

基于DCGANs的半片光伏组件电致发光图像增强技术

何翔

Electroluminescence image enhancement technology of half-cut photovoltaic module based on DCGANs

HE Xiang

引用本文:

何翔. 基于DCGANs的半片光伏组件电致发光图像增强技术[J]. 应用光学, 2023, 44(2): 314–322. DOI: 10.5768/JAO202344.0202003

HE Xiang. Electroluminescence image enhancement technology of half-cut photovoltaic module based on DCGANs[J]. Journal of Applied Optics, 2023, 44(2): 314–322. DOI: 10.5768/JAO202344.0202003

在线阅读 View online: <https://doi.org/10.5768/JAO202344.0202003>

您可能感兴趣的其他文章

Articles you may be interested in

基于多尺度空洞卷积的对抗去雾网络

Adversarial dehazing network based on multi-scale dilated convolution

应用光学. 2020, 41(6): 1207–1213 <https://doi.org/10.5768/JAO202041.0602004>

基于小波变换与卷积神经网络的图像去噪算法

Image denoising algorithm based on wavelet transform and convolutional neural network

应用光学. 2020, 41(2): 288–295 <https://doi.org/10.5768/JAO202041.0202001>

基于注意力机制与图卷积神经网络的单目红外图像深度估计

Depth estimation of monocular infrared images based on attention mechanism and graph convolutional neural network

应用光学. 2021, 42(1): 49–56 <https://doi.org/10.5768/JAO202142.0102001>

基于深度神经网络的太阳能电池组件缺陷检测算法研究

Research on detection algorithm of solar cell component defects based on deep neural network

应用光学. 2020, 41(2): 327–336 <https://doi.org/10.5768/JAO202041.0202006>

基于卷积神经网络的蛋胚活性精准检测方法研究

Research on accurate detection method of egg embryo activity based on convolutional neural network

应用光学. 2021, 42(2): 268–275 <https://doi.org/10.5768/JAO202142.0202003>

基于时空双流卷积神经网络的红外行为识别

Infrared behavior recognition based on spatio-temporal two-stream convolutional neural networks

应用光学. 2018, 39(5): 743–750 <https://doi.org/10.5768/JAO201839.0506002>



关注微信公众号, 获得更多资讯信息

文章编号: 1002-2082 (2023) 02-0314-09

基于 DCGANs 的半片光伏组件电致发光图像增强技术

何 翔^{1,2}

(1. 福建省计量科学研究院 国家光伏产业计量测试中心, 福建 福州 350003; 2. 福建省能源计量重点实验室, 福建 福州 350003)

摘 要: 针对半片光伏组件电致发光 (electroluminescence, EL) 缺陷自动识别过程中训练用样本不足导致模型过拟合的问题, 采用深度卷积生成对抗网络 (deep convolutional generative adversarial networks, DCGANs) 生成可控制属性的半片光伏组件 EL 图像, 再采用多尺度结构相似性 (multi-scale structural similarity, MS-SSIM) 指标对生成的 EL 图像与拍摄的 EL 图像之间的相似程度进行了评估。评估结果得到, 使用 DCGANs 生成的所有类型半片光伏组件的 EL 图像与拍摄的 EL 图像的 MS-SSIM 指标都大于 0.55, 大部分的 MS-SSIM 值在 0.7 附近。在分类模型的训练过程中, 测试集准确率随着训练集中生成图像数量的增加而升高, 当生成图像数量达到 6000 张时, 测试集准确率达到 97.92%。实验结果表明, 采用 DCGANs 能够生成高质量且可控制属性的半片光伏组件 EL 图像, 较好地解决因缺少训练样本而导致的模型过拟合问题。

关键词: 深度卷积生成对抗网络 (DCGANs); 电致发光 (EL); 多尺度结构相似性 (MS-SSIM); 神经网络
中图分类号: TN206 文献标志码: A DOI: [10.5768/JAO202344.0202003](https://doi.org/10.5768/JAO202344.0202003)

Electroluminescence image enhancement technology of half-cut photovoltaic module based on DCGANs

HE Xiang^{1,2}

(1. National PV Industry Measurement and Testing Center, Fujian Metrology Institute, Fuzhou 350003 China;

2. Fujian Key Laboratory of Energy Measurement, Fuzhou 350003, China)

Abstract: Aiming at the problem of model overfitting caused by insufficient training samples in the automatic identification process of electroluminescence (EL) defects for half-cut photovoltaic modules, the deep convolutional generative adversarial networks (DCGANs) were adopted to generate the half-cut photovoltaic module EL images with controllable attributes. The similarity between the generated EL images and the captured EL images was evaluated by using the multi-scale structural similarity (MS-SSIM) index. The evaluation results show that the MS-SSIM indexes of all types of EL images generated by DCGANs and captured EL images are greater than 0.55, and most of the MS-SSIM values are near 0.7. In the training process of the classification models, the accuracy of the test set increases with the increase of the number of images generated in the training set. When the number of generated images reaches 6 000, the accuracy of the test set reaches 97.92%. The experimental results show that the DCGANs can generate half-cut photovoltaic module EL images with high quality and controllable attributes, which can better solve the problem of model overfitting caused by the lack of training samples.

Key words: deep convolutional generative adversarial networks (DCGANs); electroluminescence (EL); multi-scale structural similarity (MS-SSIM); neural network

引言

近年来, 随着机器学习的发展, 在光伏组件电

致发光缺陷自动识别领域, 越来越多地应用到了机器学习技术。大量模型被应用到该领域中, 如

收稿日期: 2022-05-16; 修回日期: 2022-09-23

基金项目: 福建省市场监督管理局科技项目 (FJMS2020024); 国家市场监督管理总局科技计划项目 (2021MK050)

作者简介: 何翔 (1990—), 男, 硕士, 工程师, 主要从事光伏计量研究。E-mail: 315107763@qq.com

刘怀广等人^[1]和周颖等人^[2]分别采用了卷积神经网络和卷积神经网络+随机森林对光伏组件电致发光(electroluminescence, EL)缺陷图像分类问题进行了研究;刘怀广等人^[3]提出了一种轻量化特征增强型卷积神经网络模型,在保证准确度的前提下提升了识别效率。通常这类研究需要使用大量带有缺陷的光伏组件 EL 图像训练模型,最终使得模型能够自动识别出光伏组件 EL 图像中的各种缺陷。然而,随着组件生产工艺的不断改进,光伏组件缺陷率逐渐降低,通过电致发光缺陷检测仪拍摄所获得的 EL 图像中,缺陷图像数量占比很低,难以获得充足的训练样本,而训练样本不足会导致模型过拟合,影响自动识别结果。同时,从大量拍摄的光伏组件 EL 图像中人工筛选可用于训练用的图像耗时耗力^[4]。

生成对抗网络(generative adversarial network, GAN)^[5]自被提出以来,以其优异的性能,在各行各业都得到了不少应用,尤其在图像处理领域展示了强大的功能。如丛晓峰等人^[6]采用对抗神经网络对雾天拍摄的图像进行图像增强;徐英等人^[7]采用基于解耦表示学习的生成对抗网络(disentangled representation generative adversarial networks, DRGAN)与支持向量机(support vector machine, SVM)对合成孔径雷达图像目标识别进行了研究。而在光伏组件 EL 缺陷图像自动识别领域,采用生成对抗网络生成 EL 缺陷图像进行数据增强是一种高效经济且行之有效的方法。

虽然近年来已有部分文献采用对抗神经网络生成光伏组件 EL 图像,如刘坤等人^[8]采用负样本引导生成对抗网络对太阳能电池缺陷样本进行了数据增强,周颖等人^[9]提出了改进的深度卷积对抗神经网络(solar generative adversarial networks, SolarGAN)对四栅多晶光伏组件 EL 缺陷图像进行了数据增强,但是目前这类研究所针对的大多是整片太阳能电池组成的光伏组件。近几年来,采用半片技术的光伏组件凭借着优异的电性能、良好的稳定性及更小的光致衰减已经成为光伏行业的主流产品^[10-11],主流的异质结(heterojunction, HJT)组件、发射极和背面钝化电池(passivated emitter and rear cell, PERC)组件、隧穿氧化层钝化接触(tunnel oxide passivating contacts, TOPCon)组件已绝大多数采用半片技术^[12];然而目前尚缺少对半片电池 EL 图像的数据增强技术研究,并且由于半片光伏组件的 EL 图像存在倒角位置分布的问题,在该方面的研究上,半片光伏组件相对于整片光伏组件

存在一定的差异。

本文建立深度卷积对抗神经网络(deep convolutional generative adversarial networks, DCGANs),采用拍摄的半片光伏组件的 EL 图像对模型进行训练,最终生成了可控制属性的半片光伏组件 EL 图像,评估了生成图像与拍摄图像的相似度,并建立模型验证了生成图像在降低模型过拟合方面的有效性。

1 模型介绍

1.1 DCGANs 模型

生成对抗网络由生成器和判别器组成。如图 1 所示,模型训练时,通过将一组满足 $P_n(n)$ 分布的随机噪声 n 输入到生成器获得生成的数据 $G(n)$,该数据与真实数据 x 共同输入到判别器中。根据判别器的结果对生成器和判别器进行优化,最终使得二者达到纳什均衡状态^[13],即对于生成器生成的数据,判别器判定为真假的概率相等。




图 1 GAN 原理示意图

Fig. 1 Schematic diagram of GAN

目标函数如式(1)式所示,对于判别器来说,其目标在于准确分辨出真实数据 x 与生成数据 $G(n)$,即最大化 $E_{x \sim P_{data}(x)} [\lg D(x)]$ 项与 $E_{n \sim P_n(n)} [\lg (1 - D(G(n)))]$ 项。对于生成器来说,其目标在于使得其生成的数据 $G(z)$ 逼近真实数据 x ,即最小化 $E_{n \sim P_n(n)} [\lg (1 - D(G(n)))]$ 项,如此即可使得生成器与判别器形成对抗。

$$\min_{G, D} \max V(D, G) = E_{x \sim P_{data}(x)} [\lg D(x)] + E_{n \sim P_n(n)} [\lg (1 - D(G(n)))] \quad (1)$$

而 DCGANs 针对 GAN 训练不稳定的问题,通过将卷积神经网络与 GAN 结合,并进行一系列优化提高模型稳定性,如采用增加卷积核步长的方式替代最大池化层实现下采样,加入批量归一化层,判别器采用 LeakyReLU 激活函数,生成器采用 ReLU 激活函数等。

采用的生成器的输入为满足高斯分布的 300 维随机噪声,连接全连接层、批量标准化层、ReLU 激活函数层与重构层,使得输出尺寸为 10 像素×5 像素×512 通道,之后连接 5 层的反卷积层+批

量标准化层+ ReLU 激活函数层,使得输出尺寸为 320 像素×160 像素×16 通道,最终连接一个通道数为 1 的反卷积与 Tanh 激活函数层,生成器输出尺寸为 320 像素×160 像素×1 通道的灰度图像。生成器的结构示意图如图 2 所示。




图 2 生成器结构示意图

Fig. 2 Structure diagram of generator

判别器的输入尺寸为 320 像素×160 像素×1 通道,连接 5 层的卷积层+LeakyReLU 激活函数层+权重丢失层,使得输出尺寸为 10 像素×5 像素×256 通道,之后连接 Flatten+全连接层+Sigmoid 激活函数层,输出为尺寸为 1。判别器的结构示意图如图 3 所示。




图 3 判别器结构示意图

Fig. 3 Structure diagram of discriminator

1.2 训练策略

模型使用 Adam 优化器进行训练,学习率根据不同类型缺陷而不同,一般在 0.00005~0.0001 之间,并设置学习率衰减。训练时,对判别器训练

5 轮后对生成器训练 1 轮。每次训练判别器时,生成一组随机噪音 n ,使用生成器根据 n 生成图像。同时取训练集中同样数量的拍摄的 EL 图像,将两组图像组成生成器本次训练样本。采用 l 作为训练样本的标签, l 满足高斯分布,对于生成器生成的图像, $l \in [0, 0.2]$, 对于拍摄的 EL 图像, $l \in [0.8, 1.2]$ 。训练生成器时,冻结判别器,将随机噪音 n 作为模型输入,经过生成器生成 EL 图像,再经过判别器得出判别结果,标签 l 满足 $l \in [0.8, 1.2]$ 。

训练模型时,每隔 500 轮使用生成器生成图像并保存,每隔 3000 轮保存模型。根据生成器生成的图像质量选取最优模型。

1.3 训练所使用的样本

选取半片单晶光伏组件作为试验对象,使用电致发光缺陷检测仪拍摄其 EL 图像,通过建立 U-net 模型^[14]对拍摄的光伏组件 EL 图像进行二值化并切割,以获得每片组件中的所有太阳能电池片 EL 图像。之后对获得的电池片图像进行筛选分类,且对部分类型缺陷图像进一步细分。训练样本具体情况如表 1 所示。对表 1 中的图像采用旋转、翻转的方式进行数据增强后用于模型训练。

表 1 训练样本具体类型与数量

Table 1 Specific types and quantity of training samples

缺陷类型		样本数量
隐裂	线性隐裂	387
	交叉状裂	228
断栅	/	345
破角	/	132
虚焊	平行主栅暗块	194
	边缘条状暗块	127
	角落单块暗块	136
正常无缺陷		200

2 实验过程与结果分析

2.1 训练过程

选取线性隐裂模型计算过程为例,展示随着训练过程生成器所生成的图像。图 4 为线性隐裂模型训练过程中生成器生成的典型图像。图 4(a)~图 4(e)分别为训练 0 步、1000 步、67000 步、102000 步、148500 步生成的典型图像,图 4(f)为真实拍摄的隐裂 EL 图像。从图 4 中可以看出,训练未开始时,生成的图像杂乱无意义;当训练到约 1000 步时,生成的图像出现模糊的主栅与倒角,电池片呈

现出基本轮廓;当训练到约 67000 轮时,电池片主栅与倒角更加清晰,同时图像中出现了模糊的隐裂;当训练到 102000 轮时,图像质量进一步提高,隐裂更加清晰;最后当训练到 148500 轮时,隐裂进一步加深,整体图像基本逼真。目视感官上,图 4(f)与生成的图像质量已经十分接近。




图 4 训练过程生成器所生成的 EL 图像与拍摄的 EL 图像
Fig. 4 EL images generated during training and captured EL images

2.2 图像属性控制

由于单晶太阳能电池片存在倒角,半片工艺是将单晶电池片对称地切割成两个半片电池。因此,其拍摄的 EL 图像中倒角只可能存在于半片电池长边同侧。而模型生成该类图像时,电池片的倒角位置可能出现异常,并且随着训练轮数的增加,该类异常并不会消失。如图 5(a)所示,生成的电池片只有右下位置存在倒角,右上位置倒角缺失。

针对这个问题,本文参考 RADFORD A 等人提出^[15]的方法,使用训练完成的生成器随机生成 500 张图像,分别找出图像四角处(左上、左下、右上、右下)存在与不存在倒角的 EL 图像及其对应的随机噪声 n ,采取式(2)计算控制 4 个倒角的控制向量:

$$v = \text{mean}(n_p) - \text{mean}(n_n) \quad (2)$$

式中: n_p 为某位置存在倒角的图像集对应的随机噪声; n_n 为某位置不存在倒角的图像集对应的随机噪声。在获取属性控制向量 v 之后,通过式(3)即可控制生成图像属性:

$$n_c = n + a \cdot v \quad (3)$$

式中: n_c 为经过修改的噪声; n 为用于生成器生成图像的随机噪声; a 为系数,一般取 $\pm(1 \sim 3)$,当 a 为正值时,即赋予图像该属性,当 a 为负值时,即将该属性从图像中去除。




图 5 属性控制前后生成的图像对比

Fig. 5 Comparison of generated images before and after attribute control

选取正常无缺陷的 EL 图像与存在破角缺陷的 EL 图像为例说明效果。图 5 为控制属性前后生成的图像对比,其中图 5(a)为使用随机噪声 n_1 通过生成器生成的图像,从图中可以看出,图像右上方倒角缺失;图 5(b)为将随机噪声 n_1 加上控制右上角倒角的向量 v_1 后($a = 1$),再使用生成器生成的图像。可以看出,经过该方法处理后,图 5(b)右上角出现了倒角。图 5(c)为使用随机噪声 n_2 生成的存在破角缺陷的 EL 图像,其中破角位置为左上角和右下角;图 5(d)为将随机噪声 n_2 减去控制左上角破角的向量 v_2 后($a = -1$),再使用生成器生成的图像。可以看出,原本左上角存在破角的图像,经过该方法修改后,左上角位置的破角消失,成为倒角。

上述图像属性控制方法可以用于生成批量满足某特征的图像。以正常无缺陷的 EL 图像与虚焊-角落单块暗块的 EL 图像为例,验证上述方法可行性。首先分别针对以上 2 种类型的 EL 图像,找出控制正常无缺陷的 EL 图像右上角出现倒角的向量 v_3 和控制虚焊-角落单块暗块 EL 图像左上角出现暗块的向量 v_4 ,之后采用随机向量生成 200 张正常无缺陷的 EL 图像和虚焊-角落单块暗块的 EL 图像,分别对其随机噪声加上对应的属性控制

向量 $\mathbf{v}_3$ 和 $\mathbf{v}_4$ ($\mathbf{a}$ 分别取 ± 1 与 ± 2),并统计生成的结果,结果如表2与表3所示。

表2 正常无缺陷图像属性控制情况
Table 2 Attribute control of normal no-defect images

$\mathbf{a}$	右上存在倒角图像数量	右上不存在倒角图像数量
0	96	104
1	194	6
2	200	0
-1	12	188
-2	0	200

表3 虚焊-角落单块暗块图像属性控制情况
Table 3 Attribute control of false soldering-corner single dark block images

$\mathbf{a}$	右上存在暗块图像数量	右上不存在暗块图像数量
0	67	133
1	196	4
2	200	0
-1	15	185
-2	0	200

从表2与表3中可以看出,对于未经过属性控制的图像($\mathbf{a}=0$),正常无缺陷的EL图像右上角出现与不出现倒角的图像数量分别为96和104,虚焊-角落单块暗块EL图像左上角出现与不出现暗块图像的数量分别为67和133。对二者的向量分别加上属性控制向量后($\mathbf{a}=1$),出现对应的属性的图像相应增加,分别增加到194与196,当减去对应的属性控制向量后($\mathbf{a}=-1$),不出现对应的属性的图像分别增加到188与185。可以看出,虽然增加或减去属性控制向量($|\mathbf{a}|=1$)可以显著地控制生成的图像属性,但是仍然存在少量图像未受影响。当 $|\mathbf{a}|=2$ 时,所有图像都被属性控制向量所影响。因此,可以通过属性控制的方式批量生成满足某一特征的图像。采用上述方法,可以实现的属性控制如表4所示。

但在计算式(1)时所选取的 n_p 与 n_n 需足够多,以保证使用 n_p 与 n_n 生成的图像具有足够的多样性;否则计算出的属性控制向量 $\mathbf{v}$ 中可能附带其他属性,导致使用式(2)计算出的 n_c 生成的图像出现额外的属性。例如,计算控制右上倒角的向量 $\mathbf{v}$ 时所选取的 n_p 与 n_n 过少,在计算出 n_c 之后生成的图像均在同一位置出现额外的隐裂。

表4 可控制的图像属性
Table 4 Controllable image attributes

缺陷类型	可控制的图像属性
隐裂	线性隐裂 交叉状隐裂 倒角位置 倒角位置 倒角位置
断栅	/
破角	/
虚焊	平行主栅暗块 边缘条状暗块 角落单块暗块 倒角位置、暗块位置(位于某主栅处) 倒角位置、暗块位置(位于左或右) 倒角位置、暗块位置(位于四角)
正常无缺陷	/
	倒角位置

2.3 最终生成的图像

图6与图7分别为最终生成的EL图像与拍摄的EL图像。从图6与图7可以对比看出,生成的图像已经有较高的质量,甚至能够呈现部分细节,如主栅上的焊点。总体来说,目视感官上生成的EL图像与拍摄的EL图像十分接近。





图6 生成的EL图像
Fig. 6 Generated EL images






图7 拍摄的 EL 图像

Fig. 7 Captured EL images

2.4 图像相似度评估指标

为了量化评估生成的 EL 图像与拍摄的 EL 图像之间的相似度, 采用多尺度结构相似性 (multi-scale structural similarity, MS-SSIM) 指标对模型生成的图像进行评估, 同时将其与常见的图像相似度评估指标均方误差 (mean squared error, MSE) 与峰值信噪比 (peak signal to noise ration, PSNR) 进行对比。MSE 与 PSNR 的表达式如式(4)、式(5)所示:

$$I_{\text{MSE}} = \frac{1}{M \cdot N} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [I(i, j) - K(i, j)]^2 \quad (4)$$

$$I_{\text{PSNR}} = 10 \lg \left(\frac{255^2}{I_{\text{MSE}}} \right) \quad (5)$$

式中: M 为图像 I 的总像素点数量; N 为图像 K 的总像素点数量; i 和 j 分别表示图像的行数与列数; $I(i, j)$ 与 $K(i, j)$ 分别表示图像 I 和图像 K 在 i 行 j 列位置处的灰度值。MSE 越小, PSNR 越大则表明两幅图像越相近。

MS-SSIM 指标为结构相似性 (structural similarity index metric, SSIM) 指标的扩展形式, 且具有更好的稳定性。其通过亮度、对比度与结构 3 个方面对两幅图像的相似度进行评价, 值为 0~1 之间的数, 越接近 1 则表明两幅图像越相近。MS-SSIM 的表达式为^[16]

$$I_{\text{MS-SSIM}}(x, y) = \left[L_M(x, y)^{\alpha_M} \right] \prod_{j=1}^M [C_j(x, y)]^{\beta_j} [S_j(x, y)]^{\gamma_j} \quad (6)$$

式中: $I_{\text{MS-SSIM}}(x, y)$ 为 MS-SSIM 评估指标; $L_M(x, y)$ 为亮度对比因子; $C_j(x, y)$ 为对比度因子; $S_j(x, y)$ 为结构对比因子。

选取不同训练步数 (3000 步、15000 步、30000 步、45000 步、60000 步、75000 步、90000 步、105000 步、120000 步、135000 步、150000 步) 下的线性隐裂模型生成器, 在每个训练步数下生成 30 张线性隐裂 EL 图像, 将 30 张生成的图像与 30 张拍摄

的 EL 图像分别两两交叉计算 MSE、PSNR、MS-SSIM 指标。将计算结果取均值作为该步数下对应 MSE、PSNR、MS-SSIM 指标, 将 3 种指标分别与训练步数作曲线图, 结果如图 8 所示。




图8 MSE, PSNR, MS-SSIM 指标随训练步数变化曲线图

Fig. 8 Change curve of MSE, PSNR, MS-SSIM indexes with training steps

随着训练步数的增加, 生成器生成的图像与拍摄图像的相似度逐渐增加, 如图 4 所示, 主要体现在整体图像灰度逐渐均匀, 栅线、隐裂等细节逐渐清晰。而从图 8 中可以看出, 3 个选取的指标中只

有 MS-SSIM 指标随着训练步数呈现上升趋势, MSE 和 PSNR 指标不随训练步数的增加而呈现规律性的变化。因此, 相对来说, MS-SSIM 指标更加适合作为评估生成的 EL 图像与拍摄的 EL 图像相似度。

选取拍摄的 EL 图像与生成的 EL 图像各 30 幅, 通过两两交叉的方式计算 MS-SSIM, 并将所有计算所得的 MS-SSIM 取均值, 结果如表 5 所示。从表 5 中可以看出, 所有类型图像的 MS-SSIM 都高于 0.55, 各类型的 MS-SSIM 值大约分布在 0.55~0.71 之间, 且较多类型的图像 MS-SSIM 值在 0.7 附近。因此可以认为, 生成的 EL 图像与拍摄的 EL 图像具有较高的相似度。

表 5 生成的 EL 图像与拍摄的 EL 图像 MS-SSIM 值
Table 5 MS-SSIM values of generated EL images and captured EL images

图像类型	MS-SSIM
线性隐裂	0.6929
交叉状隐裂	0.6818
断栅	0.6960
破角	0.6917
虚焊-平行主栅暗块	0.5541
虚焊-边缘条状暗块	0.6636
虚焊-角落单块暗块	0.7122
正常无缺陷	0.7097

2.5 模型验证

本文建立一个分类模型对生成图像在降低过拟合方面的有效性进行验证。模型输入为 320 像素×160 像素×1 通道的灰度图像, 采用 5 层卷积+批量标准化层+最大池化层, 以进行特征提取。之后采用 2 层全连接层作为分类器, 输出层的尺度为 1×5, 即将电池片分为 5 类, 分别为正常、虚焊、隐裂、破角、断栅 5 种类型的电池片。模型结构示意图如图 9 所示。

一共进行 6 次训练, 所使用的训练集组成如表 6 所示。表 6 中, 所有组都采用 432 张拍摄图像作为测试集。第 1 组为对照组, 采用 500 张拍摄的图像作为训练集, 其中 5 种类型的电池片各 100 张, 在 2~6 组逐渐将生成图像加入训练集, 各种类型的电池片生成图像数量分别为 200 张、500 张、700 张、1000 张、1200 张。在模型收敛之后, 所有组

训练集准确率都超过 99%。图 10 为测试集准确率随训练集中生成图像数量变化曲线图, 从图 10 与表 6 中可以看出, 测试集准确率随着训练集中的生成图像数量增加而增加。第 1 组中, 由于没有采用生成图像进行数据增强, 训练集数量较少, 模型产生了过拟合, 测试集准确率只有 61.57%。第 2~6 组中, 随着生成图像的逐渐加入, 测试集准确率逐渐提升, 当生成图像数量增加到 6000 张时, 测试集准确率达到 97.92%。因此, 使用 DCGANs 模型生成 EL 图像并加入训练集是一种行之有效的数据增强方法, 能够改善半片光伏组件 EL 缺陷自动识别问题中训练数据不足而产生的过拟合的问题。

表 6 训练模型数据组成及结果
Table 6 Data composition and results of training model

训练编号	训练集组成	测试集组成	测试集准确率/%
1	拍摄图像500张	拍摄图像432张	61.57
2	拍摄图像500张+	拍摄图像432张	87.50
3	生成图像1000张 拍摄图像500张+	拍摄图像432张	94.21
4	生成图像2500张 拍摄图像500张+	拍摄图像432张	95.14
5	生成图像3500张 拍摄图像500张+	拍摄图像432张	96.53
6	生成图像5000张 拍摄图像500张+	拍摄图像432张	97.92
	生成图像6000张		




图 9 模型结构示意图
Fig. 9 Structure diagram of model




图 10 测试集准确率随训练集中生成图像数量变化曲线图

Fig. 10 Change curve of accuracy of test set with the number of generated images in training set

3 结论

本文提出了一种采用 DCGANs 生成光伏组件 EL 图像的方法, 实现了半片光伏组件 EL 图像的生成。得出以下结论: 1) 采用属性控制向量能够实现对生成 EL 图像属性的控制, 并且能够实现批量生成具有某一特征的图像; 2) 生成的 EL 图像与拍摄的 EL 图像相似度较高, 其不同缺陷类型的 MS-SSIM 指标范围在 0.55~0.71 之间, 并且大部分在 0.7 附近; 3) 生成的 EL 图像能够显著改善半片光伏组件 EL 缺陷自动识别问题中训练数据不足而产生的过拟合的问题, 在光伏组件电致发光缺陷自动识别验证模型的训练过程中, 测试集准确率随着训练集中生成 EL 图像的数量增加而增加, 当生成的图像达到 6000 张时, 测试集准确率为 97.92%; 4) 该方法能够在短时间内生成大量半片光伏组件 EL 图像, 相较于从大量拍摄的半片光伏组件 EL 图像中人工筛选训练所需的图像, 该方法在很大程度上提高了工作效率, 是一种高效经济且行之有效的数据增强方法。

参考文献:

- [1] 刘怀广, 刘安逸, 周诗洋, 等. 基于深度神经网络的太阳能电池组件缺陷检测算法研究[J]. 应用光学, 2020, 41(2): 327-336.
LIU Huaiguang, LIU Anyi, ZHOU Shiyang, et al. Research on detection algorithm of solar cell component defects based on deep neural network[J]. Journal of Applied Optics, 2020, 41(2): 327-336.
- [2] 周颖, 毛立, 张燕, 等. 改进 CNN 的太阳能电池缺陷识别方法研究[J]. 太阳能学报, 2020, 41(12): 69-76.
ZHOU Ying, MAO Li, ZHANG Yan, et al. Research on defect detection and classification for solar cells based on improved convolutional neural network[J]. Acta Energiae Solaris Sinica, 2020, 41(12): 69-76.
- [3] 刘怀广, 丁晚成, 黄千稳. 基于轻量化卷积神经网络的光伏电池片缺陷检测方法研究[J]. 应用光学, 2022, 43(1): 87-94.
LIU Huaiguang, DING Wancheng, HUANG Qianwen. Defects detection method of photovoltaic cells based on lightweight convolutional neural network[J]. Journal of Applied Optics, 2022, 43(1): 87-94.
- [4] 那峙雄, 樊涛, 孙涛, 等. 多损失融合的小样本光伏组件隐裂检测算法[J]. 计算机科学与探索, 2022, 16(2): 458-467.
NA Zhixiong, FAN Tao, SUN Tao, et al. Micro-cracks detection of solar cells based on few shot samples with multi-loss[J]. Journal of Frontiers of Computer Science & Technology, 2022, 16(2): 458-467.
- [5] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, Montreal, Dec 8-13, 2014. Cambridge: MIT Press, 2014: 2672-2680.
- [6] 丛晓峰, 章军, 胡强. 基于多尺度空洞卷积的对抗去雾网络[J]. 应用光学, 2020, 41(6): 1207-1213.
CONG Xiaofeng, ZHANG Jun, HU Qiang. Adversarial dehazing network based on multi-scale dilated convolution[J]. Journal of Applied Optics, 2020, 41(6): 1207-1213.
- [7] 徐英, 谷雨, 彭冬亮, 等. 基于 DRGAN 和支持向量机的合成孔径雷达图像目标识别[J]. 光学精密工程, 2020, 28(3): 727-735.
XU Ying, GU Yu, PENG Dongliang, et al. SAR ATR based on disentangled representation learning generative adversarial networks and support vector machine[J]. Optics and Precision Engineering, 2020, 28(3): 727-735.
- [8] 刘坤, 文熙, 黄闽茗, 等. 基于生成对抗网络的太阳能电池缺陷增强方法[J]. 浙江大学学报(工学版), 2020, 54(4): 684-693.
LIU Kun, WEN Xi, HUANG Minming, et al. Solar cell defect enhancement method based on generative adversarial network[J]. Journal of Zhejiang University (Engineering Science), 2020, 54(4): 684-693.
- [9] 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.

- ZHOU Ying, YE Hong, WANG Tong, et al. Photovoltaic module defect identification based on mul-scale convolution neural network[J]. *Acta Energiæ Solaris Sinica*, 2022, 43(2): 211-216.
- [10] 荣丹丹, 蒋京娜, 倪健雄, 等. 半片电池技术在光伏组件中的应用[J]. *新能源进展*, 2017, 5(4): 255-258.
- RONG Dandan, JIANG Jingna, NI Jianxiong, et al. Application of halved cells in PV module[J]. *Advances in New and Renewable Energy*, 2017, 5(4): 255-258.
- [11] 武朝磊, 刘志民, 韦德远, 等. 温度和辐照对半片与叠瓦光伏组件性能的影响[J]. *光学精密工程*, 2021, 29(8): 1782-1794.
- WU Chaolei, LIU Zhimin, WEI Deyuan, et al. Effects of ambient temperature and irradiance on performance of half-cut and shingled photovoltaic modules[J]. *Optics and Precision Engineering*, 2021, 29(8): 1782-1794.
- [12] 中国可再生能源学会光伏专业委员会. 2020年中国光伏技术发展报告——晶体硅太阳电池研究进展(9)[J]. *太阳能*, 2021(6): 5-10.
- China Photovoltaic Society. Report on 2020 China PV technology development—research progress of crystal-line silicon solar cells(part 9)[J]. *Solar Energy*, 2021(6): 5-10.
- [13] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络GAN综述[J]. *计算机科学与探索*, 2020, 14(1): 1-17.
- LIANG Junjie, WEI Jianjing, JIANG Zhengfeng. Generative adversarial networks GAN overview[J]. *Journal of Frontiers of Computer Science & Technology*, 2020, 14(1): 1-17.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// *International Conference on Medical Image Computing and Computer-assisted Intervention*. [S. l.]: [s. n.], 2015: 234-241.
- [15] RADFORD A, METZ L, CHINTALA S, et al. Unsupervised representation learning with deep convolutional generative adversarial networks[EB/OL]. (2022-05-10) [2016-01-17]. <https://arxiv.org/abs/1511.06434>.
- [16] WANG Z, SIMONCELLI E P, BOVIK A C. Multi-scale structural similarity for image quality assessment[C]// *Proceedings of the 37th IEEE Asilomar Conference on Signals, Systems, and Computers*, Pacific Grove, Nov 9-12, 2003. Piscataway: IEEE, 2003: 1398-1402.