

# 基于改进轻量化 U-Net 模型的光伏电池 EL 图像缺陷检测<sup>\*</sup>

汪方斌<sup>1,2</sup> 李文豪<sup>1,2</sup>

(1. 安徽建筑大学机械与电气工程学院 合肥 230601; 2. 安徽建筑大学建筑机械故障诊断与预警重点实验室 合肥 230601)

**摘要:** 基于实际工程检测现场神经网络结构庞大、参数量巨大、环境复杂,硬件设备性能差等原因导致缺陷的实时检测速率慢、精度低的问题,本研究结合 MobileNet 中的深度可分离卷积配合 ECA 注意力机制模块的轻量化思想,以及 U-Net 网络的特征提取模型提出了一种基于改进 U-Net 网络模型的光伏电池板缺陷检测方法。同时,根据光伏电池缺陷的特点,选择适合的激活函数以及对交叉熵损失函数进行了改进。实验结果表明,改进的 U-Net 算法较原算法不仅将参数量减少了 36%,而且对裂纹、黑斑等缺陷的检测精度达到了 97.05%,相对传统网络具有较好的光伏电池表面缺陷分割效果。

**关键词:** 电致发光;光伏电池;缺陷检测;深度可分离卷积;U-Net;ECA;图像分割

中图分类号: TP391.9; O436 文献标识码: A 国家标准学科分类代码: 510.1050

## Defect detection of photovoltaic cell EL images based on improved lightweight U-Net model

Wang Fangbin<sup>1,2</sup> Li Wenhao<sup>1,2</sup>

(1. School of Mechanical and Electrical Engineering, Anhui Jianzhu University, Hefei 230601, China; 2. Key Laboratory of Construction Machinery Fault Diagnosis and Early Warning Technology, Anhui Jianzhu University, Hefei 230601, China)

**Abstract:** Due to the large neural network structure, vast number of parameters, complex environment, and poor performance of hardware equipment in actual engineering inspection sites, the real-time detection rate of defects is slow and the accuracy is low. This study combines the lightweight concept of Depthwise Separable Convolution from MobileNet with the ECA attention mechanism module, as well as the feature extraction model of the U-Net network, to propose a photovoltaic panel defect detection method based on an improved U-Net network model. At the same time, according to the characteristics of photovoltaic cell defects, suitable activation functions were selected and the cross-entropy loss function was improved. Experimental results show that the improved U-Net algorithm not only reduced the number of parameters by 36% compared to the original algorithm, but also achieved a detection accuracy of 97.05% for defects such as cracks and black spots, demonstrating better performance in segmenting surface defects of photovoltaic cells than traditional networks.

**Keywords:** electroluminescence; photovoltaic cell; defect detection; depthwise separable convolution; U-Net; ECA; image segmentation

## 0 引言

光伏电池在各个领域有着广泛的应用,但在生产、运输和使用的过程中容易产生各种缺陷,影响光伏电池的发电

性能和产品质量,进而影响光伏电站的经济效益和安全运行<sup>[1]</sup>,及时地检测和处理缺陷具有着重要意义,电致发光检测方法因其操作简便、检测速度快等优点,应用最为广泛<sup>[1-2]</sup>,Parikh 等<sup>[3]</sup>从光伏电池电致发光(electroluminescence,

收稿日期:2024-01-10

\* 基金项目:安徽省自然科学基金(2008085UD09)、安徽省教育厅高校自然科学重点项目(KJ2020A0487)、安徽省教育厅高校研究生科学项目(YJS20210512)、安徽省教育厅高校协同创新项目(GXXT-2021-010)、安徽省住房城乡建设科学技术计划项目(2022-YF016,2022-YF065,2023-YF050)、安徽省高等学校科学项目(2022AH040044)资助

EL) 图像的直方图中提取统计参数作为特征描述符, 为光伏应用(如故障检测评估)提供了重要的特征信息。Juan 等<sup>[4]</sup>通过支持向量机(SVM)分类器, 结合 EL 成像和数字图像处理技术, 实现了对正常和有缺陷的太阳能电池的分类。Puranik 等<sup>[5]</sup>提出了一种广义定量电致发光(G-QUEL)方法, 用于根据 EL 图像评估有缺陷且不均匀降解的光伏组件的性能, 分析了不同类型的缺陷和退化对电池 EL 特性和常数的影响。近年来, 深度学习技术在光伏电池缺陷检测方面取得了显著的进展, 国内外研究人员提出了多种创新算法, Fiorese 等<sup>[6]</sup>提出了一种语义分割模型, 可以识别和分割硅光伏(PV)电池 EL 图像中的缺陷, 包括多晶硅和单晶硅电池的裂纹、接触中断、电池互连故障和接触腐蚀。Otamendi 等<sup>[7]</sup>提出了一种端到端的深度学习管道, 可以通过 EL 图像检测、定位和分割光伏电池的电池级异常。Deitsch 等<sup>[8]</sup>使用卷积神经网络对 EL 图像中的光伏电池片缺陷进行自动分类, 实现了高精度和高效率的缺陷检测。Wu 等<sup>[9]</sup>提出了一种快速的光伏板阴影检测方法 Ghost-RetinaNet, 以解决光伏电池检测中目标密度高、重叠大、成本高、实时性差的问题。李冰等<sup>[10]</sup>提出了一种融合注意力的多尺度光伏板缺陷检测方法有效地识别红外图像中的缺陷。周颖等<sup>[11]</sup>提出一种多尺度卷积神经网络模型(IMCNN), 并使用生成对抗网络生成一部分图像样本, 达到有效进行数据增强的目的。吴俊良等<sup>[12]</sup>提出了一种全注意力 FSA-UNet 网络, 用于太阳能电池片混合缺陷分割, 取得了良好的分割效果。田浩等<sup>[13]</sup>则提出了一种多尺度特征融合的光伏组件缺陷检测算法, 取得了高精度的缺陷识别结果。郭清华等<sup>[14]</sup>成功地将 U-Net 网络应用于电池片缺陷检测, 缺陷检测准确率超过了 90%。

U-Net 因其特殊的网络架构, 可以通过跳跃连接聚合更多尺度的信息<sup>[15]</sup>, 更好适应特征不明显的缺陷<sup>[16]</sup>, EL 图像常伴有高复杂背景和噪声干扰, 也会受到金属杂质、晶界、氧化物等杂质干扰, 影响对于缺陷种类的判断。因此在判断光伏电池 EL 图像中的缺陷类型时, 既需要全局把控又需要细节的支撑, U-Net 网络在这一方面表现突出, 但是通常也需要大量的数据集和高性能的硬件, 而在实际工程应用中, 光伏电站环境复杂, 分布在不同地理位置和气候条件下, 如沙漠、高原、山区、海岛等, 受到网络、高温、低温等因素影响, 导致检测设备性能下降, 实时检测速率慢, 精度低, 因此, 对于轻量化网络的研究具有重要意义。国内外研究人员提出了许多轻量化思想, 例如, Deng 等<sup>[17]</sup>提出了一种具有深度跳跃连接的高效且轻量级的 ELU-Net, 使用深度可分离卷积(depthwise separable convolution, DSConv)代替传统的标准卷积操作, 减少了参数数量和计算量, 使用特征金字塔池化模块来捕获不同尺度的特征信息, 提高了网络对于不同大小目标的分割能力。Chung 等<sup>[18]</sup>使用基于 UNet3+ 的全尺寸跳跃连接 U-Net 作为基础网络, 通过融合少量参数的特征来降低计算成本, 将残余注意块应用

于编码器的每一层以进行有效的特征提取, 有效地保证了目标检测性能和轻量级结构。Liu 等<sup>[19]</sup>使用分层解耦卷积代替标准卷积, 以减少了网络参数数量, 并在底层卷积模块中添加了扩张卷积以及在网络输出层引入了注意力机制, 增强了网络表达多尺度信息的能力, 提高了肿瘤分割精度。钟志峰等<sup>[20]</sup>针对道路场景景深变化特点, 提出了基于 U-Net 的轻量化语义分割模型 Faster-UNet, 仅进行 3 次下采样来提取图像特征, 在减少了模型参数量的同时, 又最大限度保留了物体边缘特征, 在模型拼接编码与解码部分, 使用空间金字塔池化(ASPP)模块提取图像多尺度信息进行特征增强, 在模型解码部分嵌入通道注意力模块, 进行特征图权重的自适应调节, 为自动驾驶技术提供了一定的理论基础和工程应用参考。朱立学等<sup>[21]</sup>针对香蕉果串识别系统中传统的 UNet 网络存在实时性差、参数量多、下采样后丢失空间信息等问题, 提出了基于 UNet 模型的轻量化分割网络, 构造一个轻量级的主干特征提取模块, 在降低模型参数量和计算量的同时增强网络提取特征的能力, 使用膨胀率为[2,1,2]锯齿波形多尺度串联空洞卷积组合在增大感受野的同时保持对细节的敏感度, 降低网络参数量, 提高了香蕉果串分割精度。许苗等<sup>[22]</sup>针对云遮挡下道路提取问题, 提出一种轻量化的 U-Net 网络(lightweight unet, L-UNet), 使用移动翻转瓶颈卷积模块作为特征提取的主要结构, 在 DSConv 的基础上加入扩展卷积和压缩激励模块, 在减少参数量的同时大幅提升了分割效果。但是这些网络在设计时都考虑了特定应用场景的需求, 在光伏电池缺陷检测方面表现不佳。

基于此, 本文从光伏电池缺陷处 EL 产生机理出发, 分析光伏电池缺陷特征, 结合 U-Net 网络架构与 DSConv、ECA 注意力机制<sup>[23]</sup>模块优势, 提出了一种适用于光伏电池缺陷检测的轻量化 U-Net 网络模型。首先给出 EL 原理、介绍本文所采用的 U-Net 算法以及改进部分, 然后搭建短波红外成像系统获取含缺陷的光伏电池图像, 并进行数据集制作, 再利用所提分割算法对图像进行分割, 最后对分析实验结果。

## 1 光伏电池电致发光原理

光伏电池的主要原料是半导体材料, 硅是其中最常见的半导体材料。硅原子有 4 个外层电子, 在纯硅中掺入有 5 个外层电子的原子如磷原子, 就成为 N 型半导体, 在纯硅中掺入有 3 个外层电子的原子如硼原子, 形成 P 型半导体。当 P 型半导体和 N 型半导体结合在一起时形成 PN 结, 由于二者的载流子浓度不同, 会导致扩散运动和漂移运动, 运动平衡之后, 在二者两侧形成电势差, 称为内建电势, 它会阻碍电子和空穴的扩散运动, 从而形成一个无自由载流子的耗尽区, 使得 PN 结内部电流为零, 如图 1(a)所示。

当在 PN 结的两端加正向偏压时, PN 结区的内建电势将降低, 大量非平衡载流子从扩散区 N 区注入到 P 区, 并

与 P 区向 N 区扩散的空穴不断地产生辐射复合, 电子从导带跃迁到价带, 而电子在导带和价带之间存在着能量差, 也就是禁带宽度, 根据能量守恒原理, 当电子从高能级的导带跃迁到低能级的价带时, 就会释放出与禁带宽度相对等的能量, 这些能量以光子的形式释放出来, 从而发光, 这种现象称为 EL 现象, 由于空穴的扩散速度远小于电子的扩散速度而使发光主要发生在 P 区, 如图 1(b)~(d) 所示。硅材料的禁带宽度约为 1.12 eV, 因此 EL 光谱峰值在 1150 nm 左右, 较多应用在 1100~1200 nm, 属于短波红外范畴, 利用短波红外相机可以捕捉 EL 发出的光子。

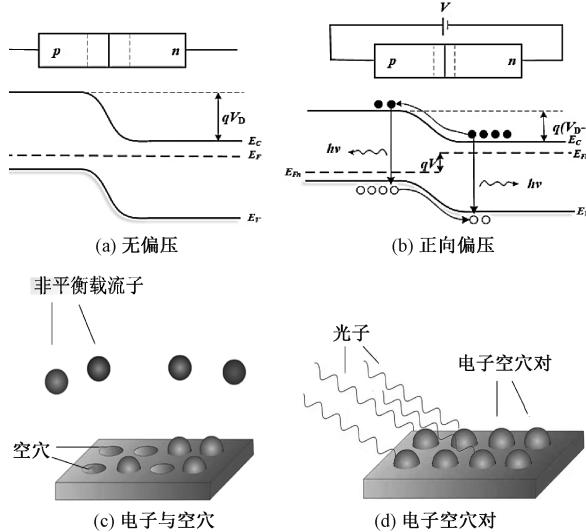


图 1 EL 原理图

当光伏电池存在缺陷时, 缺陷处的硅原子会偏离理想的平衡位置, 产生应力和畸变, 改变硅原子的势场, 影响硅原子之间的键合方式。同时, 缺陷会破坏单晶硅晶体的周期势, 导致其能带的分裂和展宽, 形成一些局域的能级, 影响硅原子的电子排布和能量, 导致缺陷处的原子势场发生改变, 造成对周期势的破坏, 形成禁带中的局域态能级或导价带中的非定域能级, 这些能级可以与导带或价带的能级相互作用, 导致载流子的捕获和释放过程。当一个自由载流子遇到一个缺陷能级时, 它可能会被俘获, 并在缺陷能级中发生非辐射复合过程(非辐射复合过程不以光子的形式释放能量), 或者经过一段时间后被释放才参与辐射复合过程。这些复合过程都会消耗载流子的能量, 导致缺陷处的载流子浓度低于正常区域, 载流子浓度越低, 发光强度也就越低。

与正常图像不同的是, 光伏电池 EL 图像是具有高分辨率和高灰度的灰度图像, 所有缺陷与非缺陷区域没有颜色之分, 仅有灰度值之差。EL 图像常伴有高复杂背景和噪声干扰, 也会受到金属杂质、晶界、氧化物等杂质的干扰, 影响对于缺陷种类的判断。因此再判断光伏电池 EL 图像中的缺陷类型时, 既需要全局把控又需要细节的支撑, U-net 网络在这一方面就表现突出。其编码器结构就以提取 EL

图像中缺陷的高层特征, 捕捉缺陷的形状和结构信息, 而其解码器结构又可以恢复 EL 图像的细节和分辨率, 生成精确的缺陷分割掩码。同时, Unet 的跳跃连接可以将编码器和解码器中相同层级的特征进行拼接, 保留了更多的维度和位置信息, 使得后续的层可以在浅层特征和深层特征之间自由选择, 从而提高缺陷分割的精度和鲁棒性。但 Unet 网络也存在着很多问题, 即虽有效提高了网络检测精度, 但其网络参数量大, 对硬件设备要求高, 实时效率低的问题, 不利于工程应用, 因此本文提出改进。

## 2 U-net 网络改进

结合 ELU-Net、UNet3+ 网络轻量化思想, 改进的 U-Net 网络模型使用 U-Net 网络模型作为骨干网络, 在特征提取即编码器部分使用了 DSConv 代替普通卷积来减少参数和计算量, 不同的是, 本研究网络引入 ECA 注意力机制对深度卷积的输出进行通道权重调整, 实现跨通道交互, 避免有用特征信息丢失, 突出缺陷特征并抑制背景干扰, 从而提高对微小和微弱特征缺陷的分割能力。在加强特征部分使用跳跃连接(skip connection)来融合不同尺度特征图, 并通过反卷积(deconvolution)或插值(interpolation)进行上采样, 将有效的标注数据更为有效地使用, 提高分割的精度和鲁棒性, 最后根据光伏电池片 EL 图像缺陷特点选择 ReLU 激活函数, 以及根据光伏电池缺陷 EL 图像数据集不足的问题, 对交叉熵损失函数进行了改进, 其具体如下。

### 2.1 深度可分离卷积与 ECA 模块

DSConv 是 Mobile-Net 网络的基本单元, 它将标准卷积分解为两个部分, 分别是深度卷积(depthwise convolution, DW)与逐点卷积(pointwise convolution, PW), 其结构如图 2 所示。

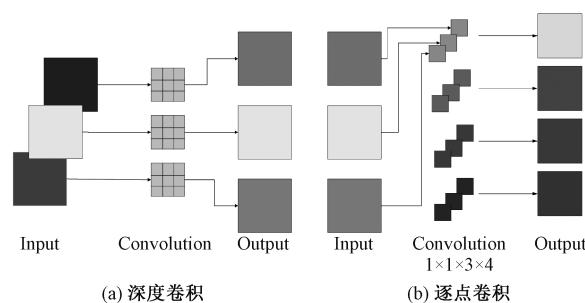


图 2 深度卷积原理图

DW 不同于普通卷积, 其采用了一个一维的卷积核, 一个卷积核负责一个特征层的通道, 即一个特征层通道只被一个卷积核卷积, 其结构图如图 2(a), 假设输入特征图的尺寸为:  $D_F \times D_F \times M$ , 输出特征图的尺寸为  $D_G \times D_G \times N$ , 卷积核的尺寸为  $D_K \times D_K$ , 步长为  $S$ , 填充为  $P$ , 那么深度卷积的参数量计算公式为:

$$P_{depth} = D_K \times D_K \times M \quad (1)$$

其深度卷积的计算量公式为:

$$C_{depth} = D_K \times D_K \times M \times D_G \times D_G \quad (2)$$

这样卷积完成以后,输出的特征层通道数与输入的特征层通道数相等。虽然这样做大大减少了计算参数,但无法进行通道数扩展,且没有有效的利用到不同通道的特征信息,因此引出逐点卷积(空间方向上的卷积)。

DW 是和 PW 结合使用的,实际上,PW 与普通卷积相似,是采用大小为  $1 \times 1$  的卷积进行卷积计算,卷积核的维度数与输入特征层(深度卷积的输出特征层)的维度数相同,其结构图如图 2(b)。逐点卷积的参数量计算公式为:

$$P_{point} = M \times N \quad (3)$$

其深度卷积的计算量公式为:

$$C_{point} = M \times N \times D_G \times D_G \quad (4)$$

PW 可以对输入的特征层进行通道数的调整,即对特征图进行升维或降维,其输出特征层的通道数与卷积核的个数相等,这样做相当于将 DW 后得到的所有特征图进行一次普通卷积,实现不同通道间的信息融合,增加了网络的非线性和表达能力。

因此,DSConv 的参数数量为:

$$P_{sep} = P_{depth} + P_{point} = D_K \times D_K \times M + M \times N \quad (5)$$

其计算量公式为:

$$C_{sep} = C_{depth} + C_{point} = D_K \times D_K \times M \times D_G \times D_G + M \times N \times D_G \times D_G \quad (6)$$

而普通卷积的参数数量为:

$$P_{std} = D_K \times D_K \times M \times N \quad (7)$$

普通卷积的计算量为:

$$C_{std} = D_K \times D_K \times M \times N \times D_G \times D_G \quad (8)$$

可以看出,DSConv 相比普通卷积,参数数量和计算量上都有显著降低,具体降低比例分别为:

$$P_{sep}/P_{std} = 1/N + 1/(D_K^2) \quad (9)$$

$$C_{sep}/C_{std} = 1/N + 1/(D_K^2) \quad (10)$$

与普通卷积相比,DSConv 参数量可减少为原来的  $1/(D_K^2 + D)$ ,其中  $D$  是输入特征图的通道数,  $k$  是卷积核大小,计算量可减少为原来的  $1/(D + k^2)$ ,还可以提高网络的非线性和表达能力、减少过拟合和提高泛化能力。但是,DSConv 每个通道的特征是独立计算的,没有考虑到不同通道之间的相关性和互补性。这样可能会导致一些有用的特征信息丢失。ECA 注意力机制模块可以通过一维卷积来捕捉局部的跨通道交互信息,从而提高深度卷积神经网络的性能<sup>[23]</sup>。具体操作是:在逐点卷积层之后加入 ECA 模块,对输入特征图进行全局平均池化操作,得到一个  $1 \times 1 \times C$  的向量,其中  $C$  是通道数。然后,对该向量进行一个大小为  $k$  的一维卷积操作,并经过 Sigmoid 激活函数得到一个  $1 \times 1 \times C$  的权重向量,其中  $k$  是卷积核大小,表示局部跨通道交互的覆盖范围。最后,将权重向量与输入特征图对应元素相乘,得到输出特征图,具体如图 3。

## 2.2 激活函数的选择

从光伏电池 EL 图像缺陷处的特点分析:光伏电池缺

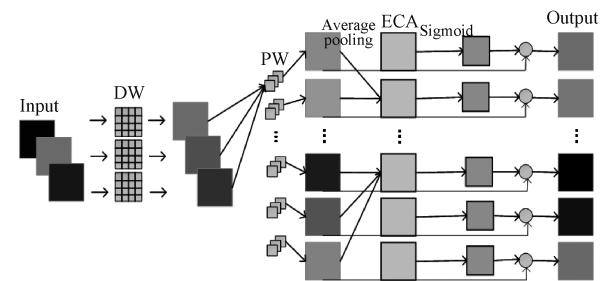


图 3 DSConv 与 ECA 模块

陷处有以下几个特点:1)缺陷处的发光强度通常低于正常区域,呈现出暗灰色状态,因为缺陷会导致电流密度降低和载流子复合增加,减少了发光效率。2)缺陷处的发光颜色通常与正常区域不同,因为缺陷会影响电池的能带结构和载流子分布,改变了发光的波长和频率。3)缺陷处的发光形状通常与缺陷的形状和位置相对应,因为缺陷会改变电池的电场分布和电流路径,从而影响发光的空间分布。因此在进行缺陷识别与缺陷语义分割时,对于缺陷的形状、边界的捕捉要求很高。

如图 4 所示,图 4(a)为存在裂纹缺陷的 EL 图像,图 4(c)为其灰度直方图,图 4(b)为存在黑斑的 EL 图像,图 4(d)为其灰度直方图,从图像可以看出:缺陷图像的灰度值存在明显规律,其正常区域的灰度值集中在 150 左右,栅栏处的灰度值集中在 100 左右,而缺陷区域的灰度值集中在 50 左右,因此其缺陷区域与正常区域、栅栏区域存在明显的边缘分化,即边缘处出现了明显的变化。

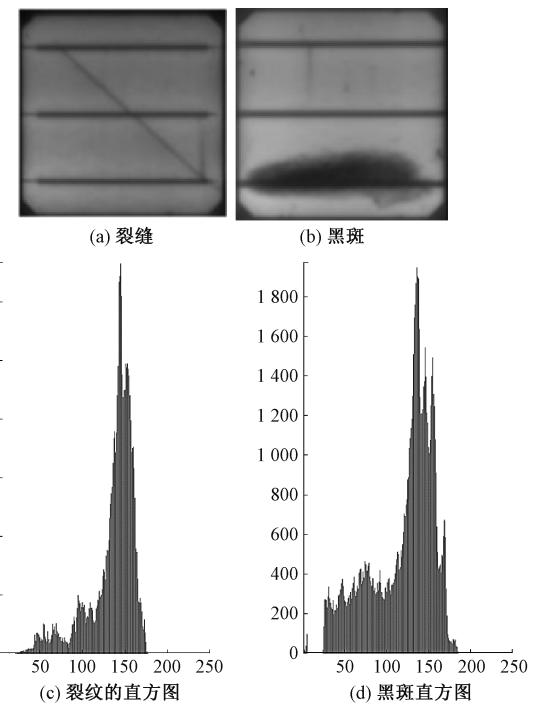


图 4 缺陷图像及其灰度直方图

ReLU 激活函数非常适合于检测边缘,且对噪声干扰也

更加具有鲁棒性,其表达式为:

$$f(x) = \max(0, x) \quad (11)$$

如图 5 为其函数及梯度图,当输入为正数时具有线性行为,在梯度下降时能够更快地收敛,并且可以更好地捕捉到边缘等高频特征。当存在较小的背景噪声时,ReLU 能够将负值映射为 0,表现出较强的鲁棒性,能够很好地捕捉到光伏电池图像中的缺陷边缘和纹理等高频特征,配合适当的全连接层可以对缺陷或异常进行准确地检测和识别,也可以通过 Softmax 函数进行归一化得到每个类别的预测概率。

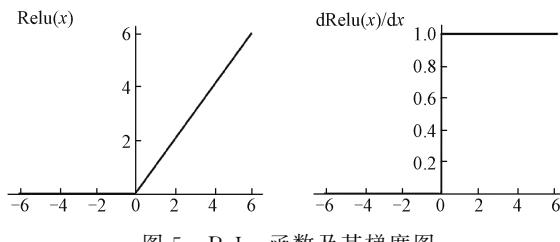


图 5 ReLU 函数及其梯度图

### 2.3 损失函数的改进

Unet 网络使用的损失函数是交叉熵损失函数(cross-entropy loss function)。交叉熵涉及到计算每个类别的概率,所以和 Softmax 函数一起使用,Softmax 函数表达式如下:

$$p_i = \text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{k=1}^n e^{z_k}} \quad (12)$$

其中,  $p_i$  是第  $i$  个节点的概率输出,  $z_i$  是第  $i$  个节点的原始输出,  $n$  是类别的个数。

交叉熵损失函数表达式:

$$L = - \sum_{i=1}^n y_i \log p_i \quad (13)$$

其中,  $L$  是损失函数的值,  $y_i$  是第  $i$  个类别的真实标签,  $p_i$  是第  $i$  个类别的预测概率。

交叉熵损失函数可以很好地配合 softmax 函数作为输出层的激活函数,因为它在求导时可以抵消掉一部分指数运算,使得最终的梯度只与预测概率和真实概率之差有关。这样既避免了数值溢出的问题,又简化了计算过程。但是在某些情况下,交叉熵损失函数可能会导致一些问题,即当预测概率接近 0 或 1 时,交叉熵损失函数的梯度会变得很小,导致模型训练缓慢或停滞,还有当正负样本的比例不均衡时,交叉熵损失函数会倾向于优化占比较大的类别,而忽略占比较小的类别,导致模型的泛化能力下降。为了解决这些问题,本文提出了一种新的带硬截断的交叉熵损失函数,其公式如下:

$$L = - \sum_{i=1}^n [y_i \cdot g(\hat{y}_i, m) \log p_i] \quad (14)$$

式中:引入了一个截断函数:

$$g(x, m) = \begin{cases} \epsilon, & x \geq m \\ 1, & x < m \end{cases} \quad (15)$$

其中,包括一个阈值  $m$  和一个平衡因子  $\epsilon$ ,当预测概率大于等于阈值  $m$  时,返回 1,否则返回  $\epsilon$  ( $0 < \epsilon < 1$ )。通过这样,损失函数和梯度就会将训练重心放在预测概率小于  $m$  的样本,从而避免了样本不平衡的问题。不仅可以有效地解决损失函数函数不稳定问题,还可以根据训练的具体情况合理选择  $\epsilon$  因子的大小,以提高网络特征识别能力,本研究将阈值  $m$  设置 0.98,而对于平衡因子  $\epsilon$  的讨论结果将在后文通过实验部分论证讲述。

## 3 实验过程及结果

### 3.1 数据集介绍

本数据集来源主要分为 3 个部分:1) 网络公开数据集;2) 自主采集获取的光伏组件缺陷 EL 图像;3) 基于自主采集获取的光伏电池缺陷图像,通过 DCgan 网络扩充生成的图像,自主标注制作给予标签,其中缺陷主要包含裂纹和实心黑斑两种缺陷,选取 70% 作为训练集,30% 作为测试集。

本研究的图像采集获取工作主要由自主设计搭建的光伏电池缺陷短波红外成像系统完成。该系统由短波红外相机、直流稳压电源、嵌入式 mini PC 及图像采集软件组成。短波红外相机型号为 Owl 640 S, 响应波长为 900~1 700 nm, 内部为 InGaAs 传感器; 激励电源为固纬 3030DD 直流电源, 可以提供电压范围 0~30 V、电流范围 0~3 A 的恒流输出。实验系统平台如图 6 所示, 本实验使用光伏电池片为异质结 HJT 双面单晶叠瓦太阳能单晶硅电池片。

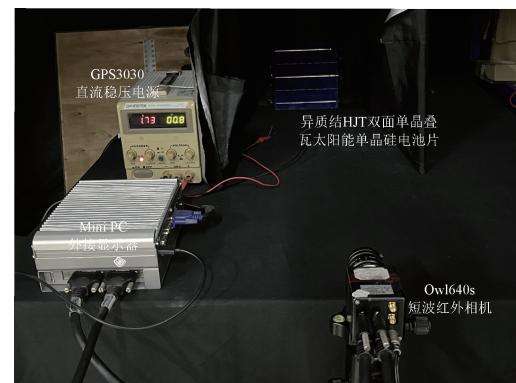


图 6 光伏电池缺陷短波红外成像系统

首先, 使用直流稳压电源对异质结 HJT 双面单晶叠瓦太阳能单晶硅电池片进行通电, 调节直流稳压电源为 12 V, 0.68 A, 打开图像采集软件, 进行相机调焦以及图像亮度调节, 最后进行图像获取工作, 如图 7 为实验获取的图像示例, 其中图 7(a)、(b)、(d) 均为存在裂纹的光伏电池板图像, 图 7(c)、(d) 为存在实心黑的光伏电池板图像。

### 3.2 实验结果对比分析

基于改进轻量化 U-net 网络, 使用制作的少量数据集在低配置 (GPU 为 NVIDIA GEFORCE MX150、CPU 为

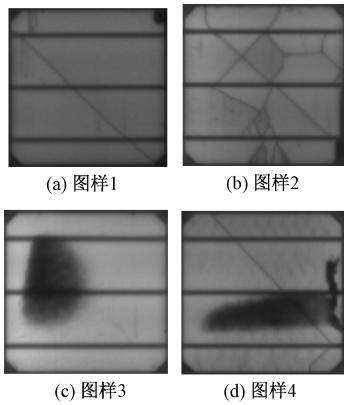


图 7 部分图像样本数据

Intel i5-8550U)设备上进行训练测试。

首先,通过实验验证网络损失函数中截断函数的  $\epsilon$  值对于训练时间以及网络准确率影响,选择出最适合的  $\epsilon$  值,其实验结果如下。图 8 为不同的  $\epsilon$  值下网络准确率对比曲线,图 9 为不同  $\epsilon$  值下网络训练时间曲线,由图 8、9 可以看出,当  $\epsilon=0.6$  时,网络的准确率最高,训练时间最短。

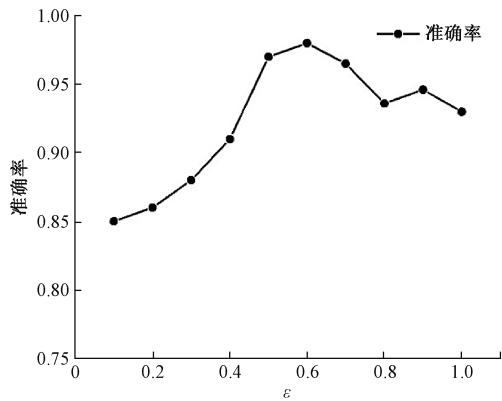
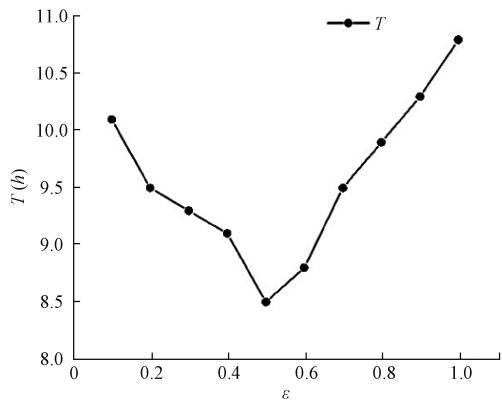
图 8 改进的 U-Net 准确率随  $\epsilon$  值变化曲线图 9 改进的 U-Net 训练时间随  $\epsilon$  值变化曲线

表 1 为使用  $\epsilon=0.6$  时改进的 U-Net 网络在自制的数据集中对于裂纹和实心黑斑的平均准确率、以及测试时间(使用训练权重预测图片的输出时间)。

表 1 缺陷分类结果

缺陷类型	训练集	测试集	准确率/%	测试时间/s
隐裂	972	329	96.7	1.05
实心黑	731	228	97.4	1.02

由表 2 可以看出,使用  $\epsilon=0.6$  的改进的 U-Net 网络与原 U-Net 网络相比,总体准确率有一定的提高,参数值以及计算量降低近 36%,平均测试时间也提高了约 0.5 s,与目前最新的轻量化 U-Net 网络相比,改进的 U-Net 网络准确率最高,参数量(Million)和计算量(100 Million)最小,测试时间最短。

表 2 与原 U-Net 及最新轻量化 U-Net 对比表

网络	准确率/%	参数值/M	计算量/FLOPs	测试时间/s
本文( $\epsilon=0.6$ )	97.05	94	10.7	1.05
U-Net	95.7	148	16.3	1.59
ELU-Net	96.5	103	12.8	1.09
UNet3+	96.7	115	13.5	1.27
Faster-UNet	96	107	13.1	1.38
L-UNet	95.5	97	11.2	1.16

表 3 为各网络模型,输入同一输入张量( $320 \times 320 \times 3$ ),经过卷积、池化等层的处理后,得到 3 个特征图的输出,调用 profile 函数,传入模型和输入,得到模型的参数量和计算量,以及各网络在同一数据集下进行训练的准确率和测试时间。由表 3 可以看出,改进的 U-Net 模型的模型复杂度最低,参数量计算量最小,检测精度最高,对于缺陷的预测时间也最短。

如图 10~13 所示,训练每 10 轮验证一次并输出验证集的损失值与准确率,其横坐标为训练轮次,纵坐标分别为验证集损失值与准确率,前者越低表示验证集的损失值越小,表示预测的结果与实际差距越小,后者表示验证集的预测准确率,准确率越高,表示模型精度越高。图 10、11 分别使用  $\epsilon=0.6$  时改进的 U-Net 网络,与原 U-Net 网络,以及其他最新轻量化 U-Net 网络在同一数据集上的训练测试对照实验结果曲线。图 12、13 分别使用  $\epsilon=0.6$  时改进的 U-Net 网络,与原 U-Net 网络,以及其他常见光伏电池 EL 缺陷分割网络在同一数据集上的训练测试对照实验结果曲线。

由图 10、11 可以看出,在光伏电池 EL 缺陷数据集上,各轻量化 U-Net 网络收敛速度相近,在约 150 步长之后,改进的 U-Net 网络的损失值逐渐收敛且低于其他轻量化 U-Net 网络,在测试集上的测试准确率也为各网络最高。

由图 12、13 可以看出,在光伏电池 EL 缺陷数据集上,改进的 U-Net 模型由于损失函数中平衡因子  $\epsilon$  的引入,损失函数收敛速度更快且更加平稳,经过 150 次的迭代,改进

表 3 各常见模型参数对比表

模型	计算量	参数量	准确率	测试时间/s
U-Net	8 821 719 040.0	2 489 120.0	0.957 0	1.59
本文( $\epsilon=0.6$ )	6 535 551 072.0	1 443 686.0	0.970 5	1.05
ELU-Net	6 872 549 120.0	1 872 970.0	0.965 0	1.09
UNet3+	6 982 876 428.0	1 913 580.0	0.967 0	1.27
Faster-Unet	7 248 293 100.0	2 119 220.0	0.960 0	1.38
L-Unet	6 659 846 100.0	1 634 786.0	0.955 0	1.16
Yolov8	8 581 139 200.0	1 813 637.0	0.879 0	1.68
Yolov7	9 486 912 000.0	2 016 735.0	0.862 0	1.77
Yolov5	9 606 464 000.0	2 662 390.0	0.869 0	1.53
Yolov4	17 739 673 600.0	63 943 071.0	0.883 0	1.32
Yolov3	19 409 612 800.0	61 529 119.0	0.889 0	1.72
Resnet50	79 556 669 440.0	235 121 300.0	0.876 0	1.82
Vgg16	13 508 780 544.0	124 054 914.0	0.903 0	1.88
Fast-Rcnn	104 033 894 400.0	136 709 509.0	0.954 0	1.78
Deeplabv3	103 255 869 440.0	58 132 660.0	0.883 0	1.65

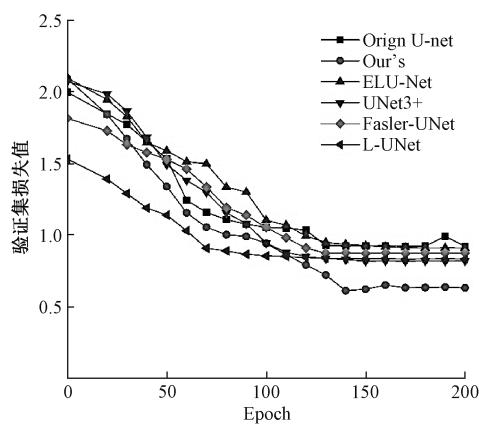


图 10 最轻量化 U-Net 网络验证集损失值曲线

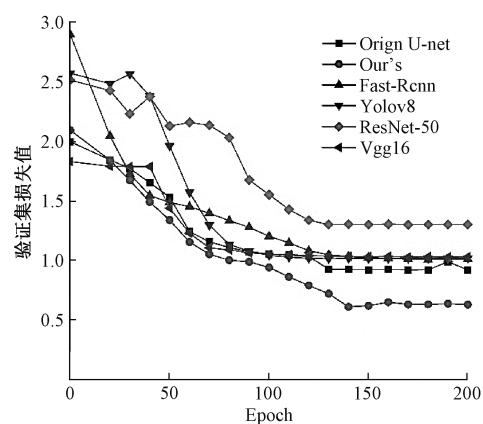


图 12 常见网络验证集损失值曲线

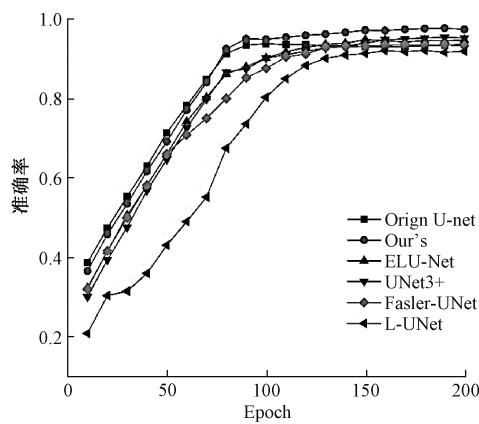


图 11 最轻量化 U-Net 网络验准确率曲线

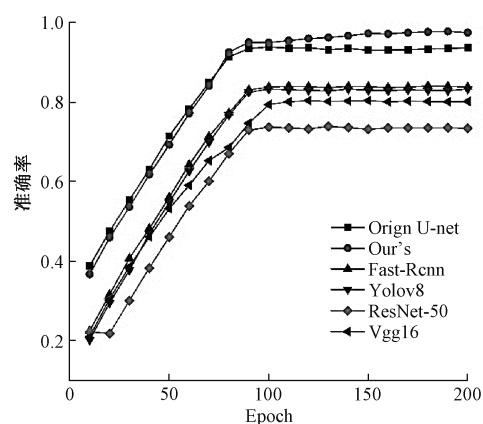


图 13 常见准确率曲线

的 U-Net 网络的损失值逐渐收敛且明显低于其他网络, 准确率与其他网络相比也有所提高。

图 14、15 为本文改进的 U-Net 模型与目前最新的轻量化 U-Net 模型分割检测效果, 其中前者为对于光伏电池

不同区域的黑斑的分割检测效果,后者为对于光伏电池不同区域的裂纹的检测效果。图 16、17 为文改进的 U-Net 模型与目前常见光伏缺陷分割模型在测试集上的分割检测效果,其中前者为对于光伏电池不同区域的黑斑的分割检测效果,后者为对于光伏电池不同区域的裂纹的检测效果。由图 14、15 可以看出,现有的轻量化 U-Net 模型对于栅线和裂纹、黑斑和片角的区分效果不佳,存在错检漏检

的问题,改进后的 U-Net 模型呈现出对缺陷性状更加敏感的特性,分割效果最好。由图 16、17 可以看出,与其他各光伏电池缺陷检测模型相比,改进后的 U-Net 模型在测试集上展现出更精确的识别和更准确的定位,有效避免了误检情况。从图像上清晰可见,改进的 U-Net 模型能够捕捉和呈现缺陷的细微特征,展现出更高的分辨率和更好的辨识能力。

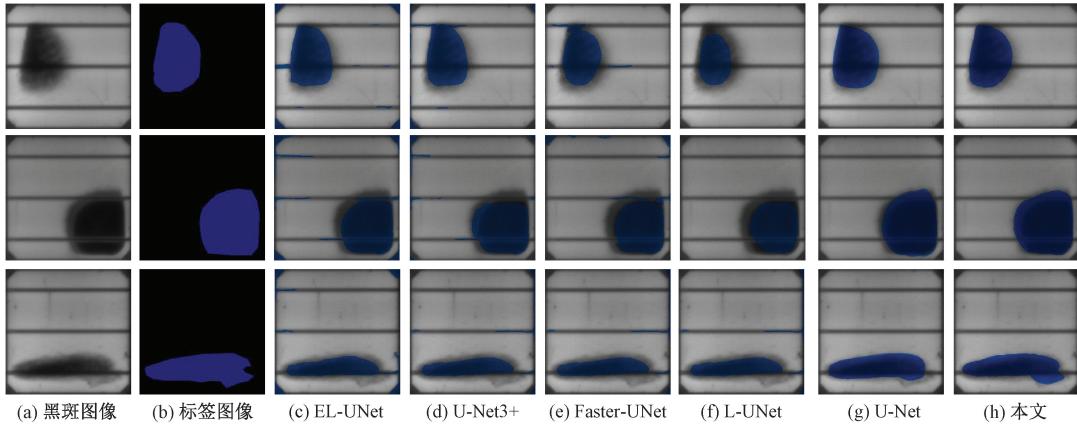


图 14 轻量化 U-Net 黑斑检测效果

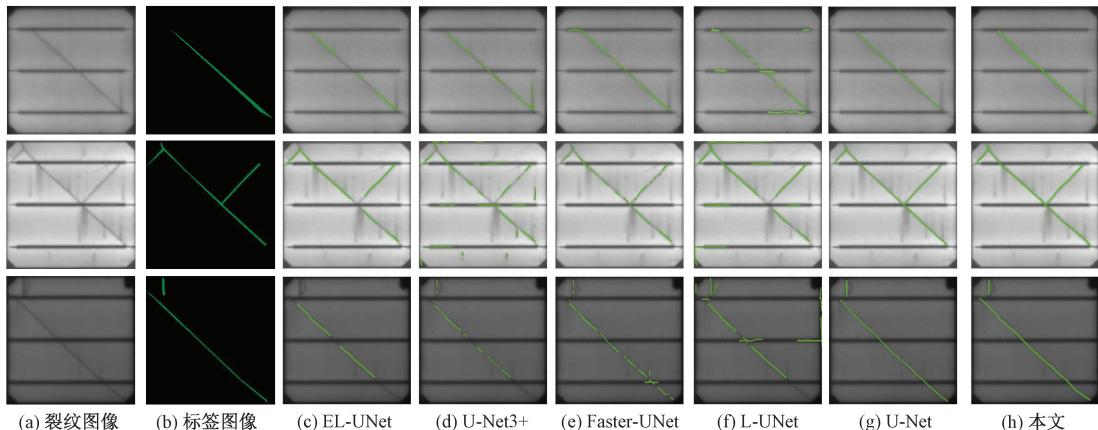


图 15 轻量化 U-Net 裂纹检测效果

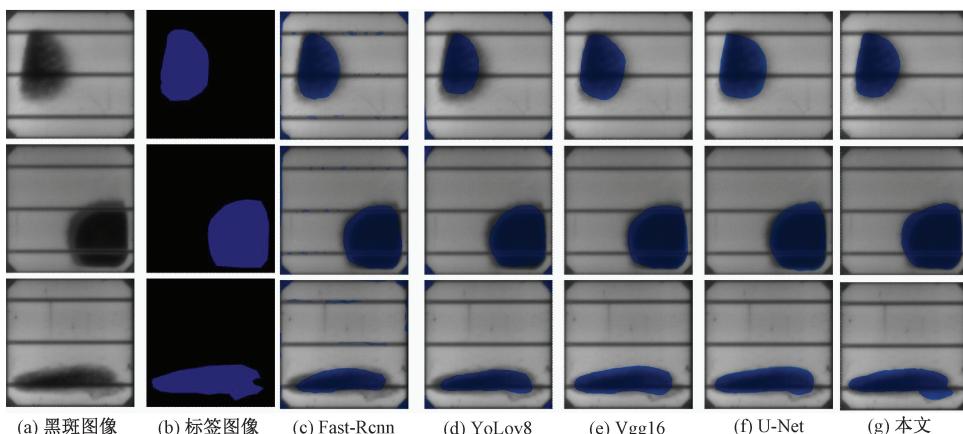


图 16 常见模型黑斑检测效果

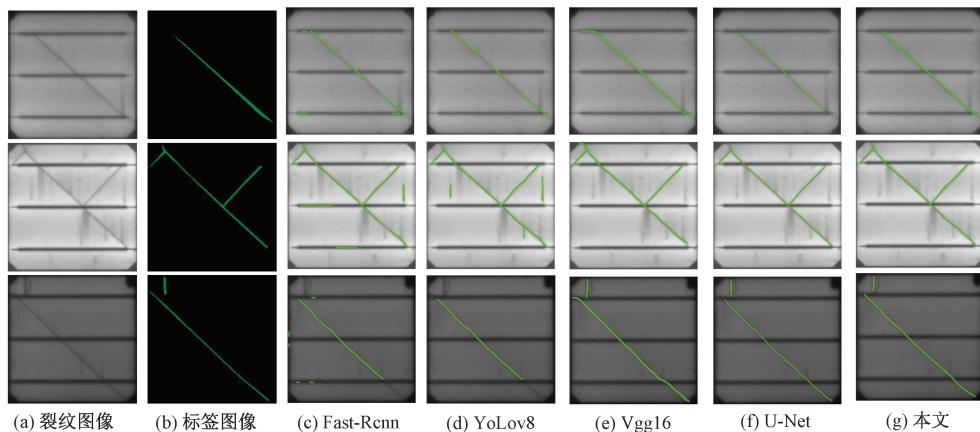


图 17 常见模型裂纹检测效果

## 4 结 论

针对实际工程应用中检测现场神经网络结构庞大,参数量巨大,环境复杂,硬件设备性能差、缺陷细节难以捕捉等原因导致缺陷的实时检测速率慢、精度低的问题。本研究从光伏电池 EL 缺陷特点出发,分析其产生机理,提出了使用跳跃连接提高模型的多尺度信息学习能力,更好地结合高低尺度的特征信息,在特征提取部分使用 DSConv 与 ECA 注意力机制模块替换普通卷积降低了网络的模型参数量,对损失函数进行了改进,引入截断函数,避免了样本不平衡的问题,同时提高了精度。

通过在光伏电池缺陷 EL 图像开源数据集和实验室自主获取的缺陷数据图像试验得出,该模型的检测精度和模型参数表现均优于常见的深度学习模型以及未改进的 U-net 模型,其优势如下:

1) 通过跳跃连接聚合了不同尺度下的特征信息,对特征不明显的缺陷、复杂背景的抗扰、和区分栅栏线有着更好的效果。

2) 改进的特征提取部分降低了网络的模型参数量,有助于在低性能设备上实现实时性检测。

3) 通过 ECA 注意力机制实现跨通道交互,突出缺陷特征,提高了对特征不明显缺陷的检测能力。

4) 改进的损失函数提高了网络的训练速度,避免了样本不平衡的问题,同时提高了精度。

需要注意的是,由于本次研究的光伏电池板图像样本数量有限,分类类别也较少。如果能够获得更多的图像样本准确率还有进一步提升的潜力。

## 参考文献

- [1] 汪方斌,张彦福,王峰,等.光伏电池电致发光偏振图像融合与缺陷检测[J].电子测量技术,2022,45(19):143-149.
- [2] 闫萍,王赶强.电致发光成像测试晶体硅光伏组件缺陷的方法标准解读[J].信息技术与标准化,2020(9):

29-31.

- [3] PARikh H R, BURATTI Y, SPATARU S, et al. Solar cell cracks and finger failure detection using statistical parameters of electroluminescence images and machine learning[J]. Applied Sciences, 2020, 10(24): 8834.
- [4] JUAN R O S, KIM J. Photovoltaic cell defect detection model based-on extracted electroluminescence images using SVM classifier[C]. 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIC), IEEE, 2020: 578-582.
- [5] PURANIK V E, KUMAR R, GUPTA R. Generalized quantitative electroluminescence method for the performance evaluation of defective and unevenly degraded crystalline silicon photovoltaic module[J]. Progress in Photovoltaics: Research and Applications, 2023, 31(3): 269-282.
- [6] FIORESI J, COLVIN D J, FROTA R, et al. Automated defect detection and localization in photovoltaic cells using semantic segmentation of electroluminescence images [J]. IEEE Journal of Photovoltaics, 2021, 12(1): 53-61.
- [7] OTAMENDI U, MARTINEZ I, QUARTULLI M, et al. Segmentation of cell-level anomalies in electroluminescence images of photovoltaic modules[J]. Solar Energy, 2021, 220: 914-926.
- [8] DEITSCH S, CHRISTLEIN V, BERGER S, et al. Automatic classification of defective photovoltaic module cells in electroluminescence images[J]. Solar Energy, 2019, 185: 455-468.
- [9] WU J, FAN P, SUN Y, et al. Ghost-RetinaNet: Fast shadow detection method for photovoltaic panels based on improved retinaNet[J]. CMES-Computer Modeling

- in Engineering & Sciences, 2023, 134(2):1305.
- [10] 李冰,赵宽,白云山,等.融合注意力的多尺度光伏板缺陷检测方法[J].电力科学与工程,2023,39(8):1-10.
- [11] 周颖,叶红,王彤,等.基于多尺度 CNN 的光伏组件缺陷识别[J].太阳能学报,2022,43(2):211-216.
- [12] 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.
- [13] 田浩,周强,贺晨龙.基于多尺度特征融合的光伏组件缺陷检测[J].计算机工程与应用,2024,60(3):340-347.
- [14] 郭清华,曾礼丽.基于 U-Net 网络的光伏组件缺陷检测方法[J].光源与照明,2021(5):49-50.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, 2015: 234-241.
- [16] PRATT L, GOVENDER D, KLEIN R. Defect detection and quantification in electroluminescence images of solar PV modules using U-net semantic segmentation [J]. Renewable Energy, 2021, 178: 1211-1222.
- [17] DENG Y, HOU Y, YAN J, et al. ELU-net: An efficient and lightweight U-net for medical image segmentation [J]. IEEE Access, 2022, 10: 35932-35941.
- [18] CHUNG W Y, LEE I H, PARK C G. Lightweight infrared small target detection network using full-scale skip connection U-Net [J]. IEEE Geoscience and Remote Sensing Letters, 2023.
- [19] LIU H, HUO G, LI Q, et al. Multiscale lightweight 3D segmentation algorithm with attention mechanism: Brain tumor image segmentation[J]. Expert Systems with Applications, 2023, 214: 119166.
- [20] 钟志峰,何佳伟,侯瑞洁,等.改进 UNet 的轻量化道路图像语义分割算法[J].现代电子技术,2022, 45(19): 71-76.
- [21] 朱立学,伍荣达,付根平,等.基于多尺度串联空洞卷积的轻量化 UNet 香蕉图像分割[J].农业工程学报,2022, 38(13): 194-201.
- [22] 许苗,李元祥,钟娟娟,等. L-UNet:轻量化云遮挡道路提取网络[J]. 中国图象图形学报, 2021, 26(11): 2670-2679.
- [23] 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.

### 作者简介

汪方斌(通信作者),博士,教授,博士生导师,主要研究方向为偏振成像探测、图像处理与人工智能、故障诊断与预警技术等。

E-mail: wangfb@ahjzu.edu.cn

李文豪,硕士研究生,主要研究方向为光伏电池缺陷检测和图像处理。

E-mail: lwh0616@stu.ahjzu.edu.cn