基于改进 UNet 网络的烧结矿粘连图像分割研究

张学锋[a]，史 桢[a]，周思雨[a]，余正伟[b]，陈良军[b]，龙红明[b]
（安徽工业大学 a. 计算机科学与技术学院；b. 冶金工程学院，安徽 马鞍山 243002）

摘要： 为了解决烧结矿粒度识别过程中颗粒形状不规则、边缘模糊、高度粘连，难以识别的问题，提出了一种基于多尺度特征融合的改进 UNet 网络对烧结矿图像进行分割。该网络通过引入残差和密集连接，并加入 SE 模块（squeeze excitation block）进行特征融合，提取低层次精确的轮廓信息，解决烧结矿轮廓特征利用率低的问题；每层利用多尺度密集连接，完成非对称信息交换，有效缓解编码特征和解码特征之间的语义鸿沟问题；在解码器部分添加两个解码器，引入烧结矿轮廓特征，进行多任务学习并形成新的损失函数，利用轮廓信息来约束烧结矿对象掩码分割，提高粘连烧结矿轮廓分割能力。试验结果表明，改进的 UNet 网络与其他网络相比，显著提高了粘连烧结矿图像的分割准确度，为烧结矿粒度的准确识别奠定了基础。

关键词： 语义分割；烧结矿；图像分割；多任务学习；UNet 网络
中图分类号： TF046.4；TP751；TP183 **文献标识码：** A **文章编号：** 1000－8764（2023）06－0083－07
doi： 10.13403/j.sjqt.2023.06.088

Research on image segmentation of sinter adhesion based on improved UNet network

ZHANG Xuefeng[a]，SHI Zhen[a]，ZHOU Siyu[a]，YU Zhengwei[b]，CHEN Liangjun[b]，LONG Hongming[b]
（Anhui University of Technology a. School of Computer Science and Technology；b. School of Metallurgical Engineering，Ma'anshan 243002，Anhui，China）

Abstract: In order to solve such problems as irregular particle shape，fuzzy edges，high adhesion and difficult to identify in the process of sinter particle size recognition，an improved UNet network based on multi-scale feature fusion to segment sinter images is proposed. By introducing residuals and dense connections and adding the SE module for feature fusion，a low-level accurate profile information is extracted and the problem of low utilization rate of sinter profile features is solved. Multi-scale dense connection is used by each layer to complete asymmetric information exchange，which effectively alleviates the semantic gap between encoded features and decoded features. Two decoders are added to the decoder part，the sinter profile feature is introduced，the multi-task learning is carried out，a new loss function is formed，and the profile information is used to constrain the mask segmentation of the sinter object，so as to improve the ability of the adhesion sinter profile segmentation. The results show that the improved UNet network significantly improves the segmentation accuracy of the adhesion sinter image compared with other networks，and lays a foundation for the accurate identification of sinter particle size.

Key words: semantic segmentation；sinter；image segmentation；multi-task learning；UNet network

随着对烧结矿产品质量和性能要求的提高，烧结矿粒度在线检测方法备受关注。然而，该领

收稿日期： 2023－11－08；**修回日期：** 2023－11－25
基金项目： 国家自然科学基金资助项目（52204331）
作者简介： 张学锋（1978—），男，博士，教授，从事计算机软件及仿真模型方面的研究。
通信作者： 余正伟（1984—），男，博士，副教授，从事冶金智能化与低碳冶金领域方面的研究。

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

域面临多重挑战。首先，烧结矿的物理特性(如粒度分布、颗粒形状、密度)变化范围大，要求在线检测具备高适应性和鲁棒性；其次，高速连续检测需要检测方法具备高速数据采集和处理能力，以满足实时性的要求；另外，烧结矿的粒度分布广泛，需要检测方法能够准确测量不同粒径的颗粒；同时，复杂环境条件和高检测精度要求也是挑战之一。为解决这些问题，研究人员和工程师致力于不断开发和改进各种在线检测方法，以满足烧结矿生产中的实时监测和控制需求。

黄鹏等[1]提出基于机器视觉的烧结矿粒度在线检测方法，利用机器视觉获取烧结矿高清图像，并利用传统图像分割方法进行烧结矿边缘分割，从而实现烧结矿粒度识别。常用的传统图像分割方法有阈值法[2]、边缘分割法[3]、区域分割法[4]及其他基于特定理论的方法。在众多的建模方法中，UNet作为一种经典的卷积神经网络架构，具备了一些优势。UNet的编码器-解码器结构能够有效地捕捉图像中的上下文信息并保留细节特征，适用于处理烧结矿粘连图像的复杂结构和多尺度信息。此外，UNet在数据量较少的情况下仍能表现出良好的性能，这对于烧结矿粘连图像分割这类数据采集和标注困难的任务尤为重要。近年来，因卷积神经网络在图像分割上具有图像分割效率高、结果准确的特点而受到广泛关注，取得了较好的研究成果。UNet[5]及其变体和其它语义分割网络相继被提出，在语义分割领域取得重大突破。然而，广泛的研究表明UNet网络具有冗余太大、感受野和定位精度不可兼得的问题，因此学者们提出了不同的UNet模型变体。MIAO等[6]提出一种改进的UNet模型，该模型包括挤压和激发(SE)与ResNet块的组合，能够在训练过程中拟合扰动，提高结果的准确性。柳小波等[7]利用UNet和Res_UNet生成矿石轮廓检测和优化模型，采用分割加优化两阶段方案进行矿石图像分割，效果有所提升，但该模型也增加了近一倍的参数量。为提取更多的低层特征，IBTEHAZ等[8]用MultiRes块替换了两个卷积层的序列，使用残差模块和密集跳跃连接，叠加不同层次的特征，提取更多低层特征信息。王俊杰等[9]提出多尺度特征融合，充分利用低级特征，进行小样本遥感图像中建筑物的提取。WANG等[10]设计了两个并行网络来提取岩石对象和轮廓掩模，采用掩模融合算法分割对象掩模中的连接岩石区域，减少了参数量，有效地检测了图像中的大型岩石颗粒，但没有涉及小型岩石颗粒的分割。

本文利用残差和SE通道注意力提出新的模块，以提取更多的烧结矿轮廓信息。借鉴文献[10]中并行网络思想，构建两个解码器，将轮廓信息融合到对象特征信息中，提高烧结矿轮廓信息特征提取能力，并在网络架构上采用多尺度密集连接，叠加不同层次的烧结矿特征，进行非对称信息交换。改进后的算法，提高了粘连烧结矿图像的分割性能，这对实现烧结矿粒度检测具有重要意义。

1 网络结构与算法原理

1.1 改进的UNet网络结构

UNet是一种经典的深度学习网络结构，广泛应用于图像分割任务。烧结矿作为一种复杂的物料，其物理特性包括粒度分布、颗粒形状、密度等具有较大的变化范围，因此在线检测方法需要具备高适应性和鲁棒性。直接使用UNet网络难以准确分割，因为它对不同结构和纹理的烧结矿表现不佳，对不同尺度、形状和光照条件的图像缺乏自适应性。本文在UNet中引入EX-B卷积，加入SE模块，利用双解码器进行图像分割。EX-B卷积可以提高网络对于图像特征的抽样和表达能力，帮助模型更好地捕捉烧结矿粘连图像中的复杂特征。在EX-B模块上通过灵活加入SE通道注意力机制，能够自适应地调整特征通道的权重，增加分割精度。双解码器能够更好地捕捉图像的边界信息，可以提高分割结果在边界处的清晰度和精确性。

改进的UNet网络结构利用EX-B模块进行卷积，并在每层设置多尺度密集连接，进行上下文信息特征提取，如图1所示。图1中，该网络使用特征复制拼接(Cat)操作将特征提取部分和上采样(Upsampling)部分的特征进行拼接融合，通过最大池化(Maxpool)聚合特征映射的空间信息，加入SE

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

通道注意力机制，用转置卷积(ConTranspose) 将低维特征图进行上采样还原图像分辨率，并通过跳跃连接(short connection) ，执行非对称信息交换，信息传播不会退化。图中 L3 层中，用 EX-B 模块进行运算，构造了 3 种尺度的感受野以提取不同大小的烧结矿特征，进行局部和全局信息的整理和融合，因为模块中存在残差连接，可降低过拟合风险。为了对多尺度密集连接模块功能进行形式化分析，设 x 为该层模块的输入特征，y 为输出结果，$B(\ )$ 为模块运算函数，z_i 为每个模块得到的结果，$C(\ )$ 表示拼接运算。传递过程见式(1) 和式(2) 。

$$\begin{cases} z_0 = B(x) \\ z_1 = B[B(x)] \\ z_2 = B\{B[B(x)]\} \end{cases} \tag{1}$$

$$y = C(z_0, z_1, z_2) \tag{2}$$

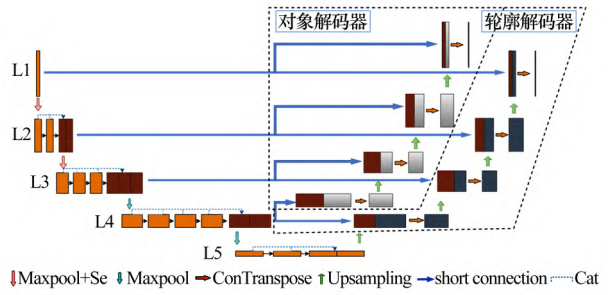


图 1　网络整体架构

Fig. 1　Overall structure of network architecture

1. 2　解码器的特征提取模块

模型解码器的特征提取模块由扩展结构模块 EX-B(expansion block) 和 SE 模块组成，具体结构如图 2 所示。其中，扩展结构模块 EX-B 借鉴 Inception block [11] 利用浅层特征的思想，将第一层 3 × 3 卷积学习到的特征直接传递给它后面的层，从而实现多尺度特征提取，减少参数量，具体结构如图 2(a) 所示。在烧结矿粘连图像分割任务中，这些特征图像可以帮助理解图像中的不同结构和纹理，从而更好地分割出粘连区域。EX-B 分为两部分，一部分将输入特征经过一次 3 × 3 Conv 卷积、Relu 激活函数和 2 × 2 最大池化后，再进行同样的卷积运算，最后将这两部分拼接进行特征融合，再进行 1 × 1 Conv 卷积操作；另一部分用 1 × 1 Conv 卷积对输入集合进行特征映射，再进行相加操作，输出结果，避免梯度消失和梯度爆炸问题。通过两部分的结合，可实现不同通道的特征信息融合，降低网络参数量，有利于烧结矿细节信息的传递。公式见式(3) ~(5) 。

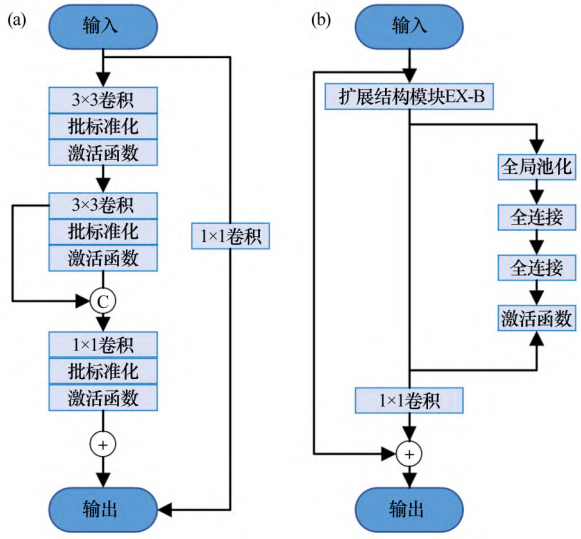
$$X_i + 1 = W(X_i),\ 0 \leqslant i \leqslant 2 \tag{3}$$

$$c = C[W(X_1), W(X_2)] \tag{4}$$

$$Y = W(X_0) + W(c) \tag{5}$$

式中：X_i 为输入的特征所经历的卷积层；$W(\ )$ 为卷积运算；$C(\ )$ 为拼接运算；c 表示拼接结果；Y 为解码器特征提取模块的最终结果。

此外，该网络在 EX-B 模块上通过灵活加入 SE 通道注意力机制，提升烧结矿分割精度，具体结构如图 2(b) 所示。该网络使用全局平均池化(global average pooling) 作为 Squeeze 操作，紧接着两个 Fully Connected 层去建立通道间的相关性，并通过一个激活函数(Sigmoid) 获得 0 ~ 1 之间归一化的权重，值越大，代表该通道重要性越高。最后对输入值用短连接进行相加操作，避免梯度消散。通过模型学习，网络自动获取重要通道特征。



(a) SE; (b) EX-B

图 2　扩展模块 SE 模块和 EX-B

Fig. 2　Expansion module SE module and EX-B

1. 3　双解码器结构

由于烧结矿表面纹理与轮廓边缘非常相似，且粘连严重，在处理粘连图像对象时，轮廓信息与掩码信息一样重要，为此本文提出双解码器，将烧结矿轮廓信息引入到特征提取中，如图 3 所示。图 3 中，设置两个并行解码器，各自学习烧结矿的特征，两个解码器共用一个编码器进行信

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

息提取，降低了计算成本。

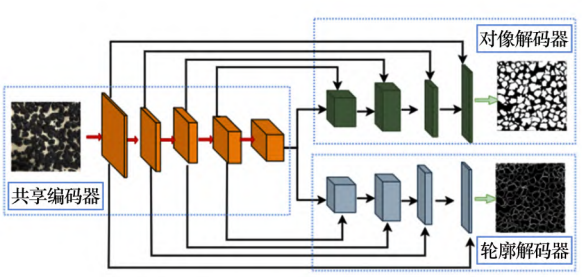


图3 双解码器网络架构

Fig. 3 Network architecture of dual decoder

在训练过程中，利用烧结矿轮廓边界信息来限制对象掩码网络的分割，得到精确分割结果。由于只有烧结矿对象(烧结矿轮廓)和背景这两个类别，因此都采用二元交叉熵损失函数，分别记为 ls_1 和 ls_2，如式(6)~(8)所示。ls_1 计算样本和对象标签的损失，ls_2 计算样本和轮廓标签的损失。最终 L 损失是加权和 [式(9)]，其中权重设置为0.8。

$$l = -\frac{1}{N}\sum_i \left[y_i \cdot \log(p_i) + (1-y_i) \cdot \log(1-p_i)\right] \tag{6}$$

$$ls_1 = l \tag{7}$$

$$ls_2 = \lambda \times l \tag{8}$$

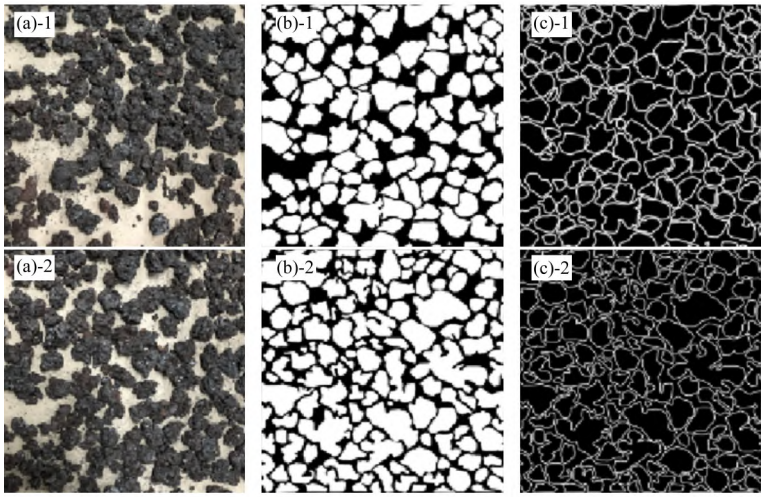
$$L = (ls_1 + ls_2)/(1+\lambda) \tag{9}$$

式中：y_i 为样本 i 的 label，正类为1，负类为0；p_i 为样本 i 预测为正类的概率；λ 是用于平衡损失函数之间的权重系数；N 为总的像素个数。

2 试验结果与分析

2.1 数据集的制作

本文利用工业相机采集了尺寸为3 012×3 012像素大小的烧结矿图像500张作为数据样本。为增加训练速度和效果，首先将烧结矿图像裁剪成为512×512像素小尺寸图像，再将数据集划分为训练集、验证集和测试集，并利用 labelme 工具对数据样本进行标注处理。图4(a)是数据图像，图4(b)是通过人工标注的对象掩码标签，图4(c)是通过人工标注的轮廓标签。本文为了增加训练模型的鲁棒性及数据特征的复杂性，在数据准备过程中，对数据进行图像预处理操作，并对训练集和验证集进行数据增强操作，做随机旋转、翻转和镜像等处理扩充样本的数量，测试集不作数据增强处理。



(a)-1、(a)-2 原图；(b)-1、(b)-2 对象标签；(c)-1、(c)-2 轮廓标签

图4 原图与标签

Fig. 4 Original image and label image

2.2 试验设置与评价指标

试验在 Windows 10 系统下运行，基于 GeForce RTX 3090 GPU 的硬件平台搭建的 PyTorch 深度学习框架上进行训练，Python 版本为3.8，并使用 Adam 作为模型的优化器，动量设置为0.9，设置批量尺寸为4，学习率为0.000 1，epoch 设置为120，OpenCV 用于检测和统计烧结矿图像。

为了定性地验证本文提及的方法，试验采用相似度系数(δ_{Dice})、类别平均像素准确率 δ_{mPA} 指标和平均交并比(δ_{mIoU})进行量化分析[12]。δ_{Dice} 是

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

指计算两个样本点的相似度；δ_{mPA}表示烧结矿图像中类别内像素正确分类概率的平均值；δ_{mIoU}是预测值和真实值的交集与并集的比值。计算公式如式(10)～式(12)。

$$\delta_{\mathrm{Dice}}=\frac{2\mid R_{\mathrm{pred}}\cap R_{\mathrm{gt}}\mid}{\mid R_{\mathrm{pred}}\mid+\mid R_{\mathrm{gt}}\mid}=\frac{2T_{\mathrm{p}}}{2T_{\mathrm{p}}+F_{\mathrm{p}}+F_{n}} \tag{10}$$

$$\delta_{\mathrm{mPA}}=\frac{\sum_{i=1}^{N}T_{\mathrm{p}i}}{\sum_{i=1}^{N}(T_{\mathrm{p}i}+F_{\mathrm{p}i})} \tag{11}$$

$$\delta_{\mathrm{mIoU}}=\frac{1}{N}\sum_{i=1}^{N}\frac{T_{\mathrm{p}i}}{T_{\mathrm{p}i}+F_{\mathrm{p}i}+F_{n_i}} \tag{12}$$

式(10)～(12)中：R_{pred}为预测的烧结矿粘连区域；R_{gt}为真实的烧结矿粘连标签区域；T_{p}表示被正确分类的烧结矿粘连像素数；F_{p}表示被错误分类的烧结矿粘连像素数；F_{n}表示被错误排除的烧结矿粘连像素数；N表示烧结矿粘连图像样本的数量。

此外，为了验证烧结矿颗粒分割的准确度，本文采用平均统计矿石粒度(S_{ASE})[13]的误差作为最终性能指标。计算预测结果图像中的统计矿石数量与实际标签统计的矿石数量之间的差值绝对值，并将其除以实际标签。该值反映了预测的粒度分布与实际分布的偏差，值越小，说明分割结果越好。它是矿石粒度统计任务的核心指标。

$$S_{\mathrm{ASE}}=\frac{1}{M}\sum_{i=1}^{M}\frac{\mid N_{\mathrm{pre}}^{i}-N_{\mathrm{label}}^{i}\mid}{N_{\mathrm{label}}^{i}} \tag{13}$$

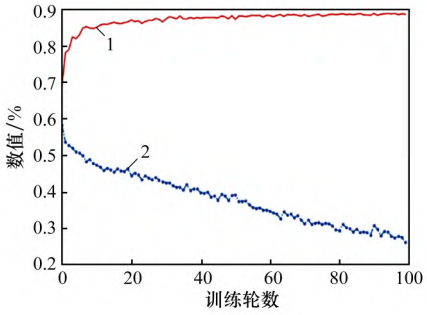
式中：M为测试数据集的数量，本文使用 10 张烧结矿图像；N_{pre}和N_{label}分别为预测图像和真实标签中烧结矿的数量。

2.3　模型训练与结果分析

2.3.1　模型训练

在双解码器 UNet 网络上进行训练，L(损失)值和δ_{Dice}值随训练轮数(epoch)的变化趋势如图 5 所示。由图 5 可以看出，随着训练 epoch 的增加，在训练集上的损失值缓慢下降，在验证集上的δ_{Dice}值缓慢上升，表明了网络的可行性。

由于烧结矿环境的复杂和颗粒大小的多变，为了提高模型对多尺度信息的感知和理解能力，增强对分割粘连区域的精确度，并提高模型的鲁棒性和泛化能力，本文在网络整体架构上采用多尺度密集连接，利用双解码器轮廓信息，进行图像分割。为了验证每个模块对分割性能的影响，



1—δ_{Dice}值；2—L值

图 5　网络训练过程 L 值和 δ_{Dice} 值

Fig. 5　L value and δ_{Dice} value in network training process

本文以 UNet 为基准，通过不断加入各种模块进行试验，结果如表 1 所示。

表 1　消融试验结果

Table 1　Results of ablation test

模型	δ_{mPA}/%	δ_{mIoU}/%	δ_{Dice}/%
UNet	90.31	82.82	86.12
+EX-B	91.28	84.74	86.95
+SE	91.64	85.19	87.26
+多尺度密集	92.02	85.98	88.81
+双解码器	92.61	86.62	89.34

由表 1 可知，改进的 UNet 网络模型中，每个新增的模块均能提升烧结矿的特征提取能力和分割能力。当加入双解码器时，S_{ASE}值最低，说明轮廓信息的加入使粘连图像得到了更加准确的分割。相较于常规 UNet 网络，该网络有效提升了网络模型的分割能力。

2.3.2　结果分析

为了进一步验证改进的 UNet 网络模型对烧结矿图像的有效性，本文将其与 Mobile-UNet 网络[14]、UNet++网络[15]、U^2-Net 网络[16]，这些变形的网络进行对比分析，结果见表 2。由表 2 可以看出，UNet++网络的各项指标均优于Mobile-UNet 和 U^2-Net，说明密集连接提取了更准确的特征信息。本文网络相较UNet++网络，在δ_{mIou}指标和δ_{Dice}指标上分别提升了 2.13% 和 1.71%，能够准确提取烧结矿信息，且本文算法在S_{ASE}指标上达到最低值，也表明改进的 UNet 网络模型在分割粘连图像时，分割更精准。在实际工业生产中 2 s 左右识别一张图片就可以实现烧结矿粒度在线检

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

表 2 不同网络模型试验结果

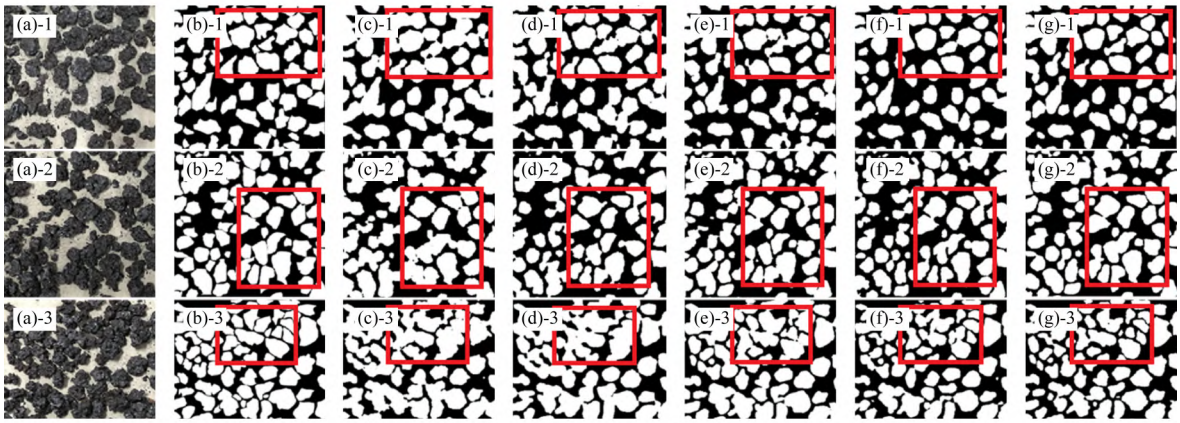
Table 2 Experimental results of different network models

模型	δ_{mPA} /%	δ_{mIoU} /%	δ_{Dice} /%	δ_{ASE} /%	δ_{IPT} /ms
阈值法	92.52	76.85	82.67	42.40	329
边缘分割法	90.51	83.12	85.76	36.77	399
区域分割法	91.36	84.03	87.53	38.89	460
UNet	90.31	82.82	86.12	39.09	523
U^2-Net	88.49	79.96	87.25	40.32	612
Mobile-UNet	91.07	84.08	86.87	36.67	416
UNet ++	91.56	83.81	87.25	32.56	625
改进 UNet	92.61	86.62	89.34	25.12	756

注: δ_{IPT}为单张图像的检测时间。

测，可以看出该方法的检测速度满足工业生产的需要。

为了测试改进的模型网络在烧结矿图像中的分割效果，本文进行了可视化显示，结果如图 6 所示。为了显示效果，应用了红色粗实线框进行标示。从图 6 红框可以看出，UNet 网络、U^2-Net 网络和 Mobile-UNet 网络均无法很好地识别矿石碎片的边缘，无法处理粘附部分，存在大量欠分割问题。UNet ++ 网络的分割效果优于前两个网络，可以识别出大部分烧结矿的边缘，但面对粘连部分没有进行处理。而改进的 UNet 网络对烧结矿图像具有良好的分割效果，可有效地分割粘连的烧结矿，并分割出离散的烧结矿碎粒，也能对黑暗区域烧结矿进行有效地分割，视觉效果更好。



(a) -1 ~ (a) -3 原图; (b) -1 ~ (b) -3 标签; (c) -1 ~ (c) -3 U^2-Net; (d) -1 ~ (d) -3 UNet; (e) -1 ~ (e) -3 Mobile-UNet; (f) -1 ~ (f) -3 UNet ++; (g) -1 ~ (g) -3 改进 UNet

图 6 网络模型分割效果

Fig. 6 Segmentation effect of network model

3 结 论

本文提出了一种基于多尺度特征融合的改进 UNet 网络算法用于烧结矿粒度分割，该算法的分割性能稳定，且显著提高了粘连烧结矿图像的分割准确度，为基于机器视觉的粒度识别研究提供参考，主要研究结论如下。

(1) 结合密集残差连接模块卷积和通道注意力模块，可提取更多低层次轮廓信息，从而解决图像中粘连烧结矿分割的问题。在跳跃连接层中引入多尺度密集连接，可实现非对称信息交换，完成不同层次特征信息的利用。边界感知双编码器 UNet 网络融合了轮廓和对象掩码两个编码器的特征信息，利用轮廓信息来约束烧结矿对象掩码分割，可提高粘连烧结矿轮廓分割能力。

(2) 经过消融试验发现，改进的 UNet 网络模型中，每个新增的模块均能提升烧结矿的特征提取能力和分割能力。当加入双解码器时，*ASE* 值最低，说明轮廓信息的加入使图像得到了更加准确的分割。相较于 UNet 网络，有效提升了网络模型的分割能力。

(3) 在改进的 UNet、U^2-Net 、Mobile-UNet、UNet ++、U^2-Net 网络中，改进的 UNet 网络的 δ_{mPA}、δ_{mIoU}和 δ_{Dice}指标均最高，S_{ASE}指标最低，证明改进

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

的 UNet 网络提取烧结矿信息的能力最强，分割粘连图像准确度最高。

参考文献:

[1] 黄鹏，郑淇，梁超. 图像分割方法综述[J]. 武汉大学学报(理学版)，2020，66(6)：519－531.
HUANG Peng，ZHENG Qi，LIANG Chao. Overview of image segmentation methods[J]. Journal of Wuhan University(Science Edition)，2020，66(6)：519－531.

[2] ZHANG Guoying，LI Mengjun，ZHAN Yantong，et al. Ore image thresholding segmentation using double windows with fisher discrimination[C]//13th International Conference on Natural Computation. Fuzzy Systems and Knowledge Discovery，2017：2715－2719.

[3] 肖扬，周军. 图像边缘检测综述[J]. 计算机工程与应用，2023，59(5)：40－54.
XIAO Yang，ZHOU Jun. Overview of image edge detection[J]. Computer Engineering and Applications，2023，59(5)：40－54.

[4] 罗朝阳，张鹏超，姚晋晋，等. 一种基于形态学的边缘检测算法[J]. 计算机应用与软件，2020，37(2)：177－181.
LUO Zhaoyang，ZHANG Pengchao，YAO Jinjin，et al. An edge detection algorithm based on morphology[J]. Computer Application and Software，2020，37(2)：177－181.

[5] RONNEBERGER O，FISCHER P，BROX T. UNet：Convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention. Berlin：Springer International Publishing，2015：234－241.

[6] MIAO Xiaokun，WANG Jing，WANG Zhengfang，et al. Automatic recognition of highway tunnel defects based on an improved UNet model[J]. IEEE Sensors Journal，2019，11413.

[7] 柳小波，张育维. 基于 UNet 和 Res_UNet 模型的传送带矿石图像分割方法[J]. 东北大学学报(自然科学版)，2019，40(11)：1623－1629.
LIU Xiaobo，ZHANG Yuwei. Image segmentation method of conveyor belt ores based on UNet and Res_UNet models[J]. Journal of Northeastern University(Natural Science Edition)，2019，40(11)：1623－1629.

[8] IBTEHAZ N，RAHMAN S M. MultiRes UNet：Rethinking the UNet architecture for multimodal biomedical image segmentation[J]. Neural Netw，2020，121：74－87.

[9] 王俊杰，张军航. 基于多尺度特征融合的小样本遥感图像分割[J]. 华中科技大学学报(自然科学版)，2022，50(3)：62－67.
WANG Junjie，ZHANG Junhang. Small sample remote sensing image segmentation based on multi－scale feature fusion[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition)，2022，50(3)：62－67.

[10] WANG Wei，LI Qing，XIAO Chengyong，et al. An improved boundary－aware UNet for ore image semantic segmentation[J]. Sensors，2021，21(8)：2615.

[11] SZEGEDY C，LIU Wei，JIA Yangqing，et al. Going deeper with convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. America：IEEE，2015：1－9.

[12] 于营，王春平，付强，等. 语义分割评价指标和评价方法综述[J]. 计算机工程与应用，2023，59(6)：57－69.
YU Ying，WANG Chunping，FU Qiang，et al. Review on evaluation indexes and methods of semantic segmentation[J]. Computer Engineering and Applications，2023，59(6)：57－69.

[13] LI Hui，PAN Chengwei，CHEN Ziyi，et al. Ore image segmentation method based on UNet and watershed[J]. Computers Materials & Continua，2020(10)：563－578.

[14] JING J，WANG Z，RÄTSCH M，et al. Mobile－Unet：An efficient convolutional neural network for fabric defect detection[J]. Textile Research Journal，2022，92(1)：30－42.

[15] ZHOU Z，RAHMAN SIDDIQUEE M M，TAJBAKHSH N，et al. UNet＋＋：A nested UNet architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Berlin：Springer International Publishing，2018：3－11.

[16] QIN Xuebin，ZHANG Zichen，HUANG Chenyang，et al. U^2Net：Going deeper with nested U-structure for salient object detection[J]. Pattern Recognition，2020，106：107404.

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net