

doi: 10.3788/gzxb20174607.0710003

基于模糊支持向量机和 D-S 证据理论的 钨矿石初选方法

胡发焕^{1,2}, 刘国平¹, 胡榕华¹, 董增文¹

(1 南昌大学 机电工程学院, 南昌 330031)

(2 江西理工大学 机电工程学院, 江西 赣州 341000)

摘 要:单一特征识别的钨矿石初选准确率低, 稳定性差, 本文提出结合模糊支持向量机和 D-S 证据理论的多特征钨矿石识别方法. 对矿石图像预处理后, 分别提取矿石的颜色、灰度和纹理等 3 类视觉特征, 对这 3 类视觉特征进行模糊分类得到各自的信任度, 再以这 3 类信任度为独立证据, 采用 D-S 证据理论对 3 类证据进行融合, 并依据分类判决规则得到最终的识别结果. 试验结果表明, 通过 D-S 理论对模糊向量机证据的融合, 钨矿石初选的正确识别率达到 96% 以上, 其准确率和稳定性较单一特征均有大幅度提高, 满足生产过程中初选工艺的要求.

关键词:机器视觉; 图像处理; D-S 证据理论; 钨矿石; 模糊支持向量机; 决策级融合; 钨矿石初选; 特征提取

中图分类号: TP391

文献标识码: A

文章编号: 1004-4213(2017)07-0710003-8

Ungsten Ore Primary Selection Based on Fuzzy Support Vector Machine and D-S Evidence Theory

HU Fa-huan^{1,2}, LIU Guo-ping¹, HU Rong-hua¹, DONG Zeng-wen¹

(1 School of Mechanical & Electrical Engineering, Nanchang University, Nanchang 330031, China)

(2 School of Mechanical & Electrical Engineering, Jiangxi University of Science and Technology,
Ganzhou, Jiangxi 341000, China)

Abstract: According to the low accuracy and low stability of the single feature-based method for tungsten ore primary selection, a multi-feature fusion based on fuzzy support vector machine and D-S evidence theory was proposed. Firstly, the three types of vision feature that is color, gray and texture were extracted from the ore image after a series of image processing. Their probability function were acquired according to each type of feature utilizing fuzzy support vector machine and the results were used to D-S evidence theory as evidence. Finally, using D-S combination rule of evidence to achieve the decision fusion and giving final recognition result by classification rules. The experimental results show that the accuracy of multi-feature fusion methods is over 96% and it has good performance on accuracy and stability compared to the single feature-based method in tungsten ore primary selection. The accuracy and stability can meet the requirement of production process.

Key words: Machine vision; Image processing; D-S evidence theory; Tungsten ore; Fuzzy support vector machine; Decision fusion; Tungsten ore primary selection; Feature extraction

OCIS Codes: 100.3008; 100.5010; 110.2960; 150.1135

基金项目: 国家自然科学基金(No. 71361014)资助

第一作者: 胡发焕(1975—), 男, 讲师, 博士研究生, 主要研究方向为机器视觉及嵌入式系统. Email: hufahuan@163.com

导师(通讯作者): 刘国平(1964—), 男, 教授, 博士, 主要研究方向为智能机器人与视觉. Email: liuguoping@vip.163.com

收稿日期: 2016-11-15; 录用日期: 2017-04-19

<http://www.photon.ac.cn>

0 引言

钨在工农业等领域具有非常重要的作用,钨资源的高效利用对中国具有重要意义^[1].钨资源的利用是一个复杂过程^[2],其中钨矿石初选是其加工的第一个环节.初选过程是将破碎后含钨的矿石收集起来,把不含钨的废石丢弃,当前钨矿石初选过程是根据矿石的颜色、纹理、灰度和光泽等信息采用人工分选.人工初选需要大量熟练工人,同时人工初选存在主观差异,难以保证选择标准的一致性.

近年来,国内外专家学者对机器视觉技术在矿物加工中的应用进行了大量研究.文献[3]将机器视觉技术与专家系统结合,在钨浮选过程提取了气泡表观特征,但它主要依据图像的灰度进行图像分割,特征单一,系统的稳定性欠佳.文献[4]通过获取浮选泡沫的纹理特征,用于浮选工况建模,但是只提取图像的纹理为识别特征,使得系统的鲁棒性不强.文献[5]采用改进的形态学方法对矿用输送带的表面损伤实时检测,取得一定效果,但它只能检测灰黑色的输送带,当输送带上粘有其他颜色的矿物时,其检测效果将受到很大的影响.文献[6]采用机器视觉对黑钨矿进行初选识别,通过提取 H 分量和 V 分量作为钨的识别特征,但只是将 2 个特征向量进行简单相加,使得识别的准确率不高.

如何将识别对象的多个特征有机融合,并形成相应的判别机制是对矿物识别的关键.为提高钨矿石初选系统的准确率和稳定度,本文提出了一种模糊支持向量机(Fuzzy Support Vector Machine, FSVM)和 D-S 证据理论相结合的决策级多特征融合的钨矿石初选方法.利用 FSVM 在小样本条件下有较好的分类能力,以及 D-S 证据理论具有度量量和组合不精确、不确定信息源的优点,并根据决策规则得到最终识别结果.

1 图像处理和特征提取

钨矿石的初选过程主要根据矿石的颜色、灰度和纹理等特征进行区分.本文研究对象是江西赣州盘古山钨矿出产的石英脉黑钨矿,图 1 为破碎后的各种主要矿石,包括钨石和废石,废石主要有石英石、花岗岩、黄铁矿等,钨常与石英石伴生(石英脉黑钨矿)如图 1(e),也有钨含量很高的钨块(精钨)如图 1(f),其中废石占 75%以上,因此要从矿石中把含钨量达到一定标准的钨石挑选出来.




图 1 破碎后的各种矿石图像
Fig. 1 Images of the different ore

从图 1 矿石图像可知,石英石呈白色,灰度上与其他矿石区别较大;黄铁矿呈金黄色,颜色上易与其他矿石区分;花岗岩,嵌有黑色斑点;变质岩呈灰黑色,有较规则的纹理;钨石呈黑色,伴有金属光泽.花岗岩、变质岩和钨石 3 种矿石在灰度和颜色上区别不大,但三者的纹理区别较大.因此本文选取颜色、灰度、纹理 3 个特征为各矿石的特征量.

1.1 图像预处理

为提取矿石特征量,将采集到的图像先进行预处理.通过 CCD 摄像机所获得的原始图像见图 1.先将原始图像进行 Gauss 滤波,再将 RGB 颜色模型转换成 HIS(Hue, Saturation, Intensity)颜色模型,它较 RGB 颜色有更强的抗干扰能力^[7],图像由 RGB 模型转为 HIS 模型,见式(1),图 2 为图 1(e)转换后 H 、 S 、 I 分量图像.




图 2 石英石和钨的 H 、 S 、 I 分量图像
Fig. 2 H , S , I images of ungssten and quartz

$$\begin{cases} H = \arccos\{[(R-B) + (R-G)/2] / \sqrt{(R-G)^2 + (R-B)(G-B)}\} \\ S = 1 - 3 \times [\min(R,G,B)/(R+B+G)] \\ T = (G+G+B)/3 \end{cases} \quad (1)$$

1.2 特征提取

要提取矿石的各特征参量,先将矿石从背景中分离出来,以避免背景颜色的干扰.从图 2 可以看出, H 分量图像的背景与前景差别较大,本文将 S 分量图像进行自适应阈值分割后得到 H 分量的二值图像,以二值图像作为掩模,与需要提取的矿石图像进行掩模运算为

$$I_m = I_c \cdot X \quad (2)$$

式中: I_c 为二值图像; X 为要除去背景的矿石图像, I_m 为除去背景后的矿石图像,按式(2)可得到除去背景的矿石图像.

1.2.1 颜色特征提取

颜色是反映视觉特征的重要参量,它的分布信息主要集中在低阶颜色矩.本文根据矿石的颜色特点,选取 H 颜色分量的一阶矩(M_{H1})、二阶矩(M_{H2})和 R 分量与 B 分量的比值(C)为其颜色特征,即

$$\begin{cases} M_{H1} = \sum_{j=1}^N q_j / N \\ M_{H2} = [\sum_{j=1}^N (q_j - E_H)^2] / N \\ C = R / B \end{cases} \quad (3)$$

式中 q_j 为像素 j 的 H 颜色分量值.一阶矩描述 H 颜色的平均值;二阶矩描述 H 颜色的方差; C 描述了 RGB 颜色模型中 R 分量与 B 分量的比例关系.因此矿石颜色特征可表示为 $\mathbf{F}_{\text{color}} = [M_{H1}, M_{H2}, C]$.

1.2.2 灰度特征提取

灰度反映了图像的亮暗程度及其变化,本文从 I 分量中提取图像的灰度特征.采用提取灰度特征的一阶矩(M_{I1})、二阶矩(M_{I2})、三阶矩(M_{I3})、和熵(Ent)为矿石的灰度特征,即

$$\begin{cases} M_{I1} = \sum_{j=1}^N b_j / N \\ M_{I2} = [\sum_{j=1}^N (b_j - M_{I1})^2] / N \\ M_{I3} = [\sum_{j=1}^N (b_j - M_{I1})^3] / N \\ \text{Ent} = \sum p_j \log_2 p_j \end{cases} \quad (4)$$

式中 b_j 为像素 j 的 I 分量值, p_j 为 b_j 出现的概率.式中三阶矩反映了灰度变换的偏移程度;熵反映了灰度变化所含信息量的大小.因此灰度特征选用 4 个特征向量 $\mathbf{F}_{\text{gray}} = [M_{I1}, M_{I2}, M_{I3}, \text{Ent}]$ 表示.

1.2.3 纹理特征的提取

纹理是由基本单元周期性或随机重复而产生的特殊图案^[8],它具有微观无规则性而宏观上有规律性的特点^[9].在矿石的分选过程中,纹理是一个非常重要的分选特征,考虑到钨矿石的纹理特征,本文先采用尺度不变局部三进制模式(Scale Invariant Local Ternary Patterns, SILTP)进行纹理变换,再用灰度共生矩阵(Gray Level Co-occurrence Matrix, GLCM)提取 SILTP 图像的纹理特征.

SILTP 描述纹理的基本原理是围绕每个像素(中心像素)选取一个局部区域^[10],将区域内中心像素的灰度值与邻域像素灰度值进行相减,当灰度差值映射在 $[-t, t]$ 范围内时差值量化为 1;差值大于 t 时量化为 2,小于 $-t$ 的量化为 0,再将量化值与从左上方为起点的权值模板相乘,并求和,即得到中心像素点的 SILTP 值.设中心像素灰度值为 p_c ,邻域像素值为 p_i ,则像素点 (x, y) 的 SILTP 值可以表示为

$$\text{SILTP}_{R,N}(x, y) = \sum_{i=0}^{N-1} s(p_i - p_c) 3^i \quad (5)$$

$$s(p_i - p_c) = \begin{cases} 2 & (p_i - p_c) > t \\ 1 & |p_i - p_c| \leq t \\ 0 & (p_i - p_c) < -t \end{cases} \quad (6)$$

式中: R 表示选择邻域的半径, N 表示以 R 为半径的邻域像素个数.本文的局部区域选取为 3×3 (像素),

$R=1, N=8$, 阈值 $t = 0.1 \times p_c$. 采用三进制模式较二进制提高了纹理描绘精度但也加大了计算量. 文献[11]对大量图像进行统计, 发现编码中 Uniform <2 的情况占绝大多数, 所以本文只对 Uniform <2 的情况进行编码. 图 3 为各矿石 SILTP 变换后的图像. GLCM 是公认的描述纹理有效方法, 它具有较强的鲁棒性^[12], 因此 SILTP 变换后可用 GLCM 提取各矿石的纹理特征. GLCM 描绘在 θ 方向上距离为 d , 灰度级别分别为 i 和 j 的一对象元出现的概率. 其描述式为

$$P(i, j, d, \theta) = \#\{(x_1, y_1), (x_2, y_2) \in L_x \times L_y \mid d, \theta, I(x_1, y_1) = i, I(x_2, y_2) = j\} \quad (7)$$

式中 $\#\{z\}$ 表示集合 z 中元素的个数, θ 为方向参数, $L_x \times L_y$ 表示图像的像素集, I 表示每个像素的灰度取自集合. 本文根据矿石的特点, 方向 θ 选取 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 这 4 个方向; 距离 $d = 4$. 反映 GLCM 纹理特征的特征参数有 14 个, 但这些参数之间存在冗余结论, 其中角二阶矩 (Asm)、熵 (Ent)、对比度 (Con) 这 3 个特征之间既有很好的分辨能力又互不相关, 因此本文选取这 3 个参数为矿石纹理特征量, 其描述式见式 (8)~(10), 式中 $p(i, j)$ 为 GLCM 元素.




图 3 各矿石的 SILTP 纹理图像
Fig. 3 SILTP texture images of the different ore

$$\text{Asm} = \sum_{i=1}^L \sum_{j=1}^L p(i, j)^2 \quad (8)$$

二阶矩反映了纹理的粗细程度和均匀度, 当图像较细、分布均匀时其值越小; 反之, 亦然.

$$\text{Ent} = \sum_{i=1}^L \sum_{j=1}^L p(i, j)^2 \ln[p(i, j)] \quad (9)$$

熵是反映纹理所包含的信息量, 当图像的灰度分布越分散, 其值越大; 反之, 亦然.

$$\text{Con} = \sum_{i=1}^L \sum_{j=1}^L (i, j)^2 p(i, j) \quad (10)$$

对比度是体现纹理的清晰程度, 其值越大, 表明图像中的纹理沟纹越深, 视觉效果越清晰; 反之亦然. 本文选取 SILTP 变换后 GLCM 的 3 个特征量为矿石的纹理特征: $\mathbf{F}_{\text{texture}} = [\text{Asm}, \text{Ent}, \text{Con}]$.

2 模糊支持向量机

2.1 传统支持向量机

提取矿石的特征之后, 要根据特征值对矿石进行分类. SVM 是一种常用的分类器, 它以非线性函数将输入样本从低维映射到高维特征空间, 再在高维特征空间建立最优分类面^[13]. SVM 是由专家根据历史资料和自己的知识进行判决, 但是很多情况下由于资料的不完整、知识的不全面, 专家对某些训练点只能做出模糊的判决, 因此涉及模糊分类问题. 传统的 SVM 只能进行二类问题分类, 因 SVM 分类过程中出现的噪声及孤立点会对结果产生影响, 所以实际的准确率会受到影响^[14]. Tnoue T 等提出了模糊支持 (Fuzzy Support Vector Machine, FSVM) 算法^[15], 在分类过程中对每类分配一个介于 0~1 的隶属度取代原来非 1 即 -1 的硬性分类, 以解决传统 SVM 分类中遇到的上述问题.

2.2 模糊支持向量机

FSVM 是由隶属度函数 $\delta \in [-1, -0.5]$ 和 $\delta \in [0.5, 1]$ 分别代替传统支持向量机的 -1 类和 +1 类^[16], 构造 FSVM 的步骤为

1) 选取 n 个样本, 根据专家库生成的样本隶属函数 δ 构成三角模糊数, 即

$$y = (r_1, r_2, r_3) = \begin{cases} [(2\delta^2 + \delta - 2)/\delta, 2\delta - 1, (2\delta^2 - 3\delta + 2)/\delta] & 0.5 \leq \delta \leq 1 \\ [(2\delta^2 + 3\delta + 2)/\delta, 2\delta + 1, (2\delta^2 - \delta - 2)/\delta] & -1 \leq \delta \leq -0.5 \end{cases} \quad (11)$$

式中 r_1, r_2, r_3 分别为三角模糊数的中心点和左右端点, 它们表示了三角模糊数的主要位置, 即通过隶属度函数 δ 确定三角模糊数的位置. 由式 (11) 得到模糊训练集 $S = \{(x_1, y_1, \delta_1), (x_2, y_2, \delta_2), \dots, (x_n, y_n, \delta_n)\}$ 样本,

训练集中的 x_i 为样本输入参数, y_i 为式(11)的三角模糊数, δ_i 为 x_i 所对应的隶属度.

2) 设模糊向量机的置信水平为 $\lambda(0 < \lambda < 1)$, 模糊分类转化为求解 $(\omega, b)^T$, 则决策变量的模糊机约束规划问题为

$$\begin{cases} \min \|\omega\|^2/2 \\ \text{s. t. } ((1-\lambda)r_3 + \lambda r_2)(\omega \cdot x_i) + b \geq 1 & r \text{ is positive membership} \\ [(1-\lambda)r_1 + \lambda r_2)(\omega \cdot x_i) + b \geq 1 & r \text{ is negative membership} \end{cases} \quad (12)$$

式中 s. t. 表示约束条件; r_1, r_2, r_3 为式(11)的 r_1, r_2, r_3 . 根据式中的约束条件, 求出最优决策变量 ω 和 b 的值, 即得到最优分类函数

$$f(x) = \text{sign}[g(x)] = \text{sign}[(\omega \cdot x) + b] \quad (13)$$

最优分类超平面为: $(\omega \cdot x) + b = 0$.

3) 由训练集 $S = \{[g(x_1), \delta_1], [g(x_2), \delta_2], \dots, [g(x_n), \delta_n]\}$, 选择适当的惩罚参数 C , 以线性核为核函数, 得到 ϵ -支持向量回归函数

$$\mu[g(x)] = \begin{cases} \varphi[g(x)] & -\varphi^{-1}(1) \leq g(x) \leq \varphi^{-1}(1) \\ 1 & g(x) > \varphi^{-1}(1) \end{cases} \quad (14)$$

式中 $\mu[g(x)]$ 即为最优分类函数的隶属度函数, $\varphi^{-1}(1)$ 为 $\varphi[g(x)]$ 的反函数在 1 处的函数值. 由式(14)可得模糊支持向量机的隶属度, 即所属类别的信任度 (Basic Possible Assignment, BPA).

3 基于 D-S 证据理论的决策级融合

D-S 证据理论是 Dempster 于 1967 年首先提出, 后由 Shafer 对它进行系统化完善^[17-18]. 其原理是通过先验概率分配函数而得后验证据区间, 在证据区间量化命题的可信程度. 它把多个证据体的信任函数通过融合规则进行有机融合, 得到一个新的信任函数并以之为判别依据, 它能有效解决具有不确定性知识的模式识别问题^[19-20].

设 S 表示 X 所有可能取值的一个论域集合, 集合内各元素之间互不相容, 则 S 定义为 X 的识别框架, 定义函数 $m: 2^S \rightarrow [0, 1]$ 满足式(15)条件时, 称 m 为识别框架上的信任度, 式(15)中 \emptyset 为空集, $m(A)$ 为 A 的信任度值; 当 $A \neq S$

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \in 2^S} m(A) = 1 \end{cases} \quad (15)$$

时, $m(A)$ 表示对命题 A 的支持程度; 当 $A = S$ 时, $m(A)$ 表示证据为不确定性. D-S 理论合成规则是: 设 m_1, m_2, \dots, m_n 为识别框架 S 中 n 个不同证据的 BPA, 相应的焦元分别为 $A_{11}, A_{12}, \dots, A_{1k}; A_{21}, A_{22}, \dots, A_{2k}; A_{n1}, A_{n2}, \dots, A_{nk}$, D-S 理论的融合是它们的正交和 $m = m_1 \oplus m_2 \oplus \dots \oplus m_n$, 即

$$\begin{cases} m(A) = K^{-1} \sum_{\alpha=A} m_1(A_{1i_1}) m_2(A_{i_2}) \dots m_n(A_{i_n}) \\ K = 1 - \sum_{\alpha=\emptyset} m_1(A_{1i_1}) m_2(A_{i_2}) \dots m_n(A_{i_n}) \\ \alpha = A_{1i_1} \cap A_{i_2} \dots \cap A_{i_n} \end{cases} \quad (16)$$

式(16)为 D-S 证据理论的融合公式, 通过它可以对多条独立的证据有机融合, 得到联合证据下的新结果. 在钨矿石初选识别过程中, 矿石的颜色、灰度和纹理等特征之间是相互独立的, 因此可以利用 D-S 理论融合来自不同特征向量的 FSVM 识别结果, 最后利用决策模块得出矿石的类型, 钨矿石的识别算法模型如图 4. 其具体的算法步骤为:

- 1) 提取各特征向量值. 依据前文的方法分别提取矿石的颜色、灰度和纹理特征的各特征值.
- 2) 利用模糊支持向量机, 按照式(14)分别获取颜色、灰度和纹理各特征信任度.
- 3) 决策融合及决策规则. 根据颜色、灰度和纹理 3 个特征信任度, 按照式(16)计算出联合证据下的信任度.

设 $A_i (i=0, 1)$ 为识别类型 (钨矿石和废石), A_i 为目标类别, $m(A_i)$ 为对 A_i 的信任度, $m_j(S)$ 为不确定信

任意度. 在联合分类判别过程中应遵循的规则有: ① $m(A_i) = \max\{m(A_i)\}$, 即目标类别的信任度最大; ② $m(S) < \epsilon_1$ ($\epsilon_1 > 0$), 即不确定信任度必小于某一阈值; ③ $m(A_i) - m(S) > \epsilon_2$ ($\epsilon_2 > 0$), 即目标类信任度与不确定信任度的差值必大于某一阈值; ④ $m(A_i) - m(A_j) > \epsilon_3$ ($\epsilon_3 > 0$), 即目标类与其他类信任度差值必大于某一阈值.




图 4 钨矿石识别算法模型
Fig. 4 The recognition model of ungssten

4 实验结果与分析

为验证算法效果, 本文进行 3 组试验, 每组都选取包含各种矿石的 50 个训练样本和 20 个测试样本, 分别进行 15 个试验. 按照本文前述的方法, 先提取矿石的颜色、灰度、纹理等 3 类共计 10 个特征向量, 并进行归一化处理, 再按图 4 的步骤对各矿石进行识别. 其中 FSVM 的核函数选用径向基函数, 通过交叉试验方法, 选定惩罚参数 $C=30$, $\sigma=1.5$; 在决策规则中, $\epsilon_1=0.15$, $\epsilon_2=0.6$, $\epsilon_3=0.5$. 因待分类的矿石常有伴生的现象, 如图 1(e) 所示, 在实际初选过程中是把含钨达到一定标准的钨石从其他石头中分选出来, 因此在图像处理过程中, 依据矿石的特点, 本文把一幅矿石图像分割成 9 个子图像, 对每个子图像的归属类进行统计, 当钨的含量达到 30% 时, 则认为该矿石为是有用的钨矿石. 根据决策规则, 试验结果如下:

1) 记录试验中单特征和多特征融合的信任度及识别结果, 表 1 为从每组随机选取的某个记录(第一组第 9 个试验标号为 1~9). 从表 1 结果可知: ①由颜色、灰度和纹理 3 种特征融合后的信任度较单一特征信任度相比, 实际目标信任度得到很大的提高, 使得目标识别的错误率和不确定性大幅度降低. ②对单个特征 FSVM 无法判别的情况(如表中的 1~9, 2~8), 经过多特征融合后能进行有效识别, 因此 D-S 证据理论的多特征融合提高了系统识别的准确度.

表 1 单特征及融合特征识别试验结果
Table 1 Results of single feature and multi-feature

Sample and the numbers	Single feature and feature fusion		Result of BPA			Result of recognition
			$m(A_0)$	$m(A_1)$	$m(S)$	
1-9 Ungsten	Colour	m_0	0.42	0.23	0.35	Uncertainty
	Gray	m_1	0.54	0.18	0.28	Uncertainty
	Texture	m_2	0.64	0.21	0.15	Uncertainty
	Fusion	m	0.84	0.13	0.03	ungsten
2-8 Ungsten and quartz	Colour	m_0	0.40	0.24	0.36	Uncertainty
	Gray	m_1	0.46	0.22	0.32	Uncertainty
	Texture	m_2	0.68	0.21	0.11	Uncertainty
	Fusion	m	0.82	0.16	0.02	ungsten
3-5 Metamorphic rock	Colour	m_0	0.33	0.42	0.25	Uncertainty
	Gray	m_1	0.30	0.52	0.18	Uncertainty
	Texture	m_2	0.11	0.75	0.14	Uncertainty
	Fusion	m	0.13	0.86	0.03	Rubbishore

2) 为了验证效果, 本文将单特征识别、D-S 证据特征融合和 BP 综合神经网络数据融合三种算法进行了比较, 表 2 为各算法的平均正确识别率的比较, 表 3 为各算法运行时间的比较.

BP 综合神经网络是一种常用的决策融合方法^[21], 本文比较试验的神经网络由 3 个特征子网络(颜色、灰度、纹理)组成, 采用 4 层结构(输入层、运算层、子网络归一层、子网络输出层)的形式. 通过实验得出: 1) 单特征识别存在识别率低、稳定系差的缺陷, 而 D-S 证据理论的多特征融合识别, 其识别率达到 96%, 与单特征相比其准确率和稳定性都有大幅度提高. 这是因为 D-S 证据理论是以 FSVM 后验概率和分类信任度为依据, 融合了颜色、灰度和纹理 3 类共计 10 个特征向量的识别信息, 实现了弱分类(单特征)决策对强分类

(多特征融合)决策的有效支持,能较大幅度地提高准确率和稳定性.2)从识别率可以看出 BP 综合神经网络数据融合的认可率要低于 D-S 证据融合,主要原因是神经网络的权重难以确定,因为颜色、灰度、纹理三个特征量在不同的矿石所占的权重不同,难以用一种权重适合不同的矿石.从各算法的运算时间可以看出,单特征识别虽时间最短,但识别率太低;BP 综合神经网络与 D-S 证据理论特征融合的运行时间相当,因此,本文算法的综合性能要优于 BP 综合神经网络数据融合算法.

表 2 不同算法识别率的比较

Table 2 Comparison of recognition rate to different algorithm

No.	Single feature/%			D-S theory/%	Neural network/%
	Colour	Gray	Texture		
1	45.8	48.4	75.2	98.5	90.4
2	42.5	52.7	68.4	96.2	89.0
3	49.4	63.2	72.5	96.5	89.6

表 3 不同算法平均运行时比较

Table 3 Comparison of runing time to different algorithm

No.	Single feature/%			D-S theory/%	Neural network/%
	Colour	Gray	Texture		
1	45.8	48.4	75.2	98.5	90.4
2	42.5	52.7	68.4	96.2	89.0
3	49.4	63.2	72.5	96.5	89.6

5 结论

通过 3 个并行 FSVM 分类器实现基于颜色、灰度和纹理等单特征的钨矿石初选识别,并以每个 FSVM 为独立证据体,利用 D-S 证据理论具有度量和组合不精确、不清晰信息源的优点,对 3 个 FSVM 证据信息进行有效融合,再依据决策规则,得到最后的识别结果.试验结果表明:采用 FSVM 与 D-S 证据理论有机结合的钨矿石识别方法,正确率达到 96%,大幅度提高了钨矿石分选识别的准确率和稳定度,能满足生产过程中初选工艺的要求.

参考文献

- [1] WANG Ming-yan, JIA Mu-xin, XIAO Yi-wu, *et al.* The present situation and sustainable development counter measures of tungsten resources in China[J]. *Nonferrous Metals Engineering*, 2014, **4**(2): 76-80.
王明燕,贾木欣,肖仪武,等.中国钨矿资源现状及可持续发展对策[J].*有色金属工程*,2014,**4**(2):76-80.
- [2] LONG Kui. Design of primary sorting system of tungsten ore based on the DSP[D]. Gan Zhou: Jiangxi University of Science and Technology, 2013; 1-3.
龙魁.基于 DSP 技术的钨矿初选系统的研究[D].赣州:江西理工大学,2013:1-3.
- [3] KAARTINEN J, HATONEN J, HYOTYIEMI H, *et al.* Machine vision based control of zinc flotation a case study[J]. *Control Engineering Practice*, 2006, **14**(12): 1455-1466.
- [4] LIN Xia. Research and application of flotation froth image texture extraction[D]. Chang Sha: Central South University, 2013; 23-27.
林霞.浮选泡沫图像纹理特征提取研究及应用[D].长沙:中南大学,2013:23-27.
- [5] LIN Ze-tan, MIAO Chang-yun, LI Xian-guo, *et al.* Conveyor belt breakage detection algorithm based on machine vision [J]. *Journal of Tianjin Polytechnic University*, 2014, **33**(03): 66-68, 79.
李泽潭,苗长云,李现国,等.基于机器视觉的输送带破损检测算法[J].*天津工业大学学报*,2014,**33**(03):66-68,79.
- [6] XIAO Ling-ling, HUANG Zhi-hui. Research on primary algorithm of wolframite ore based on the physical properties[J]. *Mining Research and Development*, 2015, **35**(9): 36-39.
肖玲玲,黄之慧.基于矿苗特征的黑钨初选算法研究[J].*矿业研究与开发*,2015,**35**(9):36-39.
- [7] HU Fa-huan, DONG Zeng-wen, KUANG Yi-shun. Online navel orange grading detection system based on machine vision[J]. *Journal of China Agricultural University*, 2016, **21**(3): 112-118.
胡发焕,董增文,匡以顺.基于机器视觉的脐橙品质在线分级检测系统[J].*中国农业大学学报*,2016,**21**(3):112-118.
- [8] MA Shuang, LIU Kun, XU Gang. Illumination analysis of texture image based on color statistics invariance[J]. *Computer Applications and Software*, 2014, **31**(2): 233-237.
马爽,刘坤,许刚.基于颜色统计不变性的纹理图像光照分析[J].*计算机应用与软件*,2014,**31**(2):233-237.
- [9] PENATTI O A B, VALLE E, TORRES R S. Comparatives study of global and texture descriptors for web image

- retrieval[J]. *Journal Visual Communication and Representation*, 2012, **23**(2): 359-380.
- [10] LI J N, ALLINSON M. A comprehensive review of current local features for computer vision[J]. *Neurocomputing*, 2008, **71**(10-12): 1771-1787.
- [11] FATHI A, CI A N N. Noise tolerant local binary pattern operator for efficient texture analysis[J]. *Pattern Recogniton Letters*, 2012, **33**(9): 1093-1100.
- [12] LIU li, KUANG Gang-yao. Over view of image textural feature extraction methods[J]. *Journal of Image and Graphic*, 2009, **14**(4): 622-635.
刘丽,匡纲要. 图像纹理特征提取方法综述[J]. *中国图象图形学报*, 2009, **14**(4): 622-635.
- [13] GUO Ming-wei, ZHAO Yu-zhou, XIANG Jun-ping, *et al.* Review of object detection methods based on SVM[J]. *Control and Decision*, 2014, **29**(2): 193-200.
郭明玮,赵宇宙,项俊平,等. 基于支持向量机的目标检测算法综述[J]. *控制与决策*, 2014, **29**(2): 193-200.
- [14] TONG Xiao-yang, LUO Zhong-yun. Transmission line faults classification method based on fuzzy support vector machine and reducing-dimension display[J]. *High Voltage Engineering*, 2015, **41**(7): 2276-2282.
童晓阳,罗忠运. 基于模糊支持向量机的输电线路故障模糊分类方法及其降维显示[J]. *高电压技术*, 2015, **41**(7): 2276-2282.
- [15] INOUE T, ABE S. Fuzzy support vector machines for pattern classification[C]. *International Joint Conference on Neural Networks*. Washington DC: IEEE, 2001, **2**: 1449-1454.
- [16] 杨志民,刘广利. 不确定性支持向量机原理及应用[M]. 北京:科学出版社,2007.
- [17] BASIR O, YUAN X H. Engine fault diagnosis base on multi-sensor information fusion using Dempster-Shafer evidence theory[J]. *Information Fusion*, 2007, **8**(4): 379-386.
- [18] 王润生. 信息融合[M]. 北京:科学出版社,2007.
- [19] ZHAO Qiu-yue, ZUO Wan-li, TIAN Zhong-sheng, *et al.* A method for assessment of trust relationship strength based on the improved D-S evidence theory[J]. *Chinese Journal of Copputers*, 2014, **37**(4): 873-883.
赵秋月,左万利,田中生,等. 一种基于改进 D-S 证据理论的信任关系强度评估方法研究[J]. *计算机学报*, 2014, **37**(4): 873-883.
- [20] OUYANG Ai-guo, TANG Tian-yi, ZHOU Xin, *et al.* Methanol content determination in methanol diesel with mid infrared spectroscopy analysis using least square support vector machine[J]. *Chinese Journal of Luminescence*, 2016, **37**(10): 1253-1258.
欧阳爱国,唐天义,周鑫,等. 最小二乘支持向量机结合中红外光谱测定甲醇柴油甲醇含量[J]. *发光学报*, 2016, **37**(10): 1253-1258.
- [21] DOU Gang, CHEN Guang-sheng, ZHAO Peng. Wood species recognition using color texture and spectral features[J]. *Journal of Tianjin University (Science and Technology)*: 2015, **48**(2): 147-254.
窦刚,陈广胜,赵鹏. 采用颜色纹理及光谱特征的木材树种分类识别[J]. *天津大学学报*, 2015, **48**(2): 147-254.