

DOI:10.19651/j.cnki.emt.2211606

# 基于全注意力 FSA-UNet 网络的 单晶电池片混合缺陷检测<sup>\*</sup>

吴俊良<sup>1</sup> 刘怀广<sup>1,2</sup> 汤 勃<sup>1,2</sup>

(1. 武汉科技大学机械传动与制造工程湖北省重点实验室 武汉 430081;  
2. 武汉科技大学冶金装备及其控制教育部重点实验室 武汉 430081)

**摘要:** 太阳能电池片的内部缺陷是降低电流传导效率的主要原因,通过 EL 或 PL 成像后的图像缺陷强弱变化较大,直接进行阈值分割会造成漏检。本文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。针对缺陷分层特点,设计出了特征增强模块,提升弱缺陷的分辨能力,同时改进骨干特征提取网络,加快了强缺陷的检出效率。本算法能精确分割出单晶硅片的多种缺陷,为了验证本文算法的有效性,将本文算法与 U-net、DeepLabV3+ 进行的比较,最佳 MIOU 达到了 77.9%,突出了本算法的优势。

**关键词:** 电池片检测;缺陷分割;U-net;全注意力网络

中图分类号: TN911.73; TP183 文献标识码: A 国家标准学科分类代码: 510.4050

## Hybrid defect detection of monocrystalline cells based on full attention FSA-UNet network

Wu Junliang<sup>1</sup> Liu Huaiguang<sup>1,2</sup> Tang Bo<sup>1,2</sup>

(1. Hubei Key Laboratory of Mechanical Transmission and Manufacturing Engineering, Wuhan University of Science and Technology, Wuhan 430081, China; 2. Key Laboratory of Metallurgical Equipment and Control Technology (Ministry of Education), Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract:** The internal defects of solar cells are the main reason for reducing the current conduction efficiency. The intensity of image defects after imaging by Electroluminescence (EL) or Photoluminescence (PL) varies greatly, and direct threshold segmentation will cause missed detection. This paper proposes a full-attention FSA-UNet network for hybrid defect segmentation in solar cells. Aiming at the characteristics of defect stratification, a feature enhancement module is designed to improve the ability to distinguish weak defects, and at the same time improve the backbone feature extraction network to speed up the detection efficiency of strong defects. This algorithm can accurately segment a variety of defects in single crystal silicon wafers. In order to verify the effectiveness of the algorithm in this paper, comparing the algorithm in this paper with U-net and DeepLabV3+, the best MIOU reaches 77.9%, which highlights the advantages of this algorithm.

**Keywords:** cell inspection; defect segmentation; U-net; full attention network

## 0 引言

太阳能作为一种“取之不尽”的绿色能源,近 10 年来飞速发展,截至 2020 年底,我国光伏发电累计装机约 253 GW,新增装机 48.2 GW,连续 7 年全球领先<sup>[1-2]</sup>,作为光伏发电的载体,太阳能电池片产能也逐渐提高,对太阳能电池组单晶硅片检测<sup>[3]</sup>也有更高的要求。在单晶硅片生产

过程中,常见的较为明显缺陷有划痕、裂纹、黑斑等<sup>[4]</sup>,这些缺陷的存在会影响电池的光电转换效率和寿命,严重甚至会影响整个太阳能组件的发电稳定性。这些较为明显的缺陷容易被检测到并剔除,可是有许多微弱损伤的单晶硅片,由于没有明显边界,且缺陷目标区域不连续,难以采用传统方法将弱缺陷部分进行分割。

为了解决上述问题,采用深度学习方法将单晶硅片的

收稿日期:2022-10-06

\* 基金项目:国家自然科学基金面上项目(51874217)、国家重点专项(2018YFC1902400)资助

弱缺陷进行分割研究<sup>[5-7]</sup>逐渐成为了趋势。深度学习能提取图像的特征<sup>[8]</sup>,并且能较好的将各类缺陷分割出来。使用深度学习来解决图像分割问题,其准确性与快速性大大优于人工检测,可以将工人从繁琐的检测环节中解放出来。

近年来,深度学习广泛应用图像识别<sup>[9]</sup>、工业缺陷的检测<sup>[10-11]</sup>,图像分割<sup>[12-13]</sup>等领域,并且在太阳能电池损伤检测领域也发挥着重要的作用,目前针对太阳能电池片的损伤检测,常见的方法有声波法、均值漂移法、多特征区域融合法、高光谱成像技术、发光成像对比法等。利用声波、激光照射等方法可以有效检测出裂纹、黑斑、划痕等明显损伤,对于复杂微弱的缺陷,采样深度学习方法可以较为准确检测出,如 Rahman 等<sup>[14]</sup>提出了一种多注意力网络,加入通道注意力来提取上下文信息,加入空间注意来有效地抑制背景噪声,将两个注意力机制混合后加入到 U-net 网络中,使该网络对复杂缺陷检测的 MIOU 达到 0.699。胡金鹏等<sup>[15]</sup>提出了改进的 DenseNet 网络检测太阳能电池板缺陷,选取 DenseNet 基础网络模型,在模型中加入 L2 正则化,并调整 BatchNormalization 层以解决过拟合问题;将激活函数 ReLU 函数替换为 SELU 函数,更好地缓解了梯度消失问题,加强了网络的鲁棒性,使用该网络检测的准确率达到 93%。以上两种检测方法对较为明显的缺陷检测效果理想,并没有针对与强弱混合缺陷进行检测。虽然单晶电池片 PL 图像尽管背景相对单一,但是因为经过多道工序印刷和封装,缺陷图像会呈现分层特性,使得图像上缺陷呈现明暗不均、强弱不均。单一的通道检测会造成过分割(强缺陷)或欠分割(弱缺陷),为了保证多种缺陷能同步检测,本文提出了基于全注意力的 FSA-UNet 单晶硅片混合缺陷检测方法。

## 1 PL 检测装置设计

待检测的单晶硅片在传送带上前行,光源位于传送带上端,发出不同波长的激光对待检测的单晶硅片进行照射,当硅片运行到 CCD 相机正下方时,光电开关收到信号,使相机进行拍摄并把拍摄结果传入计算机,图像经计算机处理后,合格的单晶硅片将通过吸盘机器人进行分拣收集到硅片收集盒中。图 1 为 PL 检测装置简图。

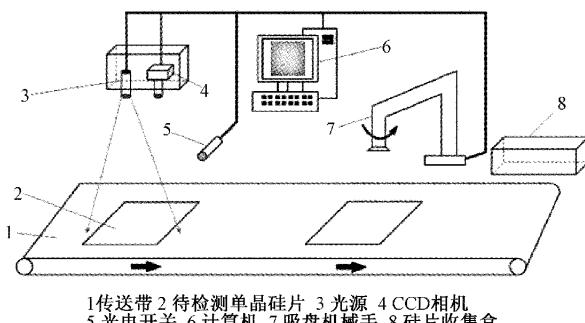


图 1 PL 检测装置简图

## 2 全注意力网络结构设计

U-net 是目前缺陷检测的一种常用的深度网络<sup>[16]</sup>,实现了图像像素级别的分割,在图像的分类上的应用广泛。但是对太阳能电池片单晶硅片弱缺陷的检测,由于背景语义信息较少,且易受背景噪音影响,用 U-net 网络进行检测容易造成的特征丢失,并且在跨层连接时,会丢失边缘信息,导致分割效果不够理想(如图 2 所示)。同时,其对于每个邻域,网络都要运行一次,且对于邻域重叠部分,网络会进行重复运算,造成效率较低。

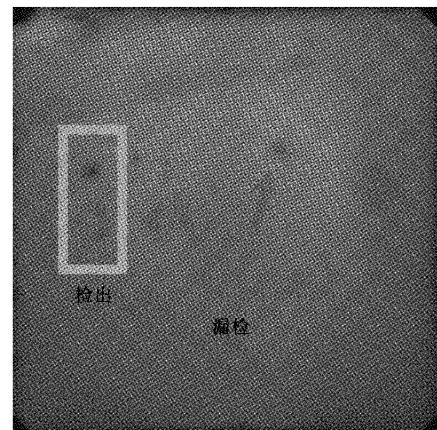


图 2 U-net 网络检测图

为了解决 U-net 网络运算效率低和跨层连接丢失边缘信息的问题,本文在 U-net 网络基础上进行了两个方向的改进,一方面对主干网络进行轻量化,把编码部分换为逆残差结构<sup>[17]</sup>(benck 模块),提升网络的运行速度,提高强缺陷的分割效率;另一方面在跨层连接部分引入全注意力模块,增加小尺度缺陷的识别率,提高特征分辨率。

### 2.1 主干网络的轻量化

针对 U-net 主体网络冗余的问题,本文引入逆残差结构对网络下采样部分进行轻量化。对输入图像先使用  $1 \times 1$  卷积进行升维提升通道数,再使用  $3 \times 3$  深度可分离卷积,最后使用  $1 \times 1$  卷积降低维度,ReLU6 激活函数换为线性激活层,保留特征多样性,增强网络的表达能力。使用  $3 \times 3$  的深度可分离卷积相比传统  $3 \times 3$  卷积,计算复杂度约为传统卷积的  $1/9$ ,公式如下:

$$\text{Complexity} = \frac{\text{DwiseConv}}{\text{Conv}} = \frac{1}{K^2} + \frac{1}{C_{out}} \approx \frac{1}{K^2} \quad (1)$$

式中: DwiseConv 为深度可分离卷积, Conv 为常规卷积, K 为卷积核大小,  $C_{out}$  为输出通道数。

主干特征提取网络进行置换后,网络效率得到提升了。图 3 为逆残差结构图(benck 模块)。

### 2.2 全注意力特征增强模块

由于弱缺陷的边缘和背景差异较小,为了保证缺陷能从背景中准确分割出来,一个重要的方法就是提高网络的特征分辨能力,因此本文设计了全注意力特征增强模块(如

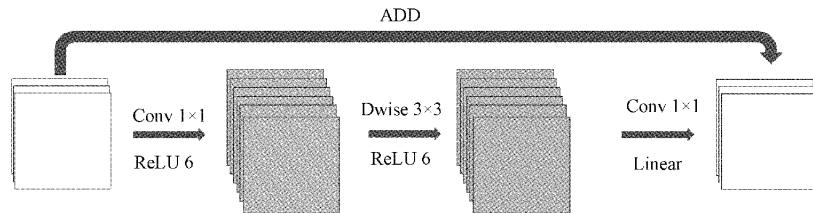


图 3 逆残差网络结构(benck 模块)

图 4 所示),其由特征筛选 Sknet 结构和二维注意力模块并联而成。

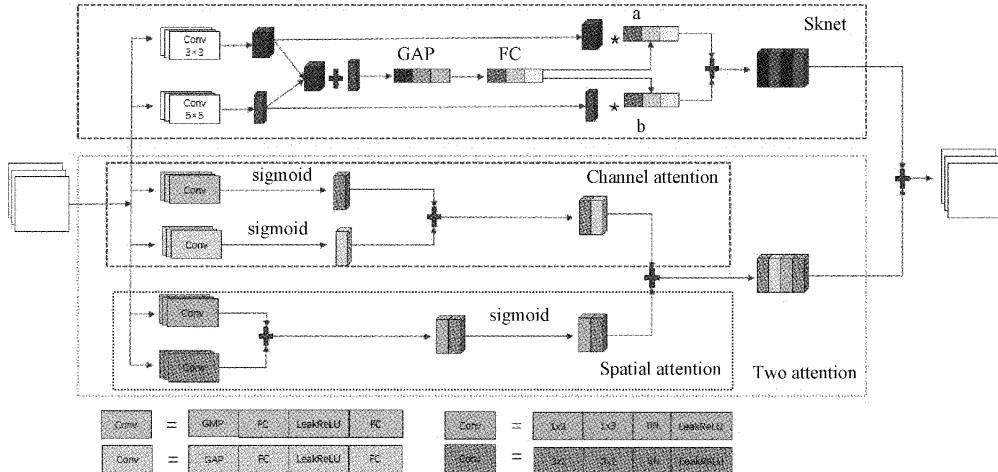


图 4 全注意力特征增强模块

### 2.3 SKnet 特征筛选

SKnet 网络模块<sup>[18]</sup>,其主要由特征分离、融合和选择 3 个步骤组成(如图 5 所示)。特征分离是对于任意输入的图像,分别使用  $3 \times 3$  和  $5 \times 5$  的卷积核得到  $U_1$  和  $U_2$ ,其中  $5 \times 5$  的卷积核替可换为一个空洞为 2 的  $3 \times 3$  的空洞卷积核。融合

部分先将经过卷积处理的  $U_1$  和  $U_2$  进行逐元素相加得到  $U$ ,再通过全局平均池化对所有通道嵌入空间信息得到  $S$ ,接着创建了一个紧凑的特征  $Z$ ,通过一个全连接层,以实现精确和自适应选择,同时,进行了降维处理提高效率。最终选择部分根据选择权重聚合不同大小内核的特征图  $V$ 。

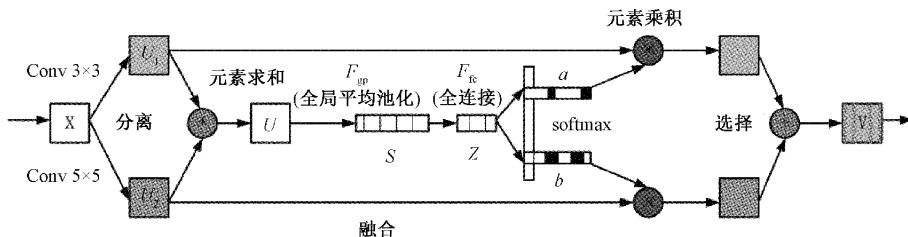


图 5 SKnet 网络结构

### 2.4 二维注意力结构

随着图像分辨率的提升,势必会引入更多噪声。因此,本文设计了二维注意力机制(通道注意力和空间注意力)<sup>[19]</sup>来抑制噪声。图 6 为二维注意力结构图。

通道注意力使网络对输入的图像进行全局最大池化与全局平均池化,再通过全连接层和 LeakReLU 层增加了非线性并且将通道数减少到适当比例,再通过第 2 个全连接层,通过 Sigmoid 激活函数,最后添加两个分支输出,重新加权其输入特征图。

空间注意力模块将  $3 \times 3$  卷积核分成  $1 \times 3$  和  $3 \times 1$  核,每个卷积操作后面跟着一个批归一化和非线性 LeakReLU 层,使用 Sigmoid 函数将特征图映射到  $[0, 1]$ ,此输出特征图映射到输入特征以生成用于缺陷分割的有效特征。

### 2.5 全注意力网络结构

为了把全注意力特征增强模块能够融入到轻量化的 U-net 结构,本文在网络前 4 层进行了跨层连接,形成了跨通道的全注意力网络(full scale attention network U-net, FSA-Unet),其网络结构如图 7 所示。

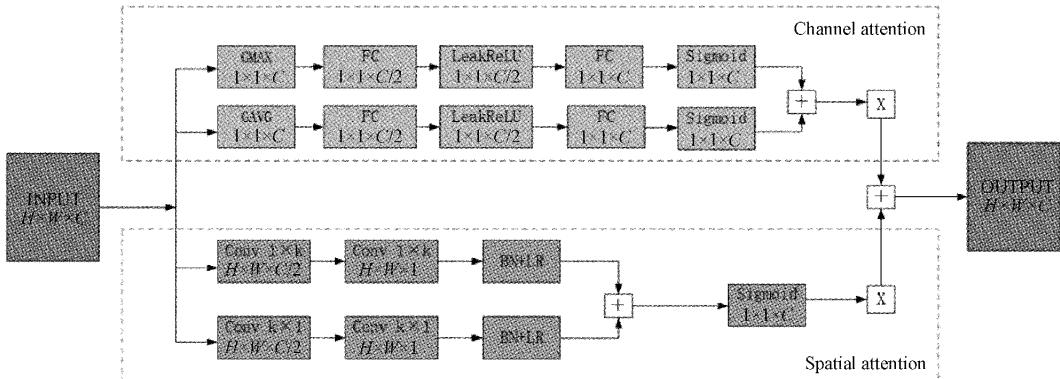


图 6 二维注意力结构图

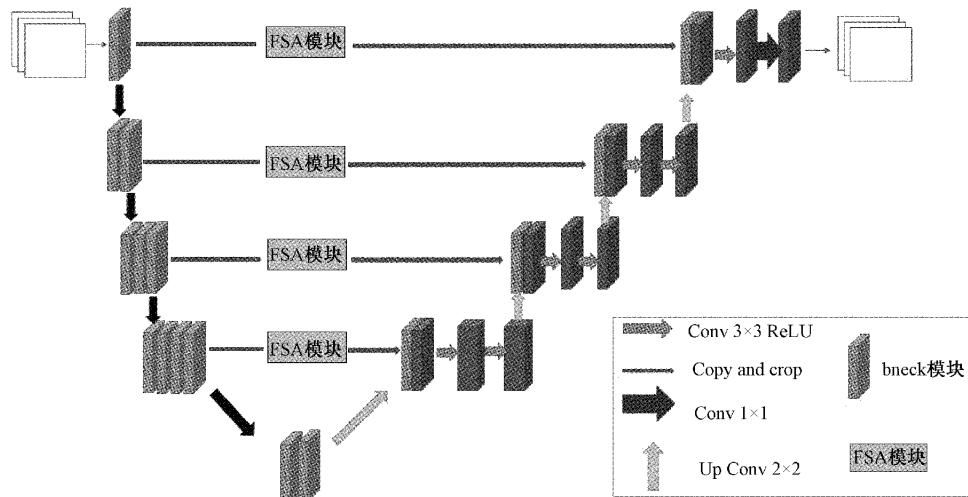


图 7 FAS-UNet 网络结构

### 3 实验及分析

本文的实验环境基于深度学习框架 Pytorch 1.7.1 结合 Python 编程语言进行搭建, 用于实现本文算法和与其他网络进行对比。电脑配置如下: 系统为 Windows10; 处理器为 AMD Ryzen 3700X; 显卡为 NVIDIA RTX 2060super, 8 G 内存; 系统内存为 16 GB。

#### 3.1 数据集及参数设置

本文单晶硅片原始数据图片由国内某大型光伏企业生产现场采集的 13 张缺陷图片, 因为电池片对感光度不同, 各图像的亮度、硅片位置、对比度有一定的差异。且原始图像较大, 由于硬件的限制, 为了使数据处理更快, 我们将图片首先进行预处理, 将需要检测部分截取出, 并将待处理图片全部缩小为  $512 \times 512$  尺寸, 将待处理图片使用 Labelme 进行标注, 由于原始数据集图片较少, 我们通过随机裁剪、旋转缩放等方式对数据集进行扩充, 最后获得 180 张图片的数据集, 本实验将数据集与验证集进行 9 : 1 进行划分, 即训练集为 162 张图片, 验证集为 18 张图片。训练过程, 采用 Adam 优化器, 初始学习率为 0.0001, 批量大

小设置为 4, 训练次数为 300 次, 前 50 次训练采用冻结训练, 使用迁移学习方法进行预训练。图 8 为图像采集现场, 图 9 样图与标注图。

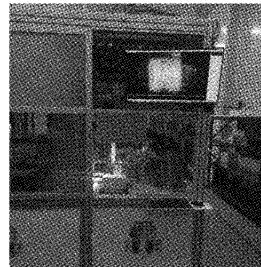


图 8 图像采集现场

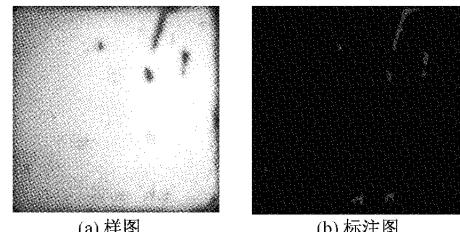


图 9 样图与标注图

### 3.2 损失函数与评价指

在进行网络训练的过程中,为了提高网络的鲁棒性和准确性,需要给本文选择一个合适的损失函数<sup>[20]</sup>。由于弱缺陷的像素分布不均匀,图片大部分为背景,少数部分为缺陷,为了解决这一问题,本文采用 Dice 损失函数作为评估,其公式如下:

$$L_{Dice} = 1 - \frac{2 | X \cap Y |}{| X | + | Y |} \quad (2)$$

式中:  $| X |$  是真实图像,  $| Y |$  是预测图像。

为了评估网络模型的性能,本文采用 3 个性能指标:平均交并比(MIOU)、像素精度(PA)和类平均像素准确率(MPA),判断模型的好坏。

$$MIOU = \frac{1}{K+1} \sum_{i=0}^k \frac{TP}{FN + FP + TP} \quad (3)$$

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$P_i = \text{对角线值} / \text{对应列的像素总数} \quad (5)$$

$$MPA = \frac{\text{Sum}(P_i)}{K+1} \quad (6)$$

式中: TP 表示标签为正样本,预测为正样本; FN 表示标签为负样本,预测为正样本; FP 表示标签为负样本,实际为正样本; FN 表示标签为负样本,实际为负样本。MIOU 分别对每个类计算(真实标签和预测结果的交并比)IOU,然后再对所有类别的 IOU 求均值,MIOU 定义为 0~1,0 表

示所有类完全不重叠,1 表示所有类完全重叠,MIOU 越高表示算法效果越好。

### 3.3 效率对比

为了验证本文的算法,本文将 U-net、DeepLabV3+ 和 FSA 模块串行的结果进行对比实验。为了使损失函数曲线容易观察,将损失函数的数据进行处理,将  $y=x$  换为底数为 2 的 Log 函数,得到了如图 10 的损失函数曲线和表 1 不同模型训练时间和权值文件大小。从损失函数曲线可以看出,FSA 模块并行最终收敛效果最好。从表 1 可以分析出 FSA 模块并行的运行速度上虽然不及 DeepLabV3+,但是其速度相对传统 U-net 网络有较大的提升,从权值文件大小可以看出 FSA 模块并行的参数量相对 U-net 的参数量大大减少。

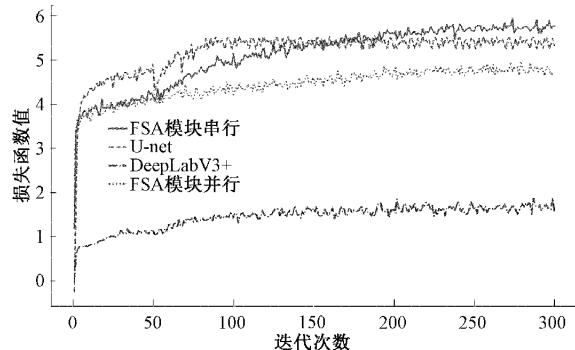


图 10 训练损失函数曲线

表 1 不同模型训练时间和权值文件大小

	U-net	DeepLabV3+	FSA 模块串行	FSA 模块并行
训练时间/h	2	0.92	1.5	1.1
pth 文件大小/MB	94.9	22.4	48.4	48.4

### 3.4 Dice 损失对比

从表 2 的数据可知,加入了 FSA 模块并行后,模型平均交并比(MIOU)、像素精度(PA)和类平均像素准确率(MPA)都得到了提升,说明 FSA 模块并行的加入使模型更能专注于弱的缺陷信息,并对其进行准确分割。

### 3.5 消融实验

为了验证增添的 bneck 模块与 FSA 模块效果,本文做了几组消融实验来验证模块的效果。实验 1:传统 Unet 网络,实验 2:只增加 bencck 模块,实验 3:只增加 FSA 模块,实验 4:增加 bneck 与 FSA 模块。从表 3 消融实验结果可

表 2 不同模型数据对比

模型	MIOU	MPA	PA
U-net	77.3	81.98	98.4
DeepLabV3+	68.14	72.04	98.26
FSA 模块串行	<b>77.9</b>	<b>82.81</b>	<b>98.77</b>
FSA 模块并行	71.2	78.51	97.8

知,bneck 模块的增加,加快了训练速度,而 FSA 模块的增加提升了分割的效果,两个模块同时增加到 Unet 网络中,既提升了训练速度,也提升了网络的分割效果。

表 3 消融实验

实验	bneck 模块	FSA 模块	MIOU	MPA	PA	训练时间/h
实验 1			77.3	81.98	98.4	2
实验 2	√		76.7	80.76	98.24	1.04
实验 3		√	77.7	82.72	98.67	2.05
实验 4	√	√	77.9	82.81	98.77	1.1

### 3.6 网络分割效果对比

为了验证本文算法的优越性将 U-net、DeepLabV3+、

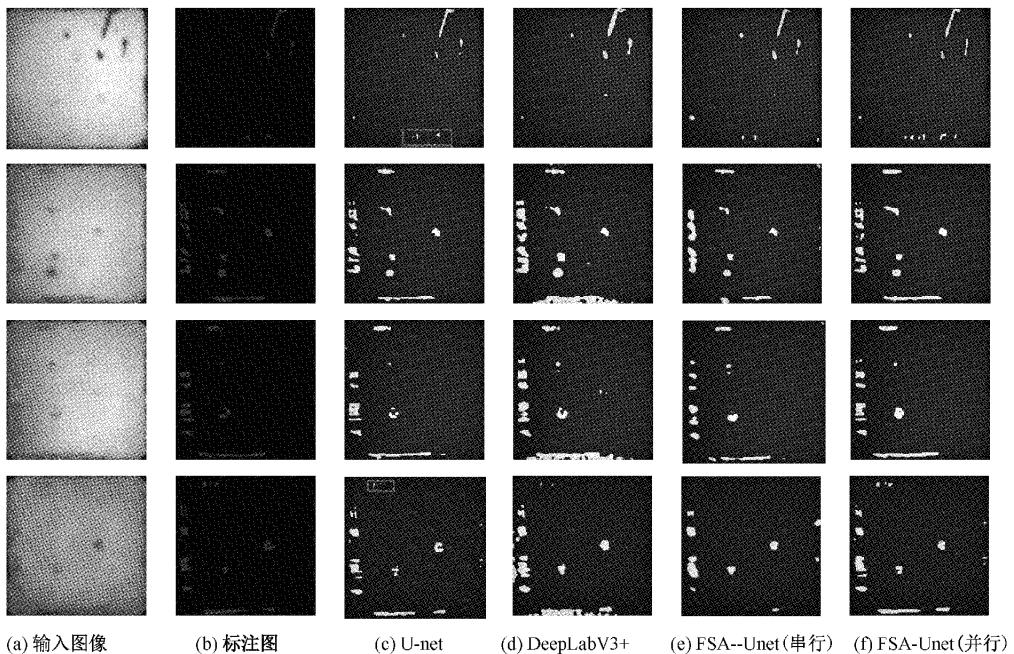


图 11 缺陷图像结果评估

从图 11 缺陷图像结果评估可以做出如下分析, 对图 11(c)U-net 模型在弱缺陷边缘检测时会丢失部分边缘信息, 导致边缘部分漏检。对图 11(d)DeepLabV3+ 模型过于关注了边界信息, 导致分割出的损伤部分的区域较实际 Ground Truth 大了一圈, 效果不佳。对图 11(e)FSA 模块串行, 会导致误检和漏检, 分割效果不佳。对图 11(f)FSA 模块并行, 分割结果既没有漏检错检, 其分割的边缘与 Ground Truth 几乎一致, 并且将 Ground Truth 忽略的边缘处的弱缺陷也检测出, 证明了其分割效果十分理想。由于弱缺陷的准确分割对太阳能光伏产业的健康发展<sup>[21]</sup>有着至关重要的意义。本文提出的 FSA-UNet 网络能准确的将弱缺陷准确分割出。在网络进行训练与评估以后, 在数据集上获得了较好的分割效果。

## 4 结 论

本文通过改进原始 U-net 网络, 提出了一种精确、高效的单晶硅片的混合缺陷检测方法。该模型将 U-net 主干特征提取网络修改为轻量化网络 MobilenetV2, 加快了网络运行速度, 在跨层连接部分增加全注意力网络模块, 在特征融合时加强获取浅层特征的语义信息, 并强调缺陷部分, 减少背景噪声干扰, 使得测试集上的平均交并比达到了 77.9%, 很好的将弱缺陷部分精确分割出, 这一进展, 对光伏产业缺陷自动化精确检测有着重要意义。

## 参考文献

- [1] 官敏, 于涛, 常郑, 等. 太阳能光伏产业智能化开发及应用[J]. 硅酸盐报, 2021, 40(3): 693-703.
- [2] 谢国辉, 李娜娜, 汪晓露, 等. 全球大型光伏电站基地开发潜力分析[J]. 陕西电力, 2018, 46(4): 1-5.
- [3] YIN J, BAI Q, ZHANG B. Subsurface damage detection on ground silicon wafers using polarized laser scattering[J]. Journal of Manufacturing Science and Engineering, 2019, DOI:10.1115/1.4044417.
- [4] BROOKS W S M, LAMB D A, IRVINE S J C. IR reflectance imaging for crystalline si solar cell crack detection[J]. IEEE Journal of Photovoltaics, 2017, 5(5): 1271-1275.
- [5] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [6] 王国力, 孙宇, 魏本征. 医学图像图深度学习分割算法综述[J]. 计算机工程与应用, 2022, 58(12): 37-50.
- [7] 汤勃, 孔建益, 伍世虔. 机器视觉表面缺陷检测综述[J]. 中国图象图形报, 2017, 22(12): 1640-1663.
- [8] HINTERSTOISSE R, LEPETIT V, WOHLHART P, et al. On pre-trained image features and synthetic images for deep learning [C]. Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 2018.
- [9] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述[J]. 中国科学: 信息科学, 2022, 52 (6): 1002-1039.
- [10] 魏秀珍, 许玉燕, 杨健. 网络监督数据下的粒度图像识别[J]. 硅酸盐报, 2021, 40(3): 693-703.

- 别综述[J]. 中国图象图形学报, 2022, 27(7): 2057-2077.
- [11] 于海涛, 李健升, 刘亚姣, 等. 基于级联神经网络的型钢表面缺陷检测算法[J]. 计算机应用, 2023, 43(1): 232-241.
- [12] 孙泽瑾, 邢洁洁, 胡宏男, 等. 基于机器视觉的天然橡胶树割胶轨迹识别规划研究[J]. 中国农机化学报, 2022, 43(5): 102-108.
- [13] 毛卫平, 高伟, 顾寄南, 等. 基于机器视觉的圆柱形蜂窝陶瓷侧面裂隙检测[J]. 电子测量技术, 2022, 45(2): 117-122.
- [14] RAHMAN, MUHAMMAD R U R, CHEN, et al. Defects inspection in polycrystalline solar cells electroluminescence images using deep learning[J]. IEEE Access, 2020, 8: 40547-40558.
- [15] 胡金鹏, 张学武, 张卓. 基于改进 DenseNet 网络的室外太阳能电池板缺陷检测方法[J]. 光学与光电技术, 2022, 20(2): 67-76.
- [16] RONNEBERGE O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-assisted Intervention. Springer, Cham, 2015: 234-241.
- [17] SANDLER M, HOWARD A, ZHU M, et al. MobilenetV2: Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [18] LI X, WANG W, HU X, et al. Selective kernel networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 510-519.
- [19] RAHMAN M, CHEN H. Defects inspection in polycrystalline solar cells electroluminescence images using deep learning[J]. IEEE Access, 2020, DOI:10.1109/access.2020.2976843.
- [20] BARRON J T. A general and adaptive robust loss function [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 4331-4339.
- [21] 丛建鸥, 张鹏远, 赵健, 等. 中国光伏产业发展战略研究[J]. 中国科技纵横, 2022(11): 142-144.

#### 作者简介

吴俊良, 硕士研究生, 主要研究方向为机器视觉、图像分割等。  
E-mail: 1065330228@qq.com