doi: 10.20239/j.issn.1671-9492.2026.09.015

PR-MobileOre:基于边界优化与关键点采样的轻量级矿石骨料图像分割算法

刘瑾彧[1],张高洋[1],刘安洋[1],张 杨[1,2,3]

(1. 湖北工业大学 机械工程学院,武汉 430068;
2. 矿冶过程智能优化制造全国重点实验室,北京 102628;
3. 矿冶过程自动控制技术北京市重点实验室,北京 102628)

摘 要:随着智能制造与工业自动化的持续发展,基于图像的矿石骨料粒度检测在选矿过程控制、工程质量监测等领域中正扮演着越来越关键的角色。然而,在实际工业场景中,矿渣干扰、颗粒堆叠、边界模糊等复杂因素广泛存在,严重影响了图像分割方法的准确性与稳定性。此外,受限于设备算力与实时性要求,如何在保障分割精度的同时兼顾模型的计算效率与工业部署适应性,成为亟待解决的关键问题。为此,本文提出一种轻量级、实时性强的矿石图像精细实例分割算法PR-MobileOre。该算法以MobileOne为骨干网络,融合自主设计的关键点自适应采样机制,依靠不确定性评分聚焦图像边界与模糊区域,并引入边界精细化策略,基于高分辨率特征图完成逐点插值与分类预测,有效提升模型局部结构感知能力与分割边缘一致性。采用多轮迭代优化方式,在维持轻量级模型规模的条件下,实现复杂工业场景下矿石颗粒边界的精准提取。试验结果表明,PR-MobileOre模型大小仅74.4 MB,在自建矿石图像数据集上mAP达到74.8%,综合精度优于多种主流实例分割算法,兼顾分割高精度与低计算开销,可为矿石骨料智能粒度分析与生产在线控制提供技术支撑。

关键词:矿石图像分割;轻量化网络;边界精细化;实时图像处理;矿石粒度检测

中图分类号:TD921;TP391.41 **文献标志码:**A **文章编号:**1671-9492(2026)09-0132-09

PR-MobileOre: A Lightweight Segmentation Algorithm for Ore Aggregate Images Based on Boundary Optimization and Keypoint Sampling

Liu Jinyu[1], Zhang Gaoyang[1], Liu Anyang[1], Zhang Yang[1,2,3]

(1. School of Mechanical Engineering, Hubei University of Technology, Wuhan 430068, China;
2. State Key Laboratory of Intelligent Optimized Manufacturing in Mining & Metallurgy Process, Beijing 102628, China;
3. National Key Laboratory of Automatic Control Technology for Mineral Processing in Beijing, Beijing 102628, China)

Abstract: With the continuous advancement of intelligent manufacturing and industrial automation, image-based particle size detection of ore aggregates is playing an increasingly critical role in process control and quality monitoring in mining and construction engineering. However, in real-world industrial scenarios, complex factors such as slag interference, particle stacking, and blurred boundaries are common, severely affecting the accuracy and stability of image segmentation methods. Moreover, due to constraints in computing power and real-time requirements, how to ensure segmentation accuracy while maintaining computational efficiency and deployment adaptability has become a key challenge. To address this, we propose PR-MobileOre, a lightweight and real-time instance segmentation algorithm for fine-grained ore images. This method employs MobileOne as the backbone network and integrates a self-designed keypoint adaptive sampling mechanism, which focuses on image boundaries

收稿日期:2025-07-23
基金项目:矿冶过程智能优化制造全国重点试验室和矿冶过程自动控制技术北京市重点实验室开放基金课题(BGRIMM-KZSKL-2023-11);湖北省自然科学基金资助项目(2024AFB153)
作者简介:刘瑾彧(2001—),女,湖北潜江人,硕士研究生,主要从事矿石图像检测及分割方面研究。
通信作者:张 杨(1992—),男,湖北黄石人,博士,副教授,主要从事机器视觉、图像处理、深度学习与多媒体信息处理等方面的研究。

and ambiguous regions based on uncertainty scoring. It further introduces a boundary refinement strategy to conduct point-wise interpolation and classification prediction on high-resolution feature maps, which effectively improves the capability of local structure perception and edge consistency. With a multi-stage iterative optimization process, the model realizes accurate boundary extraction for ore particles under complex scenarios while keeping a compact model size. Experimental results demonstrate that PR-MobileOre, with only 74.4 MB of model size, achieves a mAP of 74.8% on a self-constructed ore image dataset, outperforming various mainstream instance segmentation algorithms. It combines high precision with low computational cost, offering effective technical support for intelligent particle size analysis and real-time control in ore aggregate processing.

Key words: ore image segmentation; lightweight network; boundary refinement; real-time processing; ore particle size detection

矿石骨料作为混凝土的重要组成部分，在矿业生产和道路工程建设中起到结构支撑与性能强化的关键作用[1]。矿石骨料的粒度分布直接决定混凝土强度、耐久性以及工程材料均一性，因此发展高精度矿石骨料检测技术，对提升道路工程质量与选矿生产效率具有重要现实意义[2]。近年来，伴随智能制造技术发展，图像式矿石分割方法凭借非接触、高效率、自动化程度高的优势，成为传统人工测量与规则驱动检测手段的重要补充。但实际选矿现场普遍存在背景杂质干扰、颗粒堆叠重叠、光照不均匀、颗粒边界模糊等问题，给矿石图像分割带来较大难度。尤其针对尺寸小、形态多变的微细矿石骨料，现有算法难以完整提取边界细节，造成分割效果劣化[3]。

传统矿石粒度分析手段包含人工测量，以及边缘检测、形态学运算、阈值分割等基于规则的图像处理算法[4]。该类方法在图像背景对比度高、矿石颗粒形态规整条件下可以取得较好效果；但面对光照变化大、矿石形态复杂的场景，容易产生误分割、漏分割问题[5]。随着深度学习技术不断发展，卷积神经网络驱动的实例分割算法逐步被用于矿石图像识别与信息提取。曾中华等[6]构建改进EfficientNetV2-Unet矿石分割算法，引入注意力模块与滤波器响应归一化层优化模型性能。杨克虎等[7]设计搭载自注意力机制的轻量级编码-解码网络，完成浅层、深层多尺度语义特征提取。刘惠中等[8]提出融合特征增强与小目标检测模块的改进YOLOv5算法，提升矿带分割点识别精度，满足自动化分带控制要求。但矿石开采、转运、加工环节会产生海量待处理图像，现有卷积神经网络普遍存在计算链路复杂、硬件资源消耗大的缺陷[9]，难以满足工业生产线的实时响应要求。

针对上述问题，本文提出一种轻量级实时图像精细分割模型PR-MobileOre，兼顾矿石骨料检测任务对边界结构感知、低计算开销与在线推理性能的综合需求。为验证该算法的有效性，本文基于自建矿石图像数据集开展多组试验。试验结果表明，PR-MobileOre在矿石边界提取效果与实时推理性能上均优于现有主流算法，在小颗粒密集场景下表现出更突出的细节分割能力。该算法可为矿石粒度在线检测提供技术支撑，具备良好的工程可部署性与拓展能力，对选矿智能化与自动化控制具有参考价值。

1　PR-MobileOre算法框架

为提升小颗粒矿石图像的边界分割精度，同时兼顾模型的运行效率与工业部署适应性，本文提出了一种轻量级实时图像精细分割模型PR-MobileOre。如图1所示，整体流程以边界优化为核心，围绕特征提取、区域聚焦与掩码细化三个阶段展开。首先，输入矿石骨料图像经骨干网络MobileOne[10]提取高效的多尺度语义特征，并通过特征金字塔网络(FPN)完成多层级特征融合，获得同时具备空间细节与语义信息的特征表示，生成低分辨率的初步分割掩码。随后，基于不确定性评分的关键点采样机制，将计算资源集中分配至目标边缘及预测歧义区域，实现计算区域聚焦。在此基础上，模型在高分辨率特征图中对这些关键点执行双线性插值特征提取，融合邻域语义信息后，通过逐点分类预测类别概率，并将更新结果回写至掩码对应位置。该“采样—插值—预测—更新”的迭代过程不断细化局部区域，最终输出高质量的分割掩码。

为优化掩码边界与目标定位的准确性，PR-MobileOre采用包含边界框回归损失L_{box}与掩码预测损失L_{mask}的联合损失函数。其中，L_{box}依据预测框与真实框的广义交并比损失[11]计算，用于监督模型的目标定位能力；L_{mask}采用区域重叠度损失[12]，用于引导关键点掩码实现精准分割，改善边界区域预测质量。两项损失通过加权形式联合优化，总损失表达式

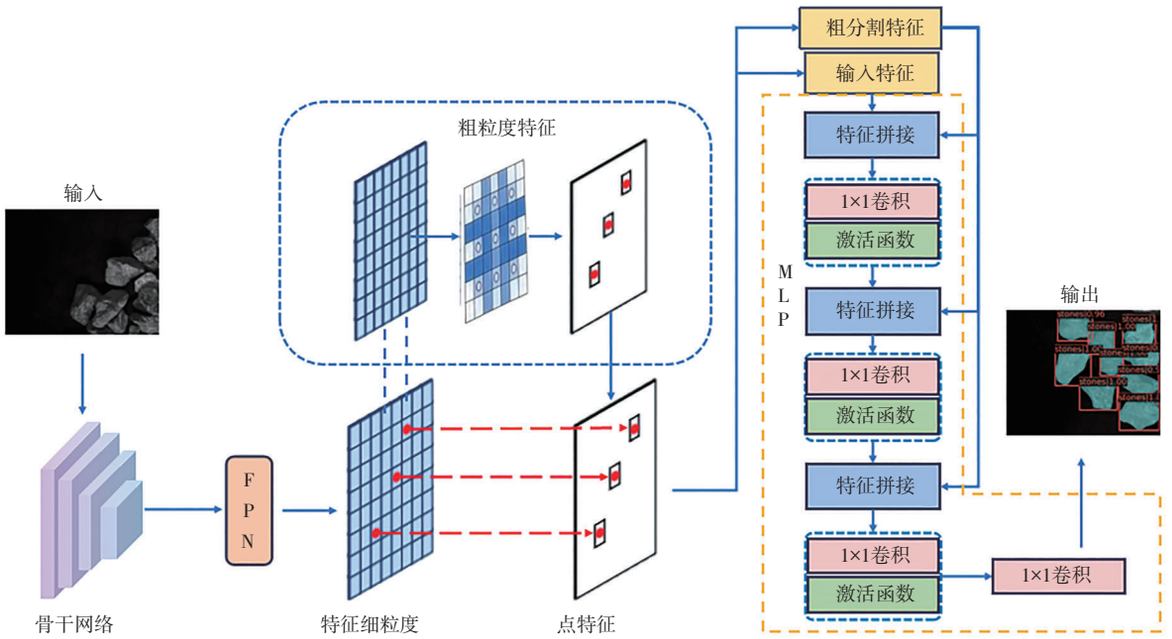


图 1　PR-MobileOre 算法框架图

Fig. 1　The framework of the PR-MobileOre algorithm

为：$L_{total}=\alpha\times L_{box}+\beta\times L_{mask}$。PR-MobileOre 既有效缓解小目标边界模糊问题，又能够保证推理过程低延迟、高效率，适用于矿石粒度分析这类对边界精度、响应速度均有较高要求的工业应用场景。

1.1　轻量级骨干网络

本文选用结构紧凑、推理延迟低的轻量级卷积神经网络 MobileOne 作为骨干网络。该网络特征表达能力较强，计算开销小，在移动终端可实现低于 1 ms 的推理耗时，能够满足在线选矿场景中小颗粒图像处理的需求。如图 2 所示，MobileOne 基础模块由 3×3 深度可分离卷积与 1×1 点卷积构成。3×3 卷积负责提取局部空间特征，在网络不同层级逐步形成多尺度特征表达；1×1 点卷积用于整合通道信息，提升特征抽象能力，并搭配 SiLU 激活函数增强模型的非线性建模能力。

为提升训练效率与特征表达能力，MobileOne 采用多重参数化多分支结构：训练阶段设置平行卷积分支与批量归一化模块，构建多路径特征流；推理阶段

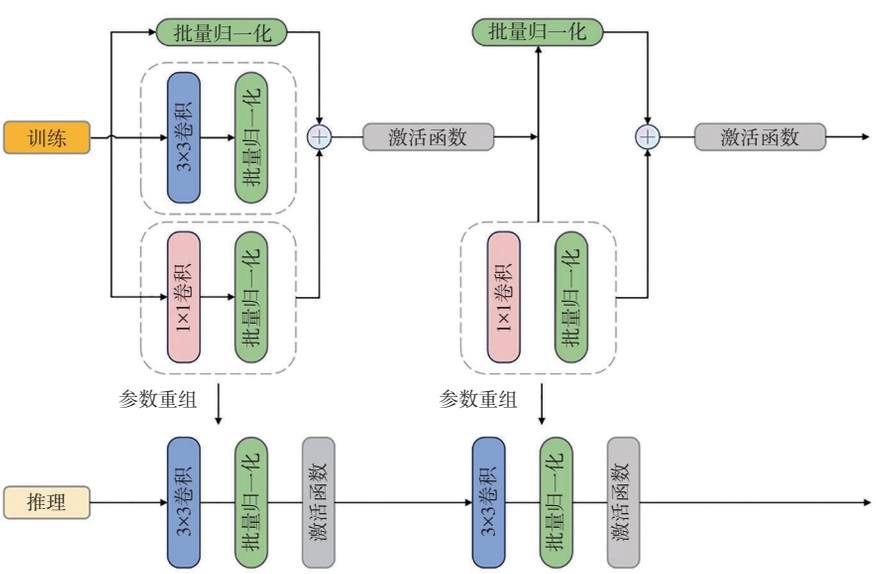


图 2　MobileOne 模块结构

Fig. 2　The structure of the MobileOne block

可将多分支结构融合为单路结构，显著降低推理阶段运算负担，提升运行速度。MobileOne 提供多个变体版本，采用深度、宽度缩放策略适配不同计算需求，核心参数如表 1 所示，包含控制通道缩放、影响模型复杂度的宽度因子，决定特征表达维度的输出通道数，以及影响计算开销与特征优化能力的 SE 模块数量，能够输出多层级、高效率特征，为后续关键点筛选、边界细化提供稳定的特征基础。

表 1　MobileOne 的变体版本

Table 1　Variant version of MobileOne

变体版本	宽度因子	输出通道数	SE 模块数量
MobileOne_s0	[0.75, 1.0, 1.0, 2.0]	[48, 128, 256, 1 024]	0
MobileOne_s1	[1.5, 1.5, 2.0, 2.5]	[96, 192, 512, 1 280]	0
MobileOne_s2	[1.5, 2.0, 2.5, 4.0]	[96, 256, 640, 2 048]	0
MobileOne_s3	[2.0, 2.5, 3.0, 4.0]	[128, 320, 768, 2 048]	0
MobileOne_s4	[3.0, 3.5, 3.5, 4.0]	[192, 448, 896, 2 048]	[0, 0, 5, 1]

1.2　基于自适应细分的关键点采样优化

为在分割过程中有效减少无关区域的冗余计算，使模型聚焦于复杂边界区域，在保障计算效率的同时提升边界预测精度，本文设计一种基于自适应细分的关键点采样优化机制。该机制通过重点处理预测不确定性较高的区域，实现边界分割精度与推理效率的平衡。该机制在推理、训练两个阶段采用不同实现形式，分别适配在线预测与反向传播模型优化的需求。如图 3 所示，在推理阶段，自适应细分执行流程如下：首先在低分辨率条件下生成初始掩码预测图，通过双线性插值逐步细化得到更密集的预测网格；每完成一次细分，在新网格中选取预测不确定性最高的 N 个像素点开展逐点预测，并将预测结果更新至掩码图。该过程可多轮迭代执行，逐步细化至目标输出分辨率 $M\times M$。其中，像素点的不确定性评分函数定义为：

$$U(p)=1-\max P(p,c) \tag{1}$$

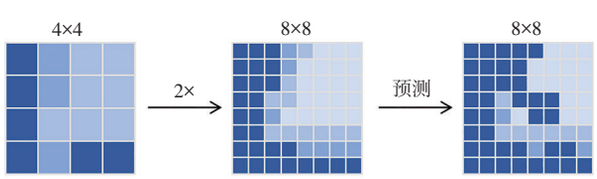


图 3　自适应细分

Fig. 3　Adaptive subdivision

式中，$U(p)$ 表示像素点 p 的不确定性，$P(p, c)$ 为该点被预测为类别 c 的概率。较高的不确定性表示该点可能处于边界或混淆区域，适合采样进行细化预测。设初始掩码分辨率为 $M_0\times M_0$，每轮采样点数为 N，则总预测点数理论上不超过：

$$N_{\text{total}}\leqslant N\cdot\log_2\left(\frac{M}{M_0}\right) \tag{2}$$

该方式相比对整图像素逐点预测，可显著减少计算开销，同时聚焦于关键区域。

在训练阶段，多轮迭代会干扰反向传播优化过程，因此，本文采用非迭代式单步自适应采样策略。在特征图上随机采样 kN 个候选点，对候选点执行插值预测并计算不确定性评分；从中选取不确定性最高的 α^N 个点作为训练采样点，剩余 $(1-\alpha)^N$ 个点从原始候选集合中均匀抽取，以此兼顾采样的空间覆盖度与边界样本学习效果。该策略保留推理阶段的区域聚焦特性，同时简化训练流程，保障模型训练稳定性以及边界判别能力。引入自适应关键点采样机制后，PR-MobileOre 能够高效聚焦关键区域并完成精细化处理，提升整体分割性能，同时显著降低训练与推理阶段的计算开销，适合工业现场算力受限环境下的小颗粒矿石图像处理任务。

1.3　边界精细化

完成关键点采样并得到高不确定性区域后，本阶段利用骨干网络输出的高分辨率特征对上述位置开展针对性修正，提升掩码边界的连续性与整体分割质量。不同于对完整掩码实施全局修正，边界精细化模块仅在关键区域开展密集计算，在控制计算开销的前提下改善局部分割细节。具体流程为：在高分辨率特征图上对各个关键点执行双线性插值，提取上下文特征，并融合该像素四邻域的语义信息，降低像素定位偏移、特征断裂对预测结果带来的干扰。随后将融合后的特征送入多层感知机（MLP）完成逐点类别预测，使用预测输出替换原掩码对应位置的响应值。针对处于多目标边界交界位置的关键点，依据类别概率分布完成判别，并结合历史掩码状态实现柔性更新，避免出现局部预测震荡或错误更新问题。

迭代过程循环执行“插值—预测—更新”操作，每一轮均对关键区域做修正处理，直至掩码达到预设分辨率 $M\times M$，或验证集指标不再提升。该流程可逐

步消除初始掩码存在的锯齿、断裂等缺陷，在细粒度结构、小目标密集重叠、边界遮挡等复杂工况下仍可维持较高的局部预测精度。边界精细化作为关键点采样机制的后置补偿环节，与前序模块构成完整处理链路，进一步增强PR-MobileOre对边界结构建模与细节恢复的处理能力。

2 基准数据集与评估指标

2.1 数据集建立

为评估本文所提算法在矿石图像分割任务中的有效性与实用性，本文构建矿石图像专用数据集作为测试基准。如图4所示，该数据集通过矿石图像采集平台采集得到，涵盖多种光照条件、颗粒分布形态以及背景复杂度，可真实还原矿石骨料的空间分布与粒径变化特征。数据集总计5 120张图像，其中训练集4 060张，测试集1 060张；全部图像完成人工标注，提供多矿石颗粒实例对应的像素级掩码，适用于小颗粒矿石的检测与分割研究。

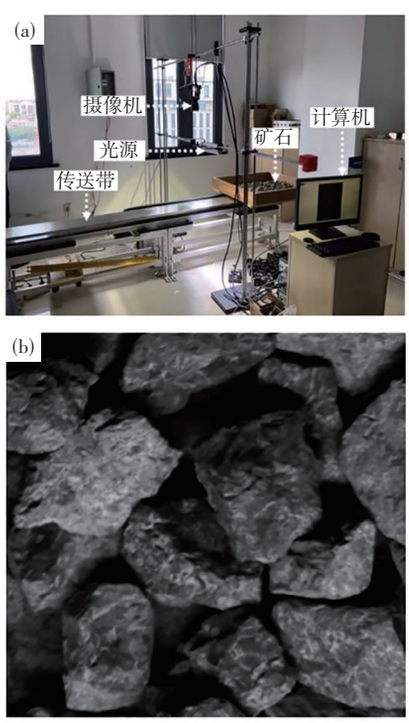


图4 (a)矿石图像采集平台；(b)采集的矿石图像

Fig. 4 (a) Ore image acquisition platform; (b) Captured ore images

为进一步量化数据集特征，本文参照通用矿石分级标准，依据物理当量直径d将矿石颗粒划分为：粗粒级(d>10 mm)、中粒级(5 mm<d<10 mm)、细粒级(1 mm<d<5 mm)、微细粒级(d<1 mm)，并统计各粒级样本占比，统计结果如表2所示。其中，物理当量直径定义为矿石颗粒的最大外接长度。完成相机内外参数标定后，将检测框的像素宽高换算为实际物理尺寸，取长边作为当量直径d。为验证粒径换算精度，对部分样本开展游标卡尺抽样比对测试，结果表明测量误差可控制在±1 mm以内。该数据集对各粒径颗粒均实现充足样本覆盖，可为模型进行多尺度特征学习及泛化能力验证提供数据支撑。

表2 不同粒径范围的分布

Table 2 Distribution of different particle size ranges

粒级/mm	占比/%
0~5	14.1
5~7	41.3
7~10	27.9
10~12	13.4
>12	3.3

2.2 评估指标

为评估所提算法的综合性能，本文从检测精度与计算复杂度两个维度，设置六项核心评价指标。精度评价层面，选用平均精度(mean average precision，mAP)作为主要评价指标，同时统计不同交并比阈值下的精度AP_{50}与AP_{75}，综合衡量模型的目标定位能力与边界预测质量。计算效率层面，统计各模型磁盘存储占用大小(MB，即模型文件磁盘占用量)、理论浮点计算量(FLOPs)以及统一硬件环境下的平均推理帧率(FPS)，以此评价模型存储开销、计算复杂度、实时推理能力与工程部署适配性。上述六项指标共同构成多维度综合评价体系，为后续算法对比及工业部署可行性分析提供客观依据。

2.3 试验参数设置

本文全部试验均采用统一训练配置。所有模型均基于单张NVIDIA GTX 2080Ti显卡开展训练，总训练迭代次数设置为30 000次，初始学习率取0.001。训练阶段输入图像尺寸统一为320×320，消融试验的批量大小设置为8。测试阶段推理时间与显存占用同样在该硬件设备上统计，保证评估结果具备一致性与可比性。在模型结构设计上，本文选用轻量级卷积神经网络作为骨干网络，骨干网络输出特征通道数设置为32，为后续多尺度分割模块与掩码预测提供特征支撑。

3　试验结果与分析

3.1　消融试验

3.1.1　骨干网络

为测试不同规模MobileOne变体对模型性能与推理效率的影响，本文保持其余模块配置不变，分别将骨干网络替换为MobileOne_s0～MobileOne_s4，在相同数据集与训练配置下进行对比试验，试验结果如表3所示。随着骨干网络规模增大，模型各项性能指标呈稳定上升趋势。其中，MobileOne_s4取得最优性能，mAP达到74.3%，但模型体积达到111.2 MB，难以适配工业终端部署。MobileOne_s0模型体积仅32.4 MB，但mAP仅为71.6%，分割精度偏低。相比之下，MobileOne_s3的mAP达到74.2%，AP_{50}与AP_{75}分别为93.6%与88.0%，模型大小为72.8 MB，在保证分割精度的同时实现良好的模型紧凑性。与MobileOne_s4相比，s3精度仅下降0.1个百分点，模型复杂度却显著降低，实现了性能与效率的良好权衡。因此，本文最终选用MobileOne_s3作为骨干网络，在保障矿石边界分割精度的同时兼顾实时推理能力与嵌入式设备适配能力，可满足小颗粒矿石图像的工业高效分析需求。

表3　对比不同版本的骨干网络

Table 3　Comparison of different backbone networks

骨干网络	mAP	AP_{50}	AP_{75}	模型大小/MB
MobileOne_s0	71.6	92.6	87.9	32.4
MobileOne_s1	73.8	92.9	87.7	35.0
MobileOne_s2	73.6	93.4	86.9	54.4
MobileOne_s3	74.2	93.6	88.0	72.8
MobileOne_s4	74.3	93.9	88.2	111.2

3.1.2　FPN的通道数

为探究特征金字塔网络(FPN)通道维度对分割性能的影响，本文设置多组不同通道数开展消融试验，试验结果如表4所示。在一定范围内增大通道数能够显著提升模型性能。当通道数由8提升至32时，mAP由72.5%上升至73.8%，AP_{75}提升3.5个百分点，更高的特征维度有利于捕捉矿石边界与结构细节。但通道数继续增大至64和128后，模型精度提升趋于饱和，模型体积却快速膨胀，此时计算资源开销的增加无法带来同等幅度的精度收益。综合分割精度、参数量开销以及工业部署的实际需求，本文将FPN通道数的默认配置设置为32，实现性能与开销的最优权衡。

表4　对比FPN的不同通道数

Table 4　Comparison of different channels in FPN

通道数	mAP	AP_{50}	AP_{75}	模型大小/MB
8	72.5	92.9	84.6	69.4
16	72.7	92.8	87.4	71.9
32	73.8	93.9	88.1	77.0
64	73.9	93.9	87.9	87.8
128	74.1	94.2	88.1	111.9

3.1.3　损失函数权重

为进一步探究边界框损失权重(α)与掩码损失权重(β)对模型整体性能的影响，本文设置多组权重组合对模型性能开展系统性评估，试验结果如表5所示。两类损失项的权重分配对模型性能存在显著影响。当取$\alpha=0.5$、$\beta=2$时，模型综合性能最优，mAP为74.2%，AP_{50}与AP_{75}分别为94.0%与88.3%，在全部权重试验组中效果最佳。与之对比，若增大边界框损失权重至$\alpha=2$，同时降低掩码损失权重至$\beta=0.5$，mAP下降至72.5%，AP_{50}与AP_{75}同步出现下降。该结果表明，过度侧重边界框回归任务会削弱模型对掩码区域的精细建模能力。为同时兼顾目标边界与掩码区域的分割精度，本文最终选取$\alpha=0.5$、$\beta=2$作为损失函数的默认配置。

表5　对比不同损失函数权重

Table 5　Comparison of different loss function weights

α	β	mAP	AP_{50}	AP_{75}
0.5	2	74.2	94.0	88.3
1	0.5	72.5	93.9	87.6
1	1	73.4	94.0	88.0
1	2	74.0	93.8	88.1
2	0.5	72.5	93.0	87.2

3.2　不同算法对比试验与可视化分析

为全面评估所提算法的实际应用性能，本文选取多种主流实例分割算法开展对比试验，包含两阶段算法Mask R-CNN[13]；单阶段算法YOLACT[14]、SOLOv2[15]；基于查询机制的算法QueryInst[16]、SparseInst[17]；近年具有代表性的轻量级算法CondInst[18]、BoxInst[19]、RTMDet[20]，以及基于Transformer架构的算法Mask2Former[21]。所有对比算法均采用公开代码实现，在同一数据集与评价指标体系下完成测试，对比试验结果如表6所示。

Mask R-CNN依托两阶段框架与精准的感兴趣区域对齐机制，可取得较高的mAP，但多级处理流程会显著增加模型复杂度。Mask2Former结合

表6 对比不同的实例分割算法

Table 6 Comparison of different instance segmentation algorithms

实例分割算法	骨干网络	mAP	AP_{50}	AP_{75}	模型大小/MB	FPS	FLOPs/G
Mask R-CNN	convnext-tiny	73.3	90.8	86.5	588	16	78.98 G
Mask R-CNN	R-50	74.3	93.9	88.8	335	17	77.31 G
BoxInst	R-50	55.9	90.0	63.7	269	23	23.51 G
CondInst	R-50	70.9	89.5	84.0	263	23	30.88 G
Mask2Former	R-50	72.1	89.8	84.4	528	20	27.30 G
SparseInst	R-50	73.5	93.3	88.2	366	21	29.47 G
QueryInst	R-50	67.4	84.4	79.5	1930	15	919.00 G
RTMDet	R-50	40.7	57.8	48.5	903	22	107.00 G
SOLOv2	R-50	72.4	92.3	86.7	352	24	79.55 G
YOLACT	R-50	72.6	93.5	85.7	269	24	64.45 G
PR-MobileOre	MobileOne_s3	74.8	94.0	88.9	74.4	27	8.69 G

Transformer架构与掩码解耦机制，具备较强的上下文建模能力，然而高分辨率条件下自注意力计算会造成计算成本激增，两种算法均难以适用于算力资源受限的应用场景。轻量级算法中，BoxInst与CondInst虽通过删减复杂模块降低参数量与计算开销，但简化设计牺牲了边界与结构细节建模能力，在目标边界复杂、小目标密集场景下分割精度不足，二者mAP分别为55.9%和70.9%。RTMDet以实时检测为设计目标，但检测优先的策略弱化了边界建模能力，同时骨干网络与预测头部匹配性不足，浮点运算量偏高，存在明显的效率瓶颈。QueryInst引入复杂多查询机制，FLOPs高达919 G，但查询资源利用率低、缺乏有效的关键点聚焦策略，mAP仅67.4%，表明该算法对边界密集的小目标任务适配性较差。与之相比，PR-MobileOre模型体积仅74.4 MB，FLOPs为8.69 G；该轻量架构依托不确定性引导的关键点采样与多轮边界精细化机制，有效提升边界识别精度与结构一致性，取得mAP=74.8%、AP_{50}=94.0%、AP_{75}=88.9%的最优结果，在所有对比算法中综合精度最高，在复杂矿石图像场景下具备明显优势与工程应用潜力。

为验证本文提出的基于自适应细分的关键点采样优化及边界精细化模块在提升边界质量与目标分离度方面的有效性，本文对比相同输入下启用与移除该组机制后的特征响应图，结果如图5所示。未启用该机制时，模型注意力分布较为分散，背景区域存在零散高响应点，部分边缘区域响应偏弱，难以生成连续、精准的边界特征表征，易造成小颗粒或相邻目标的分割边界发生断裂、黏连。与之相比，引入上述机制后，模型注意力可集中在目标轮廓与细粒度结构区域，背景噪声显著减少，边界响应的连续性与信号强度得到增强，进而提升模型整体分割精度与鲁棒性。

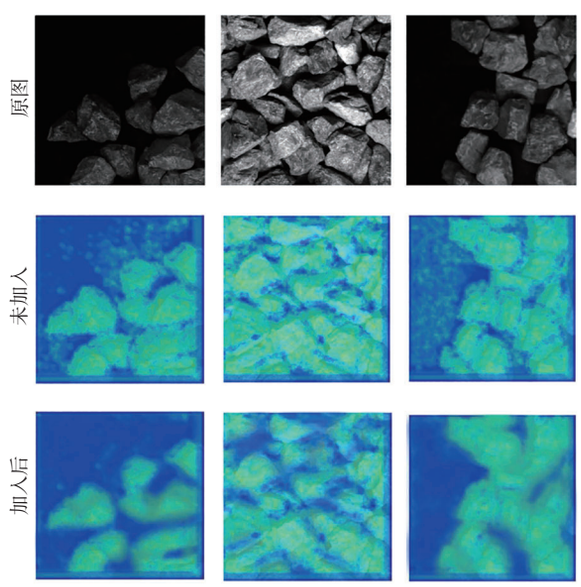


图5 关键点采样与边界精细化机制前后的特征响应对比

Fig. 5 Comparison of feature responses before and after the key point sampling and boundary refinement mechanism

如图6所示，本文对比展示PR-MobileOre与Mask R-CNN、YOLACT等主流算法在典型样本上的分割效果，PR-MobileOre在矿石颗粒分割任务中具备更优的边界贴合度与目标完整性。Mask R-CNN虽可检出大部分矿石颗粒，但边界细节存在明显锯齿与漏检问题，部分相邻颗粒出现黏连分割错误。YOLACT生成的分割边界相对平滑，但在颗粒密集接触区域易发生边界偏移与目标轮廓断裂。与之相比，PR-MobileOre依托轻量化结构、自适应关键点采样机制与边界精细化策略，可在细粒度区域有效区分相邻颗粒，大幅缓解边界黏连、轮廓断裂及误分割问题；即便针对形态复杂或存在局部遮挡的矿石颗粒，

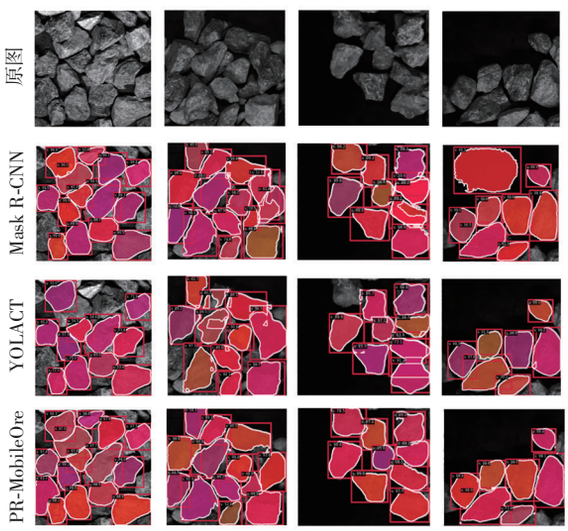


图 6　不同算法的可视化分割效果

Fig. 6　Segmentation visualization comparison of PR-MobileOre and mainstream algorithms

依旧能够维持良好的边界连续性与分割精度。

4　结论

1) 针对矿石骨料图像存在颗粒边界模糊、颗粒相互重叠，以及工业场景对模型实时推理的现实需求，本文提出轻量级高精度实例分割算法PR-MobileOre，兼顾矿石颗粒边界结构感知能力、低计算开销与在线推理的综合性能，适用于工业现场矿石骨料图像粒度检测任务。

2) 本文设计关键点自适应采样机制，实现对掩码的逐点精细化处理；构建包含边界框回归损失与掩码预测损失的联合损失函数，通过“采样 - 插值 - 预测 - 更新”迭代流程完成掩码边界优化。该机制能够在控制计算量的前提下，实现矿石颗粒边界的高质量特征提取，有效改善复杂场景下的边界分割效果。

3) 在自建矿石图像数据集上，将PR-MobileOre与多种主流实例分割算法进行对比试验。试验结果表明，PR-MobileOre模型体积仅74.4 MB，取得74.8%的mAP指标，综合性能优于本组对比的其他算法。该算法兼具模型轻量化与分割高精度的优势，验证了其在复杂矿石场景下的边界提取能力，具备工业部署与实际应用潜力。

参考文献

[1] 叶润青，牛瑞卿，张良培. 基于多尺度分割的岩石图像矿物特征提取及分析[J]. 吉林大学学报(地球科学版)，2011，41(4)：1253-1261.
Ye Runqing，Niu Ruiqing，Zhang Liangpei. Mineral features extraction and analysis based on multiresolution segmentation of petrographic images[J]. Journal of Jilin University (Earth Science Edition)，2011，41(4)：1253-1261.

[2] 何一东，陈锐，吴泽彬，等. 融合多边形拟合与凹点匹配的黏连重叠矿石图像分割算法[J]. 有色金属(选矿部分)，2024(10)：94-104.
He Yidong，Chen Rui，Wu Zebin，et al. A segmentation algorithm for adhesive overlapping ore images based on polygon fitting and concave point matching[J]. Nonferrous Metals (Mineral Processing Section)，2024(10)：94-104.

[3] 李文博，郝兵，赵虎，等. 矿石粒度图像在线分析系统的研究与应用[J]. 矿山机械，2021，49(4)：47-50.
Li Wenbo，Hao Bing，Zhao Hu，et al. Research and application of online ore particle size image analysis system[J]. Mining & Processing Equipment，2021，49(4)：47-50.

[4] 许文祥，张国英，蒋焱，等. 基于二项分布的双窗OTSU的矿石分割模型[J]. 有色金属(矿山部分)，2019，71(3)：96-102.
Xu Wenxiang，Zhang Guoying，Jiang Yan，et al. Ore segmentation model by bi-window OTSU based on binomial distribution[J]. Nonferrous Metals (Mining Section)，2019，71(3)：96-102.

[5] 危发文. 金属露天矿区传送带破碎矿石粒度检测方法研究及应用[D]. 西安：西安建筑科技大学，2022.
Wei Fawen. Research and application of ore particle size detection method for conveyor belt crushing in metal open-pit mining area[D]. Xi′an：Xi′an University of Architecture and Technology，2022.

[6] 曾中华，曹东. 基于改进Unet的矿石图像分割[J]. 电子测量技术，2023，46(21)：176-182.
Zeng Zhonghua，Cao Dong. Ore image segmentation based on improved Unet[J]. Electronic Measurement Technology，2023，46(21)：176-182.

[7] 杨克虎，龙启航，汪嘉文，等. 基于自注意力机制的矿井次光照图像语义分割研究[J]. 矿业安全与环保，2023，50(5)：9-18.
Yang Kehu，Long Qihang，Wang Jiawen，et al. Research on semantic segmentation of mine sub-illumination images based on self-attention mechanism[J]. Mining Safety & Environmental Protection，2023，50(5)：9-18.

[8] 刘惠中，宁剑，邹起华，等. 基于改进YOLOv5的螺旋选矿机矿物分带图像分割算法研究[J]. 有色金属(选矿部分)，2024(1)：96-105.
Liu Huizhong，Ning Jian，Zou Qihua，et al. Research on

a spiral concentrator mineral zoning image segmentation algorithm based on improved YOLOv5 [J]. Nonferrous Metals (Mineral Processing Section), 2024(1): 96-105.

[9] 商梦石,贾瑞强,张海林. 图像处理技术在矿石粒度检测中的应用[J]. 矿产综合利用,2016,37(6):13-16.
Shang Mengshi, Jia Ruiqiang, Zhang Hailin. Application of image processing technology in ore particle size measurement[J]. Multipurpose Utilization of Mineral Resources, 2016, 37(6): 13-16.

[10] Vasu P K A, Gabriel J, Zhu J, et al. MobileOne: an improved one millisecond mobile backbone[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Vancouver, BC, Canada. IEEE, 2023: 7907-7917.

[11] Rezatofighi H, Tsoi N, Gwak J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA. IEEE, 2019: 658-666.

[12] Milletari F, Navab N, Ahmadi S A. V-net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision(3DV). Stanford, CA, USA. IEEE, 2016: 565-571.

[13] He Kaiming, Gkioxari G, Dollar P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision(ICCV). Venice. IEEE, 2017: 2980-2988.

[14] Bolya D, Zhou Chong, Xiao Fanyi, et al. YOLACT: real-time instance segmentation[C]//2019 IEEE/CVF International Conference on Computer Vision(ICCV). Seoul, Korea. IEEE, 2019: 9156-9165.

[15] Wang Xinlong, Zhang Rufeng, Kong Tao, et al. SOLOv2: dynamic and fast instance segmentation[C]// Advances in Neural Information Processing Systems. Red Hook: Curran Associates, 2020, 33: 17721-17732.

[16] Fang Yuxin, Yang Shusheng, Wang Xinggang, et al. Instances as queries[C]//2021 IEEE/CVF International Conference on Computer Vision(ICCV). Montreal, QC, Canada. IEEE, 2021: 6890-6899.

[17] Cheng Tianheng, Wang Xinggang, Chen Shaoyu, et al. Sparse instance activation for real-time instance segmentation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). New Orleans, LA, USA. IEEE, 2022: 4423-4432.

[18] Tian Zhi, Shen Chunhua, Chen Hao. Conditional convolutions for instance segmentation[C]//Computer Vision-ECCV 2020. Cham: Springer, 2020: 282-298.

[19] Tian Zhi, Shen Chunhua, Wang Xinlong, et al. BoxInst: high-performance instance segmentation with box annotations[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Nashville, TN, USA. IEEE, 2021: 5439-5448.

[20] Lyu Chengqi, Zhang Wenwei, Huang Haian, et al. RTMDet: an empirical study of designing real-time object detectors[EB/OL]. (2022-12-16)[2026-08-26]. https://doi.org/10.48550/arXiv.2212.07784.

[21] Cheng Bowen, Misra I, Schwing A G, et al. Masked-attention mask transformer for universal image segmentation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). New Orleans, LA, USA. IEEE, 2022: 1280-1289.

(本文编辑 刘水红)