文的方法对于每种图片都有相应的识别率,我们将 4 个识别率进行求和,然后取平均,得到了平均正确识别率. “特征数”指的是经过 OLPP 或者 PCA 特征变换后,特征向量的维数. 将训练样本数目分别定为 5、10、20,对应测试样本数目分别为 75、70、60,采用 3 种不同的识别方法,经过 10 次独立的实验后,统计分类的平均正确率得到图 3 中的数据. 实验结果表明,本文提出的方

法能达到92%以上的平均正确识别率,最高识别率能达到95%。



(a) 每类 10 个训练样本的正确识别率



(b) 每类 20 个训练样本的正确识别率

图3 本文方法与其他方法的识别率比较

5 结 论

在原始特征参数空间,模式的分布呈现混叠状态,无法将它们分开.采用本文提出的基于正交保局投影和支持向量机相结合的识别方法,通过对浮选泡沫图像的纹理特征进行特征变换,新的特征模式的各个分量变得互不相关,从而使得原始呈现混叠状态的模式分布在变换后的流形嵌入空间里具有可分性.实验结果表明,先使用灰度共生矩阵方法提取浮选泡沫图像的原始特征参数,再经过本文的方法处理,能够达到较高的识别率。

参考文献:

- [1] BONIFAZIA G, SERRANTIA S, VOLPEB F, et al. Characterisation of flotation froth colour and structure by machine vision[J]. Computers and Geosciences, 2001, 27(9):1111-1117.
- [2] WOODBUM E T, STOCKTON J B, ROBBINS D J. Vision-based characterization of three-phase froths[C]// Proceedings of the International Colloquium on Developments in Froth Flotation. Piscataway, NJ, USA: IEEE, 1989: 1-30.
- [3] MOOLMAN D W, ALDRICH C, VAN DEVENTER J S J, et al. The classification of froth structures in a copper flotation plant by means of neural networks[J]. Chemical Engineering Science, 1995, 43(3/4): 193-208.
- [4] SINGH V, RAO S M. Application of image process-

ing and radial basis neural network techniques for ore sorting and ore classification [J]. Minerals Engineering, 2005, 18(15): 1412-1420.

- [5] WANG W X, LI L. Pattern recognition and computer vision for mineral froth[C]// Proceedings of the 18th International Conference on Pattern Recognition. Piscataway, NJ, USA: IEEE, 2006: 622-625.
- [6] ALDRICH C, MARAIS C, SHEAN B J, et al. On-line monitoring and control of froth flotation systems with machine vision: a review [J]. International Journal of Mineral Processing, 2010, 96(1/4):1-13.
- [7] 曾荣,沃国经. 图像处理技术在镍选矿厂中的应用[J]. 矿冶, 2002, 11(1):37-41.
ZENG Rong, WO Guojing. Application of the image processing technology in nickel concentrator [J]. Mining and Metallurgy, 2002, 11(1): 37-41.
- [8] 刘文礼,路迈西,王帆,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 Wenli, LU Maixi, WANG Fan, et al. Extraction of textural feature and recognition of coal [J]. Journal of Chemical Industry and Engineering, 2003, 54(6): 830-835.
- [9] 申清明,高建民,李成. 焊缝缺陷类型识别方法的研究[J]. 西安交通大学学报, 2010, 44(7): 100-103.
SHEN Qingming, GAO Jianmin, LI Cheng. Recognition of weld defect types [J]. Journal of Xi'an Jiaotong University, 2010, 44(7): 100-103.
- [10] HARALICK R, SHANMUGAN K, DINSTEN I. Texture feature for image classification [J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, 3(6):610-621.
- [11] LEMER B, HUGO G, MAYER A, et al. On pattern classification with Sammon's nonlinear mapping: an experimental study [J]. Pattern Recognition, 1998, 31(4): 371-381.
- [12] HE Xiaofei, YAN Shuicheng, HU Yuxiao, et al. Face recognition using Laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.
- [13] CAI Deng, HE Xiaofei, HAN Jiawei, et al. Orthogonal Laplacianfaces for face recognition [J]. IEEE Transactions on Image Processing, 2006, 15(11): 3608-3614.

(编辑 武红江)