

跨层融合的轻量化太阳能电池片缺陷分割方法^{*}

陈光耀 陈田 高学海 刘军

(上海电机学院机械学院 上海 201306)

摘要: 针对当前多晶太阳能电池片表面缺陷分割中存在的细小特征无法识别、缺陷分割边界模糊和模型参数量大等问题,本文提出一种带有交叉注意力机制和残差细化模块的轻量化语义分割模型C2LA-U2-Net。首先,通过在外部解码器阶段设计了带有交叉注意力机制的C2LA模块,以提取多尺度的空间特征,减少空间信息丢失,同时捕获长程依赖关系,从而增强对细小缺陷的分割效果;其次,为应对预测中的边界模糊的问题,引入一种轻量化的二阶段残差细化模块(D-RRM),用于细粒度特征建模,以提高预测边界精度;最后,为进一步降低模型复杂度,引入幻影卷积。实验结果表明,与基线模型相比,C2LA-U2-Net模型的类别平均像素精度(MPA)、平均交并比(MIoU)、平均召回率(MRecall)和F₁分数提升了3.1%、4.49%、4.39%和4.17%。同时,模型参数量和GFLOPs下降了89.77%和56.68%,推理速度提升了76.97%,证明了本文方法的有效性。

关键词: 多晶太阳能电池片;缺陷分割;U2-Net;注意力机制;轻量级算法

中图分类号: TP301.6; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

C2LA-U2-Net: lightweight defect segmentation method for solar cells with cross-layer fusion

Chen Guangyao Chen Tian Gao Xuehai Liu Jun

(College of Mechanical Engineering, Shanghai Dianji University, Shanghai 201306, China)

Abstract: A lightweight semantic segmentation model named C2LA-U2-Net, equipped with a cross attention mechanism and a residual refinement module, was proposed to address issues such as the inability to recognize fine features, blurry defect boundaries, and large model parameters in the segmentation of surface defects in polycrystalline solar cells. Firstly, a C2LA module with a cross attention mechanism was designed in the external decoding stage to extract multi-scale spatial features, reduce spatial information loss, and capture long-range dependencies, which enhanced the segmentation performance for small defects. Secondly, a lightweight two-stage residual refinement module (D-RRM) was introduced to tackle the issue of blurry prediction boundaries by modeling fine-grained features to improve boundary precision. Finally, Ghost convolutions were incorporated to further reduce model complexity. Experimental results indicated that, compared to the baseline model, the C2LA-U2-Net model achieved improvements of 3.1% in mean pixel accuracy (MPA), 4.49% in mean intersection over union (MIoU), 4.39% in mean recall rate (MRecall), and 4.17% in F1 score. At the same time, the model's parameters and GFLOPs decreased by 89.77% and 56.68%, respectively, while inference speed increased by 76.97%, demonstrating the effectiveness of the proposed method.

Keywords: polycrystalline solar cells; defect segmentation; U2-Net; attention mechanism; lightweight algorithm

0 引言

随着全球环境问题日益加剧以及对可再生能源需求的不断增长,作为一种清洁可再生的能源,太阳能的重要性愈发凸显。根据预测,到2050年,太阳能发电将占全球总发

电量的48%^[1]。太阳能电池片是光伏发电的核心部件之一^[2]。在多晶太阳能电池片制作过程中,因为工序繁多^[3],容易产生划痕、杂质污染、断栅、裂片、缺角等缺陷,这些缺陷会显著降低光电转换效率和使用寿命,造成巨大的经济损失^[4]。太阳能电池片缺陷分割能够提供详细的缺陷信

息,涵盖缺陷的形状、面积以及精确位置等,这些缺陷信息对于太阳能电池的高质量制造至关重要。光伏企业能够借助缺陷信息对太阳能电池片实施严格的质量分级,从而生产更多的产品,提高经济效益。此外,生产部门可以对这些信息进行分析,以调查缺陷的来源,进而对酸洗、扩散、蚀刻、清洗等生产环节进行精确优化,最终达到降低生产成本、节约资源以及保护环境的目的。

在太阳能电池片缺陷检测领域,国内外学者进行了大量的研究。在物理方法方面,主要涉及声波、电子束等技术,通过分析这些技术所提供的物理反馈信息来检测太阳能电池片的缺陷情况。如 Li 等^[5]利用兰姆波振幅在太阳能电池片上的分布结果能够反映裂痕的散射模式的特性,通过引入兰姆波对太阳能电池缺陷进行检测;Gan 等^[6]将正交调制理论引入光束感应电流(light beam-induced current, LBIC)扫描中,提出一种基于正交调制的光束感应电流(orthogonal modulation-based LBIC, OMLBIC)方法来检测光伏电池缺陷。何存富等^[7]设计并制作了一种气体基线聚焦空气耦合式超声传感器,采用空耦超声兰姆波检测技术,对含有裂纹缺陷的单晶硅太阳能电池片进行检测,通过分析接收信号的幅值信息并利用相关系数法,完成了对裂纹缺陷的检出和定位。然而,物理方法往往成本较高、检测难度较大,并且可能对太阳能电池片造成二次损伤。

与物理方法不同,传统机器视觉方法主要基于图像处理技术,通过分析图像的特征来检测缺陷。国外研究中,如 Tsai 等^[8]提出一种各向异性扩散方案来检测细微缺陷,以灰度和梯度为特征来调整扩散系数来分割多晶硅片表面的异质纹理,然而该方法在对角方向的缺陷检测上不够敏感;国内研究方面,李桥等^[9]提出了一种基于局部灰度特征的自适应阈值选择方法,以解决分割太阳能电池片缺陷时光线不均的问题,但该方法对有色差的硅片缺陷分割存在难度。综合来看,传统机器视觉方法在检测缺陷特征提取能力方面相对较弱,并且在面对复杂的环境条件和多种类型的缺陷时,鲁棒性和泛化能力不强。

深度学习的快速发展推动了卷积神经网络^[10](CNN)在计算机视觉领域的显著进步,尤其是在图像分割^[11]任务中表现尤为突出。一些研究者提出了基于深度学习的语义分割方法来分割太阳能电池缺陷。Han 等^[12]针对多晶硅晶圆缺陷分割,使用区域建议网络(RPN)从图像中生成缺陷区域,再通过膨胀卷积对 U-Net 网络进行改进,实验的最佳检测精度达到 84.6%,然而,RPN 虽能够生成缺陷区域提案,但存在不能完全覆盖所有缺陷的问题;吴俊良等^[13]提出了一种基于全注意力 FSA-UNet 网络的单晶电池片混合缺陷检测方法,通过设计特征增强模块提升弱缺陷的分辨能力,并改进骨干特征提取网络以加快强缺陷的检测效率。实验结果表明,该算法在单晶硅片缺陷分割任务中的 MIoU 值达到了 77.9%。然而,由于该论文所使用的单晶太阳能电池片缺陷数据集规模较小,这可能会影响

FSA-UNet 网络模型的鲁棒性与泛化能力。王延年等^[14]基于改进的 U-Net 网络对其自制的 542 张电致发光(electroluminescence, EL)太阳能电池片缺陷进行分割,该方法通过密集连接块缓解梯度消失的问题,并引入双注意力机制以提高网络的精度和鲁棒性,但是该网络的召回率仅为 68.9%,召回率是指在所有实际存在缺陷的像素中,能够被正确识别为缺陷的像素所占的比例。召回率偏低说明此方法可能会由于网络结构对部分缺陷特征的提取不够充分导致产生缺陷像素漏分割;王盛等^[15]提出了基于 U2-Net 网络的太阳能电池片缺陷分割算法,该算法通过将通道注意力模块和深度可分离卷积引入到残差 U 型模块(residual U-blocks, RSU)内部,从而提高模块提取有效特征信息的能力,并在外层编解码跳跃连接中添加语义嵌入分支结构防止空间信息丢失,在其自制的 942 张含缺陷的光致发光(photoluminescence, PL)太阳能电池片数据集上检测的缺陷 MIoU 值达到 80.3%,但该方法细小缺陷识别不够精确且未考虑网络计算成本的增加。Chen 等^[16]提出一种基于弱监督学习的深度卷积神经网络框架对太阳能电池片表面缺陷进行检测和分割。该框架通过引入空间注意力类激活图(spatial attention class activation map, SA-CAM)抑制背景干扰,同时采用随机森林分类器替换传统全连接层以增强模型鲁棒性,实验表明,其在自制太阳能电池片可见光数据集上像素准确率和交并比等指标有一定提升,但对于一些与背景对比度低的缺陷或复杂背景下的细小缺陷识别效果不太好;汪方斌等^[17]提出了一种轻量化的改进 U-Net 网络模型对光伏电池 EL 图像进行缺陷检测,该模型结合了 MobileNet 中的深度可分离卷积和 ECA 注意力机制模块,提高了对裂纹、黑斑等缺陷检测精度并减少了模型的参数量和计算量。

综上所述,现有太阳能电池片缺陷检测方法存在诸多不足。物理方法受成本和二次损伤问题限制,传统机器视觉方法在特征提取能力较弱,深度学习方法部分存在计算成本高、对细小缺陷特征识别不精确的问题。为了解决这些问题,本文提出一种跨层融合的轻量化太阳能电池片缺陷分割方法,主要贡献如下:

1)针对细小特征识别不准确的问题,本文在 RSU 模块的外层跳跃连接中设计了一种结合交叉注意力机制的模块(cross 2-layer attention, C2LA),以汇集多尺度特征信息,从而增强网络对细小缺陷的分割能力。

2)针对缺陷边缘模糊的问题,在 U2-Net 模型的预测特征图输出端添加了残差细化模块(DSC-residual refinement module, D-RRM),旨在对第一阶段的粗粒度输出进行深入挖掘和重建,使得杂质污染、划痕等缺陷的预测边界更加清晰。

3)针对模型参数量和计算量大问题,本文将 RSU 模块内部的普通卷积和 RSU-4F 模块中的膨胀卷积替换为幻影卷积^[18](Ghost Conv),以减小模型的参数量和计算量。

1 数据采集与图像预处理

1.1 数据集准备与处理

根据中华人民共和国电子行业标准 SJ/T 11630-2016 中对太阳能电池片表面质量检验的相关规定,本文将数据集采集环境温度保持在 20 ℃~25 ℃之间,并按照规定将成像系统的光轴垂直于被测硅片表面。图像采集装置如图 1 所示,图 1 中使用了 Mind Vision 的 MV-GE300C 相机,拍摄时设置单张图片输出为 600 pixels×600 pixels。拍摄过程中通过光源控制器调节条形光源亮度,在调节好相机焦距直到可以清晰看清太阳能电池片表明纹理之后再通过工业相机拍摄太阳能电池片图案。

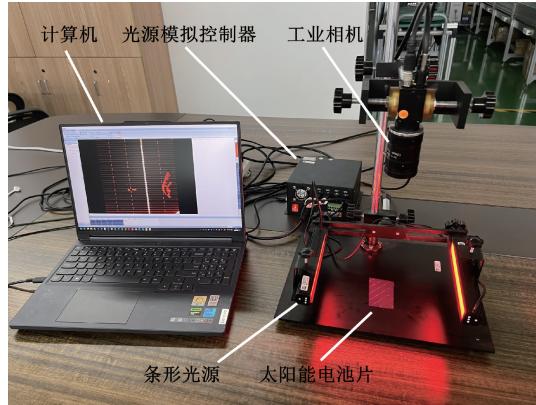


图 1 图像采集装置

Fig. 1 Image acquisition device

如图 2 所示,在进行太阳能电池片图像采集的实验过程中,受到文献[9]的启发,对红色光源和白色光源照射下的结果进行了对比。实验发现,使用红色光源照射时,太阳能电池片的栅格及其他细节识别效果更佳。在图 2(b)中,红色光源所提供的光线条件更优于图 2(a)中白色光源,使得电池片的栅格结构及细微特征更加突出,图像中的缺陷特征也更加清晰可辨,从而更有利与后续的缺陷分割等处理过程。其中红色条形光源型号为 FG-BR15017-R。

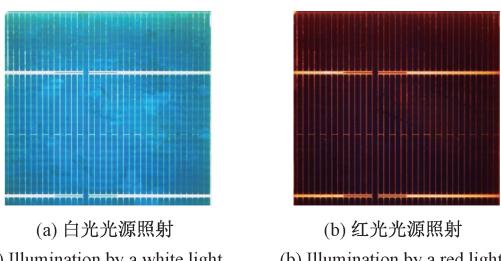


图 2 太阳能电池片通过光源处理后效果

Fig. 2 The effect of solar cell after treatment by light source

本文基于图像采集装置采集了多晶硅太阳能电池片图像 3 900 多张,通过目视检查去除拍摄失误而导致质量不佳的图片,目视检查判定为质量不佳图片的标准如下:对于

图像中太阳能电池片的边缘以及缺陷的边缘,若在正常观察距离下无法清晰辨认,即视为模糊;若电池片表面的纹理以及缺陷自身的纹理细节无法清晰呈现,也判定为图像模糊。当图像整体过亮,导致电池片表面的颜色信息丢失,或者关键特征无法通过亮度差异与背景区分开来,则判定为曝光过度;若图像整体过暗,使得电池片表面的大部分区域陷入黑暗,无法清晰看到电池片的结构以及缺陷情况,则判定为曝光不足。最终本文获得 3 800 张 60 mm×60 mm 多晶硅太阳能电池片图像,其中包含常见的划痕、杂质污染、断栅、裂片、缺角 5 种类型缺陷共计 4 667 个,其统计直方图如图 3 所示。其中划痕 1 211 个,杂质污染 937 个,断栅 896 个,裂片 791 个,缺角 832 个,构成本文的缺陷数据集。

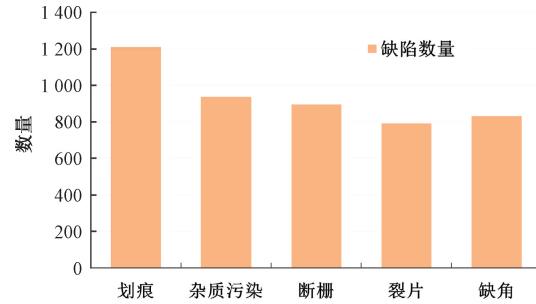


图 3 数据集缺陷类型分布

Fig. 3 Distribution of defect types in the dataset

1.2 数据集生成

使用 Labelme 软件对缺陷进行标注。经过多次实验验证,本文发现将图像由原始尺寸缩小到 512 pixels×512 pixels 是硬件内存可以处理的最适合大小,同时尽量保留图片中的最大细节数量。在网络训练之前,本文对缺陷数据集进行了一系列离线数据增强操作,其中几何变换包括随机裁剪、随机水平和垂直翻转等,像素变化包含椒盐噪声、高斯噪声、亮度调节等,模拟现实环境中各种干扰,以提升模型的鲁棒性。离线数据增强后图片总数量增加至 5 000 张,本文采用 8:2 的比例随机将太阳能电池片缺陷数据集划分为训练集和测试集,其中训练集和测试集图片分别为 4 000 张和 1 000 张。

2 网络模型

2.1 U2-Net 网络结构

U2-Net^[19] 是一种用于显著性语义分割的网络结构。如图 4 所示, U2-Net 是一个两层嵌套的 U 型结构,顶层为大 U 型结构,底层则是 RSU 模块,RSU 模块在每个阶段的配置都不同。

1) 六级编码器。如图 4 所示,RSU-7、RSU-6、RSU-5、RSU-4 分别用于 En-1、En-2、En-3 和 En-4 阶段,“RSU”后面的数字代表了高度 L。在 En-5 和 En-6 阶段,考虑到特征图分辨率已经较低,不再逐阶段下采样,而是采用带有膨胀卷积的 RSU-4F 模块。

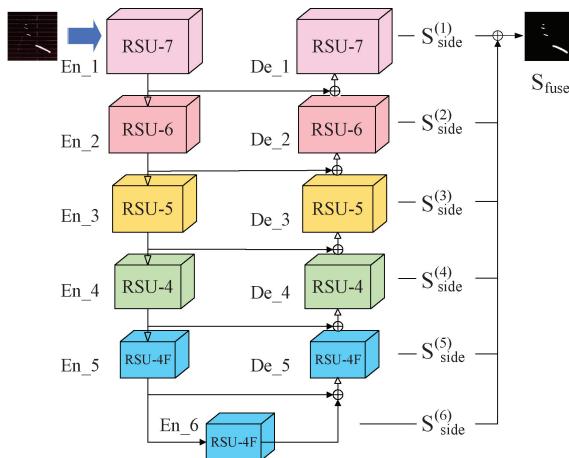


图 4 U2-Net 网络结构

Fig. 4 The structure of the U2-Net network

2)五级解码器。解码器的 5 个阶段的结构与对称的编码器 5 个阶段相似,并且在 De-5 中也使用了 RSU-4F 模块。

3)特征图融合模块。De-1、De-2、De_3、De_4、De_5 和 De_6 阶段输出的特征图分别经过 6 个 3×3 的卷积层处理。然后将这 6 张特征图上采样到输入图片大小,从而生成 $S_{side}^{(1)}$ 、 $S_{side}^{(2)}$ 、 $S_{side}^{(3)}$ 、 $S_{side}^{(4)}$ 、 $S_{side}^{(5)}$ 和 $S_{side}^{(6)}$ 。最后将这些结果通过 1×1 的卷积层进行连接和融合获得最终的 S_{fuse} 概率映射图。

如图 5 所示,RSU 模块则是由输入层、编解码结构和残差模块 3 个关键部分组成。其中输入层是一个专门用于局部特征提取的卷积层;编解码结构分为左右两部分,左侧负责实现多尺度特征提取,右侧负责通过上采样输出高分

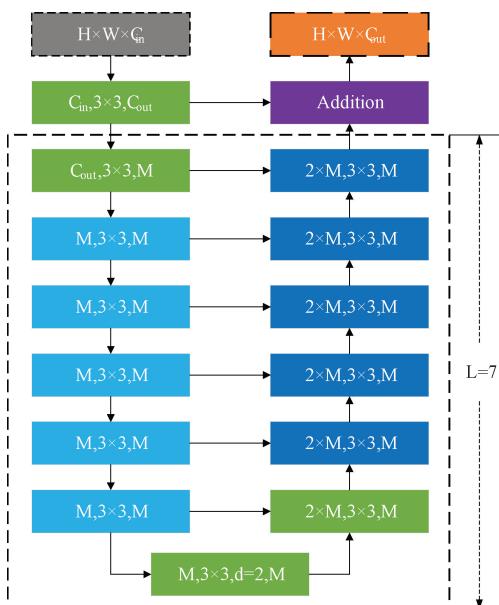


图 5 RSU-7 结构

Fig. 5 The structure of the RSU-7

辨率特征图;残差模块起到将输入特征与多尺度特征进行融合的作用。

2.2 C2LA-U2-Net 网络整体结构

本文基于 U2-Net 网络提出了带有交叉注意力模块和残差细化模块的轻量级语义分割模型 C2LA-U2-Net,该模型在太阳能电池片缺陷数据集上取得更好分割精度,同时做到了模型轻量化。如图 6 所示,其中图 6(a)为主干网络部分,图 6(b)为残差细化模块结构图,这两部分构成了 C2LA-U2-Net 整体网络结构。

为了解决细小缺陷识别效果不佳的问题,受非局部注意力机制^[20] (non-local neural networks, NLN) 的启发,结合 U2-Net 网络中不同高度 RSU 模块层层堆叠的特点,如图 6(a)所示,本文在 RSU 模块外部设计了交叉注意力模块 C2LA,以替换原网络的简单跳跃连接。该模块能够更好地融合多尺度特征信息,捕捉全局尺度长距离的特征,进而加强对细小缺陷识别能力。C2LA 模块具体结构如图 6(d)所示。此外,为了加强对杂质污染等有复杂边缘轮廓的缺陷分割效果,受边界感知显著物体检测网络 (boundary-aware salient object detection network, BASNet)^[21] 启发,本文在 U2-Net 网络的各层 RSU 模块输出的粗粒度特征图融合后再次输入到轻量化 D-RRM 模块,实现对缺陷边缘信息进一步的挖掘与细化。D-RRM 模块结构图如图 6(b)所示。为了减少模型参数量,本文将 RSU-7、RSU-6、RSU-5 和 RSU-4 模块中的普通卷积和 RSU-4F 中的膨胀卷积替换为 Ghost 卷积,确保在不影响 RSU 模块特征提取能力的前提下,降低网络模型的参数量和计算量,同时提升网络的推理速度。

2.3 C2LA 交叉注意力机制模块

U2-Net 网络通过对称的 RSU 编解码模块来提取多尺度信息。在多尺度特征融合阶段,原网络 RSU 模块仅使用简单的跳跃连接来级联全局多尺度上下文信息。这可能导致两个问题:1)单层跳跃连接容易导致空间信息丢失,从而使得细小特征分割效果变差;2)单层跳跃连在处理长程依赖和全局信息方面存在一定的局限性。

针对以上问题,C2LA-U2-Net 网络提出了新的交叉注意力模块 C2LA,如图 6(a)所示。该模块首先引入了一种跨层调节机制,通过聚合相邻两层的语义信息,在编码器 RSU 层之间实现特征融合。这一机制使得每个解码层能够聚合更多来自浅层编码的特征,从而获得更丰富的细小特征的细节信息。此外,C2LA 模块通过计算特征图中所有位置之间的相关性,能够直接捕捉到长程依赖关系,而不受空间位置的限制。这种设计不仅能够依据位置关系对特征进行加权求和,突出重要信息并抑制无关信息,从而动态调整两个不同层次特征的空间权重,增加对缺陷信息的关注,而且在反向传播时减少背景区域的干扰。通过这种方法在分割细小缺陷时能够显著提高分割效果。如图 6(d)所示,本文将深层网络特征图输入 F_L 通过 Align 操作得到

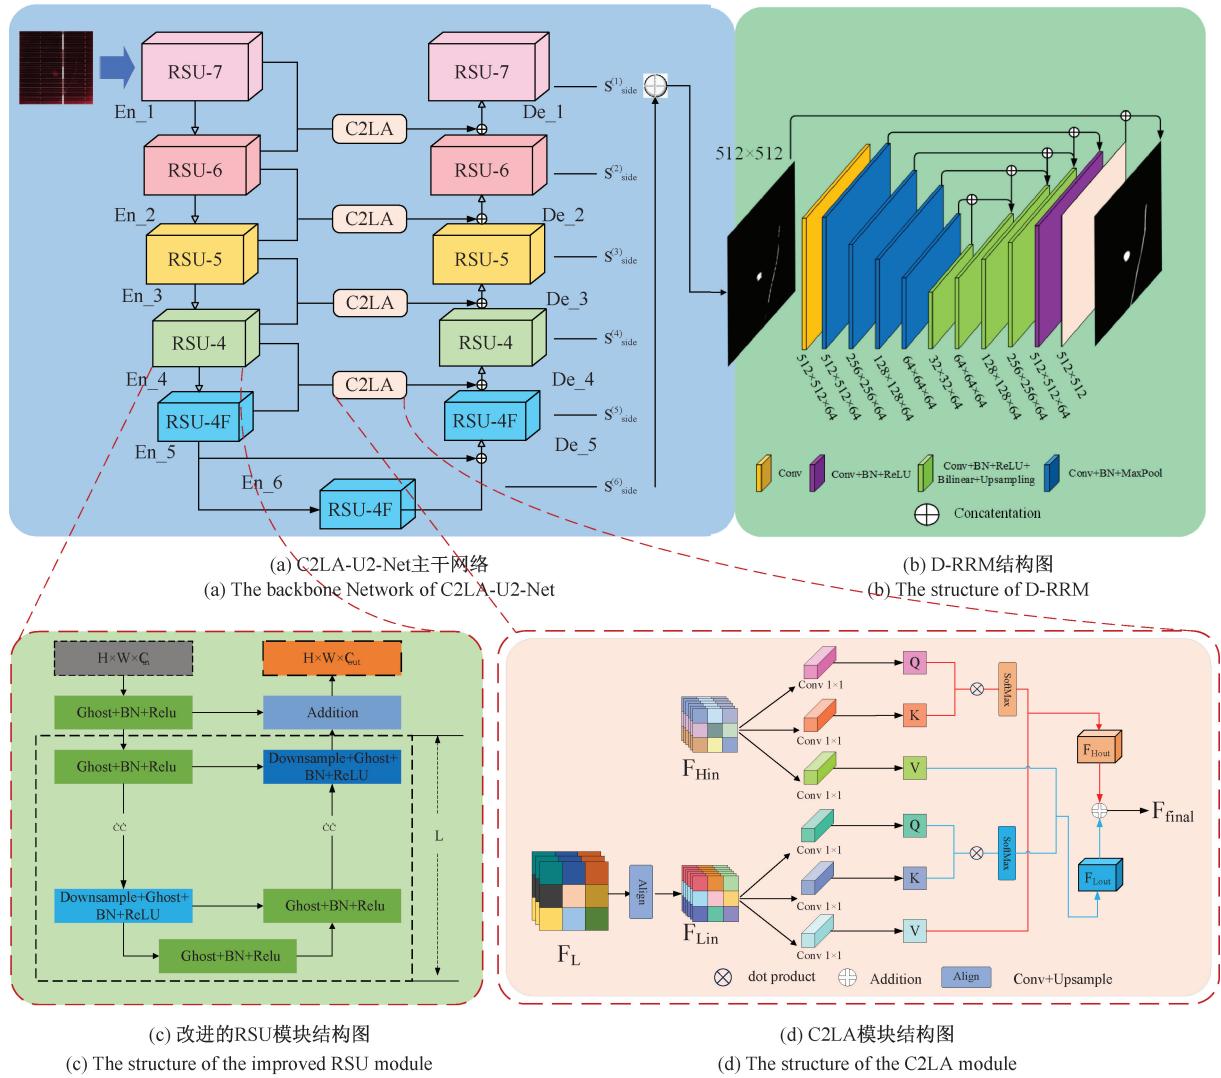


图 6 模型架构图

Fig. 6 Model architecture diagram

F_{Lin} ，并与浅层网络特征图输入 F_{Hin} 的尺寸对齐，Align 操

作包含 1×1 卷积以及上采样操作。

编码侧浅层 RSU 模块输出特征图为 F_{Hin} ，相邻深层 RSU 模块输出特征图为 F_{Lin} 。 $F_{\text{Hin}}, F_{\text{Lin}}$ 分别通过 3 个 1×1 卷积经线性变化获得查询 (query, Q)、键 (key, K)、值 (value, V)。公式为：

$$F_{\text{H}}^{\text{Q}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Hin}}), F_{\text{L}}^{\text{Q}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Lin}}) \quad (1)$$

$$F_{\text{H}}^{\text{k}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Hin}}), F_{\text{L}}^{\text{k}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Lin}}) \quad (2)$$

$$F_{\text{H}}^{\text{v}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Hin}}), F_{\text{L}}^{\text{v}} = \text{Conv}_{1d}^{1 \times 1}(F_{\text{Lin}}) \quad (3)$$

以上 3 个公式中：H、L 分别代表来自于不同层的特征，其中 F_{H} 是深层特征， F_{L} 为浅层特征；Q、K、V 分别是 $F_{\text{Hin}}, F_{\text{Lin}}$ 经过线性映射后输出的结果。

接着同层的 Q、K 点乘后通过 Softmax 函数处理得到注意力权重。为了加深层与层之间空间信息的交互，在获得注意力权重后再与相邻层的 V 值进行点乘，获得 F_{Hout}

和 F_{Lout} 。公式为：

$$F_{\text{Hout}} = \text{Softmax}(F_{\text{H}}^{\text{Q}} \odot F_{\text{H}}^{\text{k}}) \odot F_{\text{H}}^{\text{v}} \quad (4)$$

$$F_{\text{Lout}} = \text{Softmax}(F_{\text{L}}^{\text{Q}} \odot F_{\text{L}}^{\text{k}}) \odot F_{\text{L}}^{\text{v}} \quad (5)$$

最终将 F_{Hout} 和 F_{Lout} 输出相加后获得 F_{final} 输入到编码侧，公式为：

$$F_{\text{final}} = F_{\text{Hout}} + F_{\text{Lout}} \quad (6)$$

2.4 D-RRM 残差细化模块

为了细化缺陷分割边缘信息，使粗糙的缺陷图像获得更加真实的分割效果，本文引入残差细化模块 D-RRM。如图 6(b)所示，该模块采用残差编码-解码结构，将 U2-Net 编解码层输出特征图 S_{fuse} 的多尺度特征重复利用，再通过深层次的特征学习和残差学习获取高等级的全局信息和低等级的细节信息，从而获得更精细的缺陷边缘分割效果。同时该模块将普通卷积替换为深度可分离卷积 (DSC)，利用少量的卷积核和较为简单的线性变换操作，有

效减少了模块的参数量。

D-RRM 通过学习太阳能电池片预测缺陷分割图与真实值之间的差异 S_{residual} 来优化预测到的粗糙的分割图 S_{coarse} 。公式为:

$$S_{\text{refined}} = S_{\text{coarse}} + S_{\text{residual}} \quad (7)$$

D-RRM 模块的结构类似于 U2-Net 网络中的 RSU 模块,同样由编码器、跨层连接模块和解码器三部分组成。与 RSU 模块不同的是,D-RRM 模块的残差连接策略是将经过卷积处理的特征图与输入特征图直接相加,从而增强边界和细节特征的表达能力。

如图 7 所示,D-RRM 模块中的编码器和解码器各包含 4 个阶段的特征处理层,每个阶段由深度可分离卷积层、批量归一化层和 ReLU 激活函数构成。编码器通过最大池化实现下采样,而解码器则采用双线性插值进行上采样。最终,D-RRM 模块的输出特征图被用作模型的预测结果。

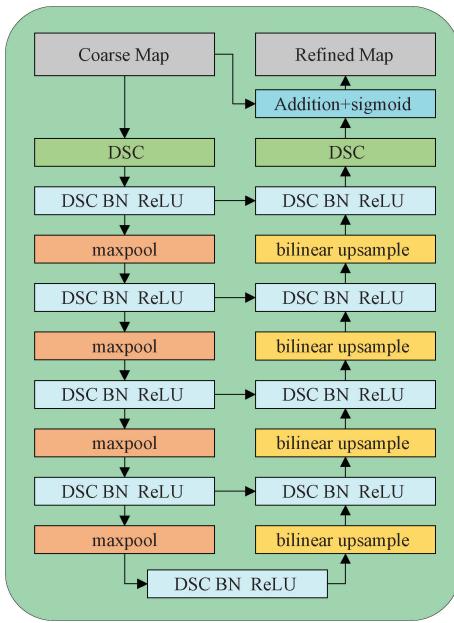


图 7 D-RRM 细化流程图

Fig. 7 D-RRM refinement process diagram

2.5 RSU 模块改进

RSU 模块通过 U 型结构混合不同尺度和感受野的特征图,以获得更多的全局信息。然而,RSU 模块中使用的普通卷积和 RSU-4F 模块中的膨胀卷积往往产生大量冗余特征^[22],导致模型推理速度降低和参数量增加。因此,本文将 RSU 模块内部的普通卷积和 RSU-4F 模块中的膨胀卷积替换为 Ghost 卷积,从而减少模型的参数数量和计算量,其结构如图 6(c)所示。Ghost 卷积结构如图 8 所示。Ghost 卷积由卷积操作、线性变换和特征图拼接 3 个部分组成。首先使用常规的卷积运算从输入特征图中提取内在特征图。接着,对内在特征图进行更廉价的 Φ 线性变换以生成幻影特征图。最后,将内在特征图和幻影特征图结

合,生成最终的特征图。通过这种方法,Ghost 卷积有效地降低了模型对计算资源的需求,同时实现了对输入特征图的准确特征提取。

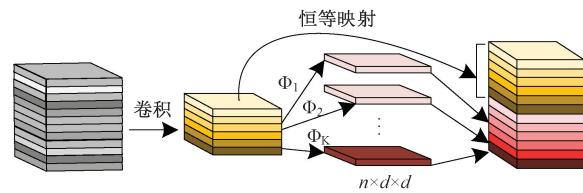


图 8 Ghost 卷积

Fig. 8 Ghost convolution

3 实验与结果分析

3.1 实验参数设置

本文的实验环境和训练参数设置如表 1 所示。

表 1 实验环境和训练参数

名称	参数
操作系统	Windows10 专业版
处理器	Intel(R) Xeon(R) CPU E5-2686 v4
显卡	4×3080 Ti-12G
网络框架	Pytorch
CUDA	12.1

本文网络采用 AdamW 优化器来动态调整学习率。初始学习率设置为 0.001。在前两轮的 Warmup 阶段,学习率从 0.001 逐渐增加到 1,以帮助模型在初期实现稳定的收敛。随后,使用余弦退火算法对学习率进行调整。训练集和测试集的输入图片尺寸都是 $512 \times 512 \times 3$,训练的 epoch 设置为 300,Batchsize 为 16。

3.2 评价指标

为了衡量改进后的 C2LA-U2-Net 网络模型在分割太阳能电池片缺陷时的有效性,本文使用了平均像素精度 (mean pixel accuracy, MPA)、平均交并比 (mean intersection over union, MIoU)、平均像素召回率 (mean pixel recall, MRecall) 和 F_1 分数 4 个指标衡量语义分割模型的性能。4 个指标计算公式如下:

$$\text{MPA} = \frac{1}{K+1} \sum_{i=0}^k \frac{TP}{TP + FN} \quad (8)$$

$$\text{MIoU} = \frac{1}{K+1} \sum_{i=0}^k \frac{TP}{FN + FP + TP} \quad (9)$$

$$\text{MRecall} = \frac{1}{K+1} \sum_{i=0}^k \frac{TP}{TP + FN} \quad (10)$$

$$F_1 = \frac{2 \times \frac{TP}{TP + FP} \times \frac{TP}{TP + FN}}{\frac{TP}{TP + FP} + \frac{TP}{TP + FN}} \quad (11)$$

式中:TP 表示实际是缺陷区域预测也为缺陷区域的面积;TN 表示实际为缺陷区域但预测为背景区域的面积;FN 实际为背景区域预测也为背景区域的面积;FP 表示实际是背景区域但预测为缺陷区域的面积。常数 K 表示类别数,K+1 表示增加了一个背景类。

其中,MPA 值高低反映了模型在像素级别上对缺陷进行分类为缺陷和背景的准确性;MIoU 则是为了衡量预测值和真实值的空间重叠程度指标;MRecall 是用于衡量模型在识别和分割目标区域时完整性的指标。它反映了所有预测为缺陷目标像素中,能够正确分割出缺陷像素所占的比例。MRecall 值越高,代表模型在分割目标区域时遗漏越少,即对目标的识别和分割越完整,模型分割效果

也就越好。 F_1 分数是计算精确度和召回率的加权平均数。上述指标数值越接近于 1,代表模型分割效果越好。

本文使用参数量 (parameters, Param) 和计算量 (floating point operations, Flops) 来评估模型大小。每秒图像处理量 (frames per second, FPS) 则用于衡量模型在实时应用场景中的运算速度。

3.3 对比实验

为了验证本文模型在太阳能电池片缺陷数据集上的分割有效性,本文算法与当前主流的语义分割算法进行了对比,包括 U-Net、U2-Net、PSPNet、SegNet、DeepLabv3+ 以及 PIDNet。在对比实验中,各网络所使用的数据集和实验环境配置均保持一致。实验结果见表 2 所示。

表 2 对比实验

Table 2 Comparative experiment

算法	MPA/%	MIoU/%	MRecall/%	F_1 /%	Parameter/M	GFLOPs/G
U-Net(VGG16)	84.97	86.27	80.03	84.14	24.56	255.16
U2-Net	85.12	87.53	82.24	85.54	176.38	150.61
PSPNet(Resnet50)	81.68	79.08	79.73	73.68	186.83	184.73
SegNet	81.73	86.86	79.92	84.91	117.48	347.24
DeepLabv3+(Xception)	78.76	84.22	77.24	81.32	54.71	158.97
PIDNet	85.33	88.12	83.34	86.58	111.05	27.66
本文	88.22	92.02	86.63	89.71	18.05	65.25

与以上 6 个算法对比,本文算法在 MPA、MIoU、MRecall、 F_1 这 3 个指标上较 U2-Net 基线模型提升了 3.10%、4.49%、4.39% 和 4.17%。对比 U-Net、PSPNet、SegNet、DeepLabv3+、PIDNet 算法,本文算法在更小的参数量的情况下,MIoU 值分别比对比网络高出 5.75%、12.94%、5.16%、7.80% 和 3.90%。同时,本文算法的 MPA、MRecall 和 F_1 指标也是最高的,这表明本文模型对缺陷像素的分割精度更优,误分割现象更少。

其中值得注意的是,相较于基线模型,本文算法参数量和计算量下降幅度分别达到了 89.77% 和 56.68%。这证明本文算法在轻量化策略上产生了明显的效果。综上所示,本文算法在多个关键性语义分割指标上都有一定的提升,分割精度更高并且更加轻量化。这证明了本文算法的优越性。

为了更直观的体现本文算法有效性,本文将改进模型与对比网络模型中 U2-Net、DeepLabv3+、PIDNet 网络进行了分割可视化对比,实验结果如图 9 所示。

从图 9 中可以观察到,MIoU 值越高的网络缺陷分割性能越好。在分割划痕和断栅时, U2-Net 网络和 DeepLabv3+ 都出现了漏检的情况,而本文算法则没有出现,同时在表 2 中本文算法的 MRecall 值比 U2-Net 和 DeepLabv3+ 网络更高,这说明 C2LA 模块加强了网络对多尺度信息的提取能力,提高了对细小目标识别效果,使

得网络在分割缺陷时出现更少的缺陷漏分割的情况;在分割杂质污染时,杂质污染颜色深浅导致的色差变化会给网络分割带来困难,本文算法相比于其他对比算法可以更好地保持缺陷边缘轮廓完整性,这说明 D-RRM 模块的残差编码-解码结构能够重复利用多尺度特征,通过深层次的特征学习和残差学习获取高等级的全局信息和低等级的细节信息,当面对杂质污染颜色深浅不一的情况时,该模块能够根据缺陷边缘的模糊程度,有效地挖掘和细化缺陷边缘信息,使预测边界更加清晰,从而更好地保持缺陷边缘轮廓完整性;从图 9 中还可以看出,在分割裂片缺陷时,本文算法识别的缺陷更加平滑,整体连通性更好,没有出现 U2-Net 网络分割裂片时缺陷断裂的情况,也没有出现 PIDNet 识别缺陷的红色边框中多分割出的点,这说明本文所提模型在处理这类缺陷时具有更好的准确性和稳定性,能够更有效地识别和分割缺陷特征,避免出现错误分割的情况。通过对不同模型在分割划痕、断栅、杂质污染以及裂片等缺陷时的表现进行对比分析,发现 DeepLabv3+ 网络在各项指标及实际分割效果上均不如 U2-Net、PIDNet 以及本文算法。本文所提网络在太阳能电池片细小缺陷的分割以及边缘特征的提取方面展现出了更出色的性能,具备更好的准确性和稳定性,能够更有效地识别和分割缺陷特征,避免出现错误分割的情况。综上所述,本文所提网络在太阳能电池片细小缺陷的分割以及边缘

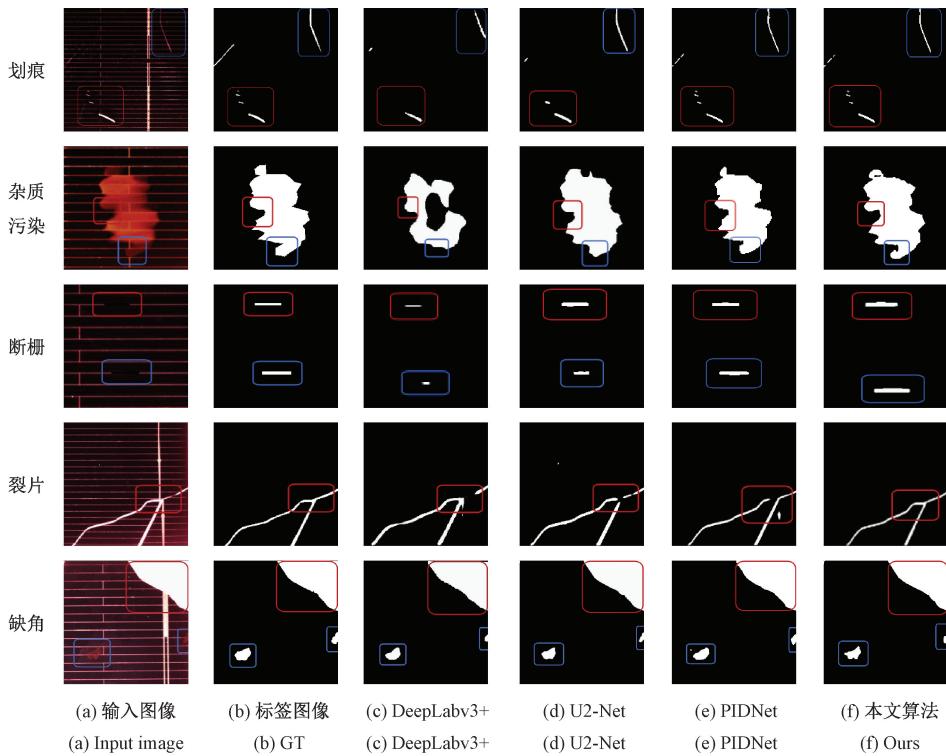


图 9 不同模型分割结果对比

Fig. 9 Comparison of segmentation results of different models

特征的提取方面具有更出色的表现。

为比较所提出的交叉注意力模块 C2LA 对 U2-Net 网络性能的影响,本文进行了系列实验。具体方法是将 C2LA 模块分别替换为卷积块注意力模块^[23](convolutional block attention module, CBAM)和凝聚注意力模块^[24](condensed attention, CA),从而评估不同模块的性能。为保证实验的公平性,CBAM 模块和凝聚注意力模块通过简单堆叠将参数量被调整至略大于 C2LA 模块参数量。实验结果如表 3 所示,其中第一列“算法”下的“—”表示跳跃连接部分没有添加注意力模块。

表 3 不同注意力机制对比实验

Table 3 Comparative experiment of different attention mechanisms

算法	MPA/	MIoU/	MRecall/	F ₁ /	Parameter/
	%	%	%	%	M
—	85.12	87.53	82.24	85.54	—
CBAM	85.41	87.84	82.27	85.56	7.15
CA	84.88	87.59	82.26	85.33	7.09
C2LA	87.97	90.01	86.44	89.53	7.08

由表 3 可知,在对不同注意力机制进行对比实验时,添加 C2LA 模块后,U2-Net 网络呈现出更优的分割指标。其中,MIoU 值相比于添加 CBAM 模块和 CA 模块分别提

高了 2.17% 和 2.42%,这说明 C2LA 模块在增强了预测缺陷与真实缺陷空间重叠程度;在平均像素精度(MPA)方面,添加 C2LA 模块后达到了 87.97%,相较于 CBAM 模块(85.41%)和 CA 模块(84.88%),有明显提升。这表明 C2LA 模块极大地提高了模型在像素级别对缺陷和背景分类的准确性;平均像素召回率(MRecall)在添加 C2LA 模块后为 86.44%,比 CBAM 模块和 CA 模块更高,这表明了模型在识别和分割目标区域时完整性更佳,遗漏更少。F₁ 分数在添加 C2LA 模块后提升至 89.53%,这体现了模型在精确度和召回率平衡上的优化。综合以上各个指标的分析结果可以看出,尽管在实验中提升了 CBAM 模块和 CA 模块的参数量,但它们并未显著提升网络的分割性能。相反,C2LA 模块在多个关键指标上均更高,这些结果验证了所提出的交叉注意力模块(C2LA)的有效性。

3.4 消融实验

为了进一步验证所提模型对太阳能电池片分割效果的有效性,本文运用控制变量法,依次在 U2-Net 网络模型中添加 C2LA 模块、D-RRM 模块、轻量化 RSU 模块(Ghost),并在太阳能电池片缺陷数据集上展开消融实验研究。实验数据如表 4 所示,其中“√”表示使用了该模块。

通过表 4 消融数据可知,相较于 U2-Net 基线模型,加入交叉注意力模块 C2LA 后 MPA、MIoU、MRecall、F₁ 的值分别提升了 2.85%、2.48%、4.2% 和 3.99%,这表明 C2LA 模块有效的聚合了多尺度特征,加强了对太阳能电

表 4 消融实验

Table 4 Ablation experiments

U2-Net	C2LA	D-RRM	Ghost	MPA/%	MIoU/%	MRecall/%	F ₁ /%	Parameter/M	GFLOPs/G	FPS/fps
✓	—	—	—	85.12	87.53	82.24	85.54	176.38	150.61	7.60
✓	✓	—	—	87.97	90.01	86.44	89.53	183.46	166.04	7.25
✓	✓	✓	—	88.19	91.77	86.58	89.70	183.72	205.44	7.02
✓	✓	✓	✓	88.22	92.02	86.63	89.71	18.05	65.25	13.45

池片缺陷信息的关注,减少缺陷的漏分割,整体提升了网络分割效果。具体而言,其跨层调节机制和计算特征图相关性的操作,使得模型能够更好地融合多尺度特征信息,捕捉长程依赖关系,从而提高了对细小缺陷的分割效果,进而提升了相关指标。D-RRM 模块的加入使得 MPA、MIoU 和 F_1 的值分别再次提升了 0.22%、1.76%、0.17%,这表明 D-RRM 模块挖掘了更多复杂边缘的信息,细化了缺陷轮廓。Ghost 卷积通过卷积操作、线性变换和特征图拼接 3 个部分协同工作,减少冗余特征,在将部分 RSU 模块的普通卷积和 RSU-4F 模块中膨胀卷积替换为 Ghost 卷积后,参数量下降了 165.67 MB,计算量下降了 140.19 G,而模型推理速度也有大幅度提升。实验结果表明,C2LA-U2-Net 模型改进相较于原 U2-Net 模型分割性能更好,同时模型参数量和计算量也大大降低,推理速度也得到提升。

本文算法和 U2-Net 算法在太阳能电池片缺陷数据集上的训练损失函数曲线(Loss)如图 10 所示。所使用的损失函数为交叉熵损失(binary cross entropy, BCE)。本文提出的 C2LA-U2-Net 算法 Loss 在训练初始的 0~50 个 Epoch 内训练收敛更快,这说明 Ghost 卷积减少了卷积神经网络冗余特征,使得模型能够更快地收敛。随着训练次数增加,在 150 个 Epoch 之后,两个模型的训练损失逐渐趋于稳定,模型逐渐收敛。但本文算法损失曲线后期波动幅度更小,Loss 值也更小。

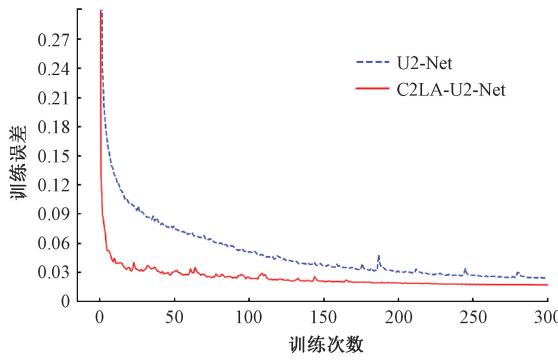


图 10 训练损失曲线对比

Fig. 10 Comparison of training loss curves

4 结 论

本文基于 U2-Net 网络提出了一种针对太阳能电池片

进行语义分割的模型。本文首先在 RSU 模块外通过交叉注意力机制进行的跳跃连接,有效融合了相邻层的特征信息,减少了有效特征信息的丢失,从而增强了对细小缺陷的识别能力。其次,引入了残差细化模块(D-RRM),对网络输出的特征图进行了二次细化,使得对杂质污染等复杂轮廓的分割效果更加精准。最后,采用了 Ghost 卷积层替换了 RSU 模块中的部分普通卷积层和 RSU-4F 模块中膨胀卷积层。

实验结果表明,相较于目前几种主流的语义分割模型,C2LA-U2-Net 在处理太阳能电池片缺陷图像时,展现出了更高的检测精度和更佳的分割效果。在多个关键性语义分割指标上都有一定的提升。同时,成功在不影响分割精度的情况下显著降低了模型的参数量和计算量,并且相较于原网络模型显著提升了推理速度。本文研究希望能为构建更有效、更准确的太阳能电池缺陷检测系统提供一定的参考和帮助。

参考文献

- [1] MAKHA O M, ALABID J M. Solar energy technology and its roles in sustainable development [J]. Clean Energy, 2022, 6(3): 476-483.
- [2] 钱晓亮, 张鹤庆, 张焕龙, 等. 基于视觉显著性的太阳能电池片表面缺陷检测[J]. 仪器仪表学报, 2017, 38(7): 1570-1578.
- [3] QIAN X L, ZHANG H Q, ZHANG H L, et al. Solar cell surface defect detection based on visual saliency[J]. Chinese Journal of Scientific Instruments, 2017, 38(7): 1570-1578.
- [4] ENNEMRI A, LOGERAIS P O, BALISTROU M, et al. Cracks in silicon photovoltaic modules: a review [J]. Journal of Optoelectronics and Advanced Materials, 2019, 21(1-2): 74-92.
- [5] DHIMISH M, D'ALESSANDRO V, DALIENTO S. Investigating the impact of cracks on solar cells performance: Analysis based on nonuniform and uniform crack distributions[J]. IEEE Transactions on Industrial Informatics, 2021, 18(3): 1684-1693.
- [6] LI Y K, HE C F, LYU Y, et al. Crack detection in monocrystalline silicon solar cells using air-coupled ultrasonic lamb waves[J]. NDT & E International, 2019, 102: 129-136.
- [7] GAN D W, QUAN L, ZHU F, et al. Orthogonal modulation based light beam induced current method

- for anti-noise defect detection in photovoltaic cells[J]. *Solar Energy*, 2022, 245: 158-164.
- [7] 何存富,李永坤,吕炎,等. 基于气体基压电复合材料的线聚焦空耦超声传感器研制与应用[J]. 复合材料学报, 2018,35(3): 653-660.
- HE C F, LI Y K, LYU Y, et al. Design and application of line-focus air-coupled ultrasonic transducer based on air-based piezoelectric composites [J]. *Acta Materiae Compositae Sinica*, 2018, 35(3): 653-660.
- [8] TSAI D M, CHANG CH CH, CHAO SH M. Micro-crack inspection in heterogeneously textured solar wafers using anisotropic diffusion [J]. *Image and Vision Computing*, 2010, 28(3): 491-501.
- [9] 李桥,钟宝江. 硅片缺陷检测中的图像分割方法[J]. *计算机应用*, 2016, 36(S1): 130-132,137.
- LI Q, ZHONG B J. Image segmentation method for detection of wafer defects[J]. *Journal of Computer Applications*, 2016, 36(S1): 130-132,137.
- [10] AKRAM M W, LI G Q, JIN Y, et al. CNN based automatic detection of photovoltaic cell defects in electroluminescence images[J]. *Energy*, 2019, 189: 1-40.
- [11] 刘玉淇,吴一全. 基于机器视觉的太阳能电池片缺陷检测算法综述[J]. *光学精密工程*, 2024, 32(6): 868-900.
- LIU Y Q, WU Y Q. Review of defect detection algorithms for solar cell based on machine vision[J]. *Optics and Precision Engineering*, 2024, 32 (6): 868-900.
- [12] HAN H, GAO CH Q, ZHAO Y, et al. Polycrystalline silicon wafer defect segmentation based on deep convolutional neural networks[J]. *Pattern Recognition Letters*, 2020, 130: 234-241.
- [13] 吴俊良,刘怀广,汤勃. 基于全注意力 FSA-UNet 网络的单晶电池片混合缺陷检测[J]. *电子测量技术*, 2023, 46(12): 98-104.
- WU J L, LIU H G, TANG B. Hybrid defect detection of monocrystalline cells based on full attention FSA-UNet network [J]. *Electronic Measurement Technology*, 2023, 46(12): 98-104.
- [14] 王延年,刘宏涛,刘航宇,等. 基于改进 U-Net 的太阳能电池图像缺陷检测方法[J]. *电子测量技术*, 2021, 44(14): 117-121.
- WANG Y N, LIU H T, LIU H Y, et al. Solar cell image defect detection method based on improved U-Net[J]. *Electronic Measurement Technology*, 2021, 44(14): 117-121.
- [15] 王盛,吴浩,彭宁,等. 改进 U2-Net 的太阳能电池片缺陷分割方法[J]. *国外电子测量技术*, 2023, 42(2): 177-184.
- WANG SH, WU H, PENG N, et al. Improved U²-Net for defect segmentation of solar cells[J]. *Foreign Electronic Measurement Technology*, 2023, 42 (2): 177-184.
- [16] CHEN H Y, HU Q D, ZHAI B SH, et al. A robust weakly supervised learning of deep Conv-Nets for surface defect inspection[J]. *Neural Computing and Applications*, 2020, 32: 11229-11244.
- [17] 汪方斌,李文豪. 基于改进轻量化 U-Net 模型的光伏电池 EL 图像缺陷检测[J]. *电子测量技术*, 2024, 47(5): 102-111.
- WANG F B, LI W H, Defect detection of photovoltaic cell EL images based on improved lightweight U-Net model [J]. *Electronic Measurement Technology*, 2024, 47(5): 102-111.
- [18] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 1580-1589.
- [19] QIN X B, ZHANG Z CH, HUANG CH Y, et al. U2-Net: Going deeper with nested U-structure for salient object detection [J]. *Pattern Recognition*, 2020, 106: 107404.
- [20] WANG X L, GIRSHICK R, GUPTA A, et al. Non-local neural networks [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7794-7803.
- [21] QIN X B, ZHANG Z CH, HUANG CH Y, et al. BASNET: Boundary-aware salient object detection [C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 7479-7489.
- [22] CHEN Y L, WANG K, LIAO X Y, et al. Channel-UNet: A spatial channel-wise convolutional neural network for liver and tumors segmentation [J]. *Frontiers in Genetics*, 2019, 10: 1110.
- [23] WOO S, PARK J CH, LEE J Y, et al. CBAM: Convolutional block attention module[C]. *European Conference on Computer Vision*, 2018: 3-19.
- [24] ZHAO H Y, GOU Y B, LI B Y, et al. Comprehensive and delicate: An efficient transformer for image restoration[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 14122-14132.

作者简介

陈光耀,硕士研究生,主要研究方向为计算机视觉、人工智能。

E-mail:923706361@qq.com

陈田(通信作者),教授,研究生导师,主要研究方向为智能化设计/制造/检测/机器视觉、数字几何处理等。

E-mail:chent@sdju.edu.cn

高学海,副教授,研究生导师,主要研究方向为复杂系统数字化建模与仿真,传动构件数字化制造及其数字孪生,传动系统工业软件。

E-mail:32123@sdju.edu.cn

刘军,教授,研究生导师,主要研究方向为电机智能控制、电力电子、微机控制技术。

E-mail:liujun@sdju.edu.cn