2023年2月 第42卷 第2期

DOI:10.19652/j. cnki. femt. 2204425

# 改进 $U^2$ -Net 的太阳能电池片缺陷分割方法<sup>\*</sup>

王  $\underline{A}^{1,2}$  吴  $\underline{B}^{1,2}$  彭  $\underline{C}^{1,2}$  宋  $\underline{A}^3$  张欢欢<sup>4</sup> 李宣韩<sup>1,2</sup>

(1.四川轻化工大学自动化与信息工程学院 自贡 643000;2.人工智能四川省重点实验室 自贡 643000;
3.阿坝师范学院 阿坝 624000;4.四川启睿克科技有限公司 绵阳 621000)

摘 要:针对太阳能电池片缺陷分割中存在的特征提取能力弱、分割精度低和漏分割等问题,提出了一种改进 U<sup>2</sup>-Net 的太阳 能电池片缺陷分割方法。为提高 RSU 内部有效特征的提取能力并减少参数量,利用残差结构将有效的通道注意模块和深度 可分离卷积结合起来,组成新的特征提取层;为防止空间信息的丢失,在外层编解码跳跃连接中添加语义嵌入分支结构,并利 用 CARAFE 算子进行上采样,将更多的语义信息引入低层特征以加强级间特征的融合,减少因跳跃连接丢失的空间信息;最 后,将所提方法与常用分割网络对比分析。实验结果表明,该方法的类别像素准确率、交并比和平均交并比分别达 74.69%、 60.68%、80.30%。相较于 U-Net、PSPNet 及 Deeplab v3+,该方法不仅有效提高了缺陷分割的精度,还实现了小目标缺陷的 准确分割,有效减少了漏分割。

关键词:太阳能电池片;U<sup>2</sup>-Net;语义分割;注意力机制;语义嵌入分支 中图分类号: TP249 文献标识码:A 国家标准学科分类代码: 510.1050

# Improved U<sup>2</sup>-Net defect segmentation method for solar cells

Wang Sheng<sup>1,2</sup> Wu Hao<sup>1,2</sup> Peng Ning<sup>1,2</sup> Song Hong<sup>3</sup> Zhang Huanhuan<sup>4</sup> Li Xuanhan<sup>1,2</sup> (1. School of Automation and Information Engineering, Sichuan University of Science and Engineering, Zigong 643000, China; 2. Key Laboratory of Artificial Intelligence in Sichuan Province, Zigong 643000, China; 3. Aba Teachers College,

Aba 624000, China; 4. Sichuan qiruike Technology Co., Ltd., Mianyang 621000, China)

Abstract: Aiming at the problems of weak feature extraction ability, low segmentation accuracy and missing segmentation in solar cell defect segmentation, an improved  $U^2$ -net solar cell defect segmentation method is proposed. To improve the extraction ability of effective features in RSU and reduce the number of parameters, the residual structure is used to combine the effective channel attention module and the depth separable convolution to form a new feature extraction layer. In order to prevent the loss of spatial information, a semantic embedded branch structure is added to the outer codec hop connection, and CARAFE operator is used for upsampling to introduce more semantic information into low-level features to strengthen the fusion of features between levels, and reduce the spatial information network. The experimental results show that the classification pixel accuracy, IOU and MIOU of this method are 74.69%, 60.68% and 80.30% respectively. Compared with U-Net, PSPNet and Deeplab v3+, this method not only effectively improves the accuracy of defect segmentation, but also realizes the accurate segmentation of small target defects and effectively reduces missing segmentation.

Keywords: solar cells; U<sup>2</sup>-Net; semantic segmentation; attention mechanism; semantic embedding branch

应用天地

**收稿日期:**2022-10-19

<sup>\*</sup>基金项目:四川省科技厅项目(2020YFG0178,2021YFG0313,2022YFS0518,2022ZHCG0035)、人工智能四川省重点实验室项目(2019RYY01)、企业信息化与物联网测控技术四川省高校重点实验室项目(2018WZY01,2019WZY02,2020WZY02)、四川理工学院四川省院士(专家)工作站项目(2018YSGZZ04)资助

### 0 引 言

太阳能光伏发电技术是太阳能的典型应用技术<sup>[1]</sup>,可 批量应用于道路照明和交通信号灯等场景,能够较好地缓 解目前的能源短缺和环境污染问题。太阳能电池片是光 伏发电核心部件之一<sup>[2]</sup>,在其生产过程中,受环境、机械压 力等因素的影响,容易产生黑斑、划痕和裂纹等。这些缺 陷会降低太阳能电池片的发电效率和使用寿命。因此,在 生产过程中对电池片进行缺陷检测,对光伏发电产业的发 展具有重要意义<sup>[3]</sup>。

传统的电池片缺陷检测手段主要是人工物理法,属于 接触性检测方法,主要利用电池片的各种物理特性进行缺 陷检测[4],在检测过程中极易对太阳能电池片造成二次损 伤,并且检测的效率较低。现代企业已经逐渐采用机器视 觉法代替人工物理法[5-6],随着卷积神经网络(convolutional neural network, CNN)<sup>[7-9]</sup>在计算机视觉(computer vision, CV)<sup>[10]</sup>领域取得的一系列成功,研究人员开始探 索将深度学习应用于太阳能电池片缺陷检测。文献[11] 提出基于深度置信网络(deep belief networks, DBN)<sup>[12]</sup>的 太阳能电池片缺陷检测法,该方法利用样本特征建立并训 练 DBN,但在面对高像素级图像时,网络训练较为困难。 文献「13]将电池片的纹理和颜色特征作为缺陷识别,利用 两种特征构成的特征矩阵优化网络参数。文献「14]提出 了一种多特征区域建议融合网络结构,从卷积神经网络的 不同特征层中提取区域建议,但该网络模型计算成本高, 检测耗时较长。文献[15]提出了基于轻量化 VGG16<sup>[16]</sup>和 数据增强的电池片缺陷检测方法,较好缓解了训练数据匮 乏造成的模型过拟合问题,但该方法无法处理一张图内存 在多缺陷的情况。文献「17]提出改进 U-Net<sup>[18]</sup>的电池片 缺陷分割算法,在网络中引入双注意力机制,以提高网络 精度和鲁棒性。由于太阳能电池片表面固有纹理的特殊 性和复杂性[19-20],上述方法仍存在特征提取不完整、小目 标缺陷检测精度低等问题。

为提高太阳能电池片缺陷分割精度,本文选用显著性 目标检测网络 U<sup>2</sup>-Net<sup>[21-22]</sup>来设计缺陷分割算法,并对网 络做了部分改进,最后将所提方法与常用分割网络进行对 比,验证该方法的有效性和合理性。 2023年2月 第42卷 第2期

#### 1 数据采集与图像预处理

#### 1.1 数据采集

本文基于 PL 成像技术采集实际生产环境下的电池 片图像,包含正常样本及常见的黑斑、划痕、条形裂纹、星 形裂纹、雾状发黑 5 类缺陷样本,构成本文数据集。PL 图 像采集装置如图 1 所示。



图1 图像采集装置

5类缺陷的主要特征如下。

1)黑斑,表现为位置不固定的小圆形或小点。

2)划痕,表现为不规则、无方向的曲线,通常在出现电 池片内部,且相比条形裂纹其线条较短。

3)条形裂纹,表现为不规则、无方向的长条曲线,面积 较大,通常会横跨部分栅线,甚至延伸到电池片的边缘。

4) 星型裂纹,表现为形状较规则、无方向的十字交叉状,整体面积较小。

5)雾状发黑,表现为位置不固定的椭圆或圆,缺陷区 域要远大于黑斑。

#### 1.2 图像预处理

本文所有图像都是在真实的工业环境中拍摄的单晶 硅电池片,拍摄到的图像往往存在图片歪斜、背景占比过 大以及噪声干扰等问题,降低了网络对图片特征提取的完 整性,为消除这些因素对后续分割的干扰,本文对图像进 行了预处理操作,处理效果如表1所示,所用方法如下。



### 2023年2月 第42卷第2期

### 应用天地

1)矫正

为消除位置偏移对后续分割的干扰,采用仿射变换中 的平移和旋转对图像进行矫正。

2) 裁剪

利用图像裁剪技术将图像中的无用背景裁剪掉,有助 于提高后续图像特征提取的有效性。

3)降噪

噪声的存在会严重影响图片的质量,使用均值滤波可 以在保留图像细节的情况下抑制图像中的噪声,提高图像 质量。

#### 2 太阳能电池片缺陷分割模型设计

### 2.1 U<sup>2</sup>-Net 算法理论

U<sup>2</sup>-Net 是一种基于编一解码结构的显著目标检测网络,主要由特征提取结构 RSU(ReSidual U-blocks)和 RSU 堆叠而成的 U 型结构组成。相比目前大多数显著目标检测网络,U<sup>2</sup>-Net 可从头开始训练网络,无需使用预先 训练的特征提取骨干网络,并且网络深度更深,高分辨率 特征提取更充分。因此,本文选取 U<sup>2</sup>-Net 网络来设计太 阳能电池片缺陷分割方法。

如图 2 所示,RSU 由输入卷积层、编解码结构和残差 结构 3 部分组成,输入卷积层用于提取局部特征和转换通 道,编码阶段用 3×3 卷积获取多尺度特征信息,解码阶段 通过上采样逐步修复分割对象的细节和空间维度,残差结 构将输入层和中间层进行融合。



图 2 RSU-7 结构

U<sup>2</sup>-Net 的具体网络结构如图 3 所示,由 6 级编码器、5 级解码器及显著图融合模块 3 部分组成。实现过程如

下:首先使用  $3 \times 3$  卷积和 sigmoid 函数从 En\_6、De\_5、 De\_4、De\_3、De\_2和 De\_1 生成 6 个输出显著概率图  $S_{side}^{(6)}$ 、  $S_{side}^{(5)}$ 、 $S_{side}^{(4)}$ 、 $S_{side}^{(3)}$ 、 $S_{side}^{(2)}$ 、 $S_{side}^{(4)}$ 、 $S_{side}^{(3)}$ 、 $S_{side}^{(2)}$ 、 $S_{side}^{(4)}$ 、 $S_{side}^{(3)}$ 、 $S_{side}^{(4)}$  、 $S_{side}^{(4$ 

U<sup>2</sup>-Net 网络结构深且复杂,通过 RSU 和跳跃连接能够提取图片不同尺寸的级内和级间信息,但在连接中容易出现非缺陷区域等无效特征<sup>[23]</sup>的保留和缺陷边缘等信息的丢失<sup>[24]</sup>,直接应用 U<sup>2</sup>-Net 网络进行电池片的缺陷分割,虽能分割出大部分缺陷,但面对小目标缺陷时,仍存在一定的漏分割情况,为进一步提升网络分割性能,本文主要从提高有效特征的提取能力和减少信息丢失两方面对网络进行改进。



### 2.2 改进的 U<sup>2</sup>-Net 结构

U<sup>2</sup>-Net 网络利用 RSU 提取级内多尺度特征时,分布 在特征图通道上的无效特征容易被保留,针对此问题,本 文在 RSU 内部编码阶段引入有效的通道注意模块<sup>[25]</sup>(efficcient channel attention,ECA)模块,该结构通过自适应 内核大小的一维卷积实现局部跨通道的信息交互,可使模 型聚焦于具有更多有效特征信息的通道。ECA 模块处理 过程如图 4 所示。

左侧输入大小为 H×W×C 的特征图,经过全局平均 池化后得到大小为[C,1,1]的聚合特征,再通过一个权重 共享的一维卷积进行学习,其卷积核大小通过通道维度 C 的映射自适应地确定,自适应确定卷积核大小公式:

$$k = \left| \frac{\log_2^C + b}{\gamma} \right|_{odd} \tag{1}$$

式中:k 为卷积核大小,代表了局部跨通道交互的覆盖率; C 表示通道数; γ 和 b 用于改变通道数 C 和卷积核大小和 之间的比例,本文设置为 2 和 1。最后将学习到的权重加 人到输入张量中,实现通道加权。计算公式为:

 $ECA(x) = \sigma(Conv_{1d}^{[\times 1]}(GAP(x))) \times x$  (2) 式中:x 为输入张量;GAP 为全局平均池化;  $\sigma$  为 sigmiod 激活函数。



图 4 ECA 模块处理流程

为减少特征提取结构的参数和计算量,本文加入深度 可分离卷积,其由逐通道卷积和逐点卷积组成。设输入特 征图大小为 $7 \times 7 \times 3$ ,输出为4通道,首先进行逐通道卷 积,利用4个 $3 \times 3 \times 1$ 的卷积核进行卷积操作,该过程的 计算量为 $3 \times 3 \times (7-3+1) \times (7-3+1) \times 3 = 675$ ,参数 为 $3 \times 3 \times 3 = 27$ ;再进行逐点卷积,其卷积核的尺寸为 $1 \times 1 \times M$ ,M为上一层输出的通道数,该过程计算量为 $1 \times 1 \times 7 \times 7 \times 3 \times 4 = 588$ ,参数个数为 $1 \times 1 \times 3 \times 4 = 12$ 。因此,应用深度可分离卷积所需的总计算量为1 2 63,总参数 为39,而传统卷积所需计算量为 $3 \times 3 \times (7-3+1) \times (7-3+1) \times 3 \times 4 = 2$ 700,参数为 $4 \times 3 \times 3 \times 3 = 108$ ,参数和计 算量都远高于深度可分离卷积。

本文利用残差结构将深度可分离卷积和注意力机制 有效地结合起来,组成新的特征提取层,其整体结构如 图 5 所示。



图 5 特征提取结构

利用残差结构将深度可分离卷积提取的特征和经

### 2023年2月 第42卷 第2期

ECA 模块处理的输入特征相加后再输入下一个特征提取 层进行特征提取,使得每级输出特征可以在聚焦于具有更 多有效特征信息通道,加强每一级有效特征的提取能力。 改进前后的 RSU 对比如图 6 所示。



图 6 改进前后的 RSU 模块对比

由于编码器和解码器阶段的不兼容功能集<sup>[20]</sup>,仅使 用简单的跳跃连接来模拟全局多尺度上下文,容易导致空 间信息的丢失,从而出现漏分割的情况。针对此问题,本 文在跳跃连接部分加入语义嵌入分支(semantic embedding branch, SEB)结构<sup>[27]</sup>,利用该结构将编码阶段输出 的高低级别的特征进行融合后再输入到对称解码阶段进 行处理,操作过程如下:先将高层次的特征经过卷积并进 行一次上采样,再将其和低级别的特征进行逐像素相乘, 使得低级特征中包含更多的语义信息。

SEB结构利用双线性插值进行上采样,该方式仅通过 像素点的空间位置来决定上采样核,并未利用特征图的语 义信息且感知域较小;为了更有效的整合特征图语义信息 和上采样核心,本文在 SEB 结构中引入上采样算子 CA-RAFE<sup>[28]</sup>,其由上采样核预测模块(kernel prediction module)和内容感知重组模块(content-aware reassembly module)两部分组成。

上采样核预测模块根据输入特征的内容生成上采样 核,通过特征图通道压缩、内容编码及上采样核预测及归 一化3步完成:将输入特征图通过一个 $1 \times 1$ 的卷积降低 通道数;然后利用一个 $k_{encoder} \times k_{encoder}$ 的卷积层进行上采样 核预测,得到形状为 $\sigma H \times \sigma W \times \sigma k_{up}^2$ 的上采样核;最后利 用 Softmax 函数将上一步得到的上采样核进行归一化。

 $w_{l'} = \psi(N(x_l, k_{encoder}))$ (3)

内容感知重组模块将原图中 k × k 大小的特征图块与 预测出的该点的上采样核作点积,得到输出值。

### 2023年2月 第42卷 第2期

$$x'_{l'} = \sum_{n = -rm}^{r} \sum_{-r}^{r} w_{l'(n,m)} \cdot x_{(i+n,j+m)}$$
(4)

本文在 SEB 结构中引入上采样算子 CARAFE,利用 CARAFE 上采样算子 替换原 SEB 结构中的双线性插值 上采样,组成新的特征融合模块并将其命名为 CSEB,其 整体结构如图 7 所示。编码阶段的输出特征经过 CSEB 模块处理后,其低层次特征中融合了充分的语义信息,再 将融合后的特征输入到对称解码阶段进行后续处理,有效 防止因跳跃连接导致空间信息的丢失。



图 7 CSEB 特征融合结构

为消除无效特征的干扰,本文在 RSU 内部编码阶段 加入 ECA 模块,以加强图像有效特征的提取能力;为降低 特征提取部分的参数量,使用深度可分离卷积替代部分原 卷积层;为减少因跳跃连接时网络丢失空间信息造成的漏 分割,在跳跃连接阶段加入 CSEB 模块。改进后的网络结 构如图 8 所示。



#### 3 实 验

#### 3.1 数据集及参数设置

为保证测试集和训练集数据分布的一致性,本文参照 图像处理常用数据集划分方法——留出法<sup>[29]</sup>,并采用常

北大中文核心期刊

### 应用天地

用的 8:2分层采样,将预处理后的太阳能电池片 PL 图像 数据集划分为训练集和测试集,如表 2 所示。所有图像 使用 Labelme 进行图像标注,将缺陷部分的像素值设为 255,作为正样本,背景部分的像素值设为 0,作为负 样本。

表 2 数据集分布

数据集	缺陷图像	正常图像
训练集	754	750
测试集	188	188

本文的分割算法实验基于深度学习框架 Pytorch 并 结合编程语言 Python 在工作站上进行环境搭建,工作站 配置如下:操作系统为 Windows10 专业版,处理器为 AMD EPYC 7302,显卡为 Nvidia Ampere A100,系统内存 为 512 G。

与文献[30]设置一致,本文网络中所有卷积层由 Xavier 初始化,损失权重  $w_{side}^{(m)}$  和  $w_{fuse}$  均设置为 1,利用 Adam 优化器优化网络,初始学习率 lr = 0.001, betas =(0.9,0.999), $eps = 1 \times 10^{-8}$ ,权重衰减为 0;经多次对比实 验后,将训练次数设定为 300,批量大小设置为 16,共训练 28 200 次,每 100 次保存一次模型参数文件,最后在网络 内加载最优的参数文件,并导入数据集进行预测。

#### 3.2 评价指标

电池片中大部分缺陷占背景的比例都较小,导致分割 的像素准确率过高,无法有效表征网络的分割能力;为更 准确评判网络性能,本文选取正样本的类别像素准确率 (CPA)、召回率 R 及交并比(IOU),进行缺陷分割效果的 评估。

$$CPA = \frac{TN}{TN + FN} \tag{5}$$

$$R = \frac{TN}{TN + FP} \tag{6}$$

$$IOU = \frac{TN}{TN + FN + FP} \tag{7}$$

式中:TP 为实际类别为正样本(缺陷部分),预测类别为 正样本的;FP 为实际类别为负样本(背景部分)却被预测 为正样本;FN 为实际类别为正样本却被预测为负样本的 概率。IOU 为预测结果和真实值的交集与并集的比值, 其值越高,表明分割效果越好。

为进一步说明本文方法在整体上的提升效果,本文还选取了类别平均像素精度(MPA)、平均召回率(MRecall)、F<sub>1</sub>分数和平均交并比(MIOU),作为评价指标综合 评估网络模型的好坏。

$$MPA = \frac{1}{2}(CPA_1 + CPA_2) \tag{8}$$

$$MRecall = \frac{1}{2}(R_1 + R_2) \tag{9}$$

国外电子测量技术 — 181 —

$$F_{1} = \frac{2CPA \times R}{CPA + R} \tag{10}$$

$$MIOU = \frac{1}{2}(IOU_1 + IOU_2) \tag{11}$$

*F*<sup>1</sup>分数为准确率和召回率的加权平均,*F*<sup>1</sup>越高,表示模型性能越好。

### 2023年2月 第42卷 第2期

### 4 结果对比与分析

### 4.1 消融实验

为了分析本文分割算法中提出的各改进方法对太阳 能电池片分割结果的影响,设计了消融实验来评估算法的 有效性,具体实验内容及分割效果如表 3 所示。

表 3 消融实验结果对比

(%)

(%)

网络	DE-RSU	CSEB	CPA	MPA	R	MRecall	$F_{1}$	IOU	MIOU
原算法	×	×	69.95	84.95	72.42	86.19	87.98	55.23	77.57
算法 1	$\checkmark$	$\times$	72.52	86.24	72.36	86.16	88.40	56.79	78.35
算法 2	$\times$	$\checkmark$	71.31	85.64	73.83	86.89	88.64	56.92	78.42
本文算法	$\checkmark$	$\checkmark$	74.69	87.32	76.39	88.18	89.45	60.68	80.30

1)算法 1 为利用 DE-RSU 替换原 RSU 进行特征提 取,DE-RSU 利用 ECA 模块良好的信息交互能力,加强了 网络对通道间关系的学习,提高了有效特征的提取能力, 由表 3 可知,算法 1 的改进使得 CPA 提升了 2.57%,IOU 提升了 1.56%;

2)算法 2 为在跳跃连接部分加入 CSEB 特征融合结构,通过在低层特征中引入更多的语义信息,弥补编解码跳跃连接过程中空间信息的丢失,减少了因信息丢失导致的漏分割,由表 3 可知,算法 2 改进使得 *R* 提高了 1.41%,MRecall 提升 1.99%;

3)本文算法将所提的 DE-RSU 结构和 CSEB 结构加入 到原网络当中,在加强编码阶段每层 RSU 结构的有效特征 提取能力的同时利用 CSEB 结构弥补跳跃连接引起的空间 信息丢失,从提高有效特征的提取能力和减少信息丢失两 方面共同改进,使得网络的分割能力有了进一步提升,如表 4 所示,相较于 U<sup>2</sup>-Net, CPA 提高了 4.74%, MPA 提高了 2.37%, R 提升了 3.97%, MRecall 提高了 1.99%, F<sub>1</sub>分数 提高 1.47%, IOU 提升了 5.45%, MIOU 提高了 2.73%。

#### 4.2 不同网络对比

本文综合利用注意力机制和语义嵌入分支的优点,提出了改进 U<sup>2</sup>-Net 的太阳能电池片 PL 图像缺陷分割方法,为定性分析该方法的有效性和合理性,将本文方法与常用分割网络 U-Net、U<sup>2</sup>-Net、PSPNet 及 Deeplab v3+进行对比,对比结果如表 4 和图 9 所示。

算法	CPA	MPA	R	MRecall	$F_{1}$	IOU	MIOU
U-Net	59.81	79.89	75.94	87.94	86.60	50.28	75.10
U <sup>2</sup> -Net	69.95	84.95	72.42	86.19	87.98	55.23	77.57
PSPNet	47.09	73.50	40.93	70.42	82.75	28.04	63.93
Deeplab v3+	71.07	85.50	58.57	79.27	85.89	47.30	73.59
本文算法	74.69	87.32	76.39	88.18	89.45	60.68	80.30

表 4 不同网络结果对比

本文算法通过注意力机制的引入增加有效特征的权 重值,从而加强了有效特征的提取;在 CSEB 结构中利用 CARAFE 整合特征图的语义信息,减少了编解码结构跳 跃连接时的信息丢失;由表 4 可知,本文方法在在各项指 标上均为最高,从实验结果角度验证了改进思路的正 确性。

为充分说明本文改进的有效性,选取了计算指标最高的3种网络分割图进行对比查看,各网络的分割结果如图9所示。

1)由图 9(b1)~(e1)和(b2)~(e2)结果可知,应用 Deeplab v3+和 U<sup>2</sup>-Net 进行分割时都存在部分漏分割现 象,而本文方法在面对黑点等小目标时漏分割情况明显减 少,证实在跳跃连接中加入 CSEB 结构,将高低级别的特 征进行融合后再输入到解码阶段进行处理,能弥补跳跃连 接中导致的信息丢失。

2)由图 9(b3)~(e3)结果可知,相比于 Deeplab v3+ 和 U<sup>2</sup>-Net,本文方法能更完整地提取缺陷的特征信息,证 实在编码器阶段加入融合注意力机制的深度可分离卷积 模块能使网络专注于拥有更多有效特征的信息通道,提高 了有效特征的提取能力,以实现更准确的分割。

3)由图 9(b4)~(e4)和(b5)~(e5)可知,在面对缺陷 情况复杂时,本文方法虽不能对所有缺陷都做出精确地分 割,但整体分割效果优于其他两种方法,并且对缺陷边缘 细节的处理更好、更平滑,整体连通性更好,为未来实现更 准确的太阳能电池片缺陷分割贡献了一定的思路。

本文方法在提高目标分割精度的同时,有效地减少了 漏分割的情况,从最终分割结果的角度验证了改进思路的 正确性。

3023年	2月
第42卷	第己期



图 9 不同方法分割结果对比

#### 5 结 论

本文针对太阳能电池片缺陷分割中存在的特征提取 能力弱、缺陷分割精度低和漏分割等问题,通过改进 U2-Net 提出了一种准确有效的分割方法,在 RSU 内部编码 阶段加入注意力机制和深度可分离卷积,利用残差结构将 二者有效地结合;在外层编解码跳跃连接中设计并引入 CSEB 特征融合结构。使网络充分利用级间特征和级内 特征,专注缺陷区域,在提升网络对目标分割精度的同时 减少了漏分割。实验结果表明,本文方法的类别像素准确 率、交并比和平均交并比分别达74.69%、60.68%、 80.30%,有较高的分割精度和较好的分割效果,对建立更 准确、高效的太阳能电池片缺陷检测系统有一定的实际意 义和推动作用。

#### 参考文献

[1] KABIR E, KUMAR P, KUMAR S, et al. Solar energy: Potential and future prospects[J]. Renewable and Sustainable Energy Reviews, 2018, 82: 894-900.

- [2] 刘磊, 王冲, 赵树旺, 等. 基于机器视觉的太阳能电池 片缺陷检测技术的研究[J]. 电子测量与仪器学报, 2018,32 (10): 47-52.
- [3] SPATARU S, HACKE P, SERA D. Automatic detection and evaluation of solar cell micro-cracks in electroluminescence images using matched filters [C]. 2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC). IEEE, 2016: 1602-1607.
- [4] 时亚涛,戴芳,杨畅民.太阳能光伏电池缺陷检测[J]. 电子测量与仪器学报,2020,34(4):162-169.
- [5] 钱晓亮,张鹤庆,陈永信,等.基于机器视觉的太阳能 电池片表面缺陷检测研究现状及展望[J].北京工业 大学学报,2017,43(1):76-85.
- [6] BALZATEGUI J, ECIOLAZA L, ARANA-AREXOLALEIBA N, et al. Semi-automatic quality inspection of solar cell based on convolutional neural networks [ C ]. 2019 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA). IEEE, 2019: 529-535.

- [7] CHEN H, PANG Y, HU Q, et al. Solar cell surface defect inspection based on multispectral convolutional neural network [ J ]. Journal of Intelligent Manufacturing, 2020, 31(2): 453-468.
- [8] 蓝金辉,王迪,申小盼.卷积神经网络在视觉图像检测的研究进展[J].仪器仪表学报,2020,41(4):167-182.
- [9] 侯学良,单腾飞,薛靖国.深度学习的目标检测典型算 法及其应用现状分析[J].国外电子测量技术,2022, 41(6):165-174.
- [10] ZHANG L X, SHEN J K, ZHU B J. A review of the research and application of deep learning-based computer vision in structural damage detection [J]. Earthquake Engineering and Engineering Vibration, 2022,21(1):1-21.
- [11] 王宪保,李洁,姚明海,等.基于深度学习的太阳能电 池片表面缺陷检测方法[J].模式识别与人工智能, 2014,27(6):517-523.
- [12] 刘方园,王水花,张煜东.深度置信网络模型及应用研究综述[J].计算机工程与应用,2018,54(1):11-18,47.
- [13] 刘忠德,陈智云,周俊杰,等.基于深度置信网络的太阳能光伏面板缺陷检测方法[J].机械设计与制造工程,2021,50(5):61-64.
- [14] ZHANG X, HOU T, HAO Y, et al. Surface defect detection of solar cells based on multiscale region proposal fusion network[J]. IEEE Access, 2021, 9: 62093-62101.
- [15] 王云艳,周志刚,罗帅.基于数据增强的太阳能电池片 缺陷检测[J].电子测量与仪器学报,2021,35(1): 26-32.
- [16] QASSIM H, VERMA A, FEINZIMER D. Compressed residual-VGG16 CNN model for big data places image recognition[C]. 2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC). IEEE, 2018: 169-175.
- [17] 王延年,刘宏涛,刘航宇,等. 基于改进 U-Net 的太阳 能电池图像缺陷陷检测方法[J]. 电子测量技术, 2021,44(14):117-121.
- [18] 苏健民,杨岚心,景维鹏.基于 U-Net 的高分辨率遥 感图像语义分割方法[J]. 计算机工程与应用, 2019, 55 (7): 207-213.
- [19] CHEN H, PANG Y, HU Q, et al. Solar cell surface defect inspection based on multispectral convolutional neural network [J]. Journal of Intelligent Manufacturing, 2020, 31(2): 453-468.
- [20] CHEN H, ZHAO H, HAN D, et al. Accurate and robust crack detection using steerable evidence filtering in electroluminescence images of solar cells[J]. Optics

and Lasers in Engineering, 2019, 118: 22-33.

2023年2月

第42卷 第2期

- [21] QIN X, ZHANG Z, HUANG C, et al. U<sup>2</sup>-Net: Going deeper with nested U-structure for salient object detection [J]. Pattern Recognition, 2020, 106: 107404.
- [22] 陈其浩,孙林,张倩. 基于改进 U<sup>2</sup>-Net 的透明件划痕 检测方法[J]. 科学技术与工程,2022,22(2): 620-627.
- [23] 徐凯成. 基于 U-Net 的胃部肿瘤分割技术[D]. 上 海:上海工程技术大学,2021.
- [24] SEO H, HUANG C, BASSENNE M, et al. Modified U-Net (mU-Net) with incorporation of object-dependent high level features for improved liver and liver-tumor segmentation in CT images[J]. IEEE Transactions on Medical Imaging, 2019, 39 (5): 1316-1325.
- [25] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020.
- [26] WANG H, CAO P, WANG J, et al. UCTransNet: Rethinking the skip connections in U-Net from a channel-wise perspective with transformer [J]. Computer Science, 2021, arXiv: 2109.04335.
- [27] ZHANG Z, ZHANG X, PENG C, et al. Exfuse: Enhancing feature fusion for semantic segmentation[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 269-284.
- [28] WANG J, CHEN K, XU R, et al. Carafe: Contentaware reassembly of features [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019.
- [29] 李果璟,夏秋婷,李宏.基于深度学习的眼底视网膜图 像疾病分类研究[J]. 传感技术学报,2022,35(5): 711-718.
- [30] QIN X, ZHANG Z, HUANG C, et al. U<sup>2</sup>-Net: Going deeper with nested U-structure for salient object detection [J]. Pattern Recognition, 2020, 106: 107404.

#### 作者简介

王盛,硕士,主要研究方向为图像处理、缺陷检测。 E-mail:2537098726@qq.com

吴浩,博士,教授,硕士生导师,主要研究方向为智能 信息处理。

E-mail:wuaho801212@163.com