

DOI: 10.13382/j.jemi.B2407783

# 基于改进 Deeplabv3+ 的磁瓦表面缺陷分割\*

李明 魏利胜

(安徽工程大学电气工程学院 芜湖 241000)

**摘要:**针对磁瓦图像中不同类型的缺陷大小不一影响分割准确率、检测模型参数量大在实际应用中难以部署、图像像素分布不均匀的问题,提出了一种基于改进 Deeplabv3+ 的磁瓦表面缺陷分割算法。首先,在结构上,主干网络采用轻量化的 MobilNetv3 网络代替原模型的 Xception 网络,使得模型的参数和计算量保持较小以提升检测速度;其次,引入 ECANet 注意力机制,提升模型的特征表达能力和泛化能力;最后,采用 Dice Loss 和 Focal Loss 相结合的损失函数,有效缓解样本像素点分布不平衡对模型训练的影响。将各个改进点进行消融实验,再将改进后的 Deeplabv3+ 与其他模型进行对比,实验结果表明,算法在 magnetic tile surface defects 数据集上平均交并比为 68.25%,平均像素准确率为 82.80%,准确率为 79.80%,相较于原 Deeplabv3+ 算法,平均交并比提升了 8.62%,平均像素准确率提升了 9.96%,准确率提升了 11.52%,验证了算法的有效性和可行性,在工业应用中具备一定的实际应用价值。

**关键词:**深度学习;缺陷检测;语义分割;磁瓦

中图分类号: TN911.73; TP391

文献标识码: A

国家标准学科分类代码: 520.6040

## Magnetic tile surface defect segmentation based on improved Deeplabv3+

Li Ming Wei Lisheng

(School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China)

**Abstract:** In order to solve the problems that the size of different types of defects in magnetic tile images affects the segmentation accuracy, the detection model parameters are large and difficult to deploy in practical applications, and the image pixel distribution is uneven, a magnetic tile surface defect segmentation algorithm based on improved Deeplabv3+ was proposed. Firstly, in terms of structure, the lightweight MobilNetv3 network was used as the backbone network to replace the Xception network of the original model, so that the parameters and computational cost of the model were kept small to improve the detection speed. Secondly, the ECANet attention mechanism was introduced to improve the feature expression ability and generalization ability of the model. Finally, the loss function combining dice loss and focal loss were used to effectively alleviate the influence of sample pixel distribution imbalance on model training. The experimental results show that the average intersection union ratio of the proposed algorithm on the magnetic tile surface defects dataset was 68.25%, the average pixel accuracy was 82.80%, and the accuracy was 79.80%, compared with the original Deeplabv3+ algorithm, the average intersection union ratio was increased by 8.62%, and the average pixel accuracy was increased by 9.96%, the accuracy of the algorithm was increased by 11.52%, which verifies the effectiveness and feasibility of the proposed algorithm, and has certain application value in industrial applications.

**Keywords:** deep learning; defect detection; semantic segmentation; magnetic tiles

## 0 引言

工业制造是现代社会的支柱之一,其中磁瓦作为工业生产中重要的材料,发挥着不可或缺的作用,磁瓦可以被用于制造电机、发电机、电磁锁、感应器等电磁装置,也可以被用于医学领域,例如,医生可以通过贴磁瓦在病人身上,来帮助治疗风湿病、偏头痛等疾病。磁瓦在制造时,因种种原因,其表面会产生各种各样的缺陷,例如气孔、裂纹、不均匀等。这些缺陷如果未能及时发现和处理,不仅会影响后续产品的质量和寿命,还可能对人身安全和环境造成威胁。因此,快速、准确地检测和识别出磁瓦的表面缺陷在现代工业领域具有一定的研究意义和应用价值。

传统的磁瓦表面缺陷检测方法主要包括人工视觉检查和机器视觉技术。其中,人工视觉检查依赖于人眼进行缺陷检测和识别。然而,由于人眼的疲劳和主观性等问题,人工视觉检查存在着效率低、准确度不高等问题。机器视觉技术是一种更加先进的缺陷检测方法,它可以通过图像处理和计算机视觉技术实现对磁瓦表面缺陷的自动检测和识别。然而,传统的机器视觉技术存在着特征提取不准确、噪声干扰等问题,难以达到高精度、高效率的缺陷检测要求。近年来,随着深度学习技术的飞速发展,基于深度学习的磁瓦表面缺陷检测技术得到了广泛的关注和研究。

国内外相关专家学者对图像分割以及磁瓦表面缺陷分割进行了大量的研究,并取得了丰富的成果。侯文庆等<sup>[1]</sup>针对磁瓦图片表面纹理复杂问题采用了改进的小波自适应阈值分割,缩短了运行时间,并且在一定程度上保留了边缘信息,但是存在一些边缘被误认为缺陷的问题;赵恩玄等<sup>[2]</sup>提出了一种基于 U-Net 的 AttRes-U-Nets 分割网络,针对 CT 图像分割弱边缘等问题,将主干特征网络融合残差结构,额外引入两条恒等映射,提高网络对图像的边缘细节分割能力;张墩利等<sup>[3]</sup>提出了一种能够有效滤除磁瓦中背景噪音和亮条纹理干扰的各向异性扩散模型,但是对于形状复杂的缺陷分割效果不佳;帖军等<sup>[4]</sup>针对肝脏肿瘤图像中形状复杂、边界模糊的问题,提出了将混合空洞卷积与高层特征融合的分割模型,减少对形状复杂肿瘤区域的特征误判率;Huang 等<sup>[5]</sup>将 MCue、U-Net 和 Push 网络结合,有效提高了磁瓦表面缺陷实时检测的精度,但是对小型缺陷检测效果不佳;Zhong 等<sup>[6]</sup>通过定位磁瓦表面缺陷位置,然后提高对比度以及将有缺陷的区域与背景分离,有效减少了纹理干扰并减少时间消耗,对小缺陷能够实现较为精准的定位;Li 等<sup>[7]</sup>提出了一种改进 YOLOv5 的算法对磁瓦表面缺陷进行检测,保留了卷积层中有关小目标和低对比度缺陷的更多消

息,但是检测速度略慢于原来的 YOLOv5;林弘焯等<sup>[8]</sup>提出一种加强空间信息引导的实时分割网络,既保证了一定的准确度,检测速度也相对较快;宁奉阁等<sup>[9]</sup>提出了基于 S-ASPP 和双注意力机制的磁瓦表面检测算法,在降低模型参数数量的同时,保证了识别精度;刘培勇等<sup>[10]</sup>提出了基于多支路卷积神经网络的磁瓦表面缺陷检测算法,该算法检测精度保持在 99% 以上,但是容易产生漏检;张露滨等<sup>[11]</sup>提出了一种基于背景纹理抑制与掩膜技术相结合的微型磁瓦表面线缺陷视觉检测方法,提高了线缺陷检测的准确度,但是在磁瓦纹理抑制后,难以彻底消除噪声点对划痕图像提取的干扰影响;Ling 等<sup>[12]</sup>提出了一种自监督学习方法,使用全连接网络来完成各种下游分类任务,具有较强的特征提取和泛化能力。

上述研究在不同程度上改进并优化了现有的网络模型,但仍然存在研究模型较大、磁瓦表面缺陷检测精度有待提高、不能精准识别小型缺陷等问题,本研究在以上专家研究基础上,提出一种基于改进 Deeplabv3+ 的检测算法。首先,用轻量级的 MobileNetv3 代替了原来的主干网络 Xception,减少了模型中的参数,使得模型简单化;其次,在主干网络之后加入 ECANet (efficient channel attention network) 注意力机制,提升网络的表达和判别能力;最后,使用 Dice Loss 与 Focal Loss 相结合的损失函数优化模型,增强最终的分割效果。实验在文献[13]公开数据集 magnetic tile surface defects 上进行实验验证并且与其它模型进行对比。通过替换轻量化主干网络、添加注意力机制、优化损失函数提高磁瓦表面缺陷分割的准确率,并且减少计算量,为缺陷的语义分割提供一个更好的思路与方法。

## 1 Deeplabv3+算法及改进

### 1.1 Deeplabv3+算法

Deeplabv3+算法在 2018 年被 Chen 等<sup>[14]</sup>研究者提出。由于该模型的语义分割效果非常好,所以一经推出便引起了极大的反响。Deeplabv3+ 网络为 Encoder-Decoder 结构。首先,图片传入主干网络 Xception 后进行特征提取;随后,提取到的深层特征传入 ASPP 结构进行膨胀卷积和平均池化,浅层特征传入解码器,之后两者进行融合;最终,将融合后的特征进行卷积和上采样,再对每一个像素点进行分割,获得分割后的图片。

### 1.2 改进的 Deeplabv3+算法

传统的 Deeplabv3+模型以 Xception 为主干网络,但其结构较为复杂,导致了大量的模型参数难以部署到嵌入式系统中,现实中不能得到普遍使用;同时,模型训练时使用的交叉熵损失函数(cross entropy loss, CE Loss)并

不太适用于磁瓦缺陷像素只占背景像素很小一部分的情况,此时背景的损失占主导地位,容易导致网络性能不佳。

基于以上问题,本研究从 3 个方面对 Deeplabv3+模型进行改进:首先,采用轻量化的 MobileNetv3 作为主干网络,有效解决参数量大、难部署的问题;其次,引入

ECANet 注意力机制模块,通过网络将关注重点集中在图像的通道间关系,从而提升了特征表示的能力;最后,使用 Focal Loss 和 Dice Loss 混合的损失函数在训练阶段优化模型,降低样本不平衡以及图片中缺陷像素占比较小对模型训练造成的影响。Deeplabv3+模型的网络结构及其改进部分如图 1 所示。

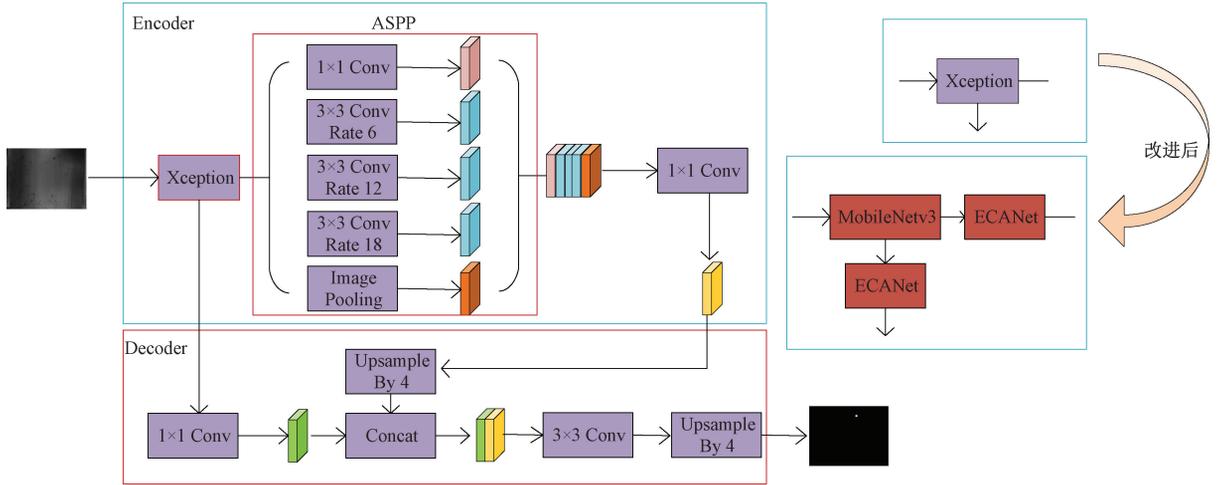


图 1 Deeplabv3+模型的网络结构及其改进部分

Fig. 1 The network structure of the Deeplabv3+ model and its improvements

1) MobileNetv3 模块

MobileNetv3<sup>[15]</sup>作为轻量化网络,在 v1<sup>[16]</sup>和 v2<sup>[17]</sup>前两代的基础上既有所保留又有新的改进。具体来说,继承了 v1 的深度可分离卷积,同时保留了 v2 具有线性瓶

颈的残差结构,并引入了 SE 通道注意力结构,在保证性能与速度上均具有优良表现的同时,具有较少参数、较小计算量、较短推理时间的优点,特别适用于内存与功耗限制的应用场合,其网络结构如表 1 所示。

表 1 MobileNetv3 网络结构

Table 1 MobileNetv3 network structure

Input	Operator	exp size	out	SE	NL	s
224 <sup>2</sup> ×3	conv2d	-	16	-	HS	2
112 <sup>2</sup> ×16	bneck, 3×3	16	16	-	RE	1
112 <sup>2</sup> ×16	bneck, 3×3	64	24	-	RE	2
56 <sup>2</sup> ×24	bneck, 3×3	72	24	-	RE	1
56 <sup>2</sup> ×24	bneck, 5×5	72	40	√	RE	2
28 <sup>2</sup> ×40	bneck, 5×5	120	40	√	RE	1
28 <sup>2</sup> ×40	bneck, 5×5	120	40	√	RE	1
28 <sup>2</sup> ×40	bneck, 3×3	240	80	-	HS	2
14 <sup>2</sup> ×80	bneck, 3×3	200	80	-	HS	1
14 <sup>2</sup> ×80	bneck, 3×3	184	80	-	HS	1
14 <sup>2</sup> ×80	bneck, 3×3	184	80	-	HS	1
14 <sup>2</sup> ×80	bneck, 3×3	480	112	√	HS	1
14 <sup>2</sup> ×112	bneck, 3×3	672	112	√	HS	1
14 <sup>2</sup> ×112	bneck, 5×5	672	160	√	HS	2
7 <sup>2</sup> ×160	bneck, 5×5	960	160	√	HS	1
7 <sup>2</sup> ×160	bneck, 5×5	960	160	√	HS	1
7 <sup>2</sup> ×160	Conv2d, 1×1	-	960	-	HS	1
7 <sup>2</sup> ×960	pool, 7×7	-	-	-	-	1
1 <sup>2</sup> ×960	Conv2d 1×1, NBN	-	1280	-	HS	1
1 <sup>2</sup> ×1 280	Conv2d 1×1, NBN	-	k	-	-	1

## 2) ECANet 注意力机制模块

ECANet 是一种用于图像处理任务的神经网络架构, 2020 年由 Wang 等<sup>[18]</sup>提出。核心思想是在保持高效性的同时, 在卷积操作中引入通道注意力机制, 有效地捕捉图像中的通道间关系, 从而提升了特征表示的能力。ECANet 的结构如图 2 所示。

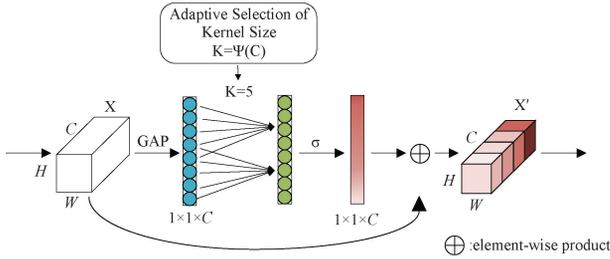


图 2 ECANet 网络结构

Fig. 2 ECANet network structure

其中, GAP 表示在不降维的情况下, 对输入的特征图执行全局平均池化, 将通道维度的数量保持不变, 而空间维度压缩为 1;  $k$  是卷积核大小。由图 3 可知, 首先是通过全局平均池化层, 将每个通道大的二维特征压缩为一个实数, 特征维度由  $(C, H, W)$  变为  $(C, 1, 1)$ , 再通过计算得到一维卷积核的  $\text{kernel\_size}$ , 如式 (1) 所示。

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (1)$$

其中,  $b=1$ ,  $\gamma=2$ ,  $C$  为通道数。将  $\text{kernel\_size} = k$  的一维卷积核用于特征图, 得到每个通道的权重向量, 维度保持  $(C, 1, 1)$ , 最后, 将归一化后的权重加权乘以输入特征图, 即  $(C, H, W) \times (C, 1, 1)$ , 得到输出的维度  $(C, H, W)$ 。

ECANet 的结构主要为通道注意力模块和嵌入式通道注意力模块两个部分。

通道注意力模块是整体结构的核心, 其目的是根据各通道之间的关系来自适应地调节各通道特征的权重值。首先, 特征图输入到此模块中, 通过全局平均化求出各通道的全局平均值, 然后再经过一组全连接层生成通道注意力的权重。再将这一系列权重值分配给输入特征图的各个通道, 得到各通道的加权组合。最后, 通过一个缩放因子对调整后的特征进行归一化, 以保证特征的范围。

嵌入式通道注意力模块是扩展部分, 在卷积操作中, 将输入特征图划分为多个子特征图, 然后分别对每个子特征图进行卷积操作, 并在卷积操作的过程中引入通道注意力, 最后, 将这些卷积得到的子特征图进行合并, 得到最终的输出特征图。这种嵌入式设计能够在卷积操作的同时, 进行通道注意力的计算, 减少了计算成本。

在主干网络之后加入 ECANet, 通道注意力机制使得

网络在不增加过多计算成本的情况下, 提升特征表达能力; 通道注意力机制能够自适应调整通道特征的权重, 使网络能够更好地关注重要的特征, 有助于提升特征的判别能力, 从而提升网络的性能; 同时抑制不重要的特征, 减少了过拟合的风险和提高泛化能力。

## 3) 损失函数

本研究使用的磁瓦数据集具有两个特点, 首先是样本比例不平衡, 无缺陷的图片数量比所有类别缺陷图片数量还要多, 并且各个缺陷的图片数量比例也是不平衡的; 其次是在缺陷数据图中, 有缺陷的像素点数量只占很小的部分。为了缓解正负样本比例以及磁瓦缺陷和无缺陷像素点分布不均匀给模型训练带来的影响, Focal Loss<sup>[19]</sup> 和 Dice Loss<sup>[20]</sup> 混合的损失函数在训练阶段被用来优化模型, 适当的 Focal Loss 与 Dice Loss 相结合使模型在样本分布不均衡的情况下更关注稀少类别。

Focal Loss 通过降低易分类的样本的权重, 减缓易分类样本对梯度的贡献, 从而专注于难以分类的样本, 在类别不平衡的情况下可以取得更好的性能, 其计算如式 (2) 所示。Dice Loss 基于 Dice 系数, Dice 系数及 Dice Loss 的计算如式 (3)、(4) 所示, Dice 系数是衡量两个集合相似度的指标, 用于评估两个二值图像或二值掩码的重叠情况。

$$L_{Focal} = -(1 - p_i)^2 \log p_i \quad (2)$$

$$Dice(A, B) = \frac{2 |A \cap B|}{|A| + |B|} \quad (3)$$

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N g_i p_i}{\sum_{i=1}^N g_i + \sum_{i=1}^N p_i} \quad (4)$$

式中:  $p_i$  表示像素  $i$  的预测概率; 集合  $A$  表示对模型进行预测后的分割结果; 集合  $B$  表示真实标签的实际分割结果;  $g_i$  表示像素  $i$  的真实值;  $N$  表示分割类别加背景的总数。本研究将两种损失函数联合, 最终如式 (5) 所示。

$$L = L_{Focal} + L_{Dice} \quad (5)$$

## 2 实验与分析

### 2.1 数据集与环境设置

本研究使用公开数据集 magnetic tile surface defects 进行实验, 该数据集包含 1 344 张磁瓦表面缺陷图像以及对应的像素级标签, 并将缺陷按照不同类型分为 6 类, 分别为气孔、断裂、裂纹、磨损、不均匀和无缺陷。由于无缺陷图像占大部分, 5 类缺陷图像总共只有 392 张, 为此本实验通过随机旋转、翻转、剪切、比例缩放等方法对每种类型的缺陷进行了数据增强。最后, 得到了总计 1 568 张增强后的数据集, 实验按照 9 : 1 的比例将增强后数据

集中的图像分为训练集与验证集。

本研究使用 Pytorch 深度学习框架,采用的硬件配置为 Windows11 操作系统, NVIDIA GeForce RTX 4060 型号的 GPU 以加速图像处理,其具有 8 GB 显存, CPU 采用 Inter Core i7-13700H。训练过程中 epoch 设置为 100,采用 Adam 优化器,并使用余弦退火的学习率下降方式。

### 2.2 评价指标

实验采用在语义分割领域被广泛使用的性能指标对检测结果进行评估,分别是平均交并比(mean intersection over union, MIoU)、平均像素准确率(mean pixel accuracy, MPA)以及准确率(precision)。上述指标的计算如式(6)~(8)所示。

$$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij}} \quad (6)$$

$$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \quad (7)$$

$$precision = \frac{TP}{TP + FP} \quad (8)$$

式中:  $k$  代表一共有  $k$  类缺陷;  $p_{ii}$  表示正确预测类  $i$  的像素点数量;  $p_{ij}$  表示将类  $i$  预测成类  $j$  的像素点数量;  $p_{ji}$  表示将类  $j$  预测成类  $i$  的像素点数量;  $TP$  (true positive) 指的是正样本被预测为正例的数量;  $FP$  (false positive) 指的是负样本被预测为正例的数量。

### 2.3 实验结果分析

#### 1) 消融实验

为验证本研究提出改进方法的可行性,进行了一组消融实验,实验结果如表 2 所示,打勾表示采用该改进点。分析表 2 可知,组 1 直接使用 Deeplabv3+检测得到的 MPA 为 72.84%, MIoU 为 59.63%, 准确率为 68.28%。组 2 将 MobilNetv3 替换 Xception 作为主干网络, MPA 增加了 0.32%, MIoU 增加了 3.13%, 准确率增加了 2.06%。组 3 将 ECANet 注意力机制加入网络,各指标在组 2 的基础上均有提升,表明 ECANet 模块的加入提高了 Deeplabv3+网络的特征提取能力。组 4 在上面两组改进之外,使用 Focal Loss 与 Dice Loss 相结合作为模型损失函数的计算方式, MPA、MIoU 以及准确率相较于原模型均取得了最好的分割效果。

表 2 消融实验结果

Table 2 Ablation test results

方法	组 1	组 2	组 3	组 4
Network	Xception	MobileNetv3	MobileNetv3	MobileNetv3
ECANet			√	√
Loss	Dice	Dice	Dice	<b>Dice+Focal</b>
MPA/%	72.84	73.16	75.74	<b>82.80</b>
MIoU/%	59.63	62.76	63.89	<b>68.25</b>
Precision/%	68.28	70.34	73.78	<b>79.80</b>

#### 2) 对比实验

为进一步验证本研究改进模型的优越性,在相同的训练条件下将原 Deeplabv3+模型与改进的模型以及 3 个经典模型算法 U-net、PSPNet、FCN 进行了对比实验,实验结果如表 3 所示。通过表 3 可知,改进的模型与原模型

相比, MPA 提升了 9.96%, MIoU 提升了 8.62%, 与经典的 3 个模型相比, MPA 分别提升了 12.38%、10.61%、7.46%, MIoU 与准确率也均为最佳结果。表明本研究选用 Deeplabv3+作为磁瓦表面缺陷分割的基础算法是有效的,并且改进的算法优于其他主流检测算法。

表 3 对比实验结果

Table 3 Compare the results of the experiment

(%)

模型	MPA	MIoU	Precision
U-net	70.42	62.38	67.29
PSPNet	72.19	58.47	66.98
FCN	75.34	67.12	72.65
Deeplabv3+	72.84	59.63	68.28
Ours	<b>82.80</b>	<b>68.25</b>	<b>79.80</b>

#### 3) 改进前后模型分割效果可视化

将 5 种不同类型的磁瓦缺陷图像原图、标签图、Deeplabv3+算法以及本研究改进的算法检测效果图进行对比,结果如图 3 所示,其中 GT 是标签图。可以看出,原 Deeplabv3+模型对 5 种不同类型的表面缺陷都存在一定

程度的误检漏检情况,本研究改进的算法有效缓解分割不连续以及分割不完全的问题,同时漏检误检概率比较低,所得到的分割结果更加精确细腻,对各类缺陷分割的效果优于原模型。

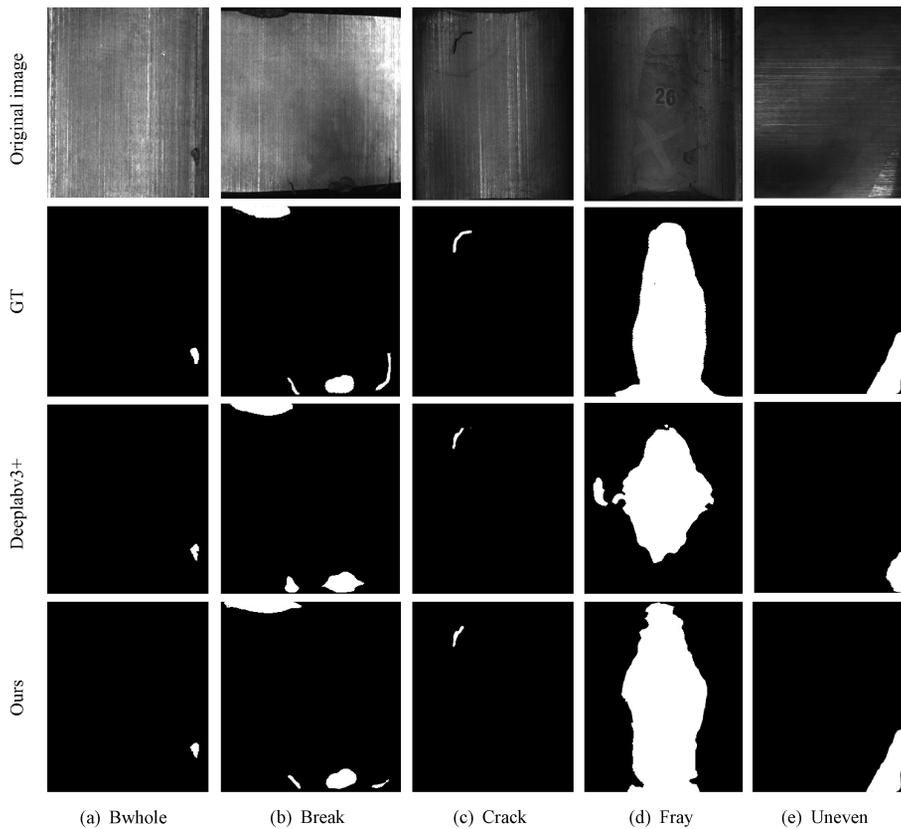


图 3 各类别缺陷分割结果对比

Fig. 3 Comparison chart of defect segmentation results of each category

### 3 结 论

本研究提出一种基于改进 Deeplabv3+的磁瓦表面缺陷分割算法。针对原模型参数量大、现实应用中难以部署,网络性能不佳等问题,在网络结构上,以轻量化网络 MobilNetV3 作为主干网络,并且引入 ECANet 注意力机制模块利用通道注意力来增强特征表示;在网络训练阶段利用 Dice Loss 和 Focal Loss 相结合的损失函数来缓解图像像素分布不平衡的影响,提升模型训练后期收敛速度。最后,在磁瓦公开数据集上进行消融实验和对比实验。实验结果表明,与现阶段其他语义分割算法相比,本研究提出的改进 Deeplabv3+模型在参数量、计算量以及检测准确率方面均表现优异,更便于实际应用和部署,现实意义得到有效提高。在未来工作中,将寻求更多优化方法,在确保精度的前提下,尽量使网络轻量化,提高分割速度,实现实时性检测。

#### 参考文献

[ 1 ] 侯文庆, 景会成, 周易林. 融合改进小波变换的小型磁瓦表面缺陷检测方法研究[J]. 制造业自动化, 2024, 46(1): 130-133, 139.

HOU W Q, JING H CH, ZHOU Y L. Research on surface defect detection method of small magnetic tile by integrating improved wavelet transform[J]. Manufacturing Automation, 2024, 46(1): 130-133, 139.

[ 2 ] 赵恩玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法[J]. 仪器仪表学报, 2023, 44(11): 176-184.

ZHAO EN X, HE Y Y, SHEN K, et al. CT image segmentation algorithm for castings based on deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(11): 176-184.

[ 3 ] 张墩利, 周国栋. 基于改进扩散模型的磁瓦表面缺陷检测方法[J]. 中国测试, 2024, 50(6): 28-34.

ZHAN D L, ZHOU G D. Magnetic tile surface defect detection method based on improved diffusion model[J]. China Testing, 2024, 50(6): 28-34.

[ 4 ] 帖军, 朱祖桐, 郑禄, 等. 基于混合空洞卷积与特征融合的肝脏肿瘤图像分割[J]. 电子测量技术, 2023, 46(22): 122-130.

TIE J, ZHU Z T, ZHENG L, et al. Image segmentation of liver tumor based on hybrid dilated convolution and feature fusion[J]. Electronic Measurement Technology, 2023, 46(22): 122-130.

- [ 5 ] HUANG Y B, QIU C Y, YUAN K. Surface defect saliency of magnetic tile [ J ]. The Visual Computer, 2020, 36(1) : 85-96.
- [ 6 ] ZHONG ZH Y, WANG H X, XIANG D. Small defect detection based on local structure similarity for magnetic tile surface [ J ]. Electronics, 2022, 12(1) : 185.
- [ 7 ] LI Y, FANG J. Detection of surface defects of magnetic tiles based on improved YOLOv5 [ J ]. Journal of Sensors, 2023(1) : 2466107.
- [ 8 ] 林弘焯, 裘君, 潘泽民, 等. 加强空间信息引导的道路场景实时语义分割 [ J ]. 国外电子测量技术, 2023, 42(7) : 8-15.  
LIN H Y, QIU J, PAN Z M, et al. Strengthen real-time semantic segmentation of road scenes guided by spatial information [ J ]. Foreign Electronic Measurement Technology, 2023, 42(7) : 8-15.
- [ 9 ] 宁奉阁, 石金进. 基于 S-ASPP 和双注意力机制的磁瓦外观缺陷检测算法 [ J ]. 电子测量技术, 2023, 46(2) : 146-153.  
NING F G, SHI J J. Magnetic tile appearance defect detection algorithm based on S-ASPP and dual attention mechanism [ J ]. Electronic Measurement Technology, 2023, 46(2) : 146-153.
- [ 10 ] 刘培勇, 董洁, 谢罗峰, 等. 基于多支路卷积神经网络的磁瓦表面缺陷检测算法 [ J ]. 吉林大学学报(工学版), 2023, 53(5) : 1449-1457.  
LIU P Y, DONG J, XIE L F, et al. Magnetic tile surface defect detection algorithm based on multi-branch convolutional neural network [ J ]. Journal of Jilin University(Engineering Science), 2023, 53(5) : 1449-1457.
- [ 11 ] 张露滨, 李俊峰, 沈军民. 微型磁瓦表面线缺陷视觉检测方法研究 [ J ]. 光电子·激光, 2019, 30(9) : 951-959.  
ZHANG L B, LI J F, SHEN J M. Research on visual detection method of surface line defects of micro magnetic tiles [ J ]. Optoelectronics Lasers, 2019, 30(9) : 951-959.
- [ 12 ] LING X, WU Y, ALI R, et al. Retracted: Magnetic tile surface defect detection methodology based on self-attention and self-supervised learning [ J ]. Computational Intelligence and Neuroscience, 2022(1) : 3003810.
- [ 13 ] HUANG Y, QIU C, YUAN K. Surface defect saliency of magnetic tile [ J ]. The Visual Computer, 2020, 36(1) : 85-96.
- [ 14 ] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [ C ]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801-818.
- [ 15 ] HOWARD A, SANDERLER M, CHU G, et al. Searching for Mobilenetv3 [ C ]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.
- [ 16 ] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [ J ]. IEEE Access, 2017, 6:1-14.
- [ 17 ] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottle-necks [ C ]. IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake: IEEE, 2018: 4510-4520.
- [ 18 ] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [ C ]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2020: 11534-11542.
- [ 19 ] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [ C ]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [ 20 ] 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). IEEE, 2016: 565-571.

## 作者简介



李明, 2022 年于黄山学院获得学士学位, 现为安徽工程大学硕士研究生, 主要研究方向为图像处理、深度学习。

E-mail: lm18256562416@163.com

**Li Ming** received her B. Sc. degree from Huangshan University in 2022. Now she is a M. Sc. candidate at Anhui Polytechnic University. Her main research interests include image processing and deep learning.



魏利胜(通信作者), 2001 年于安徽工程大学获得学士学位, 2004 年于中国航天科工集团 061 基地获得硕士学位, 2009 年于上海大学获得博士学位, 现为安徽工程大学教授、硕士生导师, 主要研究方向为图像识别与应用、智能化网络控制系统和仿真。

E-mail: lshwei\_11@163.com

**Wei Lisheng** (Corresponding author) received his B. Sc. degree in 2001 from Anhui Polytechnic University and received his M. Sc. degree in 2004 from China Aerospace Science and Industry Corporation 061 Base, and received his Ph. D. degree in 2009 from Shanghai University. Now he is a professor and master's supervisor at Anhui Polytechnic University. His main research interests include image recognition and application, intelligent network control system and simulation.