



基于密度感知引导的煤泥浮选泡沫分割方法

陈贵震 王红艳 刘鑫 熊峰 邹国锋 代伟

Coal Flotation Foam Segmentation Method Based on Density-aware Guidance

CHEN Gui-Zhen, WANG Hong-Yan, LIU Xin, XIONG Feng, ZOU Guo-Feng, DAI Wei

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250607>

您可能感兴趣的其他文章

基于序列注意力和局部相位引导的骨超声图像分割网络

Bone Ultrasound Segmentation Network Based on Sequential Attention and Local Phase Guidance

自动化学报. 2024, 50(5): 970–979 <https://doi.org/10.16383/j.aas.c210298>

基于WCGAN的矿物浮选泡沫图像光照不变颜色提取

WCGAN-based Illumination-invariant Color Measuring of Mineral Flotation Froth Images

自动化学报. 2022, 48(9): 2301–2315 <https://doi.org/10.16383/j.aas.c190330>

基于多节点拓扑重叠测度高阶MRF模型的图像分割

Image Segmentation Based on Higher-order MRF Model With Multi-node Topological Overlap Measure

自动化学报. 2022, 48(5): 1353–1369 <https://doi.org/10.16383/j.aas.c190780>

数据与模型联合驱动的陶瓷材料晶粒分割

Grain Segmentation of Ceramic Materials Using Data-driven Jointing Model-driven

自动化学报. 2022, 48(4): 1137–1152 <https://doi.org/10.16383/j.aas.c200277>

基于结构频谱感知框架的配电网点云语义分割

Semantic Segmentation of Distribution Network Point Clouds Based on a Structure Spectrum-Aware Framework

自动化学报. 2026, 52(4): 833–845 <https://doi.org/10.16383/j.aas.c250540>

视觉Transformer研究的关键问题: 现状及展望

Key Problems and Progress of Vision Transformers: The State of the Art and Prospects

自动化学报. 2022, 48(4): 957–979 <https://doi.org/10.16383/j.aas.c220027>

基于密度感知引导的煤泥浮选泡沫分割方法

陈贵震¹ 王红艳¹ 刘鑫¹ 熊峰¹ 邹国锋² 代伟¹

摘 要 针对浮选精煤泡沫分割中因低质图像数据导致的目标漏检及误分割问题, 提出一种基于密度感知引导的煤泥浮选泡沫分割方法. 首先, 构建跨尺度区域密度感知模块, 设计层次化密度估计子模块提取多尺度差异化区域密度信息, 并提出基于全局语义引导的跨尺度聚合方式, 融合生成具有区域差异感知能力的密度引导表征. 其次, 设计基于密度引导的分支增强模块, 建立基于分布感知的动态密度注意力机制, 构成以密度分布为先验来动态调节双分支空间特征响应的增强策略, 降低泡沫漏检率. 最后, 设计基于密度引导的互信息约束优化模块, 提出以互信息最大化为目标的语义耦合策略, 形成强化密度与分割表征间统计依赖的联合优化方法, 提升泡沫边界的分割判别能力. 在两个实际浮选泡沫数据集上的实验结果表明, 所提方法有效提升了泡沫分割性能.

关键词 浮选精煤泡沫; 图像分割; 密度感知; 动态密度注意力; 互信息约束

引用格式 陈贵震, 王红艳, 刘鑫, 熊峰, 邹国锋, 代伟. 基于密度感知引导的煤泥浮选泡沫分割方法. 自动化学报, 2026, 52(7): 1477–1490

DOI 10.16383/j.aas.c250607 **CSTR** 32138.14.j.aas.c250607

Coal Flotation Foam Segmentation Method Based on Density-aware Guidance

CHEN Gui-Zhen¹ WANG Hong-Yan¹ LIU Xin¹ XIONG Feng¹ ZOU Guo-Feng² DAI Wei¹

Abstract To address the problems of missed detection and mis-segmentation of targets in clean coal flotation foam segmentation caused by low-quality image data, this paper proposes a coal flotation foam segmentation method based on density-aware guidance. First, a cross-scale regional density perception module is constructed, in which a hierarchical density estimation submodule is designed to extract multi-scale differential regional density information. Furthermore, a global semantic-guided cross-scale aggregation approach is proposed to integrate and generate density-guided representations with regional difference awareness capability. Second, a density-guided branch enhancement module is designed, in which a distribution-aware dynamic density attention mechanism is established to construct an enhancement strategy that uses density distribution as a prior to dynamically regulate the spatial feature responses of dual branches, thereby reducing the missed detection rate of foam. Finally, a density-guided mutual information constraint optimization module is designed, introducing a semantic coupling strategy based on mutual information maximization to jointly optimize and strengthen the statistical dependence between density and segmentation representation, improving the discriminative ability of foam boundary segmentation. Experimental results on two real flotation foam datasets demonstrate that the proposed method effectively improves foam segmentation performance.

Keywords clean coal flotation foam; image segmentation; density-aware; dynamic density attention; mutual information constraint

Citation Chen Gui-Zhen, Wang Hong-Yan, Liu Xin, Xiong Feng, Zou Guo-Feng, Dai Wei. Coal flotation foam segmentation method based on density-aware guidance. *Acta Automatica Sinica*, 2026, 52(7): 1477–1490

收稿日期 2025-11-07 录用日期 2026-05-13

Manuscript received November 7, 2025; accepted May 13, 2026
国家自然科学基金 (62373361, 52504313), 江苏省研究生科研与实践创新计划 (KYCX25_2842), 江苏省杰出青年基金 (BK20240102), 中国矿业大学研究生创新计划 (2025WLKXJ106) 资助

Supported by National Natural Science Foundation of China (62373361, 52504313), Postgraduate Research & Practice Innovation Program of Jiangsu Province (KYCX25_2842), Distinguished Young Scholars of Jiangsu Province (BK20240102), and Graduate Innovation Program of China University of Mining and Technology (2025WLKXJ106)

本文责任编辑 徐昕

Recommended by Associate Editor XU Xin

1. 中国矿业大学信息与工程学院 徐州 221116 2. 山东理工大学电气与电子工程学院 淄博 255049

1. School of Information and Control Engineering, China Uni-

煤泥浮选是一种基于矿物表面疏水性差异, 实现煤与杂质分离的选矿技术^[1]. 在浮选过程中, 精煤灰分作为衡量浮选效果和产品质量的关键指标^[2–3], 对生产具有重要意义. 然而, 目前工业现场主要依赖人工化验获取浮选精煤灰分值, 存在明显的滞后性, 难以满足浮选过程的实时调控需求^[4–6]. 研究表明, 浮选精煤泡沫的形态及分布特征与精煤灰分之间存在强相关性, 其动态变化能够一定程度上反映

versity of Mining and Technology, Xuzhou 221116 2. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049

灰分变化^[7-8]。因此,快速、准确地获取泡沫图像中的关键特征,对实现精煤灰分的实时预测具有重要意义。

当前研究主要依托图像分割方法^[9-12]提取泡沫的关键形态分布特征,这些方法大致可分为传统图像分割方法和基于深度学习的分割方法两类。传统图像分割方法主要依赖图像的灰度、纹理或边缘等底层视觉特征,通过设定规则或构建能量函数实现前景与背景的分离。例如,文献[13]通过直方图均衡化提高图像对比度,再通过阈值分割提取泡沫轮廓,以此获取泡沫形状及粒度分布等信息。不同于分割完整泡沫的思路,文献[14]为简化分割过程并提高适应性,提出一种基于泡沫高光分析的粒度评估方法。该方法依据泡沫高光与自身面积的强相关性,通过自适应阈值分割高光区域,实现对泡沫粒度的有效评估。前述基于阈值的分割方法主要依赖像素的独立强度信息进行判断,在泡沫粘连情况下难以精准分割。为此,Jahedsaravani等^[15]引入分水岭算法,该算法将图像梯度视为一种拓扑地貌,通过识别不同泡沫之间的边界,从结构上有效切分粘连对象。文献[16]进一步通过优化内部标记精度与外部边缘完整性对分水岭算法进行改进,实现复杂情况下的泡沫分割。此类方法虽具有较高的计算效率,但在实际浮选过程中易受光照不均与噪声干扰影响,导致分割精度难以满足应用需求。

相较于传统图像分割方法,基于深度学习的分割方法在复杂视觉任务^[17]中表现出较强的抗干扰能力。根据目标区分精度的不同,这类方法可分为语义分割^[18-24]与实例分割^[25-34]两类。语义分割旨在对图像中每个像素点进行类别标注。例如,文献[22]提出的 SCTNet 方法,通过引入 Transformer 建模全局上下文语义信息,以增强像素级语义特征的表达能力;为缓解注意力机制在大规模像素建模中的计算开销,文献[23]引入状态空间模型,将 Vision Mamba 融入编码-解码结构中,在保持线性计算复杂度的同时提升了全局语义建模能力;为进一步兼顾全局语义建模能力与多尺度特征表达,文献[24]提出融合注意力机制与状态空间模型的方法,实现语义信息的高效统一建模。语义分割仅进行像素级的类别标注,而实例分割则在其基础上进一步区分同一类别中不同目标个体,因而更适用于目标边界贴合的泡沫分割任务。

根据技术路线的差异,实例分割方法又可划分为两阶段实例分割和单阶段实例分割两大类。两阶段实例分割方法中的目标定位和掩码生成具有顺序依赖性。例如,文献[25]提出的 Mask R-CNN 方法,

其先通过区域提议网络(region proposal network, RPN)生成候选目标框,再对每个候选框进行特征对齐与分类回归,最后生成目标掩码;文献[26]所提 Cascade Mask R-CNN,在 Mask R-CNN 基础上将检测与掩码生成阶段拓展为多个级联结构,使每个阶段在更高的 IoU 阈值下对候选框进行精细化处理,从而提升整体分割性能;为进一步改善 Cascade Mask R-CNN 在不同阶段间掩码信息流传递不佳的问题,文献[27]提出 Hybrid Task Cascade 模型,引入跨阶段传递机制,增强语义联系,并通过交替执行边界框回归与掩码预测,实现任务间的深度融合;为进一步提升检测对分割任务的引导作用,文献[28]提出 Mask DINO 方法,基于 DINO 的 Transformer 框架引入掩码预测分支,通过共享查询向量实现目标检测与实例分割的端到端统一建模;针对实时性要求,文献[29]构建基于 Transformer 的端到端轮廓演化机制,利用子轮廓解耦与细粒度分布细化技术,提升推理速度。两阶段实例分割方法因引入候选框机制和多阶段精细化处理,通常具有更高的分割精度,但其多步骤结构也导致推理速度较慢,实际应用中需权衡精度与效率。

相较于两阶段方法,单阶段实例分割方法跳过显式的候选框生成步骤,将目标检测与掩码生成任务并行处理,因而具有更高的运算效率。例如,文献[30]提出的 EmbedMask 方法在 FCOS 检测网络的基础上,同时预测候选框及其嵌入向量,并通过像素级嵌入进行聚类匹配,在保证分割精度的同时提升了推理速度;文献[31]提出的 YOLACT 方法基于 RetinaNet 检测框架,通过预测每个实例对应的掩码加权系数与共享的全局掩码特征,直接生成实例掩码,避免了 RoI Align 对局部特征图的复杂提取过程,结构更加轻量,实现实时分割;在单阶段范式的持续演进中,文献[32]提出的 SimCIS 方法,引入懒惰查询预对齐与虚拟查询重放机制,通过强化特征对齐解决了持续学习问题;在通用分割领域,文献[33]提出的 FastSAM 方法,将 SAM^[34]重构为单阶段实例分割范式,利用全卷积架构实现快速的掩码生成与提示引导选择。单阶段实例分割方法通过并行化处理,实现高效推理,为浮选精煤泡沫图像的实时分割提供了可行方案。

然而,受工业现场环境及泡沫动态变化影响,采集到的泡沫图像存在噪声干扰、成像模糊及分辨率受限等低质量问题。此类成像退化因素导致单阶段实例分割方法面临两个主要问题:1)在泡沫密集区域,小尺度泡沫受噪声与分辨率限制影响,纹理细节被掩盖、显著性下降,在特征提取阶段易被忽

略, 导致漏检率高; 2) 在泡沫稀疏区域, 大尺度泡沫受成像模糊及附着颗粒影响, 边界清晰度下降, 在掩码预测阶段易出现边界定位偏差, 导致误分割. 此类问题与泡沫的空间密度分布紧密相关. 因此, 通过引入泡沫的空间密度分布作为先验信息, 驱动模型主动感知并优化不同密度区域的特征响应, 可提升低质图像数据条件下模型对泡沫复杂结构的表征与判别能力.

综上, 为解决低质图像数据条件下的浮选泡沫分割问题, 提出一种基于密度感知引导的煤泥浮选泡沫分割方法, 由多尺度特征提取模块、跨尺度区域密度感知模块、基于密度引导的分支增强模块以及互信息约束优化模块组成. 主要贡献如下:

1) 针对泡沫密度分布表征不足问题, 构建跨尺度区域密度感知模块, 在多尺度特征提取模块构建的特征空间中引入所提层次化密度估计子模块, 提取多尺度差异化区域密度信息, 并以全局语义引导跨尺度密度信息自适应融合, 生成具有区域差异感知能力的密度引导表征;

2) 针对泡沫密集区域中小尺度目标漏检问题, 设计基于密度引导的分支增强模块, 建立动态密度注意力机制将密度表征映射为空间加权因子, 融合至检测分支与原型分支, 以密度先验动态调整区域

特征响应, 从而缓解目标漏检问题;

3) 针对泡沫稀疏区域中大尺度目标误分割问题, 设计基于密度引导的互信息约束优化模块, 通过量化密度表征与预测掩码之间的互信息, 并以此构建特征一致性正则项, 与主分割目标进行联合优化, 提升泡沫边界的分割判别能力.

1 浮选精煤泡沫形成机理及其图像特征分析

煤泥浮选作业中, 浮选精煤泡沫的形成原理如图 1(a) 所示. 来自上游选煤流程的含煤矿浆与起泡剂、捕收剂充分混合后, 经输送泵泵入浮选机. 浮选机底部通过供气系统注入空气, 并借助叶轮将气体打散成细微气泡, 使其与矿浆充分接触. 在起泡剂的作用下, 气泡表面形成稳定的液膜结构, 具备良好的颗粒附着能力. 疏水性的精煤颗粒在捕收剂的作用下吸附于气泡表面, 并随气泡上浮至液面, 聚集成浮选精煤泡沫层.

浮选精煤泡沫的生成过程本质上是一个由气、液、固多因素耦合驱动的动态系统^[35]. 受充气量、矿浆浓度和加药量等因素影响, 泡沫本身会呈现出复杂空间分布特征, 如图 1(b) 所示. 然而, 在实际煤

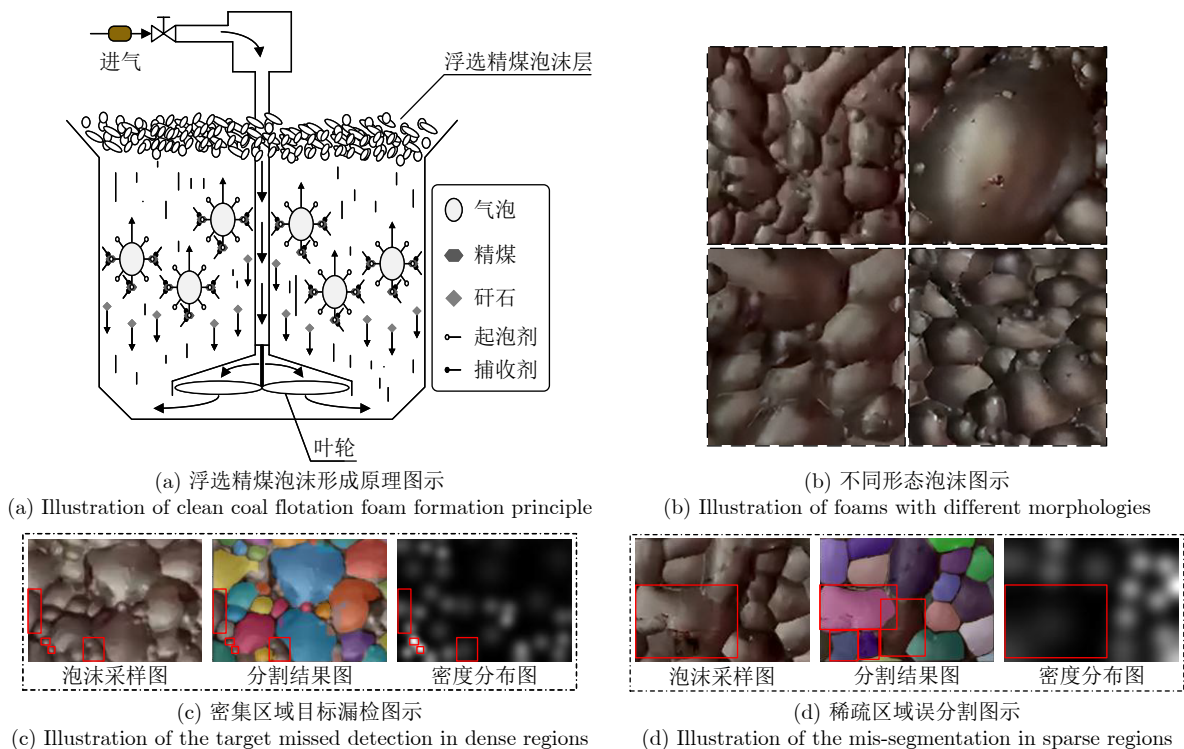


图 1 浮选精煤泡沫形成原理、图像特征及分割特性分析图

Fig.1 Analysis diagram of formation principle, image features, and segmentation characteristics of clean coal flotation foam

泥浮选生产现场, 图像采集系统需在长期连续运行与工程经济性约束下工作, 受成像距离较远、泡沫持续高速运动以及光照条件不稳定等因素共同影响, 现场采集的浮选泡沫图像普遍存在分辨率受限、成像模糊及噪声干扰等低质量成像问题. 这类成像退化因素会导致泡沫边界对比度降低、局部纹理细节丢失, 并在不同空间密度区域表现出差异化影响: 在泡沫密集区域, 小尺度泡沫的显著性进一步下降, 易在特征提取阶段被忽略, 导致目标漏检, 如图 1(c) 所示; 在泡沫稀疏区域, 大尺度泡沫的边界清晰度降低, 易在掩码预测阶段产生边界偏差, 引发误分割问题, 如图 1(d) 所示. 因此, 如何在低质图像条件下有效刻画泡沫的复杂空间分布特征, 并提升模型对密集与稀疏区域的差异化感知能力, 是本文重点关注和解决的问题.

2 基于密度感知引导的煤泥浮选泡沫分割网络

鉴于煤泥浮选现场泡沫图像采集存在分辨率受限、成像模糊及噪声干扰等低质成像问题, 传统单阶段实例分割方法在泡沫密集与稀疏区域性能退化. 为提升模型在低质成像条件下对泡沫复杂空间分布特征的感知与判别能力, 本文利用煤泥浮选生产过程中采集的浮选泡沫图像, 结合泡沫的空间密

度分布特征, 建立如图 2 所示的煤泥浮选泡沫分割网络架构. 该网络主要由多尺度特征提取模块、跨尺度区域密度感知模块、基于密度引导的分支增强模块与互信息约束优化模块组成.

泡沫分割过程中, 将采集到的浮选精煤泡沫图像作为网络输入, 先经多尺度特征提取模块, 获取图像中不同层次的语义与结构特征; 然后, 利用跨尺度区域密度感知模块对提取到的特征图进行空间密度建模, 生成具有泡沫分布差异信息的区域密度图; 再以该密度图为分布先验, 输入基于密度引导的分支增强模块, 引导网络根据泡沫分布状态对不同区域特征进行差异化增强, 提升模型在泡沫密集与稀疏区域的判别能力; 最后, 通过互信息约束优化模块优化密度表征与实例掩码间的语义一致性, 提升模型对复杂结构的理解能力与整体分割精度.

2.1 多尺度特征提取模块

泡沫多尺度特征提取模块用于构建泡沫图像的层级特征表示, 该模块由 ResNet 主干网络和特征金字塔网络 (feature pyramid network, FPN) 两部分构成. 如图 2 所示, 输入图像首先经 ResNet 的多个卷积块, 依次提取初步特征图 $Rn1$ 至 $Rn5$, 分别对应从浅层到深层的不同语义与结构特征. 然后, FPN 模块以特征图 $Rn5$ 为起点, 构建自顶向下的




图 2 基于密度感知引导的煤泥浮选泡沫分割网络整体架构图

Fig. 2 Overall architecture diagram of coal flotation foam segmentation network based on density-aware guidance

多尺度融合路径. 具体而言, 特征 $Rn5$ 经过 1×1 卷积生成特征图 P_5 , P_5 上采样后与 $Rn4$ 经过 1×1 卷积所得特征图相加, 得到融合后的特征图 P_4 , P_4 再以相同方式构建特征图 P_3 . 同时, 为增强网络对大尺度结构信息的感知能力, P_5 通过 3×3 卷积进行连续下采样, 得到 P_6 与 P_7 两个更深层的特征图. 具体公式如下:

$$P_i = \begin{cases} Conv_{3 \times 3}(P_{i-1}), & i = 6, 7 \\ Conv_{1 \times 1}(Rn_i), & i = 5 \\ Conv_{1 \times 1}(Rn_i) + f_{up}(P_{i+1}), & i = 3, 4 \end{cases} \quad (1)$$

其中, $Conv_{1 \times 1}(\cdot)$ 、 $Conv_{3 \times 3}(\cdot)$ 分别表示 1×1 和 3×3 卷积操作, 用于通道调整与特征转换; $f_{up}(\cdot)$ 表示上采样函数, 本文中采用双线性插值以保持特征尺寸一致性.

由于煤泥浮选泡沫目标在工业现场图像中存在显著的尺度差异, 且受分辨率受限、成像模糊等低质成像因素影响, 特征提取层既需具备提取高层语义信息的能力, 又需在复杂成像条件下保留一定的空间分辨率, 以确保对小尺度泡沫目标的稳定感知能力. ResNet 所具有的稳定特征传递机制与清晰的层级特征表达, 有利于在噪声干扰与细节退化条件下实现深、浅特征的协同提取与鲁棒融合. 同时, 相较于近年来计算结构更为复杂的 Transformer 类主干网络, ResNet 在模型规模与计算复杂度方面具有更好的可控性, 更有利于在算力受限的工业环境中实现稳定、实时的推理任务. 因此, 本文在整体架构设计中选用 ResNet 作为主干网络, 以在低质量成像条件下兼顾分割性能与实时性要求.

2.2 跨尺度区域密度感知模块

浮选泡沫图像中密集与稀疏区域在纹理及边界特征上差异显著. 传统的特征金字塔网络虽能整合多尺度语义信息, 但缺乏对区域密度差异的感知, 无法根据泡沫局部密集程度自适应调整特征响应. 为此, 本文提出跨尺度区域密度感知模块, 通过多尺度特征图的密度建模与信息融合, 显式地学习并整合泡沫的区域密度分布特征, 有效表征密集与稀疏区域的空间差异. 如图 2 所示, 其主要由密度估计子模块 MP (图 3 中实线框) 与自适应权重生成模块 AW (图 3 中虚线框) 两部分组成, 其结构如图 3 所示.

密度估计子模块部署于特征金字塔各输出层, 用于提取多尺度下的局部密度信息. 具体而言, 每个特征图 P_i 经对应密度估计子模块处理后, 得到单通道的密度预测图 $D'_i \in \mathbf{R}^{1 \times H_i \times W_i}$, H_i 、 W_i 分别为对应密度图的高和宽, 其计算过程如下:




图 3 跨尺度区域密度感知模块结构

Fig.3 Structure of cross-scale regional density-aware module

$$D'_i = Conv_{1 \times 1}(\psi(Conv_{3 \times 3}(P_i))), \quad i = 3, 4, 5, 6, 7 \quad (2)$$

其中, $\psi(\cdot)$ 表示 ReLU 非线性激活函数.

随后, 为实现多尺度密度信息的统一融合, 需将所得密度图上采样至统一空间尺度 $H \times W$, 上采样处理后的结果记为:

$$\bar{D}_i = f_{up}(D'_i), \quad i = 3, 4, 5, 6, 7 \quad (3)$$

其中, $\bar{D}_i \in \mathbf{R}^{1 \times H \times W}$ 为上采样后的密度图.

不同尺度特征在密度建模中的贡献存在差异, 平均融合会忽略尺度间的语义差异与响应分布, 难以充分发挥层间特征的互补作用. 为此, 提出自适应权重生成模块, 根据全局语义信息动态分配融合权重. 具体而言, 模块首先通过全局平均池化提取特征的通道级语义统计, 以整合全局响应分布并抑制局部噪声干扰. 随后, 利用两层全连接层 Fc 与 ReLU 激活函数建模通道间的非线性依赖关系, 使模型能够自适应学习不同尺度特征对密度建模的相对贡献. 最后, 经 Softmax 归一化获得融合权重, 实现多尺度密度图的加权聚合, 具体公式如下所示:

$$\begin{cases} z_i = \phi_2(\psi(\phi_1(f_{gap}(P_i)))) \\ w_i = \frac{e^{z_i}}{\sum_{j=3}^7 e^{z_j}}, \quad \hat{D} = \sum_{i=3}^7 w_i \bar{D}_i \end{cases} \quad (4)$$

其中, z_i 为各层原始权重得分; $\phi_1(\cdot)$ 、 $\phi_2(\cdot)$ 为全连接层, $\phi_1(\cdot)$ 用于压缩输入特征通道维度, $\phi_2(\cdot)$ 用于将压缩后的特征映射为原始权重得分; $f_{gap}(\cdot)$ 表示全局平均池化操作; w_i 为各层最终的融合权重; $\hat{D}$ 为最终所得统一密度表示.

综上, 本文提出的跨尺度区域密度感知模块以密度建模为基础, 并结合全局语义引导的自适应权重融合策略, 实现区域差异下的密度感知, 可提升多尺度特征间的协同建模能力与密度表征一致性.

2.3 基于密度引导的分支增强模块

在实例分割中, 检测分支主要负责目标定位与

类别判别, 原型分支侧重共享掩码特征建模. 为兼顾语义判别与空间细节, 本文采用检测与原型双分支结构^[31]. 然而, 在低质量泡沫图像中, 受小目标特征弱化及局部密度分布复杂的影响, 该结构对密集区域的表征能力受限, 易导致小尺度泡沫漏检. 基于此, 本文提出基于密度引导的分支增强模块, 在双分支输入阶段引入密度感知注意力机制. 该机制以跨尺度区域密度感知模块生成的融合密度图作为输入先验, 通过动态调节特征响应强度, 在密集区域强化不同分支之间的语义一致性和特征对齐, 该注意力结构如图 4 所示.

所提密度感知注意力机制旨在通过建模密度分布与特征激活之间的空间对应关系, 使特征权重能够根据局部密度变化实现动态调节. 为实现密度先验与多尺度特征的空间对齐, 首先依据对应特征图 P_i 的空间尺寸进行动态上采样, 以保证分辨率一致性. 然后, 为增强密度表示的局部结构感知能力, 通过 3×3 卷积进行通道扩展与邻域特征建模, 捕获密度变化的空间依赖关系. 随后, 通过 Sigmoid 激活函数将卷积输出映射至 $[0, 1]$, 以归一化响应幅值并生成空间密度注意力权重图. 最后, 将该权重图与对应特征图 P_i 逐元素相乘, 构建密度感知增强项, 并与其进行加性融合, 完成密度引导下的特征增强. 其计算过程如下所示:

$$\begin{cases} A_i = \varphi(\text{Conv}_{3 \times 3}(f_{\text{up}}(\hat{D}))) \\ P_i' = P_i + P_i \odot A_i, \quad i = 3, 4, 5, 6, 7 \end{cases} \quad (5)$$

其中, $\varphi(\cdot)$ 表示 Sigmoid 激活函数; A_i 表示空间密度注意力权重图; $\odot$ 表示逐元素乘积操作; P_i' 表示经密度注意力增强后的第 i 层金字塔输出特征图.

经密度感知注意力增强后的多尺度特征图分别输入检测分支与原型分支, 以实现目标定位与掩码建模的协同优化. 检测分支基于所有增强后的多尺度特征图进行目标检测, 密度引导机制动态调节特征响应, 以实现尺度自适应检测并提升定位鲁棒性; 原型分支以最高分辨率特征图 P_3' 为输入, 强化空




图 4 密度感知注意力结构

Fig.4 Structure of density-aware attention

间细节与边界刻画能力, 生成原型掩码特征图, 作为所有实例掩码的基础表示. 所提密度感知注意力机制利用融合密度作为结构先验, 引导模型在特征与密度之间建立响应映射, 增强密集区域的语义一致性和特征表达能力, 以缓解小尺度泡沫由于特征响应不足而引起的漏检问题.

2.4 互信息约束优化模块

在分支预测结果的基础上, 输出层依次经快速非极大值抑制 (fast NMS)、裁剪 (crop) 与阈值 (threshold) 筛选生成实例掩码. 该过程可表示为:

$$\hat{M}_k = \zeta \left(\text{Crop} \left(\sum_{j=1}^J S_{kj} Q_j \right) \right), \quad k = 1, \dots, N \quad (6)$$

其中, Q_j 为原型分支生成的第 j 个原型掩码特征; J 为原型掩码特征的总数; S_{kj} 表示经 fast NMS 筛选后的第 k 个候选实例对应的第 j 个掩码系数; N 为筛选后的候选实例数量. Q_j 与 S_{kj} 线性组合得到实例掩码的初步表示, 随后根据对应候选框进行裁剪 $\text{Crop}(\cdot)$, 再通过阈值函数 $\zeta(\cdot)$ 进行二值化, 生成最终的实例掩码 $\hat{M}_k$.

现有掩码预测逻辑依赖像素级的独立映射, 会忽视泡沫群体在空间分布上的拓扑关联, 导致模型易受噪声干扰而产生边界歧义. 基于此, 本文提出互信息约束优化模块, 建立一种从密度感知到形态重构的跨维度语义绑定机制, 将空间分布强度转化为掩码生成的结构约束先验. 根据所提模型结构, 训练过程采用以下三项损失函数对掩码进行多元优化:

掩码损失. 为衡量预测掩码与真实掩码之间的差异, 本文采用二值交叉熵损失进行计算:

$$\text{loss}_M = \frac{1}{N} \sum_{j=1}^N \text{BCE}(\hat{M}_j, M_j) \frac{\gamma}{E_j} \quad (7)$$

其中, loss_M 为掩码损失; $\hat{M}_j$ 与 M_j 分别表示第 j 个预测掩码与其对应的真值掩码; $\text{BCE}(\cdot)$ 表示交叉熵函数; E_j 为真实框的像素面积; γ 为采样缩放因子. 通过真实框面积归一化与采样补偿机制, 有效缓解不同目标尺度与样本不平衡对训练结果的影响.

密度回归损失. 该项损失衡量网络预测密度图 $\hat{D}$ 与标签密度图 D 之间的差异, 采用均方误差形式定义:

$$\text{loss}_D = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (\hat{D}_{ij} - D_{ij})^2 \quad (8)$$

其中, loss_D 表示密度回归损失. 该项损失旨在引导

模型学习图像中泡沫的密度分布规律, 通过约束预测密度图逼近真实密度图, 优化模型对泡沫分布密度的表征能力。

互信息约束损失. 为增强预测掩码与密度建模之间的关联性, 本文引入互信息约束损失. 预测掩码 $\hat{M}$ 与生成密度图 $\hat{D}$ 二者的互信息可定义为:

$$I(\hat{D}, \hat{M}) = \sum_{d \in \hat{D}} \sum_{m \in \hat{M}} p(d, m) \log \frac{p(d, m)}{p(d)p(m)} \quad (9)$$

其中, $p(d, m)$ 表示 $\hat{M}$ 与 $\hat{D}$ 的联合概率分布; $p(d)$ 、 $p(m)$ 为边缘概率分布, 二者互信息值越大则表明预测掩码与密度分布之间的相关性越强. 训练中, 采用互信息倒数作为惩罚项, 构建损失函数:

$$loss_I = \frac{1}{I(\hat{D}, \hat{M}) + \varepsilon} \quad (10)$$

其中, ε 为数值稳定常数, 用于避免分母趋近于零引发数值不稳定. 该损失的核心在于构建空间感知层面的正则化平衡. 通过惩罚预测结果中与密度先验相悖的噪声特征, 驱动模型在模糊区域进行基于密度背景的结构化推理, 利用泡沫分布规律修正单体边界偏差, 实现密度与掩码的深度统一.

基于此, 本文将上述三项损失统一为联合优化目标:

$$loss_{MDI} = loss_M + \alpha loss_D + \beta loss_I \quad (11)$$

其中, α 和 β 分别为密度回归损失与互信息约束损失的权重系数. 由于 $loss_M$ 为核心监督函数, 直接决定分割精度, 因此不引入额外权重; $loss_D$ 与 $loss_I$ 作辅助约束, 其作用需与主任务保持适度平衡, 故在训练中引入可调节的权重系数.

3 浮选精煤泡沫分割实验与结果分析

为验证所提方法的有效性, 本节在实际采集的浮选精煤泡沫数据集上开展实验研究. 主要包括消融实验与调参实验分析, 以及与主流实例分割方法的对比验证, 以全面评估所提方法的分割性能.

3.1 实验配置与数据集构建

为保证实验结果的公平与有效性, 本文所有实验均在统一的实验配置下进行. 硬件配置方面: NVIDIA RTX 3090 Ti 显卡 (24 GB 显存)、Intel i9-12900K 处理器、64 GB 内存以及 Windows 10 (64 位) 操作系统. 软件配置方面: Python 3.10、PyTorch 2.6 以及 CUDA 12.6. 模型参数配置方面: 优化器为 Adam、初始学习率为 1×10^{-4} 、权重衰

减参数为 5×10^{-4} 、批大小 (batch size) 为 8、训练轮数 (epoch) 为 200.

本文所使用的两个泡沫数据集 Froth-Plant1 和 Froth-Plant2, 分别采集自两座不同选煤厂的浮选生产现场, 涵盖不同时段工况条件, 采集装置主要包括: MV-CS050-10GC 型工业相机、MVL-KF0618M-12MPE 型镜头及 IP67DC24-30W 型补光灯, 该装置固定于浮选槽上方进行数据采集, 如图 5 所示.




图 5 浮选精煤泡沫采集现场图

Fig.5 Field image of clean coal flotation foam collection

其中, 采集 Froth-Plant1 数据集的选煤厂采用充气式浮选机, 泡沫尺寸整体偏小, 小泡沫占比更高; 采集 Froth-Plant2 数据集的选煤厂采用搅拌式浮选机, 泡沫尺寸整体偏大, 大泡沫占比更高. 同时, 由于两厂浮选入料浓度及灰分指标要求不同, 药剂配比存在差异: Froth-Plant1 中起泡剂与捕收剂配比稳定在 1 : 5 左右; Froth-Plant2 中起泡剂与捕收剂配比稳定在 1 : 8 左右. 上述设备条件与工艺参数差异, 使两数据集在泡沫尺寸分布、空间密度及形态结构等方面呈现出不同特征, 构成同类工业流程下的跨工况数据分布差异. 因此, 在上述两个数据集上的实验可用于验证本文方法在不同工况条件下的泛化性能.

采集所得图像统一缩放至 512×512 像素, 共收集 3 926 幅图像进行实验, 并由专业人员进行逐泡沫精细标注, 构建 167 950 个泡沫实例的真值标签. 然后, 利用泡沫实例标签进一步自动计算生成密度回归标签: 首先, 利用三角形重心加权方法计算每个泡沫在图像中的质心坐标 (x_r, y_r) ; 然后, 将质心坐标以冲激函数形式投影至图像平面, 形成离散点场; 最后, 将离散点场与自适应带宽的二维高斯核函数进行卷积叠加, 得到最终的密度图标签 $D(x, y)$:

$$\begin{cases} D(x, y) = \sum_{r=1}^R \delta(x - x_r, y - y_r) * G_{\sigma_r}(x, y; x_r, y_r) \\ G_{\sigma_r}(x, y; x_r, y_r) = \frac{1}{2\pi\sigma_r^2} e^{-\frac{(x-x_r)^2 + (y-y_r)^2}{2\sigma_r^2}} \end{cases} \quad (12)$$

其中, R 为单帧图像中的泡沫总数; $\delta(\cdot, \cdot)$ 为二维冲激函数; G_{σ_r} 为第 r 个泡沫质心对应的二维高斯核函数; “ $*$ ”为卷积叠加操作; σ_r 采用基于 K 近邻的自适应带宽策略计算:

$$\sigma_r = \frac{1}{K} \sum_{q=1}^K \|(x_r, y_r) - \vartheta_q(x_r, y_r)\|_2 \quad (13)$$

其中, $\vartheta_q(x_r, y_r)$ 为离第 r 个质心点最近的第 q 个质心点; K 取 3; $\|\cdot\|_2$ 表示两点之间欧氏距离. 整体数据标注过程如图 6 所示.

所构建的 Froth-Plant1 数据集, 包含 1 980 幅图像, 共 113 910 个泡沫实例; Froth-Plant2 数据集, 包含 1 946 幅图像, 共 54 040 个泡沫实例. 两个数据集均按照 8 : 1 : 1 的比例划分训练集、验证集和测试集, 进行模型训练与性能评估.

3.2 评价指标介绍

为评估本文所提方法在浮选精煤泡沫分割任务中的性能, 采用 AP (average precision)、mIoU (mean intersection over union) 和 FPS (frames per second) 三类指标进行性能分析.

AP 表示在特定 IoU 阈值下, 模型预测掩码与真实掩码的匹配准确性. 计算公式如下:

$$AP = \int_0^1 Pr(\tau) d\tau \quad (14)$$

其中, $Pr(\tau)$ 表示在召回率为 τ 时的精度值.




图 6 数据标注示意图

Fig.6 Schematic diagram of data annotation

mIoU 用于衡量模型预测掩码与真实掩码的空间重合程度, 以此反映分割边界的准确性. 该指标计算公式如下:

$$mIoU = \frac{1}{S} \sum_{s=1}^S \frac{U_s^{pr} \cap U_s^{gt}}{U_s^{pr} \cup U_s^{gt}} \quad (15)$$

其中, U_s^{pr} 和 U_s^{gt} 分别表示第 s 幅图像中预测掩码与真实掩码的区域; S 为测试图像总数.

FPS 表示模型每秒可处理的图像帧数, 用于衡量模型的推理速度. 其定义为:

$$FPS = \frac{S}{T} \quad (16)$$

其中, T 表示模型完成所有测试图像推理的总时间.

3.3 消融实验结果与分析

为验证所提各模块对泡沫分割任务的有效性, 本文以 YOLACT 网络^[31] 为基线, 在 Froth-Plant1 和 Froth-Plant2 两个数据集上设计多组消融实验. 其中跨尺度区域密度感知模块定义为 MA, 基于密度引导的分支增强模块定义为 MB, 互信息约束优化模块定义为 MC. 由于 MB 和 MC 均依赖 MA 所提供的密度特征支持, 故实验按照表 1 配置进行验证.

表 1 中, “√”表示在该实验配置中启用了对应模块, “—”表示未引入该模块. 分析表中结果可知, 当在基线基础上仅引入跨尺度区域密度感知模块时, 模型在 Froth-Plant1 的 AP 和 mIoU 指标上分别提升了 1.87% 和 1.58%、在 Froth-Plant2 的 AP 和 mIoU 指标上分别提升了 1.13% 和 0.38%. 这表明引入跨尺度区域密度感知模块, 可以使模型训练过程中关注到泡沫密度分布信息以提升分割性能. 当在此基础上分别引入基于密度引导的分支增强模块和互信息约束优化模块时, 模型性能得到了进一步的提升. 但值得注意的是, 引入基于密度引导的分支增强模块时, 模型在两个数据集的 AP 指标上得到了较大提升, 分别提升 2.70% 和 1.39%, 证明在跨尺度区域密度感知模块基础上, 引入所提基于

表 1 各模块消融实验验证结果 (%)
Table 1 Ablation experiment verification results of each module (%)

基线	MA	MB	MC	Froth-Plant1		Froth-Plant2	
				AP	mIoU	AP	mIoU
√	—	—	—	63.27	50.36	73.36	57.20
√	√	—	—	65.14	51.94	74.49	57.58
√	√	√	—	67.84	52.32	75.88	58.03
√	√	—	√	66.52	53.55	75.01	58.62
√	√	√	√	68.27	53.78	76.15	58.84

密度引导的分支增强模块可以有效解决基线模型的漏检问题, 以此提高掩码预测的准确性; 引入互信息约束优化模块时, 模型在两个数据集的 mIoU 指标上得到较大提升, 分别提升 1.61% 和 1.04%, 证明在跨尺度区域密度感知模块基础上, 引入所提互信息约束优化模块可以有效改善基线模型的边界模糊问题, 以此提升边界定位的精确性。

当同时引入跨尺度区域密度感知模块、基于密度引导的分支增强模块和互信息约束优化模块时, 模型在两个数据集的 AP 和 mIoU 性能指标上得到大幅提升. 在 Froth-Plant1 数据集上, AP 指标提升了 5.00%, mIoU 指标提升了 3.42%; 在 Froth-Plant2 数据集上, AP 指标提升了 2.79%, mIoU 指标提升了 1.64%. 证明所提三个模块协同作用, 能有效增强模型对泡沫的密度分布、小目标特征和边界精度的综合感知能力, 共同推动模型分割性能的提升。

3.4 调参实验结果与分析

由式 (11) 可知, 本文所提模型在优化过程中通过 α 与 β 两个参数对密度回归损失和互信息约束损失进行加权调节. 由于两个参数作用的辅助损失项存在耦合影响, 为确定 α 和 β 参数的最优配置, 本文对参数空间进行网格搜索, 即在 $[0.1, 1.0]$ 范围内以步长 0.1 对 α 和 β 进行联合调节, 实验结果如图 7 所示。

实验结果以二维热力图的形式呈现, 其中横轴与纵轴分别对应 α 和 β 的取值, 颜色鲜艳程度表示模型在该参数组合下的 AP 性能指标, 颜色越浅, 性能越好. 由图 7 可知, 热力图整体呈现出明显的非线性变化趋势, 进一步验证了 α 和 β 两项损失权重之间存在耦合关系, 从而印证了采用联合调优的




图 7 参数调优结果图


Fig.7 Result plot of parameter tuning

合理性。


进一步分析图中结果可知, 当 α 取值为 0.3、 β 取值为 0.8 时, 模型在 Froth-Plant1 数据集上取得最优性能. 因为适度的密度回归损失有助于增强模型感知泡沫的空间聚集特性, 提升对小目标的结构识别能力; 较高的互信息约束则增强了密度表示与掩码结构之间的语义一致性, 从而改善了边界模糊问题. 两者共同作用下, 模型在小目标识别与大目标边界定位精度方面得到兼顾, 最终实现整体性能最优. 因此, 以该参数组合作为后续实验的默认配置。

为进一步验证模型在该参数配置下不同数据集上的适应性和稳定性, 本文可视化了模型在 Froth-Plant1 和 Froth-Plant2 两个数据集上, 训练与验证过程中的 AP 和 Loss 变化曲线, 结果如图 8 所示。

分析图 8 可知, 在 Froth-Plant1 和 Froth-Plant2 两个数据集上, 模型的训练和验证过程表现出较为一致的收敛趋势. 两个数据集上的训练 Loss



(a) Froth-Plant1 数据集上训练验证曲线
(a) Training and validation curves on the Froth-Plant1 dataset



(b) Froth-Plant2 数据集上训练验证曲线
(b) Training and validation curves on the Froth-Plant2 dataset

图 8 不同数据集上模型训练验证曲线图

Fig.8 Model training and validation curves on different datasets

曲线在训练初期快速下降并趋于稳定,表明模型能够快速学习到可靠的特征表示;验证 Loss 曲线在前几个 epoch 内也同步下降,并在后期逐渐趋于平稳,说明模型可同时在验证集上保持良好的泛化能力.在 AP 曲线方面,训练 AP 曲线在前几个 epoch 内快速上升,随后逐步提升并趋于稳定,表明模型在不断迭代中能够持续提升对目标的分割能力;验证 AP 曲线在前几个 epoch 内也同步提升,随后逐步提升并稳定至较高水平,说明模型在泛化到未见样本时仍具备稳定的分割性能.

进一步分析图中曲线可知, Froth-Plant1 数据集上的训练与验证的 AP 和 Loss 曲线波动幅度相对较大.这主要由于 Froth-Plant1 数据集采集自包含更多小尺度泡沫的工况环境,使模型在训练过程中面临细粒度表征挑战.而模型在该类数据上仍表现出整体收敛趋势,证明了所提方法在复杂目标结构下的适应能力.

综上,联合调优实验验证了 α 和 β 权重系数对模型性能的影响,当 $\alpha = 0.3$ 、 $\beta = 0.8$ 时可达到最优性能,并在不同数据集上表现出一致的收敛性与良好的泛化能力.

3.5 对比实验结果与分析

为进一步验证所提方法的有效性,本文与主流的两阶段和单阶段两类实例分割方法在 Froth-Plant1 和 Froth-Plant2 数据集上开展对比实验,结果如表 2 所示.

分析表 2 可知,两阶段实例分割方法在 Froth-

Plant1 和 Froth-Plant2 两个数据集的 AP 指标上具有一定优势.原因在于,其依托候选框生成与区域特征对齐机制,能够实现较为精细的目标定位,从而获得较高的检测精度.然而,此类方法固有的多阶段串行依赖结构限制了推理过程的并行性,导致整体推理速度较低,难以满足工业浮选过程对实时性的要求.此外,基于大规模基础模型的 Grounded SAM 分割方法虽在部分场景下具备较强的语义泛化能力,但其模型结构复杂、计算开销较大,在浮选泡沫分割任务中推理效率显著受限,难以兼顾分割精度与实时性能.相比之下,本文方法在保持高效推理能力的同时,通过互信息约束策略增强了密度建模与边界预测的一致性,因而在两个数据集上均实现了最优的 mIoU 指标.

相较于两阶段方法,单阶段实例分割方法整体具有较好的实时性优势,但分割精度存在一定局限性.由实验结果可知,本文方法在 Froth-Plant1 和 Froth-Plant2 两个数据集上的 AP 和 mIoU 指标整体优于多数单阶段方法.其中, FastSAM 在 Froth-Plant1 数据集上的 AP 指标略高于本文方法,这主要是其在继承 SAM 分割范式的基础上,将任务重构为基于 CNN 的全实例检测过程,对显著泡沫区域具备更优的目标响应能力.然而,在低质浮选泡沫图像条件下,单阶段方法难以有效感知泡沫的复杂空间分布特征,面临小尺度泡沫易漏检及大尺度泡沫边界定位不准确的问题.相比之下,本文方法通过跨尺度区域密度感知与密度引导的分支增强机制,并结合互信息约束优化密度表征与实例掩码之

表 2 与主流方法的对比实验结果
Table 2 Comparative experimental results with mainstream methods

方法类别	方法名称	Froth-Plant1			Froth-Plant2		
		AP (%)	mIoU (%)	FPS	AP (%)	mIoU (%)	FPS
两阶段	Mask R-CNN ^[25]	69.30	49.48	10.6	75.70	56.66	11.3
	Cascade Mask R-CNN ^[26]	68.90	50.11	7.1	78.20	58.65	7.9
	Hybrid Task Cascade ^[27]	69.40	50.92	5.2	77.30	54.65	5.7
	Mask DINO ^[28]	67.61	53.36	10.7	72.84	54.96	12.1
	ContourFormer ^[29]	68.85	44.15	15.3	73.27	39.07	16.5
	Grounded SAM ^[34]	56.55	53.12	0.1	68.71	54.80	0.2
单阶段	EmbedMask ^[30]	61.30	45.67	18.2	75.10	51.99	19.4
	BoxInst ^[36]	64.70	45.17	15.6	71.30	55.71	16.7
	SOLO ^[37]	66.30	48.96	18.7	72.40	52.08	19.5
	SparseInst ^[38]	65.90	52.27	20.5	74.20	57.82	20.7
	SimCIS ^[32]	61.12	51.90	19.0	73.30	56.18	20.3
	FastSAM ^[33]	69.18	52.39	22.3	73.26	57.12	23.6
	YOLACT ^[31]	63.27	50.36	24.9	73.36	57.20	25.6
	本文方法	68.27	53.78	23.6	76.15	58.84	24.3

间的语义一致性,在保证较高推理效率的同时,在两个数据集上实现了更优的 AP 与 mIoU 综合性能。

为更直观地展示本文方法相较于单阶段实例分割方法的优势,在 Froth-Plant1 和 Froth-Plant2 两个数据集上进行了可视化分割对比实验,结果如图 9 所示。

可视化结果分别展示了以小尺度泡沫和大尺度泡沫为主的测试样本。从整体对比可知,在低质图像条件下,主流单阶段方法在不同尺度场景下均存在一定程度的漏检与误分割现象。相比之下,本文方法能够在两类场景中均实现更完整且清晰的分割结果,有效缓解了小目标漏检与大目标误分割问题,体现出较强的特征表达与结构辨识能力。该现象与表 2 中的量化结果一致,进一步验证了本文方法在低质图像环境下分割的有效性。

此外,为进一步分析密度感知机制在低质图像条件下对分割优化的驱动机理,本文通过图 10 所示的可视化结果,从空间表征与结构约束对密度估计进行解析。

图 10 共设四列,每列代表一个独立样本,各列

自上而下包含三部分可视化结果:第一部分为带质心点标注的原始泡沫图像,用于直观呈现泡沫的空间分布与密集程度;第二部分为对应的真实密度图标签,并包含真实泡沫数量;第三部分为模型的预测密度图,同时包含预测泡沫量。

分析图 10 可知,预测密度图在拓扑形态与响应强度上与真值标签保持高度的统计一致性。其核心不仅在于数值维度的数量感知,更在于模型可学习到泡沫在复杂空间中的分布逻辑。通过将离散的目标个体转化为连续的、具有区域差异感的密度场,构建了一个介于底层像素与高层语义之间的结构化中间表征,从而能够精准映射不同分布区域的特征显著性差异。该可视化结果验证了模型能够有效捕获泡沫的空间分布特征,并可根据密度场提供的泡沫分布规律,对模糊边界进行结构化补全与语义一致性修正,以提升低质数据条件下的分割性能。

综上,本文方法以单阶段网络结构,结合泡沫密度分布建模,有效缓解了小尺度与大尺度泡沫的漏检和误分割问题。在 Froth-Plant1 和 Froth-Plant2 两个数据集上实现了分割精度与推理效率




图 9 可视化分割对比图

Fig.9 Diagram of visual segmentation comparison




图 10 泡沫密度估计结果图
Fig.10 Diagram of foam density estimation results

的兼顾, 证明了所提方法在实际泡沫分割任务中的有效性.

3.6 跨场景数据分布下的泛化性能分析

为进一步验证所提方法在不同场景与不同数据分布条件下的泛化性, 本文选取 3 个相似开源数据集进行实验, 包括 PanNuke、bubble_size_distribution 和 BubbleBench. 其中, PanNuke 数据集来源于显微病理细胞核分割任务, 包含 7 901 幅图像和 189 744 个实例; bubble_size_distribution 数据集来源于流体力学气泡分割任务, 包含 322 幅图像和 13 882 个实例; BubbleBench 数据集面向工业多相流与微气泡测量场景, 包含 100 幅图像和 13 066 个实例. 上述数据集虽然在具体成像对象上与煤泥浮选泡沫存在差异, 但均具有目标尺度变化明显、局部区域密集分布、实例间边界易粘连等特点, 因此能够从跨场景角度验证本文方法对复杂空间分布目标的建模能力. 在统一实验设置下, 本文依据式 (12) 和 (13) 为各数据集生成密度回归标签, 并开展相应的泛化性验证实验. 实验结果如表 3 所示.

由表 3 可知, 本文方法在 3 个具有不同场景特征与数据分布的数据集上均取得了较为稳定的分割结果, 表明所提方法在不同应用场景下具有一定的

表 3 泛化性验证实验结果 (%)
Table 3 Results of generalization validation experiments (%)

数据集	AP	mIoU
PanNuke	73.88	63.33
bubble_size_distribution	64.76	47.77
BubbleBench	64.01	51.96

泛化能力. 为进一步直观展示本文方法在不同场景下的分割效果, 泛化性验证的可视化分割结果如图 11 所示.




图 11 泛化性验证可视化分割结果图
Fig.11 Diagram of visual segmentation results for generalization validation

由图 11 可知, 本文方法在不同场景数据集上均能够取得较好的分割效果. 尽管不同数据集在成像对象和空间分布特征上存在差异, 所提方法仍表现出较为稳定的分割能力. 该结果与表 3 中的量化结果一致, 进一步验证了本文方法的泛化能力.

4 结束语

针对低质图像数据条件下的泡沫分割问题, 本文提出一种基于密度感知引导的煤泥浮选泡沫分割方法. 该方法通过跨尺度区域密度感知模块和动态密度感知注意力机制的协同作用, 增强了模型对高密度区域的特征响应, 缓解了小尺度泡沫的漏检问题. 同时, 将密度感知信息与互信息优化策略结合, 强化了分割特征与密度表征的语义一致性, 提升了大尺度泡沫的边界定位精度. 在两个采集自不同选煤厂及不同工况条件下的数据集上的实验结果表明, 所提方法在分割精度与推理速度上具有优势.

在未来的工作中, 将进一步探索在保持实时推

理能力的前提下, 融合轻量化 Transformer 结构的实例分割建模方法, 并借鉴显微细胞、CT 及病理图像等实例分割领域中的创新思想, 进一步提升模型性能与方法创新性; 同时, 结合分割结果提取泡沫结构与空间分布特征, 开展实时灰分预测研究, 以期推动煤泥浮选过程的智能化发展。

参考文献

- Polat M, Polat H, Chander S. Physical and chemical interactions in coal flotation. *International Journal of Mineral Processing*, 2003, **72**(1-4): 199-213
- Wang Hong-Yan, Sun Zhuo-Qi, Wang Lan-Hao, Nan Jing, Dai Wei. Intelligent detection method for flotation clean coal ash based on multi-source information fusion. *Coal Science and Technology*, 2025, **53**(12): 280-292
(王红艳, 孙卓琪, 王兰豪, 南静, 代伟. 基于多源信息融合的浮选精煤灰分智能检测方法. 煤炭科学技术, 2025, **53**(12): 280-292)
- Han N, Li Y F, Zhang Z Y, Gong J B, Zhang B L, Li Y F. A Bayesian optimization stacked ensemble learning method: Predicting ash content in flotation cleaned coal using X-ray fluorescence oxides data. *Minerals Engineering*, 2026, **242**: Article No. 110227
- Lu F C, Liu H Z, Lv W B. Deep correlation and precise prediction between static features of froth images and clean coal ash content in coal flotation: An investigation based on deep learning and maximum likelihood estimation. *Measurement*, 2024, **224**: Article No. 113843
- Yang T, Zhang Z Y, Chen P, Gui D J, Li Y F. Study on the prediction of cleaning coal ash content based on principal component analysis and machine learning. *International Journal of Coal Preparation and Utilization*, 2025: 1-17
- Zhao Hong-Wei, Xie Yong-Fang, Jiang Zhao-Hui, Xu De-Gang, Yang Chun-Hua, Gui Wei-Hua. An intelligent optimal setting approach based on froth features for level of flotation cells. *Acta Automatica Sinica*, 2014, **40**(6): 1086-1097
(赵洪伟, 谢永芳, 蒋朝辉, 徐德刚, 阳春华, 桂卫华. 基于泡沫图像特征的浮选槽液位智能优化设定方法. 自动化学报, 2014, **40**(6): 1086-1097)
- Massinaei M, Jahedsaravani A, Taheri E, Khalilpour J. Machine vision based monitoring and analysis of a coal column flotation circuit. *Powder Technology*, 2019, **343**: 330-341
- Tan J K, Liang L, Peng Y L, Xie G Y. Correction of froth gray value in the prediction of clean coal ash content in coal flotation. *International Journal of Coal Preparation and Utilization*, 2022, **42**(9): 2742-2755
- Wang Hai-Yang, Pan De-Lu, Xia De-Shen. A fast algorithm for two-dimensional Otsu adaptive threshold algorithm. *Acta Automatica Sinica*, 2007(9): 968-971
(汪海洋, 潘德炉, 夏德深. 二维 Otsu 自适应阈值选取算法的快速实现. 自动化学报, 2007(9): 968-971)
- Brar K, Goyal B, Dogra A, Mustafa M, Majumdar R, Alkhayyat A, et al. Image segmentation review: Theoretical background and recent advances. *Information Fusion*, 2025, **114**: Article No. 102608
- Gui Wei-Hua, Yang Chun-Hua, Xu De-Gang, Lu Ming, Xie Yong-Fang. Machine-vision-based online measuring and controlling technologies for mineral flotation: A review. *Acta Automatica Sinica*, 2013, **39**(11): 1879-1888
(桂卫华, 阳春华, 徐德刚, 卢明, 谢永芳. 基于机器视觉的矿物浮选过程监控技术研究进展. 自动化学报, 2013, **39**(11): 1879-1888)
- Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, **44**(7): 3523-3542
- Lu Mai-Xi, Wang Yong, Wang Fan, Liu Wen-Li. Threshold segmentation technology applied to get physical features of foam image from slime floatation. *Coal Science and Technology*, 2002(8): 34-37
(路迈西, 王勇, 王凡, 刘文礼. 利用阈值分割技术提取煤泥浮选泡沫图像的物理特征. 煤炭科学技术, 2002(8): 34-37)
- Shilov R E, Logunova O S, Lednov A V. Methods and algorithms for segmentation of the image in control flotation process. In: Proceedings of the International Russian Automation Conference. Sochi, Russia: IEEE, 2018. 1-4
- Jahedsaravani A, Massinaei M, Marhaban M H. An image segmentation algorithm for measurement of flotation froth bubble size distributions. *Measurement*, 2017, **111**: 29-37
- Jia R D, Ren M X, Lang D, Zheng J, He D K, Yu F. A semantic segmentation-based algorithm for fast flotation bubble size distribution measurement. *Chemical Engineering Research and Design*, 2024, **208**: 795-807
- Zeng T, Wu B, Ji S W. DeepEM3D: Approaching human-level performance on 3D anisotropic EM image segmentation. *Bioinformatics*, 2017, **33**(16): 2555-2562
- Luo Hui-Lan, Li Xiao. Image semantic segmentation method based on context and shallow space encoder-decoder network. *Acta Automatica Sinica*, 2022, **48**(7): 1834-1846
(罗会兰, 黎宵. 基于上下文和浅层空间编解码网络的图像语义分割方法. 自动化学报, 2022, **48**(7): 1834-1846)
- Yu C Q, Wang J B, Peng C, Gao C X, Yu G, Sang N. BiSeNet: Bilateral segmentation network for real-time semantic segmentation. In: Proceedings of the European Conference on Computer Vision. Munich, Germany: Springer, 2018. 334-349
- Strudel R, Garcia R, Laptev I, Schmid C. Segmenter: Transformer for semantic segmentation. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE, 2021. 7242-7252
- Wan Z F, Zhang P P, Wang Y H, Yong S L, Stepputtis S, Sycara K, et al. Sigma: Siamese mamba network for multi-modal semantic segmentation. In: Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE, 2025. 1734-1744
- Xu Z Z, Wu D Y, Yu C Q, Chu X X, Sang N, Gao C X. SCT-Net: Single-branch CNN with Transformer semantic information for real-time segmentation. In: Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI Press, 2024. 6378-6386
- Wu R K, Liu Y H, Ning G C, Liang P C, Chang Q. UltraLight VM-UNET: Parallel vision mamba significantly reduces parameters for skin lesion segmentation. *Patterns*, 2025, **6**(11): Article No. 101298
- Fu Y X, Lou M, Yu Y Z. SegMAN: Omni-scale context modeling with state space models and local attention for semantic segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE, 2025. 19077-19087
- He K M, Gkioxari G, Dollár P, Girshick R. Mask R-CNN. In: Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 2961-2969
- Cai Z, Vasconcelos N. Cascade R-CNN: High quality object detection and instance segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, **43**(5): 1483-1498
- Chen K, Pang J M, Wang J Q, Xiong Y, Li X X, Sun S Y, et al. Hybrid task cascade for instance segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019. 4974-4983
- Li F, Zhang H, Xu H Z, Liu S L, Zhang L, Ni L M, et al. Mask DINO: Towards a unified Transformer-based framework for object detection and segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE, 2023. 3041-3050
- Yao W W, Li C, Xiong M J, Dong W B, Chen H, Xiao X. Con-

tourFormer: Real-time contour-based end-to-end instance segmentation Transformer. In: Proceedings of the International Joint Conference on Neural Networks. Rome, Italy: IEEE, 2025. 1–8

- 30 Ying H, Huang Z J, Liu S, Shao T J, Zhou K. EmbedMask: Embedding coupling for one-stage instance segmentation. In: Proceedings of the 30th International Joint Conference on Artificial Intelligence. Montreal, Canada: IJCAI, 2021. 1266–1273
- 31 Bolya D, Zhou C, Xiao F Y, Lee Y J. YOLACT: Real-time instance segmentation. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, Republic of Korea: IEEE, 2019. 9157–9166
- 32 Zhu Y C, Shi C, Wang D Y, Tang J J, Wei Z X, Wu Y, et al. Rethinking query-based Transformer for continual image segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, USA: IEEE, 2025. 4595–4606
- 33 Zhao X, Ding W C, An Y Q, Du Y L, Yu T, Li M, et al. Fast segment anything. arXiv preprint arXiv: 2306.12156, 2023.
- 34 Ren T H, Liu S L, Zeng A L, Lin J, Li K C, Cao H, et al. Grounded SAM: Assembling open-world models for diverse visual tasks. arXiv preprint arXiv: 2401.14159, 2024.
- 35 Cao Bin-Fang, Xie Yong-Fang, Yang Chun-Hua, Gui Wei-Hua, Wang Xiao-Li. Integrated modeling for production index of bauxite flotation based on multi-source data. *Control Theory & Applications*, 2014, **31**(9): 1252–1261
(曹斌芳, 谢永芳, 阳春华, 桂卫华, 王晓丽. 基于多源数据的铝土矿浮选生产指标集成建模方法. *控制理论与应用*, 2014, **31**(9): 1252–1261)
- 36 Tian Z, Shen C H, Wang X L, Chen H. BoxInst: High-performance instance segmentation with box annotations. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Virtual Event: IEEE, 2021. 5443–5452
- 37 Wang X L, Kong T, Shen C H, Jiang Y N, Li L. SOLO: Segmenting objects by locations. In: Proceedings of the European Conference on Computer Vision. Glasgow, UK: Springer, 2020. 649–665
- 38 Cheng T H, Wang X G, Chen S Y, Zhang W Q, Zhang Q, Huang C, et al. Sparse instance activation for real-time instance segmentation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE, 2022. 4433–4442



陈贵震 中国矿业大学信息与控制工程学院博士研究生. 主要研究方向为复杂工业过程图像信息处理.

E-mail: chen_cumt@cumt.edu.cn
(**CHEN Gui-Zhen** Ph.D. candidate at the School of Information and Control Engineering, China

University of Mining and Technology. His main research interest is image information processing for complex industrial processes.)



王红艳 中国矿业大学信息与控制工程学院讲师. 主要研究方向为复杂工业过程智能建模, 智能检测与智能控制.

E-mail: wanghongyan@cumt.edu.cn
(**WANG Hong-Yan** Lecturer at the School of Information and Con-

trol Engineering, China University of Mining and Technology. Her research interests include intelligent modeling of complex industrial processes, intelligent detection, and intelligent control.)



刘 鑫 中国矿业大学信息与控制工程学院教授. 主要研究方向为系统辨识, 数据驱动的工业建模和软测量.

E-mail: liuxin_hit@cumt.edu.cn

(**LIU Xin** Professor at the School of Information and Control Engineering, China University of Mining and Technology. His research interests include system identification, data-driven industrial modeling, and soft sensing.)



熊 峰 中国矿业大学信息与控制工程学院硕士研究生. 主要研究方向为基于深度学习的工业视觉系统.

E-mail: ts25060090a31ld@cumt.edu.cn

(**XIONG Feng** Master student at the School of Information and Control Engineering, China University of Mining and Technology. His main research interest is deep learning-based industrial vision system.)



邹国锋 山东理工大学电气与电子工程学院副教授. 主要研究方向为低压电气故障智能检测与电力视觉技术.

E-mail: gfzou@sdut.edu.cn

(**ZOU Guo-Feng** Associate professor at the School of Electrical and Electronic Engineering, Shandong University of Technology. His research interests include intelligent detection of low-voltage electrical faults and power vision technology.)



代 伟 中国矿业大学信息与控制工程学院教授. 主要研究方向为复杂工业过程建模、运行优化与控制. 本文通信作者.

E-mail: weidai@cumt.edu.cn

(**DAI Wei** Professor at the School of Information and Control Engineering, China University of Mining and Technology. His research interests include modeling, operational optimization, and control of complex industrial processes. Corresponding author of this paper.)