

基于改进 U-Net 的太阳能电池图像缺陷检测方法^{*}

王延年 刘宏涛 刘航宇 陶 谦

(西安工程大学 电子信息学院 西安 710048)

摘要: 针对现有方法对太阳能电池图像缺陷分割上的不足,提出了一种对太阳能电池图像进行缺陷分割的改进型U-Net。首先引入密集连接结构,用来缓解梯度消失问题,使缺陷提取更加充分;同时在每个卷积层后面添加批量归一化层和ReLU激活层,防止缺陷细节特征丢失;接着引入双注意力机制增强目标特征,抑制无关特征,进而提升模型的整体缺陷检测精度。最后利用两种不同的网络与本文方法进行缺陷检测对比。实验结果表明,本文网络可以获得更细节的特征信息,进一步提高了对太阳能电池图像的分割精度。

关键词: 太阳能电池;缺陷检测;U-Net;密集连接;双注意力

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

Solar cell image defect detection method based on improved U-Net

Wang Yannian Liu Hongtao Liu Hangyu Tao Qian

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: To overcome the shortcomings of existing methods in the segmentation of solar cell images, an improved U-Net structure for defect segmentation of solar cell images is proposed. First, the dense connection structure is introduced to alleviate the problem of gradient disappearance and make defect extraction more fully, at the same time, a batch normalization layer and ReLU layer are added after each convolution layer to prevent the loss of defect details, then a dual attention mechanism is introduced. To enhance target features and suppress irrelevant features, improving the overall detection accuracy of the model. Finally, two different networks are used to be compared with the method in this paper. The experimental results show that the network can obtain more detailed feature information, which further improves the accuracy of solar cell image segmentation.

Keywords: solar cell; defect detection; U-Net; dense connection; dual attention

0 引言

当前太阳能电池发展迅速,应用广泛,但由于太阳能电池硅晶片易碎和严酷的操作环境,太阳能电池生产中会产生各种缺陷(裂纹、黑斑、过焊等),这些缺陷会阻碍电流传输,降低组件整体效率,更为严重的风险是不可预测的^[1]。因此缺陷检测是太阳能电池生产过程中至关重要的一步^[2]。

近年来CNN^[3]随着深度学习的发展在图像处理领域取得了一席之位^[4],图像分割^[5]同时在太阳能电池领域也蓬勃发展。如Deitsch等^[6]分别使用SVM和CNN对太阳能电池片EL图像进行缺陷检测,CNN模型准确率为88.42%,SVM模型准确率为82.44%,但其应用场景受限制且处理时间较长;Tsai等^[7]在电致发光(EL)图像的傅里

叶重建中消除了代表微裂纹缺陷的光谱成分,利用输入图像与重建图像之间的差异来检测缺陷的存在。Han等^[8]将区域建议网络(RPN)添加到U-Net中,并使用扩展卷积来分割多晶硅晶片缺陷。但这些方法都存在检测效率低,特征提取不完整等问题^[9]。

针对以上方法的不足,本文提出一种改进型U-Net,通过引入密集^[10]连接和双注意力机制^[11],使太阳能电池缺陷特征提取更加完整,分割结果更加精确,大大提高了缺陷检测的准确性。

1 算法理论

1.1 U-Net 网络

2015年,Ronneberger等在MICCAI会议上发表了U-Net。其结构如图1所示,它将卷积层代替全连接层实

收稿日期:2021-06-02

*基金项目:陕西省重点研发计划项目(2021GY-076)、西安工程大学(柯桥)研究生创新学院研究生联合培养项目(19KQYB02)资助

现图像端到端训练输出，并且能够结合浅层信息和深层信息减小特征提取时的损失。原始 U-Net 包含 18 个 3×3 的卷积层，1 个 1×1 的卷积层，4 个 2×2 的下采样层，4 个 2×2 的上采样层，使用 ReLU 作为激活函数，同时使用了 4 次跳跃连接来连接浅层与深层的特征图^[12]。

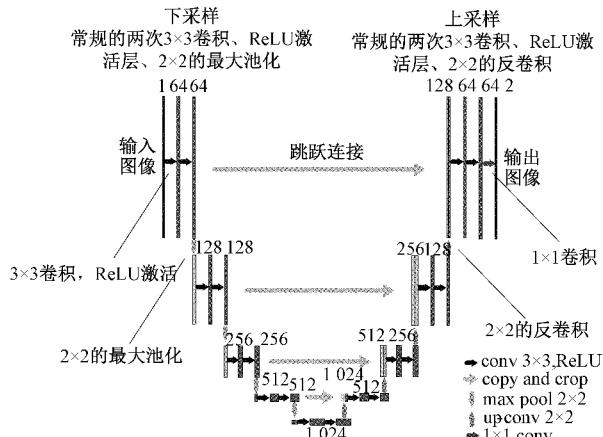


图 1 U-Net 网络结构

1.2 密集连接块

本文设计了密集连接块用来增强网络的性能，其结构如图 2 所示，每个密集连接块主要包括两个 3×3 的卷积层和两次特征融合。对于输入特征图，在经过卷积后，再与一开始的特征图相融合形成新的特征图，最后将融合后的结果输入下一个连接块。它使当前层的特征与之前层的特征相结合，再将得到的特征传递给后面。这种级联方式使每一层网络都能学习到前几层的特征，重复利用特征的同时还加强了特征的传递^[13]。若密集连接网络中第 i 层的输出为 x_i ，则 x_i 的定义为：

$$x_i = H_i([x_{i-1}, x_{i-2}, \dots, x_0]) \quad (1)$$

式中： H_i 表示第 i 层的非线性变换， $[\dots]$ 表示网络中各层特征融合。

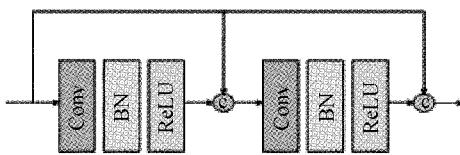


图 2 密集连接模块

1.3 双注意力机制

本文对瓶颈块池化后的特征图使用空间注意力模块和通道注意力模块。空间利用所有位置特征的加权和选择性地将不同位置特征汇合，使相似的特征关联起来。同时，通道整合所有通道图间的关联特征，选择性地强调相互依赖的通道特征图。空间注意力抑制背景噪声，通道注意力强调缺陷区域，最后将两个模块的结果求和后输出，提高了特征表示，进而提高缺陷分割精度。

1) 空间注意力模块

位置特征在分割任务中起重要的作用，它通过提取像素间的上下文信息获得。由传统的特征提取网络而生成的局部特征未考虑临近像素的影响可能导致错误的分割，因此，为了在目标特征上得到丰富的像素间位置关系，本文引入了空间注意力模块，其结构如图 3 所示，流程如下。

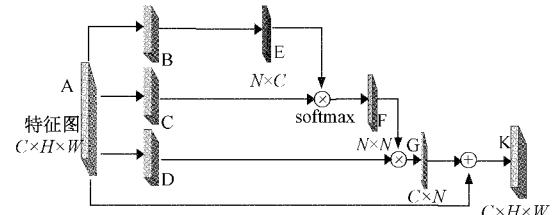


图 3 空间注意力模块

(1) 输入的特征图 A 分别通过 3 个卷积层，得到 3 个新的特征映射，即 B、C、D，且 $\{B, C, D\} \in R^{C \times H \times W}$ 。

(2) 对 B 进行尺寸变换（reshape）和维度变换（transpose）得到 E，尺寸从 $C \times H \times W$ 变为 $N \times C$ ，其中 N 的大小为 $H \times W$ 。

(3) 然后 E 与 C 相乘，再通过 softmax 函数得到空间监督图 F，这时 F 的尺寸为 $N \times N$ 。

(4) 将 D 经过尺寸变换与 F 相乘得到 G，再乘以系数 α ，之后进行尺寸变换将维度变为 $C \times H \times W$ 。其中 α 初始化为 0，并在训练过程中逐渐分配更多权重。

(5) 最后 G 与 A 相加得到 K，K 即为空间注意力模块的输出。

2) 通道注意力模块

深层特征的每个特征图的通道都可以作为一个特定分割的响应，而不同的响应间又相互联系，通过提取通道图间的依赖关系，可以将特征图的依赖关系表示出来。因此，本文引入了通道注意力模块来搭建通道间的依赖关系，结构如图 4 所示，流程如下。

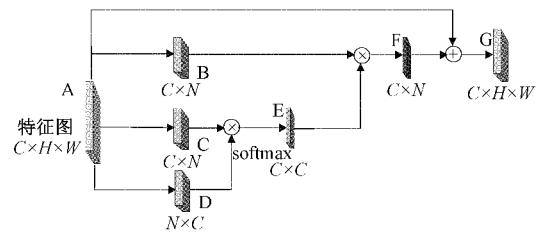


图 4 通道注意力模块

(1) 分别对特征图 A 进行 reshape、reshape、reshape 和 transpose，得到特征图 B、C 和 D。

(2) 其中 $N \times C$ 的特征图 D，与 C 相乘再通过 softmax 函数得到 E，E 的大小为 $C \times C$ 。

(3) 然后 B 与 E 相乘得到 F，F 与系数 β 相乘后，reshape 为 $C \times H \times W$ ，其中 β 初始为 0，并在训练过程中逐渐分配更多权重。

(4) 最后 F 与 A 相加得到 G, G 为通道注意力模块的输出。

1.4 网络架构(DAD-U-Net)

太阳能电池的缺陷检测由于背景复杂语义特征少,浅层信息多,需要处理很多细节特征。原始 U-Net 存在如下问题:1)考虑细节特征较少,忽略了图像本身与缺陷目标之间的联系;2)考虑较多深层特征,对浅层信息重复利用少。所以要对 U-Net 进行改进,从而实现更好的缺陷检测效果。本文将密集连接、双注意力机制等与 U-Net 融合得到一种双注意力密集网络(dual attention dense U-Net, DAD-U-Net),结构如图 5 所示,参数设置如表 1 所示。它采用编码器—解码器结构,左边网络称为主干部分提取网络(编码器),右边网络称为加强特征提取网络(解码器)。编码器用于下采样,提取深层特征:对于输入网络的 512×512 图像,首先经过密集连接模块进行两次卷积,然后特征图经过池化大小减半,最后,在经过 4 次卷积和池化后,得到 32×32 特征图。解码器用于上采样,其中池化层变为反卷积层,用来恢复图像分辨率,实现端到端分割。左边和右边网络对应层之间通过跳跃连接相连。跳跃连接将左边深层特征传递给右边,与浅层特征融合,实现了像素级别的细

致分割。并联在一起的空间注意力模块和通道注意力模块,分别在空间和通道获取特征依赖,并对特征图中任意两个具有关联的特征进行加强,增强缺陷特征,抑制晶粒特征,从而更准确地将缺陷分割出来,提升网络的表达能力。

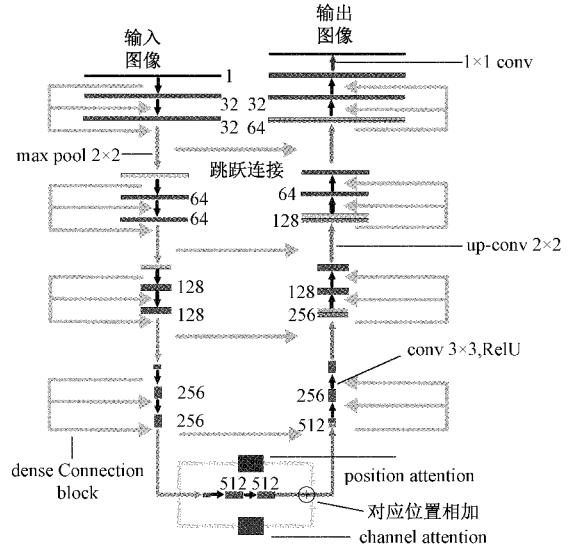


图 5 DAD-U-Net 结构

表 1 DAD-U-Net 网络各层的参数设置

| 网络层 | 卷积核 | 过滤器数量 | 步长 | 特征图尺寸 |
|-------------------|--------------|-------|----|-----------------------------|
| Conv1、2+BN+ReLU | 3×3 | 32 | 1 | $512 \times 512 \times 32$ |
| Max-pooling | 2×2 | — | 2 | $256 \times 256 \times 32$ |
| Conv3、4+BN+ReLU | 3×3 | 64 | 1 | $256 \times 256 \times 64$ |
| Max-pooling | 2×2 | — | 2 | $128 \times 128 \times 64$ |
| Conv5、6+BN+ReLU | 3×3 | 128 | 1 | $128 \times 128 \times 128$ |
| Max-pooling | 2×2 | — | 2 | $64 \times 64 \times 128$ |
| Conv7、8+BN+ReLU | 3×3 | 256 | 1 | $64 \times 64 \times 256$ |
| Max-pooling | 2×2 | — | 2 | $32 \times 32 \times 256$ |
| Conv9、10+BN+ReLU | 3×3 | 512 | 1 | $32 \times 32 \times 512$ |
| Up-conv | 2×2 | — | 2 | $64 \times 64 \times 512$ |
| Conv11、12+BN+ReLU | 3×3 | 256 | 1 | $64 \times 64 \times 256$ |
| Up-conv | 2×2 | — | 2 | $128 \times 128 \times 256$ |
| Conv13、14+BN+ReLU | 3×3 | 128 | 1 | $128 \times 128 \times 128$ |
| Up-conv | 2×2 | — | 2 | $256 \times 256 \times 128$ |
| Conv15、16+BN+ReLU | 3×3 | 64 | 1 | $256 \times 256 \times 64$ |
| Up-conv | 2×2 | — | 2 | $512 \times 512 \times 64$ |
| Conv17、18+BN+ReLU | 3×3 | 32 | 1 | $512 \times 512 \times 32$ |
| Conv19+Sigmoid | 1×1 | 1 | 1 | $512 \times 512 \times 1$ |

2 实验

本文的实验环境基于深度学习框架 keras2.2.4 结合 Python 编程语言进行搭建,用于实现本文网络和其他对比的网络。电脑配置如下:系统为 Windows10;处理器为

Intel Corei7-8700K;显卡为 NVIDIA RTX 1080,11 GB 内存;系统内存为 16 GB。

2.1 数据集及参数设置

如表 2 所示,本文太阳能电池 EL 图像数据集由 542 张图像组成,其中缺陷图像 145 张,无缺陷图像 397 张。所

有图像都是在真实的工业环境中拍摄,每幅图像都有不同的对比度、亮度和图案。图像尺寸大小为 943×923 ,并由专家使用 Label ME 对图像进行标注,由于硬件限制,将图像从原始尺寸缩小到 512×512 。经过不同的试验后,此图像大小是计算机内存可以处理的最合适大小,并在网络结构的下采样-上采样中没有出现错误。本文尽量尝试选择最大可能的图像尺寸,以保留图像中的最大细节数量。所有数据均通过随机裁剪、缩放及旋转等方式进行数据增强^[14],以提高模型的泛化能力和训练精度。

表 2 数据集图像

| | 无缺陷 | 有缺陷 |
|-----|-----|-----|
| 训练集 | 371 | 128 |
| 测试集 | 26 | 17 |

训练过程中,采用 RMSprop 优化器进行优化,其中,初始学习率设置为 0.0001,训练次数为 100,批量大小设置为 1,使用 Xavier 统一初始化器初始化参数。

2.2 损失函数与评价指标

在学习训练期间,通过估计权重来增加网络的鲁棒性和准确性是很有必要的,因此本文要选择一个合适的损失函数。由于本文的数据集像素分布不平衡,大约 90% 的背景和 10% 的缺陷。所以,本文选择 Dice 损失函数^[15]进行评估,公式如下:

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

式中: $|X_g|$ 是地面真实图像, $|X_p|$ 是预测图像。

为了评估网络模型的性能,本文用了 4 个指标,可以用来度量分类方法的性能,判断一个模型的好坏。如式(3)中交并比(intersection over union),式(4)中正样本

分类精度(Precision),式(5)的正样本召回率(Recall)和式(6)的 F 测度(F-measure)。

$$IOU = \frac{TP}{TP + FP + FN} \quad (3)$$

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$

$$F = \frac{2PR}{P + R} \quad (6)$$

式中: TP 表示实际标签为正样本、预测为正样本的数目; FN 表示实际样本为负样本、预测为正样本的数目; FP 表示实际标签为负样本、预测结果为正样本的数目; IOU 为计算预测和地面真值之间的空间重叠,定义在 0 和 1 之间,0 表示不重叠,1 表示完全重叠; F 为组合精确度和召回率一个单独的得分,被定义为精确度和召回率的平均数; F 越高,表示卷积网络分类模型性能越好,对应的数据增强方法越好。

2.3 结果对比与分析

由于背景不均匀性和缺陷形状的多样性,光伏 EL 图像中缺陷分割是一项艰巨的任务。本文充分利用了双注意力网络和密集连接的优点提出了一种准确、高效的 EL 图像缺陷检测方法。在对网络进行训练和评估后,在数据集上获得了很好的分割结果。本文选取了 FCN、U-Net 进行对比实验,结果如表 3 和图 6 所示。

表 3 DAD-U-Net 与其他网络数据对比

| 网络 | IOU | P | R | F |
|-----------|-------|-------|-------|-------|
| FCN | 0.493 | 0.665 | 0.544 | 0.594 |
| U-Net | 0.556 | 0.899 | 0.664 | 0.764 |
| DAD-U-Net | 0.648 | 0.931 | 0.689 | 0.792 |

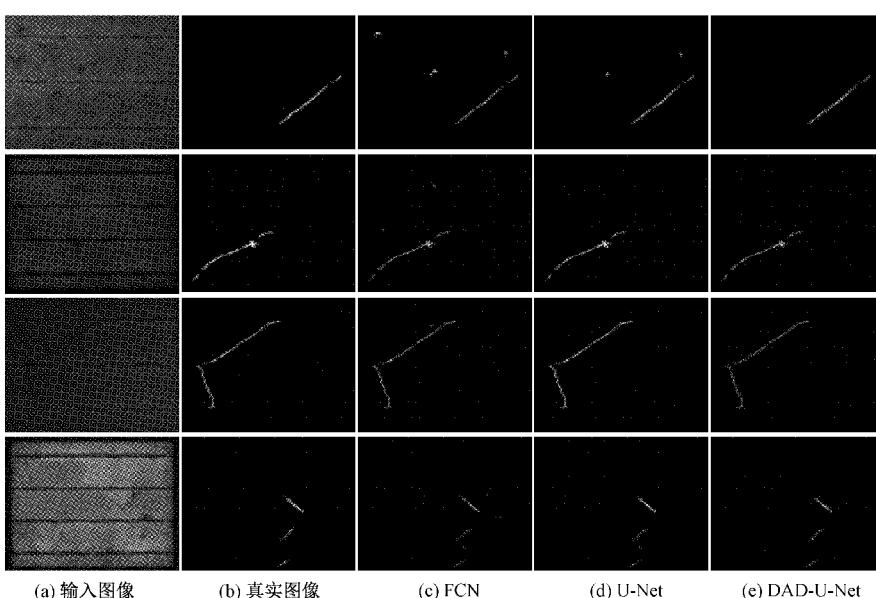


图 6 不同方法分割结果对比

表3所示为不同算法在同一测试集上的 IOU 、 P 、 R 和 F 值。可见,本文DAD-U-Net结构的各项指标均最高,表明本文算法优于其他算法。图6所示为不同方法的对比结果,第1列和第2列表示输入图像和地面真实图像,第3~5列表示各方法的分割结果。本文方法的结果如图6(e)所示,很明显,所有缺陷被精确分割,背景晶粒图案被成功忽略,优于其他方法。本文在U-Net网络瓶颈块加入的双注意力机制突出了缺陷区域,使得网络更加关注缺陷,可以很明显提高缺陷分割的分类精度和召回率。

3 结 论

本文通过改进U-Net网络提出一种准确、高效的太阳能电池缺陷检测方法。该方法具有两个关键特征:密集连接块和双注意力网络。密集模块既可以加强对特征的传递,又能缓解梯度消失。双注意力网络有助于网络关注缺陷,同时抑制复杂的异质背景信息。这些使得本文方法能够以更高的精度和鲁棒性分割复杂的缺陷。实验结果表明,此方法在光伏EL图像上有较高的检测精度和较好的分割效果,它优于以往的方法,对建立更有效、更稳健的太阳能电池缺陷检测系统有十分重要的意义。

参考文献

- [1] KABIR E, EHSANUL P, KUMAR S, et al. Solar energy: Potential and future prospects [J]. Renew. Sustain. Energy Rev., 2018, 82: 894-900.
- [2] JULEN B, LUKA E, NESTOR A, 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), 2019: 529-535.
- [3] 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: 116319.
- [4] 王森,伍星,张印辉,等.基于全卷积神经网络和结构化森林的结构体裂纹分割方法[J].仪器仪表学报,2020,41(8):170-179.
- [5] 桑艳艳,李听.基于改进风水岭算法的菌落图像分割[J].电子测量技术,2019,42(6):87-93.
- [6] DEITSCH S, BUERHOP-LUTZ C, SOVETKIH E, et al. Segmentation of photovoltaic module cells in uncalibrated electroluminescence images [J]. Machine Vision and Applications, 2021, DOI: 10.1007/s00138-021-01191-9.
- [7] TSAI D M, LI G N, LI W C, et al. Defect detection in multi-crystal solar cells using clustering with uniformity measures [J]. Advanced Engineering Informatics, 2015, 29: 419-430.
- [8] HAN H, GAO C, ZHAO Y, et al. Polycrystalline silicon wafer defect segmentation based on deep convolutional neural networks [J]. Pattern Recognit. Letters, 2018, 130: 234-241.
- [9] CHEN H Y, ZHAO H F, HAN D, et al. Accurate and robust crack detection using steerable evidence filtering in electroluminescence images of solar cells [J]. Lasers Eng., 2019, 118: 22-33.
- [10] LIN T Y, GOYAL P, HE K M, et al. Focal loss for dense object detection [J]. IEEE Trans. Pattern Anal. Mach. Intell., 2020, 42: 318-327.
- [11] 郭玥,于希明,王少军,等.遥感图像云检测的多尺度融合分割网络方法[J].仪器仪表学报,2019,40(6):31-38.
- [12] 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,2018,55(7):207-213.
- [13] 庞英,刘畅.一种改进的基于超像素的SAR图像海陆分割方法[J].国外电子测量技术,2019,38(8):12-18.
- [14] 邱跟,王锂,白利兵.基于生成对抗网络数据扩充的缺陷识别方法[J].电子测量与仪器学报,2021,35(2):212-220.
- [15] CHEN H Y, PANG Y, HU Q D, et al. Solar cell surface defect inspection based on multispectral convolutional neural network [J]. Journal of Intelligent Manufacturing, 2018, 310: 453-468.

作者简介

王延年,教授,硕士研究生导师,主要研究方向为工业信息化系统、计算机控制系统、工业信息通信系统、专用工业电子装置开发。

E-mail:1766617602@qq.com

刘宏涛,硕士研究生,主要研究方向为深度学习与图像处理。

E-mail:1107291405@qq.com