基于改进 Mask R-CNN 的前驱体颗粒检测方法①

武子健，肖晶峰，卓晓军，黄勇，夏星
（长沙矿冶研究院有限责任公司，湖南 长沙 410012）

摘　要：提出基于改进 Mask R-CNN 的前驱体颗粒检测方法，通过多分支特征提取颗粒特征并进行特征融合，由双分支输出模块输出前驱体颗粒检测结果。结果表明，该方法可使前驱体颗粒检测准确率达 93.2%，单张图像推理时间为 15.1 ms。模型兼具较高精度与实时推理效率，可为高一致性前驱体颗粒生产提供关键技术支撑。

关键词：深度学习；前驱体；颗粒检测；图像分割；Mask R-CNN；机器视觉
中图分类号：TF03　　**文献标志码**：A　　doi：10.3969/j.issn.0253-6099.2026.04.029
文章编号：0253-6099(2026)04-0190-06

A Precursor Particle Detection Method Based on Improved Mask R-CNN

WU Zijian, XIAO Jingfeng, ZHUO Xiaojun, HUANG Yong, XIA Xing
(*Changsha Research Institute of Mining and Metallurgy Co., Ltd., Changsha* 410012, *Hunan*, *China*)

Abstract: An improved Mask R-CNN based method for precursor particle detection is proposed. Multi-branch feature extraction is employed to capture particle features for feature fusion, and detection results of precursor particles are output through a dual-branch output module. The experimental results demonstrate that the proposed method achieves a detection accuracy of 93.2% for precursor particles, with an inference time of 15.1 ms per image. The model is characterized by both high accuracy and real-time inference efficiency, which can provide critical technical support for the production of highly-consistent precursor particles.

Key words: deep learning; precursor; particle detection; image segmentation; Mask R-CNN; machine vision

随着全球能源危机凸显以及碳减排需求持续提升，锂电池产业迅速发展[1]。相较于传统铅酸电池，锂电池具有能量密度高、充电快、循环次数多等优势[2]。三元正极材料因高能量密度成为动力电池主流选择，但其性能取决于前驱体颗粒的球形度、粒径分布等参数[3]。前驱体图像具有颗粒密集、边界模糊、噪声干扰强等特点，在目标检测、实例分割与粒径测量中存在粘连难分割、特征难提取等难点。传统人工检测前驱体颗粒的模式存在周期长、效率低、误差大等问题，难以满足高一致性前驱体颗粒的生产需求[4]。因此，采用自动识别方法（如使用计算机视觉技术）不仅能减少人工成本，还能实时观察前驱体颗粒的状态，以便及时调整工艺参数，确保前驱体颗粒的一致性。

目前机器视觉算法（如分水岭分割、Canny 边缘检测、Hough 变换等）受限于颗粒重叠、灰度不均和背景噪声，分割和检测的误差较大[5-6]。U-Net、SOLO-V2 和 Deep Snake 等深度学习方法在颗粒检测领域已取得显著进展[7-8]，但前驱体颗粒的形变、粘连、尺寸差异给检测的准确性带来困难[9]。针对这些问题，本文提出一种基于改进 Mask R-CNN 的前驱体颗粒检测方法，旨在克服前驱体颗粒识别准确率低的问题，在经典 Mask R-CNN 模型中加入多尺度特征提取模块，减少计算量的同时，显著提升模型对粘连、形变颗粒的识别能力；改进双分支输出模块，同步输出颗粒参数向量，实现全尺度颗粒检测性能的均衡提升。

1　基于改进 Mask R-CNN 的前驱体颗粒检测网络

1.1　Mask R-CNN 网络

Mask R-CNN 是一种创新性两阶段实例分割框架[10]，在保留目标空间位置的同时，为每个实例生成

① **收稿日期**：2026-03-16
基金项目：长沙矿冶研究院有限责任公司青年基金（23-C5ZN004）
作者简介：武子健（2001—），男，安徽蚌埠人，硕士研究生，主要研究方向为计算机视觉与动力电池回收。E-mail：2795446243@qq.com
通信作者：夏星（1983—），女，江西新余人，正高级工程师，主要研究方向为冶金智能化。E-mail：xiaxing@minmetals.com

像素级精度的分割掩码,具有出色的多任务学习能力和区域对齐机制,在颗粒识别中兼具检测与分割能力,能精准定位颗粒并逐像素勾勒轮廓。Mask R-CNN 使用特征金字塔网络 FPN(feature pyramid network)作为其核心特征提取结构;FPN 多尺度特征保障微米级小颗粒不漏检,端到端训练支持批量显微图像自动分析,显著节省人工耗时,在工业质检与机器视觉领域得到广泛应用和认可。

虽然 Mask R-CNN 在实例分割领域具有卓越表现和广泛适用性,但其骨干网络层数固定,提取的特征表达能力受限;默认 FPN 跳跃连接对所有通道和区域等权融合,无法突出关键缺陷或目标区域,极易受到背景噪声干扰;其计算复杂度和推理时间也极大限制了工业场景实时性。

1.2　PBLOCK 模块

传统 Mask R-CNN 以 ResNet101 为骨干网络,其输出的 C2~C5 多尺度特征直接输入 FPN 进行融合,缺乏对缺陷区域的针对性增强,导致分割精度受限。为此,本文引入 PBLOCK(多分支特征提取)特征增强模块:该模块首先将骨干输出特征按通道维度分割为1/3与 2/3 两部分;对 1/3 子特征,采用 DWConv 深度可分离卷积进行细粒度特征提取,再通过 SE 注意力模块进行通道重标定;随后将重标定后的 1/3 特征与 2/3 特征进行通道拼接,得到增强基础特征图;最后进行特征融合,通过自顶向下路径增强与侧向连接,在 P2~P5 各层级进行 2 次上采样与特征融合,输出 F2~F5 多尺度增强特征图。图 1 为 PBLOCK 模块结构图。

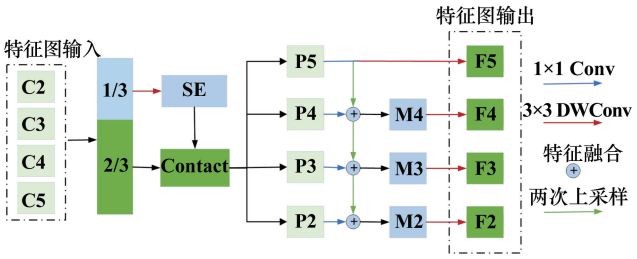


图 1　PBLOCK 模块结构图

Fig. 1　Structure of PBLOCK module

给定中间特征图 $F \in R^{H\times W\times C}$,PBLOCK 首先在通道维度上将 F 划分为 F_1 和 F_2 两部分:

$$\begin{cases} F_1 \in R^{H\times W\times \frac{C}{3}} \\ F_2 \in R^{H\times W\times \frac{2C}{3}} \end{cases} \tag{1}$$

式中 H、W、C 分别为图片的高度(像素)、宽度(像素)、通道数。

分支 F_1 经过以下步骤处理:

$$F_1' = \mathrm{SE}[\mathrm{DWConv}(F_1)] \tag{2}$$

将重标定后的特征 F_1' 与未处理的恒等映射分支 F_2 沿通道维拼接,得到模块输出 F_{out}:

$$F_{\mathrm{out}} = \mathrm{concat}(F'_1, F_2) \in R^{H\times W\times C} \tag{3}$$

式中 concat 表示沿通道维拼接。

将增强后的基础特征图 P2~P5 经 1×1 卷积输入模块内部的改进 FPN 结构,通过自顶向下路径增强与侧向连接机制,实现多尺度特征融合。

$$\begin{cases} M_2 = \mathrm{Upsample}(P_3) \oplus \mathrm{Conv}(P_2) \\ M_3 = \mathrm{Upsample}(P_4) \oplus \mathrm{Conv}(P_3) \\ M_4 = \mathrm{Upsample}(P_5) \oplus \mathrm{Conv}(P_4) \end{cases} \tag{4}$$

式中:Upsample 表示 2 次上采样;⊕表示逐元素特征融合。

最终,对融合后的中间特征通过 3×3 深度可分离卷积进行处理,输出多尺度增强特征 F2~F5。

相比传统特征融合方式,该模块能在保持轻量化的同时显著提升检测精度与细节还原度。

1.3　双分支输出模块

双分支输出模块(DBOH)以 RoIAlign 提取的空间对齐特征为输入,经卷积层进行特征变换后,通过全局平均池化(GAP)、反卷积(DEConv)及全连接(FC)分支,通过 1 次 1×1 降维与 2 条参数独立的并行分支,同步输出类别置信度、像素掩码及颗粒参数向量,并行实现目标分类、实例分割、边界框精修与多模态特征嵌入。给定来自主干网络的统一区域特征 $F \in R^{14\times 14\times 256}$,通过 1×1 卷积进行通道压缩:

$$F' = \mathrm{Conv}_{1\times 1}(F) \in R^{14\times 14\times 128} \tag{5}$$

DBOH 将特征 F' 分配至完全解耦的分类-分割双路结构,分类分支通过全局平均池化获得 128 维区域描述向量,经全连接层投影至 N_{class} 维输出类别 p_{cls}。

$$p_{\mathrm{cls}} = W_{\mathrm{cls}} \cdot \mathrm{GAP}(F') \in R^{N_{\mathrm{class}}} \tag{6}$$

式中:W_{cls} 为分类损失的权重系数;N_{class} 为类别数。

掩码分支采用 3×3 反卷积上采样至 28×28,再经 1×1 卷积生成颗粒特征掩码 M。

$$M = \mathrm{Conv}_{1\times 1}[\mathrm{DEConv}_{3\times 3}(F')] \in R^{28\times 28\times N_{\mathrm{class}}} \tag{7}$$

多模态分支对 F' 执行 GAP,获得 128 维区域表征后,经全连接层映射至 D 维连续空间:

$$v = W_{\mathrm{multi}} \cdot \mathrm{GAP}(F') \in R^{D} \tag{8}$$

式中:W_{multi} 为多模态损失的权重系数;D 为颗粒参数向量维度。

该输出向量作为嵌入特征输入后续检测网络,进一步优化前驱体颗粒检测。图 2 为双分支输出模块结构图。其设计兼顾轻量化与任务解耦性,在保证实时

性的同时,实现了检测、分割任务的高效融合。

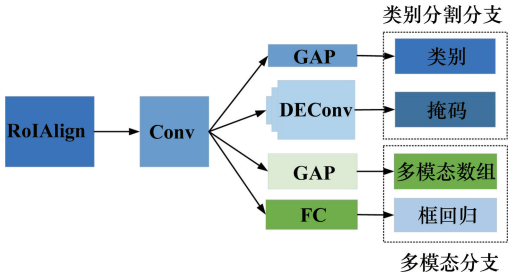


图 2 双分支输出模块结构图

Fig. 2 Structure of dual-branch output module

1.4 改进 Mask R-CNN 网络结构

针对原始 Mask R-CNN 中 FPN 单尺度、单层级上采样特征深度受限,导致粘连、形状不规则的前驱体颗粒图像实例分割边缘精度低、小目标漏检率高、无法识别具体缺陷类型的问题,本文提出改进 Mask R-CNN:模型在保持两阶段检测框架的前提下,结合 PBLOCK 模块提高模型特征提取和融合能力;结合双分支输出模块,输出颗粒特征多模态数组。改进后的 Mask R-CNN 网络结构如图 3 所示。

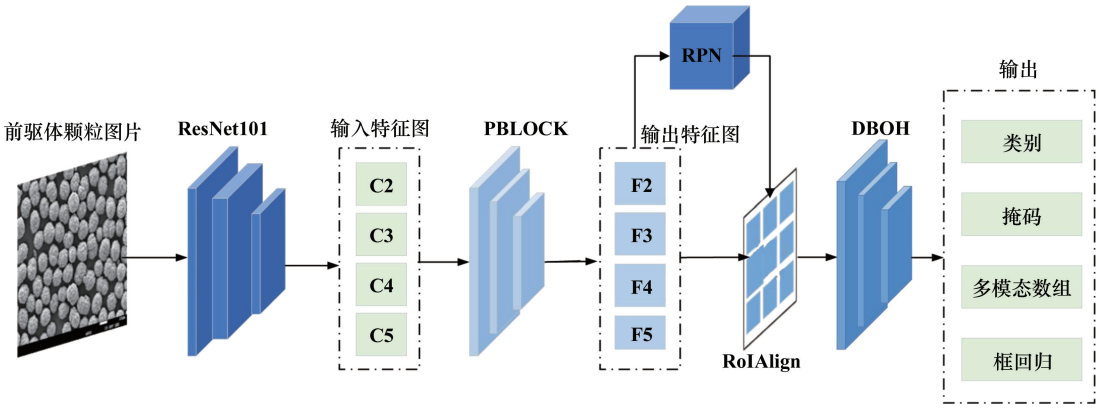


图 3 改进后的 Mask R-CNN 网络结构图

Fig. 3 Structure of improved Mask R-CNN network

通过设置分割损失、分类损失、边界约束损失、模态对齐损失这 4 类损失函数,实现对前驱体颗粒检测框架的多维度协同优化与表征对齐。

改进后的 Mask R-CNN 对处理小样本数据集的效果非常突出,但图像中颗粒边缘像素点分布较少,部分图像中颗粒较少而背景较多,因此特别设置损失函数。

总损失函数公式如下:

$$L = \lambda_1 L_{seg} + \lambda_2 L_{cls} + \lambda_3 L_{edge} + \lambda_4 L_{align} \tag{9}$$

式中 $\lambda_1 = \lambda_2 = \lambda_3 = \lambda_4 = 0.25$。

1) 分割损失 L_{seg} 结合二元交叉熵(BCE)与 Dice Loss 提升小缺陷区域检测性能。

$$L_{seg} = \mathrm{BCE}(Y, \hat{Y}) + 1 - \frac{2|Y \cap \hat{Y}|}{|Y| + |\hat{Y}|} \tag{10}$$

2) 分类损失 L_{cls} 采用交叉熵函数。

$$L_{cls} = -\sum_{c=1}^{C} y_c \ln(\hat{y}_c) \tag{11}$$

3) 边界约束损失 L_{edge} 利用 Sobel 边缘梯度保持预测边界平滑。

$$L_{edge} = \| \nabla Y \hat{Y} - \nabla Y \|_1 \tag{12}$$

4) 模态对齐损失 L_{align} 保证图像与参数特征嵌入空间一致性。

$$L_{align} = \| Z_{img} - Z_{reg} \|_2^2 \tag{13}$$

2 实验设置

2.1 数据采集和预处理

图 4 为数据采集流程。由图 4 可知,将前驱体颗粒样本置于扫描电镜下获取整体微观分布图像;随后,针对图像中具有代表性的局部区域进行细节提取,得到分别代表大、中、小颗粒的多尺度微观形貌细节图。

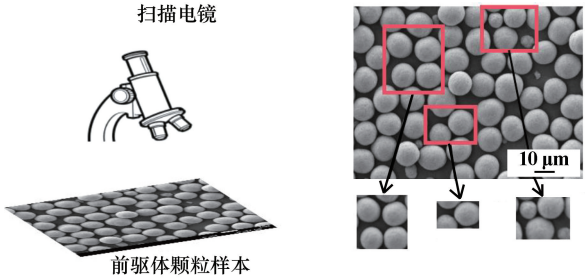


图 4 数据采集流程

Fig. 4 Schematic diagram of data acquisition

在不同环境中使用高精度显微电镜采集前驱体颗粒图像 3 000 张,利用各种数据增强方法获得有效数据集,从数据集中随机选取 8 张样本图片,如图 5 所示。

为了判断前驱体颗粒的属性(粒度大小、等效直

径以及球形度等)识别是否准确,采用标准数据库进行对比,从而实现对前驱体颗粒特征参数的准确提取和比对。

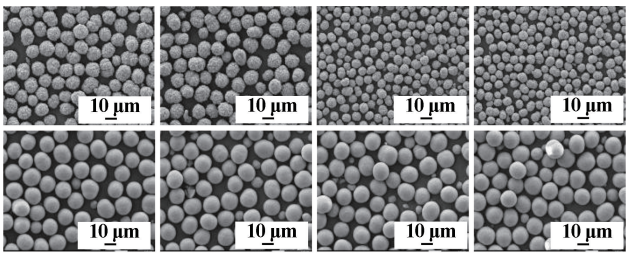


图 5　Particle-PL 数据集

Fig. 5　Particle-PL dataset

2.2　评价指标

为评估模型在实例分割任务中的性能,本文采用多维度评估指标体系进行评价。该体系包括单阈值平均精度($AP_{0.50}$)、全测试集综合平均精度(mAP)和各尺度的平均精度(AP_S、AP_M、AP_L)。

基于所有检测结果计算的像素级掩码平均精度,对全测试集排序后的精确率 P-召回率 R 曲线积分后得到:

$$AP_{0.50} = \int_0^1 P(R)\,dR \tag{14}$$

式中 $P(R)$ 为在 IoU 阈值 0.50 下的精确率随召回率的变化曲线。

$$mAP = \frac{\sum_{t\in[0.50,0.95]} AP_t}{10} \tag{15}$$

式中:mAP 表示模型在 IoU ∈ [0.50, 0.95]、步长为 0.05 条件下,10 个阈值下的综合分割精度;AP_t 为固定 IoU 阈值等于 t 条件下的平均精度。

为进一步分析模型对不同粒径颗粒的检测能力,将测试集样本按真实掩码面积 A_{gt} 分为 3 档,分别对应小、中、大颗粒:

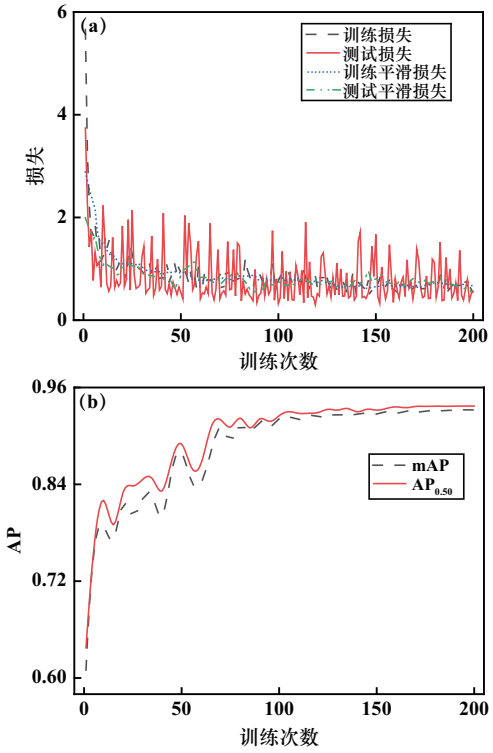
$$\begin{cases} \text{小颗粒:} & 0 < A_{gt} < 89^2 \\ \text{中颗粒:} & 89^2 \leqslant A_{gt} < 133^2 \\ \text{大颗粒:} & A_{gt} \geqslant 133^2 \end{cases} \tag{16}$$

采用与 mAP 相同的 10 阈值 IoU 策略分别计算 AP_S、AP_M、AP_L,从而得到模型在不同粒径颗粒检测场景下的性能分布。

2.3　模型训练

采用 Adam 优化器,初始学习率设置为 0.01,批量大小 8;采用 L2 正则化,权重衰减为 0.000 1,学习率采用步长下降策略。改进模型基于 NVIDIA RTX 4090 显卡开展训练,共训练 200 个轮回。

图 6 为改进后 Mask R-CNN 模型对实验获取颗粒图像训练流程。利用 LabelMe 进行图像标注并制作数据集,用于模型训练,直至损失函数值稳定,分割准确率收敛,模型拟合完成。



(a) 损失函数值曲线;(b) 分割准确率曲线

图 6　改进后 Mask R-CNN 模型对实验获取颗粒图像训练流程

Fig. 6　Training pipeline for improved Mask R-CNN using experimentally captured particle images

3　实验结果及分析

3.1　消融实验

为验证本文提出的网络中各功能模块的有效性与性能贡献,对比训练了 5 种不同结构的模型进行消融实验。各模型在相同的训练与测试设置下完成训练,消融实验结果见表 1。由表 1 可知,模型 c 在保留细粒度特征的同时,强化全局特征提取与边界框精修能力,小幅提高模型精度。模型 b 在中小颗粒上精度更高,而在大颗粒上表现弱于模型 d,主要原因在于模型 b 所采用的多分支特征提取结构更擅长捕捉细粒度空间信息与边缘特征,对纹理复杂、尺度较小的目标具有更强表征能力,因此在中、小颗粒上优势明显,但该结构对全局上下文依赖较弱,在大尺度目标上易出现特征冗余与定位偏差。模型 d 在模型 b 基础上加入双分支输出模块,更适合捕捉前驱体颗粒的全局特征,各尺度

平均精度显著提升,mAP 达到了 93.2%,显著优于其他模型,但该模块在一定程度上稀释了纯细粒度特征占比,使得中小颗粒精度略有降低。

表 1 消融实验结果

Table 1 Result of ablation study %

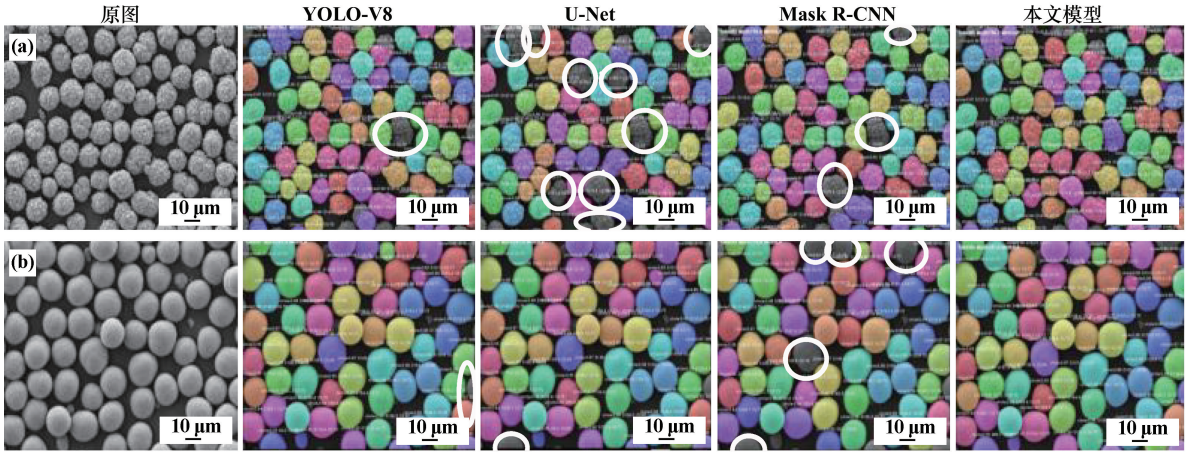
模型名称	AP_L	AP_M	AP_S	$AP_{0.50}$	mAP
a	90.0	83.2	87.6	88.2	84.2
b	85.6	93.4	94.5	91.1	90.1
c	84.2	84.3	83.2	90.0	85.0
d	92.4	90.9	94.1	93.7	93.2

注:模型 a 为原始 Mask R-CNN;模型 b、c 分别引入 PBLOCK、DBOH 模块;模型 d 同时引入 PBLOCK 和 DBOH 模块。

综合分析,本文提出的改进策略能有效缓解粘连颗粒过分割与颗粒漏检的问题,在保证轻量化的同时,实现更高的实例分割精度与更稳定的检测性能。

3.2 主流算法对比

为验证所提模型在前驱体颗粒实例分割任务中的性能优越性,基于所提评价体系设计对比实验,将使用自建数据集训练的结果与其他主流算法进行比较。图 7 为不同检测模型效果图对比,表 2 为不同检测模型结果对比。由图 7 和表 2 可知,不同模型的两类前驱体颗粒图片检测结果存在显著差异。基线模型 Mask R-CNN 受传统 FPN 等权融合机制与庞大参数量限制,且 mAP 仅为 84.2%;U-Net 因缺乏实例级区分能力,各项指标数值均为最低,无法适配颗粒个体检测需求;YOLO-V8 整体性能较好,但综合性能不及本文模型。本文模型在各项指标中均表现出显著优势,较模型 YOLOv8 的 mAP 值提升了 2.9 百分点。



(a) 低镍型三元前驱体 SEM 图像;(b) 高镍型三元前驱体 SEM 图像

图 7 不同检测模型效果图对比

Fig. 7 Comparison of visual results of different detection models

表 2 不同检测模型结果对比

Table 2 Comparison of different detection models %

模型名称	$AP_{0.50}$	AP_S	AP_M	AP_L	mAP
YOLO-V8	90.0	93.1	94.1	94.4	90.3
U-Net	80.6	81.2	81.0	84.3	78.3
Mask R-CNN	88.2	87.6	83.2	90.0	84.2
本文模型	93.7	92.6	90.9	92.4	93.2

表 3 为模型复杂度和计算时间分析。由表 3 可知,YOLO-V8 模型在轻度与计量化与实时性的平衡上优势显著,本文模型相较于 Mask R-CNN 模型,可有效减少参数量和计算时间,其单张图像推理时间为 15.1 ms。

综上,本文模型通过轻量化特征提取与任务解耦架构的协同优化,可实现参数量与推理效率的高效平衡。

表 3 模型复杂度与计算时间分析

Table 3 Analysis of model complexity and computation time

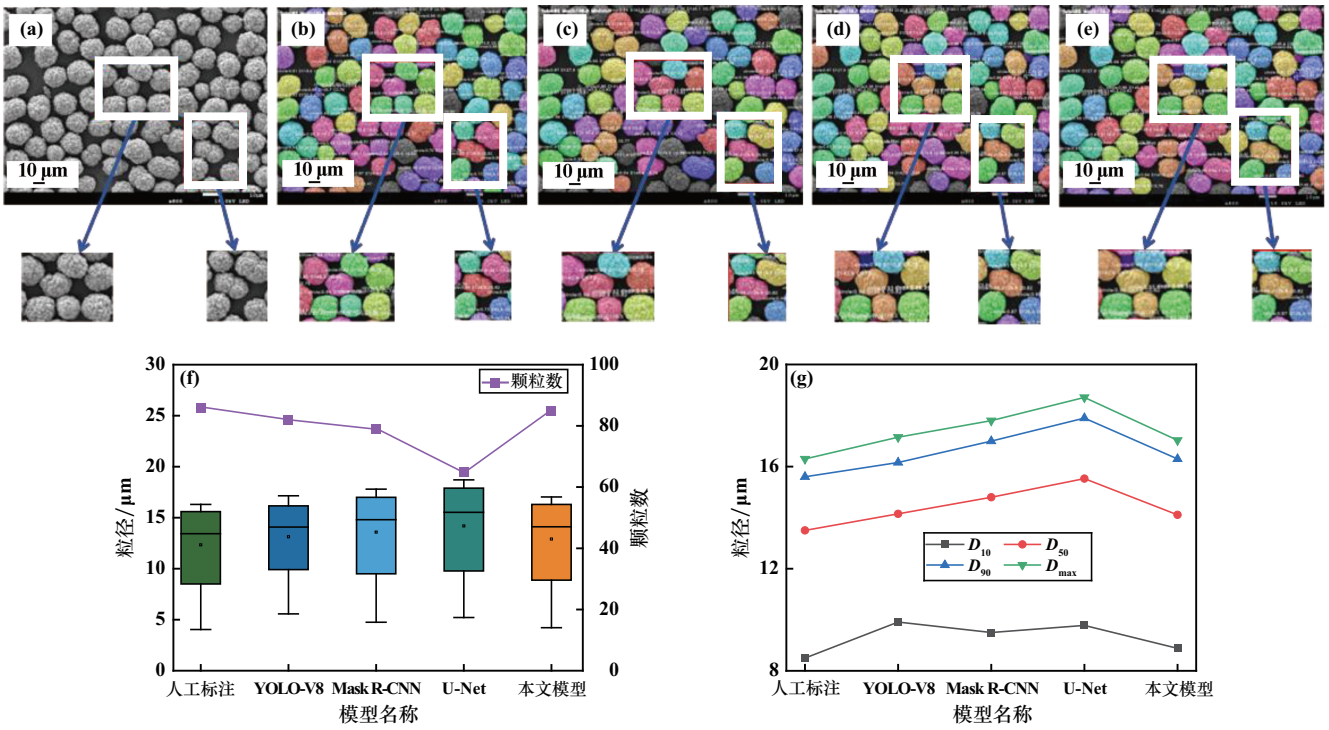
模型名称	模型尺寸/MB	参数量/M	时间/ms
YOLO-V8	6.5	3.2	8.5
Mask R-CNN	124.0	32.2	27.1
U-Net	178.0	46.4	36.9
本文模型	101.0	28.5	15.1

3.3 检测效果分析

为系统验证本文所提模型在前驱体颗粒检测任务中的可视化性能与量化精度,从实例分割可视化、识别精准度及粒径分布量化 3 个维度展开分析。图 8 为不同模型检测效果对比。其中 D_{10}、D_{50}、D_{90}分别为累计 10%、50%、90%对应的粒径,D_{max}为最大颗粒粒径。由图 8 可知,本文模型在显微图像颗粒分割与粒径量化任务中表现最佳,其中 D_{10}、D_{50}、D_{90}、D_{max}等粒径指标及

颗粒数量统计结果均更接近人工标注,误差显著低于 YOLO-V8、Mask R-CNN 和 U-Net 等模型。本文模型粒径累计分布曲线与真实分布高度重合,有效解决了颗粒漏检、边界混淆及粒径估算偏差等问题,在分割准确率、粒径量化精度和分布拟合度上全面优于对比模型。本文模型实现了高精度的显微图像颗粒智能化分析,可为相关领域提供可靠技术支撑。

然而,本研究仍存在若干局限性:① 跨模态泛化能力有待验证,当前模型依赖高精度 SEM 图像输入,对光学显微等低成本成像模态的泛化能力尚未充分验证;② 损失函数权重缺乏自适应机制,损失函数的权重分配采用经验性超参数设定,未能实现动态自适应调整;③ 时序动力学特征尚未挖掘,本研究聚焦于静态图像分析,未涉及时序维度上颗粒生长动力学特征的挖掘。



(a) 原图;(b) YOLO-V8;(c) U-Net;(d) Mask R-CNN;(e) 本文模型;(f) 不同模型颗粒粒径分布箱线图;(g) 不同模型颗粒粒径参数对比图

图 8　不同模型检测效果对比

Fig. 8　Comparison of visual results for different detection models

4　结论

1) 实验结果表明,本文模型综合检测准确率在自建数据集上达到 93.2%,模型优越性得到充分验证。

2) 本文模型框架通过通道剪枝与深度可分离卷积,有效缓解了传统模型梯度退化与冗余计算问题,而 SE 注意力机制与边缘加权策略则显著增强了对粘连颗粒及微尺度缺陷的辨识能力。

参考文献(References):

[1] 马颢菲,武晓燕,苑鹏. 新能源汽车废旧锂电池回收利用技术与产业现状[J]. 再生资源与循环经济, 2025,18(8):31-37.
Ma Haofei, Wu Xiaoyan, Yuan Peng. The recycling technologies and industry of spent LIBs from EVs[J]. Recyclable Resources and Circular Economy, 2025,18(8):31-37.

[2] 熊杰,于海波,李响,等. 储能锂电池充放电特性和热管理研究[J]. 储能科学与技术, 2026,15(2):616-627.
Xiong Jie, Yu Haibo, Li Xiang, et al. Research on charge-discharge characteristics and thermal management of lithium battery for energy storage[J]. Energy Storage Science and Technology, 2026,15(2):616-627.

[3] 白立雄,贡浩天,甘柏瑶,等. 前驱体合成工艺对高镍三元正极材料性能的影响[J]. 矿冶工程, 2025,45(1):133-137.
Bai Lixiong, Gong Haotian, Gan Boyao, et al. Influence of precursor synthesis process on nickel-rich NCM cathodes[J]. Mining and Metallurgical Engineering, 2025,45(1):133-137.

[4] 高策,张素良,杨洋,等. 晶种串釜法共沉淀工艺制备超高镍三元前驱体[J]. 有色金属(冶炼部分), 2025(6):182-190.
Gao Ce, Zhang Suliang, Yang Yang, et al. Preparation of ultra-high nickel ternary precursor by pre-seeded co-precipitation process[J]. Nonferrous Metals (Extractive Metallurgy), 2025(6):182-190.

[5] Kim H, Han J, Han T Y. Machine vision-driven automatic recognition of particle size and morphology in SEM images[J]. Nanoscale, 2020, 12(37):19461-19469.

(下转第 202 页)

Zeng Xianping, Chen Jianhong. The effect of synergistic phytoremediation of phragmites australis and nymphaea tetragona on heavy metal wastewater with Mn contained[J]. China Manganese Industry, 2023, 41(4):22-25.

[8] 高春丽,周涵君,李先振,等. 吸附剂在重金属污染废水修复中的研究进展[J]. 工业水处理, 2023,43(9):1-19.
Gao Chunli, Zhou Hanjun, Li Xianzhen, et al. Research progress of adsorbents in the remediation of heavy metal contaminated wastewater[J]. Industrial Water Treatment, 2023,43(9):1-19.

[9] 杨建林,胡迎丽,李伟源,等. SiO_2@松香基阳离子交换树脂对水中微量Cd吸附[J]. 化学研究与应用, 2022,34(1):18-25.
Yang Jianlin, Hu Yingli, Li Weiyuan, et al. Study on adsorption of trace of Cd^{2+} in water with SiO_2@rosin-based cationic exchange resin[J]. Chemical Research and Application, 2022,34(1):18-25.

[10] 李贝贝,张亚平,郭炳跃,等. 生物炭/凹凸棒石复合材料对铅镉的吸附[J]. 农业环境科学学报, 2023,42(5):1116-1127.
Li Beibei, Zhang Yaping, Guo Bingyue, et al. Adsorption characteristics of Cd^{2+} and Pb^{2+} on biochar/attapulgite composites[J]. Journal of Agro-Environment Science, 2023,42(5):1116-1127.

[11] 周荣忠,谢锦文,李攀荣,等. 有机硅生产行业重金属废水膜分离技术研究[J]. 中国给水排水, 2022,38(13):90-96.
Zhou Rongzhong, Xie Jinwen, Li Panrong, et al. Membrane technology for heavy metal separation from organic silicon production industry wastewater[J]. China Water & Wastewater, 2022,38(13):90-96.

[12] 税桂鸿,程晓英,刘强,等. 电化学-膜分离法组合工艺深度处理化工废水中水研究[J]. 水处理技术, 2023,49(4):124-127.
Shui Guihong, Cheng Xiaoying, Liu Qiang, et al. Study on advanced treatment and reuse of chemical industry wastewater by combined process of electrochemical-membrane separation method[J]. Technology of Water Treatment, 2023,49(4):124-127.

[13] 张天石,李佼妍. 基于金属有机骨架材料负载型催化剂的研究进展[J]. 辽宁化工, 2022,51(11):1636-1640.
Zhang Tianshi, Li Jiaoyan. Research progress of supported catalysts based on metal organic frameworks[J]. Liaoning Chemical Industry, 2022,51(11):1636-1640.

[14] 康永锋,董清丽,于颖媛,等. 改性环糊精金属有机骨架材料对亚甲基蓝吸附性能研究[J]. 安全与环境学报, 2023,23(4):1231-1240.
Kang Yongfeng, Dong Qingli, Yu Yingyuan, et al. Adsorption performances of carboxylated cyclodextrin-based metal-organic framework for MB[J]. Journal of Safety and Environment, 2023,23(4):1231-1240.

[15] 李庆,陈灵辉,李丹,等. 锆-金属有机骨架对印染废水中Cr(Ⅵ)的高效检测[J]. 西安工程大学学报, 2022,36(3):46-53.
Li Qing, Chen Linghui, Li Dan, et al. High efficiency detection of Cr(Ⅵ) in printing and dyeing wastewater by Zr-metal organic frameworks[J]. Journal of Xi'an Polytechnic University, 2022,36(3):46-53.

引用本文:陈宁,张辉,杨金梅. 改性UIO-66对水溶液中铅、锌、锰离子的吸附研究[J]. 矿冶工程, 2026,46(4):196-202.
Chen Ning, Zhang Hui, Yang Jinmei. Adsorption performance of modified UIO-66 for lead, zinc and manganese ions in aqueous solution[J]. Mining and Metallurgical Engineering, 2026,46(4):196-202.

(上接第195页)

[6] 陈宗元,张磊磊,赵宁宁,等. 混合颗粒系重叠图像分割与分类方法研究[J]. 计量学报, 2022,43(6):746-753.
Chen Zongyuan, Zhang Leilei, Zhao Ningning, et al. Research on segmentation and classification methods of mixed overlapped particle images[J]. Acta Metrologica Sinica, 2022,43(6):746-753.

[7] Zhang R, Li K L, Yu F, et al. Aggregate particle identification and gradation analysis method based on the deep learning network of Mask R-CNN[J]. Materials Today Communications, 2023,35:106269.

[8] 苏丽,孙雨鑫,苑守正. 基于深度学习的实例分割研究综述[J]. 智能系统学报, 2022,17(1):16-31.
Su Li, Sun Yuxin, Yuan Shouzheng. A survey of instance segmentation research based on deep learning[J]. CAAI Transactions on Intelligent Systems, 2022,17(1):16-31.

[9] Latif G, Bouchard K, Maitre J, et al. Deep-learning-based automatic mineral grain segmentation and recognition[J]. Minerals, 2022, 12(4):455.

[10] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2):386-397.

引用本文:武子健,肖晶峰,卓晓军,等. 基于改进Mask R-CNN的前驱体颗粒检测方法[J]. 矿冶工程, 2026,46(4):190-195.
Wu Zijian, Xiao Jingfeng, Zhuo Xiaojun, et al. A precursor particle detection method based on improved Mask R-CNN[J]. Mining and Metallurgical Engineering, 2026,46(4):190-195.