doi: 10.20239/j.issn.1671-9492.2026.09.013

铜锡多金属矿矿石矿物显微图像智能识别与应用

张聿隆[1,2],肖仪武[1,2],张 钰[1,2],王名越[1,2],权鸿雁[1,2]
(1. 矿冶科技集团有限公司,北京 100160;
2. 矿物加工科学与技术全国重点实验室,北京 102628)

摘 要:随着人工智能技术快速发展,基于图像处理的矿物显微图像智能识别,可自动获取光学显微镜下矿石矿物嵌布粒度、解离度等工艺矿物学关键参数,能够减轻人工镜下统计工作量,降低人为带来的主观误差,提升测试数据的客观性与分析效率。某铜锡多金属矿以铜、锡为主要回收元素,伴生锌;主要金属矿物为锡石、黄铜矿、闪锌矿、黄铁矿,含少量蓝辉铜矿、铜蓝等次生硫化铜矿物,非金属矿物主要为石英、绿泥石。本文利用矿冶科技集团开发的矿物特征参数分析系统(MCPAS),融合HSV色彩阈值分割与深度学习注意力机制算法,对矿石原样以及-0.074 mm占50%~80%四组不同磨矿细度产品光片开展图像采集、矿物识别与定量统计,测定主要金属矿物嵌布粒度组成、单体解离、连生及包裹特征。测试结果表明,矿石锡石嵌布粒度粗细分布不均,铜矿物集合体粒度整体偏粗,闪锌矿粒度偏细;锡石、蓝辉铜矿、铜蓝性脆易碎,磨矿过程易发生过磨。结合矿石工艺矿物学特征,建议在-0.074 mm占60%的磨矿细度条件下优先分选已单体解离铜矿物,得到高品质铜精矿;选铜后将硫化物矿物富集再磨分选,产出另一部分铜精矿、锌精矿和硫精矿;浮选尾矿采用重选回收锡石,细粒锡石辅以浮选回收。

关键词:铜锡多金属矿;矿物图像;智能识别;工艺矿物学;自动分析
中图分类号:TD91;TD952 **文献标志码**:A **文章编号**:1671-9492(2026)09-0113-09

Intelligent Recognition and Application of Microscopic Images of Copper-Tin Polymetallic Ore Minerals

Zhang Yulong[1,2], Xiao Yiwu[1,2], Zhang Yu[1,2], Wang Mingyue[1,2], Quan Hongyan[1,2]
(1. BGRIMM Technology Group, Beijing 100160, China;
2. State Key Laboratory of Mineral Processing, Beijing 102628, China)

Abstract: With the rapid development of artificial intelligence technology, intelligent recognition of mineral micro-images based on image processing can automatically obtain key process-mineralogical parameters such as grain-size distribution and mineral liberation degree under an optical microscope. It can reduce the workload of manual microscopic statistics, lower subjective human errors, and improve the objectivity and analysis efficiency of test data. For a copper-tin polymetallic ore, copper and tin are the main recovery elements with associated zinc. Its main metallic minerals are cassiterite, chalcopyrite, sphalerite and pyrite, together with a small amount of secondary copper sulfide minerals including digenite and covellite, and its main non-metallic minerals are quartz and chlorite. In this paper, the Mineral Characteristic Parameter Analysis System (MCPAS) developed by BGRIMM was adopted. Combined with HSV color threshold segmentation and deep-learning attention-mechanism algorithm, image acquisition, mineral identification and quantitative statistics were carried out on raw ore and four groups of grinding products with grinding fineness of -0.074 mm accounting for 50%-80%. The grain-size composition, monomer liberation, intergrowth and inclusion characteristics of major metallic minerals were determined. The test results show that cassiterite has uneven grain-size distribution, copper mineral aggregates are relatively coarse-grained, while sphalerite is fine-grained. Cassiterite, digenite and covellite are brittle and friable, and are prone to over-grinding. According to the process-mineralogical characteristics of the ore, it is recommended to preferentially

收稿日期:2025-09-30
基金项目:云南省科技计划项目(202504BW050001)
作者简介:张聿隆(1995-),男,内蒙古巴彦淖尔人,硕士,工程师,主要从事矿石工艺矿物学研究。
通信作者:肖仪武(1965-),男,江西上饶人,硕士,正高级工程师,主要从事工艺矿物学研究及矿产资源可利用性评价。

separate monomer-dissociated copper minerals at the grinding fineness of −0.074 mm accounting for 60% to obtain high-quality copper concentrate. After copper flotation, sulfide minerals are enriched for regrinding and separation to produce another copper concentrate, zinc concentrate and sulfur concentrate. Cassiterite is recovered by gravity separation from flotation tailings, and fine-grained cassiterite is further recovered by flotation.

Key words: copper-tin polymetallic ore; mineral image; intelligent recognition; process mineralogy; automatic analysis

工艺矿物学研究中，矿石矿物嵌布粒度以及磨矿产品的矿物解离特征，对确定磨矿细度与选矿工艺流程具有重要指导意义[1-2]。传统工艺矿物学依靠反光偏光显微镜人工观察统计光片，需要科研人员逐颗粒判别矿物种类、嵌布关系与连生状态，不仅工作强度大、分析周期长，分析结果还易受人为主观经验干扰[3-4]。同时人工镜下统计可观测的矿物颗粒数量有限，统计样本规模偏小，不可避免带来抽样偏差，一定程度上会影响对矿石整体性质的客观判断[5-6]。

随着机器视觉与人工智能技术的快速发展，图像处理、深度学习算法逐步被引入矿物学领域，为矿物显微图像自动解析提供了新的技术路径[7-9]。基于光学显微图像的智能识别技术，能够批量处理光片图像，自动完成矿物识别、粒度统计、解离度计算，可大幅提升工艺矿物学测试的工作效率，扩大统计样本量，降低人为因素带来的数据偏差[10-15]。但矿物反射光学特征复杂，部分矿物反射色、灰度区间相互重叠，如何实现相似光学特征矿物的精准分割，仍是该类技术实际应用需要解决的难点。

本文采用矿冶科技集团有限公司研发的矿物特征参数分析系统(MCPAS)，该系统融合HSV色彩阈值与深度学习注意力机制算法，针对某铜锡多金属矿开展矿物图像智能识别测试。通过对原矿样品及不同磨矿细度产品的光片进行分析，获取主要金属矿物的嵌布粒度、解离特征，结合测试结果开展工艺矿物学解析，提出适配该矿石性质的选矿工艺方案，为该铜锡多金属矿的选矿流程制定提供矿物学依据。

1 样品制备和图像采集

某铜锡多金属矿矿石铜和锡品位分别为0.53%、0.30%，锌含量为0.12%。矿石中金属矿物主要为锡石、黄铜矿、闪锌矿、黄铁矿，含少量蓝辉铜矿、铜蓝；非金属矿物主要以石英、绿泥石为主，其次为斜长石、钾长石、黑云母、石榴石、白云母等。

1.1 光片制备

将−8 mm破碎样或磨矿产品与环氧树脂、固化剂按配比混合，在适宜温度固结制成光片，采用矿冶科技集团有限公司自主研发的全自动磨抛机(图1)对光片开展细磨、精磨与抛光处理，保证样品表面光洁无划痕。制样质量直接决定后续图像识别精度，光片表面存在的划痕、麻点、凸起等缺陷均会引发算法误分割。抛光完成后需在显微镜下进行初筛检查，剔除表面缺陷明显的不合格光片，保障后续图像数据集质量。



图1 全自动磨抛机

Fig. 1 Fully automatic grinding and polishing machine

1.2 图像采集

采用配置*XYZ*三轴电动平台的蔡司反射偏光显微镜对制备完成的光片进行图像拍摄，通过CCD电荷耦合器件将模拟图像转换为数字图像并导入计算机(图2)。借助软件完成图像拼接，生成无缝、高分辨率全景图像，完整还原光片视域内矿物真实形貌特征。显微镜三轴电动平台可实现视域自动移位、批量图像采集，摆脱人工逐帧拍照的限制，短时间内即可采集海量矿物显微图像，为大样本量的矿物统计提供数据基础，也是智能分析系统降低抽样误差的前提条件。

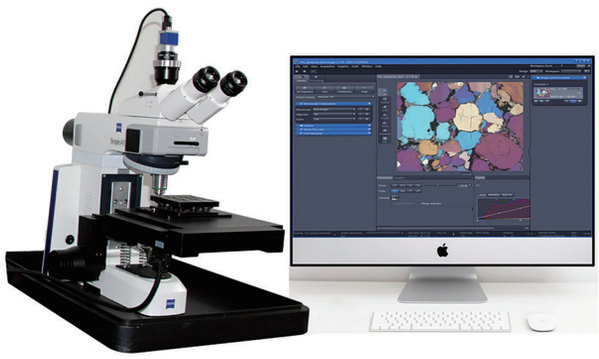


图2　自动矿物显微图像采集系统

Fig. 2　Automatic mineral microscopic image acquisition system

2　金属矿物的图像识别

2.1　图像预处理

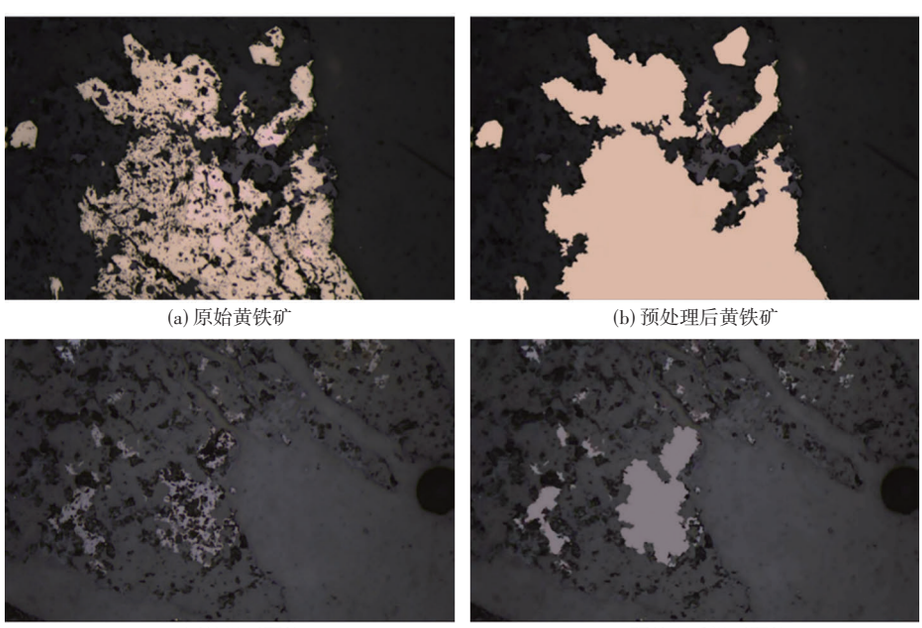
在进行矿物识别前，需要对拼接后的全景图像执行预处理操作。采用自适应阈值分割算法，在频域空间实现目标矿物特征与背景噪声分离，降低外部条件带来的干扰。该方法可消除制样缺陷、光照不均、成像噪声造成的划痕伪影，避免伪影干扰矿物识别结果。同时采用图像增强算法提升暗区域辨识度，在不改变矿物本体特征的前提下强化矿物相边界轮廓，使矿物边界轮廓更加清晰，为后续智能识别提供基础(图3)[16-23]。

2.2　图像识别机制

矿石中锡石、黄铜矿、闪锌矿、黄铁矿、蓝辉铜矿、铜蓝等金属矿物，在反射偏光显微镜下具备差异化反射颜色特征。将图像RGB色彩(Red：红，Green：绿，Blue：蓝)空间转换为HSV(Hue：色调，Saturation：饱和度，Value：明度)色彩模型，依托不同矿物的颜色特征完成矿物识别(表1、图4)。表1中HSV阈值为MCPAS系统针对本类矿石标定得到。

锡石反射色与部分脉石矿物接近，仅依靠HSV颜色阈值难以有效区分锡石与伴生脉石。注意力机制是深度学习领域有效的特征增强策略，通过对输入信息加权赋值，对图像不同区域分配差异化权重，兼顾计算效率与全局特征传递[24-29]。锡石具备区别于脉石的高凸起光学特征，引入注意力机制可以强化该关键特征，弥补单纯颜色识别的不足。因此在HSV颜色空间识别基础上融合深度学习算法，提升锡石与脉石矿物的识别精度(图5、6)。

仅依靠反射光颜色信息难以区分部分光泽接近的矿物，是传统镜下图像识别普遍存在的问题。本文矿石中锡石与部分浅色脉石矿物灰度区间高度重叠，单纯HSV阈值分割容易出现漏识别、误分割。引入窗口多头自注意力机制后，模型能够重点捕捉锡石颗粒高浮雕、边缘棱角等形态学特征，弥补颜色特征不足带来的识别缺陷。从识别效果来看，融合形态特征



(a) 原始黄铁矿　(b) 预处理后黄铁矿

(c) 原始锡石颗粒　(d) 预处理后锡石颗粒

图3　矿物图像预处理效果

Fig. 3　Effect of mineral image preprocessing

表 1 部分矿物 HSV 颜色阈值数据

Table 1 HSV color threshold data of partial minerals

矿物名称	H	S	V
黄铜矿	16～18	118～139	145～230
蓝辉铜矿	100～127	25～35	155～190
铜蓝	106～115	81～125	115～160
黄铁矿	14～20	35～80	156～210
闪锌矿	156～173	13～33	75～90
锡石	150～173	15～42	42～52
脉石	130～165	17～30	39～50

之后，锡石颗粒与脉石的分割边界更加准确，降低了细粒锡石的漏检概率，为后续粒度、解离度的定量统计提供可靠图像基础。

3 金属矿物特征参数的测量

3.1 嵌布粒度

通过测量矿物颗粒图像(图 7)的颗粒面积 S、颗粒最大弦长 a，计算等效椭圆短径 b；以等效椭圆短径作为矿物颗粒特征粒径划分粒级区间 D_i，统计各粒级区



(a) 原始黄铜矿颗粒 (b) 预处理后 (c) 识别后

图 4 基于 HSV 的黄铜矿识别效果

Fig. 4 Recognition effect of chalcopyrite based on HSV

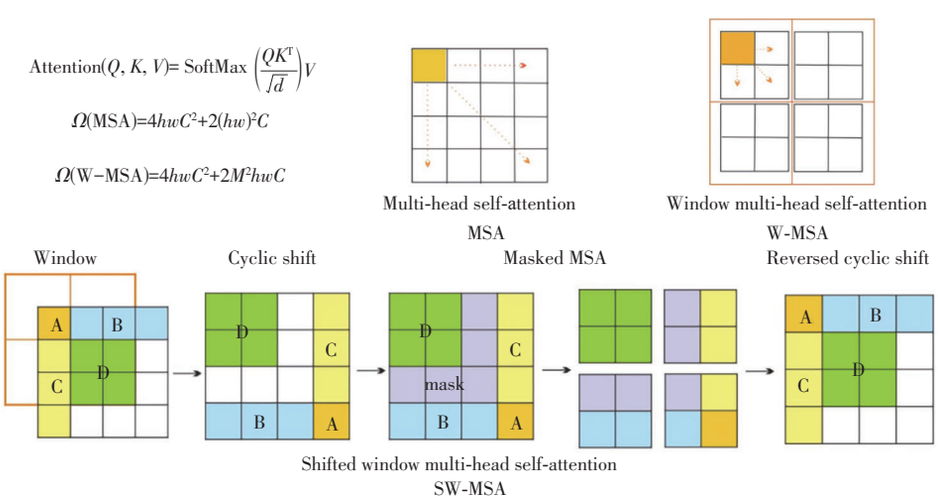
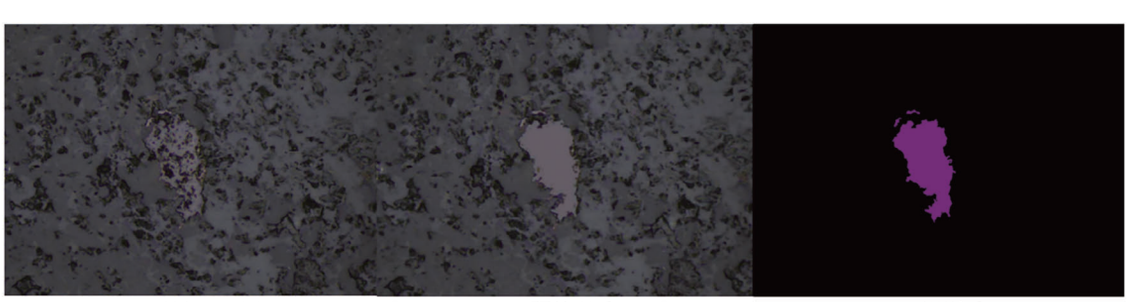


图 5 自注意力及窗口多头自注意力计算过程[24]

Fig. 5 Calculation process of self-attention and window multi-head self-attention[24]



(a) 原始锡石颗粒 (b) 预处理后 (c) 识别后

图 6 引入深度学习后锡石识别效果

Fig. 6 Recognition effect of cassiterite after introducing deep learning

间内矿物颗粒累计面积S_i，进而计算得到各粒级的矿物面积占有率P_i。

$$b=4S/(\pi\times a) \tag{1}$$

式中，b为等效椭圆的短径，mm；S为等效椭圆的面积，mm^2；a为等效椭圆的长径，mm。

$$P_i=\left(S_i/\sum S_i\right)\times 100\% \tag{2}$$

式中，P_i为第i个粒度区间的占有率，%；S_i为第i个粒度区间目的矿物面积，mm^2；$\sum S_i$为所有目的矿物颗粒面积之和，mm^2。

采用面积占有率表征嵌布粒度，符合工艺矿物学显微图像统计的通用方法，能够客观反映不同粒级矿物的质量占比，为后续磨矿—选矿工艺分析提供依据。

3.2　连生类型的划分及表征

浮选作业中，矿物颗粒表面需要具备足够的有效裸露面，浮选药剂才能够与矿物表面发生作用实现分选，因此矿物的连生状态直接影响矿物的可浮性。依据矿物之间的结合形式，将矿物连生体划分为裸露连生体与包裹连生体两类(图8)。

利用边缘检测算法对完成识别的矿物图像进行运算检测，提取不同矿物相的边界轮廓，判别矿物颗粒之间的接触关系，完成单体颗粒与连生体颗粒的初步划分(图9)。在此基础上，结合目标检测算法锁定矿物颗粒之间的接触边界位置，进一步区分裸露连生体和包裹连生体(图10)，分别统计单体、各类连生体的颗粒面积，计算各自面积占比，得到矿物解离特征参数。

4　应用

矿冶科技集团有限公司开发的矿物特征参数分析系统(Mineral Characteristic Parameter Analysis System，MCPAS)，可完成矿物显微图像智能识别，实现矿石矿物嵌布粒度、不同磨矿细度产品解离度的测定，在工艺矿物学实际测定工作中得到应用。

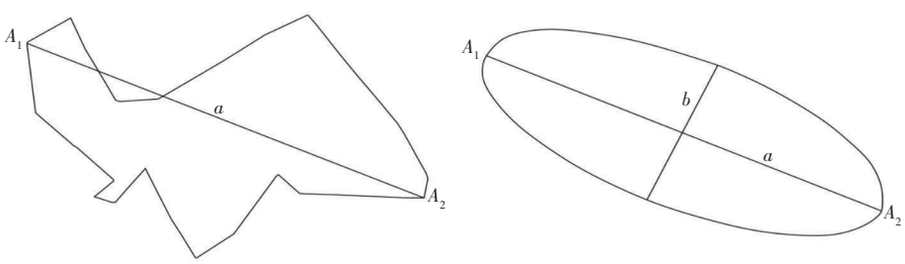
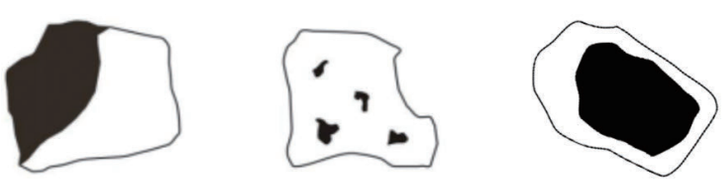


图7　等效椭圆粒度计算示意图

Fig. 7　Schematic diagrams of grain-size calculation by equivalent ellipse



(a) 裸露连生　　(b) 贫包裹连生　　(c) 富包裹连生

图8　矿物连生体类型

Fig. 8　Types of mineral intergrowths

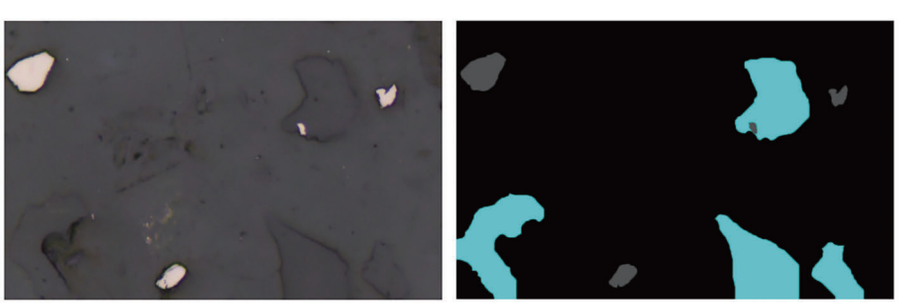


图9　矿物单体与连生体划分

Fig. 9　Division of mineral monomers and intergrowths



图 10 脉石中黄铜矿包裹体识别

Fig. 10 Recognition of chalcopyrite inclusion in gangue

4.1 矿石中重要矿物的嵌布粒度

利用MCPAS测定原矿中锡石、铜矿物集合体、闪锌矿、黄铁矿的嵌布粒度,结果见表2。由表2可知,矿石中锡石粒度粗细分布不均,主要集中在0.020~0.147 mm粒级;铜矿物集合体粒度相对较粗,集中于0.043~0.208 mm;闪锌矿整体粒度偏细,主要分布于0.020~0.104 mm;黄铁矿粒度集中在0.043~0.295 mm。

锡石粒度粗细有差别,既存在粗粒易解离颗粒,同时产出大量-0.020 mm微细粒锡石。锡石硬度低、性脆,磨矿过程中极易发生过磨现象,会显著增大重选回收难度。铜矿物集合体整体粒度较粗,在中等磨矿细度条件下就可以获得较好的单体解离效果;但闪锌矿整体粒度偏细,即便铜矿物实现较好解离,闪锌矿仍大量以连生体形式产出,难以同步单体解离,这也是原矿不宜采用一次性磨矿的重要依据。黄铁矿粒度分布粗细不均,对磨矿细度变化的适应性相对较好。

4.2 磨矿产品中重要矿物的解离特征

采用MCPAS测定磨矿细度为-0.074 mm粒级含量分别占50%、60%、70%、80%四组磨矿产品中锡石、铜矿物集合体、闪锌矿、黄铁矿的解离特征,测定结果见表3~6。由表3~6可知,当磨矿细度为-0.074 mm占60%时,锡石、铜矿物集合体、闪锌矿和黄铁矿的单体解离度分别为67.75%、71.89%、57.36%和70.54%,被脉石矿物包裹占比分别为5.42%、5.48%、6.42%和7.42%;锡石主要与脉石矿物连生,黄铜矿与闪锌矿嵌布关系密切。

随着磨矿细度提高,四种矿物单体解离度整体均呈上升趋势,但不同矿物解离改善幅度差异明显。当磨矿细度由-0.074 mm占60%提高至80%时,锡石单体解离度提升较为显著,但锡石脆性大,过磨会生成大量难以回收的微细粒;铜矿物集合体解离度同步提升,但继续强化磨矿带来的增益有限。闪锌矿在整个磨矿细度区间单体解离度均处于偏低水平,其中与黄铜矿连生的闪锌矿含量较高,仅依靠提高磨矿细

表 2 锡石、铜矿物集合体、闪锌矿、黄铁矿的嵌布粒度

Table 2 Particle size distribution of cassiterite, copper mineral aggregates, sphalerite and pyrite

粒级/mm	锡石		铜矿物集合体		闪锌矿		黄铁矿	
	含量/%	累计/%	含量/%	累计/%	含量/%	累计/%	含量/%	累计/%
-1.168+0.833			1.67	1.67			1.02	1.02
-0.833+0.589			3.74	5.41			2.23	3.25
-0.589+0.417	0.45	0.45	6.95	12.36	0.46	0.46	5.46	8.71
-0.417+0.295	3.32	3.77	7.64	20.00	5.96	6.42	7.69	16.40
-0.295+0.208	4.65	8.42	8.63	28.63	6.02	12.44	12.24	28.64
-0.208+0.147	8.25	16.67	12.45	41.08	7.49	19.93	13.64	42.28
-0.147+0.104	13.51	30.18	13.28	54.36	9.88	29.81	12.62	54.90
-0.104+0.074	16.95	47.13	13.81	68.17	16.59	46.40	12.25	67.15
-0.074+0.043	17.71	64.84	12.55	80.72	19.25	65.65	11.37	78.52
-0.043+0.020	17.41	82.25	7.99	88.71	18.20	83.85	7.11	85.63
-0.020+0.015	7.72	89.97	4.46	93.17	8.25	92.10	6.46	92.09
-0.015+0.010	6.22	96.19	4.24	97.41	5.25	97.35	4.85	96.94
-0.010	3.81	100.0	2.59	100.0	2.65	100.0	3.06	100.0
颗粒数*	114 919		72 335		32 413		54 786	

注:*单位为颗。

表 3　锡石的解离特征

Table 3　Liberation degree of cassiterite at different grinding fineness

磨矿细度(−0.074 mm)/%	单体/%	连生体/%						颗粒数
		与硫化物	与脉石裸露连生				脉石包裹	
			＞3/4	＞1/2～3/4	＞1/4～1/2	≤1/4		
50	60.94	6.83	7.10	5.90	4.84	8.27	6.12	4 540
60	67.75	3.55	6.52	4.90	4.11	7.75	5.42	4 671
70	73.67	2.77	6.21	3.69	3.05	5.77	4.84	5 039
80	82.78	1.96	2.85	2.69	2.75	4.50	2.47	4 183

表 4　铜矿物集合体的解离特征

Table 4　Liberation degree of copper mineral aggregates at different grinding fineness

磨矿细度(−0.074 mm)/%	单体/%	连生体/%								颗粒数
		与闪锌矿	与黄铁矿	与锡石	与脉石裸露连生				脉石包裹	
					＞3/4	＞1/2～3/4	＞1/4～1/2	≤1/4		
50	64.47	6.73	5.73	2.39	4.09	2.13	3.87	4.58	6.01	2 976
60	71.89	5.08	4.93	2.04	3.56	1.80	2.16	3.06	5.48	2 991
70	79.76	3.37	2.73	1.73	3.02	1.41	1.63	2.32	4.03	3 337
80	84.17	2.16	2.01	1.44	2.37	1.32	1.16	2.04	3.33	2 835

表 5　闪锌矿的解离特征

Table 5　Liberation degree of sphalerite at different grinding fineness

磨矿细度(−0.074 mm)/%	单体/%	连生体/%						颗粒数
		与黄铜矿	与黄铁矿	与锡石	与脉石裸露连生		脉石包裹	
					≥1/2	＜1/2		
50	50.66	16.16	5.84	1.01	7.76	9.71	8.86	3 291
60	57.36	14.37	4.62	0.67	7.46	9.10	6.42	3 199
70	62.41	13.71	4.02	0.23	6.84	8.02	4.77	2 842
80	68.27	11.72	3.78	0.13	6.54	6.20	3.36	1 735

表 6　黄铁矿的解离特征

Table 6　Liberation degree of pyrite at different grinding fineness

磨矿细度(−0.074 mm)/%	单体/%	连生体/%								颗粒数
		与黄铜矿	与锡石	与闪锌矿	与脉石裸露连生				脉石包裹	
					＞3/4	＞1/2～3/4	＞1/4～1/2	≤1/4		
50	61.16	6.49	4.18	2.34	1.37	3.39	4.05	7.16	9.86	2 563
60	70.54	4.37	3.56	1.62	1.30	2.59	3.48	5.12	7.42	2 758
70	80.54	2.85	1.05	1.35	1.12	2.17	2.41	3.28	5.23	2 759
80	83.47	2.51	0.72	0.83	0.97	1.73	1.82	3.21	4.74	2 042

度很难实现二者的充分解离，需要对硫化物混合富集产物进行再磨。各矿物被脉石包裹的占比整体不高，连生体以裸露连生为主，具备分选回收的基础条件。

相比于传统人工镜下统计，MCPAS 智能识别系统可以处理大量矿物颗粒，本次研究单组样品统计颗粒数最高超过 11 万颗，统计样本规模远大于人工统计，有效降低抽样带来的统计误差。但该识别方法仍然高度依赖光片制样质量以及矿物光学反射特征，对于反射光学特征高度近似的矿物，识别精度存在一定局限。

5　结论

1）矿物特征参数分析系统 MCPAS 融合 HSV 色彩阈值分割与深度学习窗口多头自注意力机制，针对本矿石可以完成锡石、黄铜矿、闪锌矿、黄铁矿、蓝辉铜矿、铜蓝等金属矿物的智能识别。系统可实现大批量矿物颗粒统计，有效降低传统人工镜下统计带来的主观误差与抽样偏差，为工艺矿物学嵌布粒度、解离度的测定提供高效技术手段。

2)该铜锡多金属矿主要回收元素为铜、锡,伴生锌。矿石中锡石嵌布粒度粗细悬殊,存在大量-0.020 mm粒级的微细粒;铜矿物集合体整体粒度较粗;闪锌矿整体粒度偏细。在-0.074 mm粒级含量占60%的磨矿细度条件下,铜矿物集合体单体解离度为71.89%,脉石包裹体占比仅为5.48%;闪锌矿单体解离度偏低,部分与黄铜矿连生产出,仅依靠提高磨矿细度难以实现充分解离。矿石中包裹体占比不高,连生体部分以裸露连生为主,具备分选回收的基础条件。

3)锡石、蓝辉铜矿、铜蓝性脆易碎,磨矿易发生过粉碎,不宜采用强磨矿制度。结合嵌布特征与解离测试结果,推荐选矿工艺:在-0.074 mm粒级含量占60%的磨矿细度条件下优先分选已单体解离铜矿物,得到高品质铜精矿;选铜尾矿将全部硫化物富集后进行再磨和分选作业,分别产出另一部分铜精矿、锌精矿与硫精矿;浮选尾矿采用重选回收锡石,细粒级锡石辅以浮选回收。

参考文献

[1] 肖仪武. 选矿工艺矿物学[M]. 北京:科学出版社,2020.
Xiao Yiwu. Process mineralogy[M]. Beijing: Science Press, 2020.

[2] 周乐光. 工艺矿物学[M]. 2版. 北京:冶金工业出版社,2002.
Zhou Leguang. Process mineralogy[M]. 2nd ed. Beijing: Metallurgical Industry Press, 2002.

[3] 肖仪武. 中国选矿工艺矿物学发展历程、研究现状与展望[J]. 有色金属(选矿部分),2019(5):6-8.
Xiao Yiwu. Development history, research status and outlook of process mineralogy in China[J]. Nonferrous Metals (Mineral Processing Section), 2019(5): 6-8.

[4] 潘兆橹. 结晶学及矿物学:下册[M]. 3版. 北京:地质出版社,1994.
Pan Zhaolu. Crystallography and mineralogy: Volume Ⅱ[M]. 3rd ed. Beijing: Geological Publishing House, 1994.

[5] 肖仪武,叶小璐,冯凯,等. "四稀"金属矿工艺矿物学研究技术现状与展望[J]. 矿冶,2022,31(3):6-13.
Xiao Yiwu, Ye Xiaolu, Feng Kai, et al. Current situation and prospect of "Four Rare" process mineralogy research technology[J]. Mining and Metallurgy, 2022, 31(3): 6-13.

[6] 肖仪武,方明山,付强,等. 工艺矿物学研究的新技术与新理念[J]. 矿产保护与利用,2018,38(3):49-54.
Xiao Yiwu, Fang Mingshan, Fu Qiang, et al. New techniques and concepts in process mineralogy[J]. Conservation and Utilization of Mineral Resources, 2018, 38(3): 49-54.

[7] 周开军,桂卫华,朱红求. 矿物浮选泡沫图像分割参数的最优性分析[J]. 华中科技大学学报(自然科学版),2013,41(增刊1):432-435.
Zhou Kaijun, Gui Weihua, Zhu Hongqiu. Parameter optimality analysis for mineral floatation froth image segmentation[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2013, 41(S1): 432-435.

[8] 牛福生,张悦,聂轶苗. 图像处理技术在工艺矿物学研究中的应用[J]. 金属矿山,2010,39(5):92-95,103.
Niu Fusheng, Zhang Yue, Nie Yimiao. Applications of image processing techniques in process mineralogy[J]. Metal Mine, 2010, 39(5): 92-95, 103.

[9] Dias N M P, Gonçalves D, Leite W C, et al. Morphological characterization of soil clay fraction in nanometric scale[J]. Powder Technology, 2013, 241: 36-42.

[10] Kim S, Ree Jinhan. Quantification of the spatial distribution of mineral phases and grains in rock using a 2-D multiple-area density map technique[J]. Tectonophysics, 2012, 522/523: 176-186.

[11] Kistner M, Jemwa G T, Aldrich C. Monitoring of mineral processing systems by using textural image analysis[J]. Minerals Engineering, 2013, 52: 169-177.

[12] 李洪艳,曹建荣,谈文婷,等. 图像分割技术综述[J]. 山东建筑大学学报,2010,25(1):85-89,93.
Li Hongyan, Cao Jianrong, Tan Wenting, et al. Review of image segmentation technology[J]. Journal of Shandong Jianzhu University, 2010, 25(1): 85-89, 93.

[13] 徐丽燕,刘复昌,曹国,等. 基于边缘流与区域归并的彩色图像分割方法[J]. 光电子·激光,2011,22(10):1582-1587.
Xu Liyan, Liu Fuchang, Cao Guo, et al. Color image segmentation algorithm based on edgeflow and region merging[J]. Journal of Optoelectronics·Laser, 2011, 22(10): 1582-1587.

[14] 张建明,张菊,王娟. 基于梯度修正和区域融合的分水岭分割算法[J]. 计算机应用,2011,31(2):369-371.
Zhang Jianming, Zhang Ju, Wang Juan. Watershed segmentation algorithm based on gradient modification and region merging[J]. Journal of Computer Applications, 2011, 31(2): 369-371.

[15] 陈丽芳. 融合改进分水岭和区域生长的彩色图像分割方法[J]. 计算机工程与科学,2013,35(4):93-98.
Chen Lifang. Color image segmentation by combining improved watershed and region growing[J]. Computer

Engineering & Science, 2013, 35(4): 93-98.

[16] 黄永进, 何剑锋, 李卫东, 等. 基于改进Swin-Transformer模型的铜矿X射线图像分类研究[J]. 有色金属(选矿部分), 2024(6): 116-124.
Huang Yongjin, He Jianfeng, Li Weidong, et al. Research on copper ore X-ray image classification based on improved Swin-Transformer model[J]. Nonferrous Metals (Mineral Processing Section), 2024(6): 116-124.

[17] 张臻悦, 蒋灵, 郭文达, 等. 智能技术在矿物加工领域中的应用进展[J]. 有色金属(选矿部分), 2023(6): 1-8, 18.
Zhang Zhenyue, Jiang Ling, Guo Wenda, et al. Application progress of intelligent technology in mineral processing field[J]. Nonferrous Metals (Mineral Processing Section), 2023(6): 1-8, 18.

[18] 司佳, 陈思平, 袁洲, 等. 基于图像识别与生成技术的人工智能技术应用[J]. 科技资讯, 2023, 21(22): 47-50.
Si Jia, Chen Siping, Yuan Zhou, et al. Application of artificial intelligence technology based on image recognition and generation technology[J]. Science & Technology Information, 2023, 21(22): 47-50.

[19] 胡雅祺, 孔静, 李宇恒, 等. 基于深度学习的图像识别技术在选矿中的应用进展[J]. 矿冶, 2024, 33(1): 131-140.
Hu Yaqi, Kong Jing, Li Yuheng, et al. Progress on the application of image recognition technology based on deep learning in mineral processing[J]. Mining and Metallurgy, 2024, 33(1): 131-140.

[20] 付文博, 孙涛, 梁藉, 等. 深度学习原理及应用综述[J]. 计算机科学, 2018, 45(增刊1): 11-15, 40.
Fu Wenbo, Sun Tao, Liang Ji, et al. Review of principle and application of deep learning[J]. Computer Science, 2018, 45(S1): 11-15, 40.

[21] 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20-36.
Zheng Yuanpan, Li Guangyang, Li Ye. Survey of application of deep learning in image recognition[J]. Computer Engineering and Applications, 2019, 55(12): 20-36.

[22] 邱俊航. 基于人工智能算法的图像识别技术分析[J]. 数字通信世界, 2024(12): 25-27.
Qiu Junhang. Research on graphics and image processing technology based on artificial intelligence[J]. Digital Communication World, 2024(12): 25-27.

[23] 孙传尧, 周俊武, 贾木欣, 等. 基因矿物加工工程研究[J]. 有色金属(选矿部分), 2018(1): 1-7.
Sun Chuanyao, Zhou Junwu, Jia Muxin, et al. Research on genetic mineral processing engineering[J]. Nonferrous Metals (Mineral Processing Section), 2018(1): 1-7.

[24] Liu Ze, Lin Yutong, Cao Yue, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]// 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, Canada. IEEE, 2021: 9992-10002.

[25] Song Wei, Zheng Nan, Liu Xiangchun, et al. An improved U-Net convolutional networks for seabed mineral image segmentation[J]. IEEE Access, 2019, 7: 82744-82752.

[26] Zhang Wei, Borji A, Wang Zhou, et al. The application of visual saliency models in objective image quality assessment: a statistical evaluation[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(6): 1266-1278.

[27] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer, 2015: 234-241.

[28] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.

[29] Zhao Hengshuang, Shi Jianping, Qi Xiaojuan, et al. Pyramid scene parsing network[PP/OL]. V2. arXiv (2017-04-27) [2025-09-29]. https://doi.org/10.48550/arXiv.1612.01105.

（本文编辑　刘水红）