

文章编号:1007-2780(2024)08-1057-13

基于 cycleGAN 的太阳电池电致发光 图像数据增强方法

何翔*, 杨爱军, 黎健生, 陈彩云, 游宏亮

(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;

福建省计量科学研究院 福建省能源计量重点实验室, 福建 福州 350003)

摘要:针对光伏组件电致发光缺陷自动识别研究中训练用图像不足以及生成图像质量不佳的问题,采用 cycleGAN 生成了太阳电池 EL 缺陷图像,并与 DCGAN 生成的图像进行了综合性对比。将拍摄到的 EL 图像进行分类和数据增强形成训练集。接着采用训练集对 cycleGAN 与 DCGAN 进行训练。最后,从生成图像的有效性、相似性和多样性 3 个角度对比了两个模型所生成的图像。实验结果表明, cycleGAN 所生成的图像中,有效图像的占比显著高于 DCGAN。与真实拍摄的图像相比, cycleGAN 所生成图像的感官相似性极高,难以通过人眼分辨。 cycleGAN 所生成图像的 FID 指标显著低于 DCGAN。采用 cycleGAN 生成图像训练的分类模型对真实拍摄图像的准确率达到 93.45%,当训练集中混入少量真实拍摄图像时,该准确率提升至 98.26%,显著高于 DCGAN。 cycleGAN 生成图像的平均 MS-SSIM 指标显著低于 DCGAN。采用 cycleGAN 进行太阳电池 EL 图像的数据增强是一种行之有效的方法,在有效性、相似性和多样性 3 方面显著优于 DCGAN。

关键词:光伏组件;太阳电池;电致发光; cycleGAN; DCGAN

中图分类号: TN206 **文献标识码:** A **doi:** 10.37188/CJLCD.2023-0234

Electroluminescence defect image augmentation method of solar cell based on cycleGAN

HE Xiang*, YANG Aijun, LI Jiansheng, CHEN Caiyun, YOU Hongliang

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

Fujian Key Laboratory of Energy Measurement, Fujian Metrology Institute, Fuzhou 350003, China)

Abstract: In order to solve the problems of insufficient training images and poor quality of generated images in the automatic recognition research of electroluminescence (EL) defects in photovoltaic modules, the solar cell EL defect images are generated by using the cycleGAN, and the generated images are compared with the images generated by the representative DCGAN. The captured EL images are classified and performed data augmentation to form a training set. Next, cycleGAN and DCGAN are trained using training set. Finally, a detailed comparison is made between the generated images of the two models from three perspectives: effectiveness, similarity and diversity. The experimental results show

收稿日期:2023-07-04;修订日期:2023-07-31.

基金项目:国家市场监督管理总局科技计划(No.2021MK050)

Supported by Science and Technology Plan of State Administration for Market Regulation of China
(No.2021MK050)

*通信联系人, E-mail: 315107763@qq.com

that the proportion of effective images generated by cycleGAN is significantly higher than that of images generated by DCGAN. Compared with captured EL images, the images generated by cycleGAN have extremely high sensory similarity, making it difficult to distinguish them through the human eye. The FID indicators of the images generated by cycleGAN are significantly lower than images generated by DCGAN. The classification model trained with images generated by cycleGAN achieves a 93.45% accuracy rate on the test set composed of captured EL images. When a small number of captured EL images are included in the training dataset, the accuracy is improved to 98.26%, significantly higher than that of DCGAN. Finally, the average MS-SSIM indicators of images generated by cycleGAN are significantly lower than that of DCGAN. The use of cycleGAN is an effective method for data augmentation of solar cell EL images, which is significantly superior to DCGAN in terms of effectiveness, similarity and diversity.

Key words: photovoltaics module; solar cells; electroluminescence; cycleGAN; DCGAN

1 引言

电致发光(Electroluminescence, EL)缺陷检测仪是光伏组件生成过程中不可获缺的测试设备之一(以下简称EL设备),其作用是能够发现光伏组件内部由于工艺不良、转运碰撞等各种原因导致的肉眼无法发现的缺陷,如隐裂、断栅和虚焊等,这些缺陷直接影响光伏组件的发电效率。EL设备的基本原理是通过给光伏组件两极通电,使其发出红外光,之后采用CCD相机或红外相机对光信号进行捕捉,通过计算机图像处理形成电致发光(EL)图像^[1]。光伏组件生产企业根据EL图像中缺陷数量及尺寸对光伏组件进行分级。

早期光伏企业采用人工识别EL图像中的各种缺陷。随着机器学习技术的发展,光伏组件EL缺陷的自动识别技术也随之得到了发展,大量光伏企业开始采用机器学习技术对光伏组件EL图像进行缺陷的自动或辅助识别。同时,大量研究也投入到了光伏组件EL缺陷的自动识别领域中。部分学者采用分类算法对带有缺陷的光伏组件进行分类,即采用图像处理算法将光伏组件EL图像中的太阳能电池EL图像进行切割,之后采用模型对太阳能电池EL图像进行分类。刘斌辉等人^[2]采用GoogLeNet实现了光伏组件EL缺陷图像的分类,同时与SVM方法进行比较,准确率达到88.7%。那峙雄等人^[3]提出了多损失融合的小样本光伏组件隐裂检测算法,对光伏组件EL隐裂图像进行分类识别,并且与VGG19、ResNet50等模型进行比较,其召回率较其他模型提高10%以上。也有学

者采用检测算法对光伏组件EL图像中的缺陷进行检测,即采用模型直接检测光伏组件的EL图像或太阳能电池EL图像中的缺陷区域。赵晓雨等人^[4]采用融合注意力机制的YOLOv5模型实现了光伏组件EL缺陷图像的自动识别,相比原版YOLOv5模型,准确率提高1.1%。

大部分光伏组件EL缺陷的自动识别研究需要用到数据集训练模型,数据集通常包含大量带有标识的太阳能电池EL缺陷图像。目前所采用的数据集主要有以下两种:一是公开的数据集^[5-6],二是由企业提供或自行采集的图像^[4,7-10]。然而,采用上述两种方法普遍存在的问题是数据量不足。同时,对于公开的数据集,其图像所对应的太阳能电池技术大多已经淘汰,训练的模型难以用于现有太阳能电池技术。而自行采集或企业提供的数据需要收集大量生产过程中拍摄的光伏组件EL图像,经过图像处理后(如纠偏、切割等),人工筛选出带有缺陷的太阳能电池EL图像。整个过程极其耗时耗力,效率低下。

针对训练数据量不足的问题,部分文献^[3-4,7-8,11]采用少量数据直接训练模型,其各缺陷类型的训练图像数量一般不超过1 000张。然而,过少的训练图像不具有代表性,训练模型所用的图像分布与实际应用中的图像分布可能存在差异,这将影响实际应用中模型的准确率。部分文献采用了数据增强的方式扩充数据集,主要采用的方式为小角度旋转^[6]、翻转^[3,6,9,12]、切割^[5,12]、亮度对比度调节^[6,9]及添加高斯噪声^[13]等。对于翻转与切割,虽然能够产生一定数量有效的

图像,但是产生的图像数量有限,无法从根本上解决缺少训练图像的问题。而采用小角度旋转、亮度对比度调节以及添加高斯噪声这3种方式所产生的图像与原图差异较小,对模型性能的提升有限。

随着生成对抗网络(Generative Adversarial Networks, GANs)的发展,采用GANs进行数据增强成为一种行之有效的方法。具体做法是采用少量的带有缺陷的EL图像对GANs进行训练,之后采用训练完成的GANs的生成器直接生成带有缺陷的EL图像,实现数据增强。目前已有文献采用GANs对太阳电池EL缺陷图像进行数据扩充^[12,14-17],但是目前文献中所采用的GANs都是“向量-图像”模式,即模型接收一维随机噪声作为输入并输出图像,所生成的太阳电池EL图像与真实拍摄的太阳电池EL图像尚有肉眼可分辨的差异,图像质量有待提高。

循环对抗生成网络(Cycle-Consistent Adversarial Networks, cycleGAN)自被提出以来得到了广泛的关注,其功能之一是实现图像的风格迁移。生产过程中拍摄的EL图像绝大多数为无缺陷的太阳电池EL图像,而带有缺陷的太阳电池EL图像只有极少数。与现有研究不同的是,本文采用cycleGAN将无缺陷的太阳电池EL图像进行风格迁移,形成带有缺陷的太阳电池EL图像,实现太阳电池EL缺陷图像的生成。同时,选取采用“向量-图像”模式以及具有代表性的模型DCGAN与之进行对比,将二者生成的图像在有效性、相似性和多样性3方面进行对比。

2 模型介绍

2.1 DCGAN

GANs于2014年由Goodfellow等人^[18]提出,其包含一个生成器和一个判别器。训练时,生成器接收随机噪声并生成数据,将带有标签的生成数据与真实数据输入到判别器中,根据判别器的输出结果对生成器和判别器的参数进行优化,直到生成器和判别器达到纳什均衡状态^[17],之后即可使用生成器生成所需的数据。

GANs的目标函数如式(1)所示, n 为满足 P_n 分布的随机噪声, x 为真实数据,生成器 G 通过优

化参数使生成数据 $G(n)$ 不断逼近真实数据 x ,即最小化 $E_{n \sim P_n(n)}[\log(1 - D(G(n)))]$ 项。判别器通过优化参数不断提高区分生成数据与真实数据的能力,即最大化 $E_{x \sim P_{\text{data}}(x)}[\log D(x)]$ 与 $E_{n \sim P_n(n)}[\log(1 - D(G(n)))]$ 项,与生成器形成对抗^[17]:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)}[\log D(x)] + E_{n \sim P_n(n)}[\log(1 - D(G(n)))] \quad (1)$$

由于GAN的训练过程不稳定,训练难度较大。Radford等人^[20]提出了深度卷积生成对抗网络(DCGAN),将GAN与卷积神经网络(Convolutional Neural Network, CNN)相结合,并通过取消池化层、采用批量标准化层(Batch Normalization, BN)等一系列优化,提升了训练的稳定性及生成结果的质量。DCGAN的结构已经成为目前为止生成对抗网络最重要的基本结构。

本文采用的DCGAN的生成器结构示意图如图1所示。其中生成器的输入为 300×1 的向量,向量中每个元素为满足高斯分布的随机值,取值范围为 $[0, 1]$ 。再经过连接全连接层+批量标准化层+ReLU激活函数层与重构层,使得输出为 $10 \times 5 \times 512$ 。之后通过一些系列反卷积层+批量标准化层+ReLU激活函数层,使得输出为 $320 \times 160 \times 16$,最终连接一个通道数为1的反卷积与Tanh激活函数层,使得输出为 $320 \times 160 \times 1$ 的灰度图像。

判别器结构示意图如图2所示,其输入为 $320 \times 160 \times 1$ 的灰度图像,通过一系列卷积层+




图1 DCGAN生成器结构示意图

Fig. 1 Structure diagram of DCGAN generator

LeakyReLU 激活函数层 + 权重丢失层使得图像降维到 10×5 , 之后通过 Flatten + 全连接层 + Sigmoid 激活函数层, 使得输出尺寸为 1。




图 2 DCGAN 判别器的结构示意图

Fig. 2 Structure diagram of DCGAN discriminator

对于每一种类型的缺陷, 训练一个 DCGAN。模型使用 Adam 优化器, 学习率在 $0.000\ 05 \sim 0.000\ 1$ 之间, 根据缺陷类型而异, 同时设置学习率衰减。对标签采用标签平滑操作, 对于生成的 EL 图像, 标签值为满足高斯分布的 $[0, 0.2]$ 范围内的随机数; 对于真实拍摄的 EL 图像, 标签值为满足高斯分布的 $[0.8, 1.2]$ 范围内的随机数。训练模型时, 间隔一定步数保存模型, 并采用生成器生成 EL 图像, 根据生成 EL 图像的相似性、多样性、有效性、目视感官 4 个维度对生成 EL 图像进行评估, 根据评估结果选取最优模型。

2.2 cycleGAN

cycleGAN 于 2017 年由 Jun-Yan Zhu^[21] 等人提出, 模型包含两个生成器与两个判别器, 通过加入循环一致损失函数和一致性损失函数实现无配对数据的领域迁移。模型的目标函数如式(2)所示:

$$G^*, F^* = \arg \min_{G, F} \max_{D_x, D_y} \mathcal{L}(G, F, D_x, D_y), \quad (2)$$

其中: $\mathcal{L}(G, F, D_x, D_y)$ 为模型的损失函数, 包含 4 个部分, 如式(3)所示, 其中 $\mathcal{L}_{\text{GAN}}(G, D_y, X, Y)$ 与 $\mathcal{L}_{\text{GAN}}(F, D_x, X, Y)$ 分别为两个生成器 G 和 F 的生成对抗损失函数, 表达式如式(4)和式(5)所示, 其目的与 GAN 的损失函数相同, 在于使两个生成器能够生成逼真的图像。 $\mathcal{L}_{\text{cyc}}(G, F)$ 为循环一致损失函数, 表达式如式(6)所示, 其目的在于

建立输出与输入图像之间的循环一致对应关系。 $\mathcal{L}_{\text{identity}}(G, F)$ 为一致性损失函数, 表达式如式(7)所示, 其目的在于约束生成器使其保留更多的原图像颜色方面信息。

$$\mathcal{L}(G, F, D_x, D_y) = \mathcal{L}_{\text{GAN}}(G, D_y, X, Y) + \mathcal{L}_{\text{GAN}}(F, D_x, X, Y) + \lambda_{\text{cyc}} \mathcal{L}_{\text{cyc}}(G, F) + \lambda_{\text{identity}} \mathcal{L}_{\text{identity}}(G, F), \quad (3)$$

$$\mathcal{L}_{\text{GAN}}(G, D_y, X, Y) = \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log D_y(y)] + \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log (1 - D_y(G(x)))], \quad (4)$$

$$\mathcal{L}_{\text{GAN}}(F, D_x, X, Y) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D_x(x)] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log (1 - D_x(F(y)))], \quad (5)$$

$$\mathcal{L}_{\text{cyc}}(G, F) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [\|G(F(y)) - y\|_1], \quad (6)$$

$$\mathcal{L}_{\text{identity}}(G, F) = \mathbb{E}_{y \sim p_{\text{data}}(y)} [\|G(y) - y\|_1] + \mathbb{E}_{x \sim p_{\text{data}}(x)} [\|F(x) - x\|_1]. \quad (7)$$

生成器的目标在于最小化循环一致损失函数、一致性损失函数以及对抗损失函数中的 $\mathbb{E}_{x \sim p_{\text{data}}(x)} [\log (1 - D_y(G(x)))]$ 与 $\mathbb{E}_{y \sim p_{\text{data}}(y)} [\log (1 - D_x(F(y)))]$ 项。判别器的目标在于最大化对抗损失函数中的 $\mathbb{E}_{y \sim p_{\text{data}}(y)} [\log D_y(y)]$ 与 $\mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D_x(x)]$ 项, 以此二者形成对抗。当训练达到纳什平衡后, 即可使用生成器实现 x 领域到 y 领域 (或 y 领域到 x 领域) 的风格迁移。

本文的生成器采用 Unet 结构, 如图 3 所示。输入为 $320 \times 160 \times 1$ 的灰度图, 之后连续经过 4 次 Conv2D 层 + LeakyReLU 激活函数层 + Instance Normalization 层对图像进行下采样, 以此对图像进行降维。连续经过 3 次 UpSampling2D 层 + Conv2D 层 + LeakyReLU 激活函数层 + Instance Normalization 层进行上采样, 最终输出图像尺寸与输入图像尺寸一致。上下采样过程中输出尺寸相同的 Instance Normalization 层进行连接。其中, Instance Normalization 层采用式(8)~式(10)^[22] 计算:

$$y_{ijk} = \frac{x_{ijk} - \mu_{ii}}{\sqrt{\sigma_{ii}^2 + \epsilon}}, \quad (8)$$

$$\mu_{ti} = \frac{1}{HW} \sum_{l=1}^W \sum_{m=1}^H x_{tilm}, \quad (9)$$

$$\sigma_{ti}^2 = \frac{1}{HW} \sum_{l=1}^W \sum_{m=1}^H (x_{tilm} - \mu_{ti})^2, \quad (10)$$

式中: t 为图像索引, i 为特征图像索引, l 与 m 分别

为图像在高度与宽度方向的像素点索引, H 与 W 分别为图像的高度与宽度, x_{ijk} 为图像 t 在归一化前特征图像 i 第 k 行 j 列的图像灰度值, y_{ijk} 为归一化后 x_{ijk} 对应的灰度值, ϵ 是一个很小的数, 作用是防止分母为 0 导致数学上的错误。




图 3 cycleGAN 生成器的结构示意图

Fig. 3 Structure diagram of cycleGAN generator

判别器用 PatchGAN 结构^[21], 其结构示意图如图 4 所示。输入为 $320 \times 160 \times 1$ 的灰度图, 之后连续经过 4 次 Conv2D 层 + LeakyReLU 激活函数层 + Instance Normalization 层对图像进行下采

样, 最终输出图像尺寸为 $20 \times 10 \times 1$ 。

对于每一种类型的缺陷, 训练一个 cycleGAN。模型使用 Adam 优化器, 学习率在 0.000 2~0.000 5 之间, 根据缺陷类型而异, 同时设置学习率衰减。训练模型时, 间隔一定步数保存图像并采用生成器生成图像, 根据相似性、多样性、有效性和目视感官 4 个维度对生成的图像进行评估, 根据评估结果选取最优模型。

2.3 训练数据

本文选取五栅半片光伏组件 EL 缺陷图像作为研究对象。首先将拍摄的光伏组件 EL 图像中的所有太阳能电池 EL 图像切割分离, 之后通过人工筛选的方式找出包含缺陷的图像并进行分类, 一共获得 4 种类型的太阳能电池 EL 缺陷图像: 隐裂、断栅、破角、虚焊。将每一张图像进行以下操作实现数据增强: 沿水平方向翻转、沿垂直方向翻转、旋转 180° 。为了降低模型的训练难度, 将隐裂的图像进一步细分为含有线性隐裂、交叉状隐裂的图像。对于 DCGAN, 将含有虚焊的图像




图 4 cycleGAN 判别器结构示意图

Fig. 4 Structure diagram of cycleGAN discriminator

进一步细分为含有平行主栅暗块、边缘条状暗块、角落单块暗块的 3 种类型图像。训练集分类及数量组成如表 1 所示。

表 1 训练样本的具体类型与数量
Tab. 1 Type and quantity of training samples

缺陷	类型	DCGAN 训练 用样本数量	cycleGAN 训练 用样本数量
隐裂	线性隐裂	1 548	1 548
	交叉状裂	912	912
断栅		1 380	1 380
破角		528	528
	平行主栅暗块	776	
虚焊	边缘条状暗块	508	1 828
	角落单块暗块	544	

3 图像评估

3.1 生成图像的有效性评估

生成图像的有效性指的是生成的 EL 图像中可以直接用于数据增强的 EL 图像的占比。在模型训练完成后,并非所有生成器生成的 EL 图像都能直接用于数据增强,原因在于生成的图像中还存在着一些无效的 EL 图像,如图像无缺陷、缺陷部分模糊和缺陷形状异常等。在实际数据增强的过程中,通常需要对生成的 EL 图像再次进行人工筛选,选取有效的图像加入训练集。生成图像的有效性过低将会增加人工筛选的时间。

为了对比 cycleGAN 和 DCGAN 生成 EL 图像的有效性,选取训练完成的 cycleGAN 和 DCGAN 模型,各缺陷类型分别生成 1 000 张 EL 图像,统计生成 EL 图像中有效图像的占比,结果如表 2 所示。从表 2 可以看出,有效图像占比因缺陷类型不同而不同,虚焊和破角的有效图像占比较高,而隐裂与断栅占比较低。同时,对于 4 种类型的缺陷,cycleGAN 所生成的图像中有效图像的占比都高于 DCGAN。因此,在生成图像有效性方面,cycleGAN 显著优于 DCGAN。

DCGAN 的生成器通过将一维随机噪声经过多次上采样形成图像。根据文献[20],对随机噪声在某个方向上进行连续变化,所生成的图像在某些特征方面会发生连续的改变。如图 5 所

表 2 有效生成图像的占比
Tab. 2 Proportion of effectively generated images %

模型	虚焊	隐裂	破角	断栅
cycleGAN	98.8	83.9	92.5	77.6
DCGAN	72.7	57.7	81.1	57.6

示,EL 缺陷图像的生成必然存在某些方向,使得一维随机噪声在这些方向上连续变化时,其生成图像的缺陷部分由模糊到清晰连续变化。同时存在一定的区间,使得当一维噪声落在该区间时,生成的 EL 图像无缺陷或者缺陷模糊。而大量生成一维噪声时,数据的随机性导致很大一部分一维噪声落在无缺陷或缺陷模糊区间内,使模型生成无效的 EL 图像。




图 5 生成图像随一维噪声的变化示意图
Fig. 5 Schematic diagram of the variation of generated images with noise

cycleGAN 由于其输入是真实拍摄的 EL 图像,所以不存在上述现象。其生成无效 EL 图像的原因主要为生成 EL 图像时,输入 EL 图像的分布与训练用 EL 图像分布存在差异。由于输入 EL 图像与训练用 EL 图像都来自于真实拍摄的 EL 图像,二者的分布差异较小。因此,cycleGAN 所生成图像的有效性显著优于 DCGAN 所生成的图像。

3.2 生成图像的相似性评估

生成图像的相似性指的是生成的 EL 图像与真实拍摄的 EL 图像之间的相似程度。本文从生成图像的感官质量、FID 指标以及分类模型验证 3 个角度评估生产图像的相似性。

3.2.1 生成图像感官质量

图 6 为 cycleGAN 和 DCGAN 生成的典型缺陷图像及真实拍摄的图像,从图 6 可以看出,cycleGAN 和 DCGAN 都能够生成相似性较高的

太阳能电池EL缺陷图像,两种模型生成的EL图像都很好地还原了太阳能电池的基本特征。从目视感官上看,cycleGAN生成的EL图像质量极高,相比真实拍摄的EL图像,难以通过人眼分辨。而DCGAN所生成的EL图像质量略低,主要体现在太阳能电池无缺陷区域的目视感官存在“脏污感”与“粗糙感”。在目前采用GANs对太阳能电池EL缺陷图像进行数据增强的研究中^[12,14-17],这种现象普遍存在。

DCGAN生成图像的“脏污感”与“粗糙感”可以通过图像的灰度梯度进行量化。采用DC-




图6 典型的生成图像与拍摄图像。(a)隐裂(真实拍摄);(b)断栅(真实拍摄);(c)破角(真实拍摄);(d)虚焊(真实拍摄);(e)隐裂(DCGAN);(f)断栅(DCGAN);(g)破角(DCGAN);(h)虚焊(DCGAN);(i)隐裂(cycleGAN);(j)断栅(cycleGAN);(k)破角(cycleGAN);(l)虚焊(cycleGAN)。

Fig. 6 Typical generated and captured images. (a) Cracks (real); (b) Grid failure(real); (c) Fragments(real); (d) False soldering(real); (e) Cracks(DCGAN); (f) Grid failure (DCGAN); (g) Fragments (DCGAN); (h) False soldering(DCGAN); (i) Cracks (cycleGAN); (j) Grid failure (cycleGAN); (k) Fragments(cycleGAN); (l) False soldering(cycleGAN).

GAN和cycleGAN对不同类型的缺陷各生成2000张EL图像,每张EL图像采用sobel算子计算图像灰度梯度,统计同一缺陷类型下cycleGAN和DCGAN所生成的所有EL图像的灰度梯度幅值。由于栅线及缺陷附近的灰度梯度较大,为了避开这些区域,统计过程中剔除灰度梯度大于75的数据。结果如图7所示,从图7可以看出,对于所有类型的EL图像,DCGAN所生成的EL图像在低灰度梯度(0~15)的统计数量少于cycleGAN所生成的EL图像,而高灰度梯度(15~50)的数量多于cycleGAN所生成的EL图像。因此,可以认为cycleGAN所生成的EL图像在无缺陷区域的灰度梯度较DCGAN所生成的EL图像偏低。因此,EL图像的目视感官更加“干净整洁”,整体灰度变化更加“光滑”,并且与真实拍摄的EL图像更加相似。

3.2.2 FID评价指标

本节选取FID(Fréchet Inception Distance)指标对cycleGAN和DCGAN生成的EL图像相似性进行量化评估。FID指标由Martin Heusel等人于2017年提出^[23],其原理是通过将生成图像集合与真实图像集合分别采用Inception-v3进行预测,取Inception-v3最后一层池化层作为输出,采用式(11)计算FID指标:

$$d^2((m, C), (m_w, C_w)) = \|m - m_w\|_2^2 + \text{Tr}(C + C_w - 2(CC_w)^{1/2}), \quad (11)$$

式中: m 为真实图像集合输出结果的均值, C 为真实图像集合输出结果的协方差矩阵, m_w 为生成图像集合输出结果的均值, C_w 为生成图像集合输出结果的协方差矩阵,Tr为矩阵的迹。FID指标越小,表明生成图像集合于真实图像集合越相似。

通常情况下,为了准确评估生成器生成的EL图像与真实拍摄的EL图像之间的FID指标,需要使用生成器生成足够数量的EL图像,具体数量视情况而定。本文采用动态生成图像的数量确定FID指标。首先,采用生成器生成2000张EL图像,计算这2000张EL图像与训练集图像(真实拍摄的EL图像)之间的FID指标,之后依次递增2000张生成EL图像并不断重复上述步骤。当生成的EL图像数量超过10000张之后,连续3个相邻FID指标差值小于5时停止计算,取最后3




图 7 生成图像的灰度梯度分布。(a)虚焊;(b)隐裂;(c)破角;(d)断栅。

Fig. 7 Grayscale gradient distribution of generated images. (a) False soldering; (b) Cracks; (c) Fragments; (d) Grid failure.

次FID指标的均值作为该生成器的FID评价指标。图 8 为不同缺陷类型的 cycleGAN 和 DCGAN 所生成 EL 图像的 FID 指标与图像数量的关系曲线,表 3 为不同缺陷类型的 cycleGAN 和

DCGAN 所生成的 EL 图像的最终计算 FID 指标。从图 8 与表 3 可以看出,对于 4 种缺陷类型, cycleGAN 生成的 EL 图像对应的 FID 指标都显著小于 DCGAN 生成的 EL 图像的 FID 指标。




图 8 FID 曲线图。(a)虚焊;(b)隐裂;(c)破角;(d)断栅。

Fig. 8 FID curves. (a) False soldering; (b) Cracks; (c) Fragments; (d) Grid failure.

可以认为,在生成 EL 图像与真实拍摄 EL 图像的相似性上,cycleGAN 明显优于 DCGAN。

表 3 FID 指标

Tab. 3 FID indicators

缺陷类型	cycleGAN	DCGAN
虚焊	156	375
隐裂	142	366
破角	292	474
断栅	144	292

3.2.3 分类模型验证

通过建立一个分类模型对比 cycleGAN 和 DCGAN 所生成的 EL 图像在实际数据增强应用中的效果。模型结构如图 9 所示,模型实现的功能是将输入的带有缺陷的 EL 图像进行分类。分类结果包含 4 种,分别为虚焊、隐裂、破角和断栅。选取经过筛选有效的生成的 EL 图像作为训练集,包含 32 000 张 EL 图像,其中 4 种缺陷类型各




图 9 分类模型的结构示意图

Fig. 9 Structure diagram of classification model

8 000 张 EL 图像。另外选择少量有效生成的 EL 图像作为测试集 1,包含 400 张 EL 图像,4 种缺陷类型各 100 张。选择所有真实拍摄的 EL 图像作为测试集 2,共 6 196 张 EL 图像。数据组成如表 4 所示。

表 4 模型训练所用的数据组成

Tab. 4 Composition of data used for model training

模型	训练集	测试集 1	测试集 2
cycleGAN	32 000 张(每种缺陷类型 8 000 张)	400 张(每种缺陷类型 100 张)	6 196 张(缺陷类型分布如表 1 所示)
DCGAN	32 000 张(每种缺陷类型 8 000 张)	400 张(每种缺陷类型 100 张)	6 196 张(缺陷类型分布如表 1 所示)

训练完成后,计算各集合的准确率,结果如表 5 所示。从表 5 可以看出,对于采用 cycleGAN 和 DCGAN 所生成的 EL 图像训练的分类模型,其最终训练集的准确率都达到 99.99%。测试集 1 的准确率与训练集准确率较为接近,分别达到 99.50% 和 99.75%;而测试集 2 的准确率略低,分别为 93.45% 和 92.50%。由于测试集 1 与训练集都来自于生成的 EL 图像,可以认为二者具有相同的分布。对于两个分类模型,测试集 1 的准确率与训练集的准确率相差仅为 0.49% 和 0.24%,可以认为两个分类模型在相同分布的图像上都具有较强的泛化能力。由于测试集 2 来自于真实拍摄的 EL 图像,因此测试集 2 与训练集之间的准确率差异来源于真实拍摄的 EL 图像与生成 EL 图像之间的分布差异。对于两个分类模型,该差值分别为 6.54% 和 7.49%,可以认为 cycleGAN 和 DCGAN 所生成

的 EL 图像与真实拍摄的 EL 图像都存在一定的分布差异,但是 cycleGAN 所生成的 EL 图像分布差异小于 DCGAN。

表 5 模型的准确率

Tab. 5 Accuracies of model

模型	训练集	测试集 1	测试集 2
cycleGAN	99.99	99.50	93.45
DCGAN	99.99	99.75	92.50

然而,在实际使用生成的 EL 图像进行数据增强时,通常不会将生成的图像单独作为训练集,而是将生成的 EL 图像与真实拍摄的 EL 图像混合形成训练集。为了模拟真实的使用场景,从测试集 2 中选取 400 张真实拍摄的 EL 图像(4 类缺陷各 100 张)放入训练集中,其余的图像作为测试集 3。训练结果如表 6 所示。从表 6 可以看出,在训练

集中加入真实拍摄的 EL 图像后,两种分类模型的测试集 3 的准确率相较于测试集 2 都得到大幅提升,采用 cycleGAN 所生成的 EL 图像训练的分类模型测试集准确率相对略高。可以认为,实际应用中,在只有少量真实拍摄的 EL 图像时,采用 cycleGAN 所生成的图像进行数据增强的效果优于采用 DCGAN 所生成的图像。

表 6 模型的准确率

Tab. 6 Accuracies of model		%
模型	训练集	测试集 3
cycleGAN	99.99	98.26
DCGAN	99.99	98.08

虽然 cycleGAN 和 DCGAN 所生成的 EL 图像都与真实拍摄的 EL 图像存在一定的分布差异,但是 cycleGAN 所生成的 EL 图像的分布差异相对较小。在实际应用中,采用 cycleGAN 所生成的 EL 图像进行数据增强效果更好。

综合来说,在与真实拍摄 EL 图像之间的相似性方面,cycleGAN 优于 DCGAN。产生这种现象的主要原因是,DCGAN 的生成器是“向量-图像”模式,即输入为一维随机向量,采用一系列上采样最终形成输出图像,仅通过生成对抗损失函数优化模型参数。而 cycleGAN 的生成器是“图像-图像”模式,其输入为真实拍摄的无缺陷 EL 图像,输出是带有缺陷的 EL 图像,不仅通过生成对抗损失函数优化模型参数,还通过循环一致损失函数和一致性损失函数使得输出图像尽可能地保留了输入图像中的信息,其生成器生成图像的难度远远低于 DCGAN。因此,cycleGAN 所生成的 EL 图像在相似性方面显著优于 DCGAN。

3.3 生成图像多样性评估

生成图像的多样性主要指生成的 EL 图像在缺陷形貌、缺陷亮度以及太阳能电池片整体亮度等方面的多样性。生成图像的多样性直接影响数据增强的效果与分类模型的性能。本文采用 MS-SSIM 指标评估 cycleGAN 和 DCGAN 生成的 EL 图像的多样性。MS-SSIM 指标通过亮度、对比度、结构 3 个方面对两幅图像之间的相似性进行评价,其值在 0~1 之间,越接近 1 表明两张图像相似性越高。MS-SSIM 的表达式如式 (12) 所示^[24]:

$$MSSSIM(x,y)=$$

$$[L_M(x,y)]^{\alpha} \prod_{j=1}^M [C_j(x,y)]^{\beta} [S_j(x,y)]^{\gamma}, \quad (12)$$

其中: $L_M(x,y)$ 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。首先对每一种类型的缺陷建立 3 个图像集,分别是由 cycleGAN 和 DCGAN 生成图像组成的图像集以及真实拍摄的图像组成的图像集。cycleGAN 和 DCGAN 生成图像集中图像的数量为 FID 指标达到稳定时所对应的图像数量,真实拍摄图像集中图像的数量与表 1 相同。各生成图像集中具体图像数量如表 7 所示。

表 7 各生成图像集中的图像数量

Tab. 7 Number of images in each generated image set			
缺陷类型	cycleGAN 图像/张	DCGAN 图像/张	真实拍摄 图像/张
虚焊	18 000	16 000	2 460
隐裂	16 000	16 000	1 380
破角	16 000	16 000	528
断栅	14 000	30 000	1 828

通过在各个图像集中进行多次取样计算 MS-SSIM,以多次取样计算的 MS-SSIM 均值作为评估图像集的多样性指标。然而,由于随机因素的影响,取样次数过少无法准确评估生成图像集的多样性。因此,本文通过动态增加取样次数的方法获得稳定的 MS-SSIM 指标:初始取样次数为 200,每次取样时,从图像集中随机选取两张图像计算 MS-SSIM 指标,直到达到本轮的取样次数时停止取样,并计算本轮的平均 MS-SSIM 值。之后进入下一轮计算并增加取样次数,如此反复。当连续 3 次相邻两轮计算的平均 MS-SSIM 差值小于 0.000 5 时,停止计算,取最后 3 轮计算的 MS-SSIM 均值作为该图像集的多样性评价指标。图 10 为各图像集的平均 MS-SSIM 指标与取样次数曲线图,表 8 为各图像集的多样性评估指标。从图 10 和表 8 可以看出,当取样次数较少时,所有曲线的平均 MS-SSIM 指标震荡明显;随着取样次数的增加,平均 MS-SSIM 指标趋于稳定。同时,对于所有类型的 EL 缺陷图像,cycleGAN 和 DCGAN 生成图像集的平均 MS-SSIM 都高于真实拍摄图像集的平均 MS-SSIM,并且 cycleGAN 生成图像集的平均 MS-SSIM 显著低




图 10 MS-SSIM 曲线图。(a)虚焊;(b)隐裂;(c)破角;(d)断栅。

Fig. 10 MS-SSIM curves. (a) False soldering; (b) Cracks; (c) Fragments; (d) Grid failure.

表 8 MS-SSIM 指标

Tab. 8 MS-SSIM indicators

缺陷类型	cycleGAN	DCGAN	真实拍摄
虚焊	0.659 4	0.729 4	0.613 2
隐裂	0.684 5	0.776 2	0.619 0
破角	0.641 7	0.783 0	0.633 5
断栅	0.667 2	0.805 2	0.631 9

于 DCGAN 生成图像集的平均 MS-SSIM。可以认为,两种模型生成的 EL 图像多样性都低于真实拍摄的 EL 图像,但是由于 cycleGAN 生成的 EL 图像与真实拍摄的 EL 图像更加相似,其多样性也与真实拍摄的 EL 图像更加接近,因此, cycleGAN 生成图像的多样性显著优于 DCGAN。

4 结 论

本文针对光伏组件 EL 自动识别研究中缺乏足够的训练图像以及生成图像质量不佳的问题,采用 cycleGAN 生成了太阳电池 EL 图像,实现了对太阳电池 EL 图像的数据增强。同时选取具有

代表性的 DCGAN 进行对比,从生成图像的有效性、相似性、多样性 3 个角度详细对比了两个模型所生成 EL 图像。得出以下结论:

(1)对于 cycleGAN 和 DCGAN,不同的缺陷类型生成图像的有效性存在差异,虚焊和破角的生成图像有效性较高,而隐裂与断栅生成图像的有效性较低。总体来说,在生成图像的有效性方面, cycleGAN 显著优于 DCGAN。

(2)与真实拍摄的 EL 图像相比, DCGAN 所生成的 EL 图像存在肉眼可分辨的差异,主要差异在于感官上图像存在“脏污感”和“粗糙感”,具体体现在太阳电池 EL 图像中无缺陷区域的灰度梯度整体偏高,并且现有的同类研究所生成的太阳电池 EL 图像普遍存在这种现象。而 cycleGAN 所生成的 EL 图像不存在这种现象,并且相较于真实拍摄的 EL 图像,其感官相似性极高,难以通过人眼分辨生成的 EL 图像与真实拍摄的 EL 图像。

(3)对于虚焊、隐裂、破角、断栅 4 种类型的缺陷, cycleGAN 所生成的 EL 图像与真实拍摄的

EL 图像之间的 FID 指标都显著低于 DCGAN,即在 FID 指标方面,cycleGAN 所生成的 EL 图像相似性更高。

(4)使用 cycleGAN 和 DCGAN 所生成的 EL 图像训练分类模型,当训练集中只有生成的 EL 图像时,分类模型对于与训练集同分布的 EL 图像具有很强的泛化能力,而对于不同分布的 EL 图像(真实拍摄的 EL 图像)泛化能力有所下降,即 cycleGAN 和 DCGAN 生成的 EL 图像都与真实拍摄的 EL 图像存在分布差异,但是 cycleGAN 的分

布差异更小。当训练集中混入真实拍摄的 EL 图像时,两个分类模型对于真实拍摄的 EL 图像组成的测试集准确率显著提升,并且采用 cycleGAN 所生成 EL 图像训练的分类模型的准确率更高。总体来说,cycleGAN 的实际应用效果更加显著。

(5)对于虚焊、隐裂、破角和断栅 4 种类型的缺陷,cycleGAN 所生成的 EL 图像的 MS-SSIM 指标显著低于 DCGAN,更接近于真实拍摄图像的 MS-SSIM 指标。即 cycleGAN 所生成的 EL 图像的多样性显著优于 DCGAN。

参 考 文 献:

- [1] 林剑春,杨爱军,沈熠辉. 电致发光缺陷检测仪的成像性能评估[J]. 光学精密工程,2017,25(6):1418-1424.
LIN J C, YANG A J, SHEN Y H. Evaluation of imaging performance for electroluminescence defect detector [J]. *Optics and Precision Engineering*, 2017,25(6):1418-1424. (in Chinese)
- [2] 刘斌辉,黄璇,杨强荣,等. 基于 GoogLeNet 与 EL 的光伏电池缺陷检测技术研究[J]. 电子产品可靠性与环境试验,2019(0):150-155.
LIU B H, HUANG X, YANG Q R, *et al.* Research on defect detection technology of photovoltaic cells based on GoogLeNet and EL [J]. *Electronic Product Reliability and Environmental Testing*, 2019(0):150-155. (in Chinese)
- [3] 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 Z X, FAN T, SU T, *et al.* Micro-cracks detection of solar cells based on few shot samples with multi-loss [J]. *Journal of Frontiers of Computer Science and Technology*, 2022,16(2):458-467. (in Chinese)
- [4] 赵晓雨,高林,杨校李,等. 融合注意力机制的 YOLOv5 光伏板电致发光图像缺陷检测算法[J]. 湖北民族大学学报(自然科学版),2023,41(1):65-70.
ZHAO X Y, GAO L, YANNG X L, *et al.* Algorithm of YOLOv5 fusing attention mechanism for defect detection of photovoltaic panel electroluminescent image [J]. *Journal of Hubei Minzu University(Natural Science Edition)*, 2023,41(1):65-70. (in Chinese)
- [5] 沈凌云,张洁,孙甲云,等. 基于改进 Alexnet 模型的光伏电池片瑕疵分类方法[J]. 自动化与信息工程,2022,43(4):42-47.
SHEN L Y, ZHANG J, SUN J Y, *et al.* Defect classification method of photovoltaic cells based on Improved alexnet model [J]. *Automation & Information Engineering*, 2022,43(4):42-47. (in Chinese)
- [6] 周建凯,许盛之,赵二刚,等. 基于深度学习的电池片缺陷识别研究[J]. 电子技术应用,2019,45(5):66-69,77.
ZHOU J K, XU S Z, ZHAO E G, *et al.* Cell defect recognition based on deep learning [J]. *Application of Electronic Technique*, 2019,45(5):66-69,77. (in Chinese)
- [7] 吴涛,赖菲. 基于 LeNet-5 模型的太阳能电池板缺陷识别分类[J]. 热力发电,2019,48(3):120-125.
WU T, LAI F. Identification and classification of defects in solar cells based on LeNet-5 model [J]. *Thermal Power Generation*, 2019,45(5):66-69,77. (in Chinese)
- [8] 沈凌云,朱明,陈小云. 基于径向基神经网络的太阳能电池缺陷检测[J]. 发光学报,2015,36(1):99-105.
SHEN L Y, CHEN X Y. Solar panels defect detection based on radial basis function neural network [J]. *Chinese Journal of Luminescence*, 2015,36(1):99-105. (in Chinese)
- [9] 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 H G, DING W C, HUANG. Defects detection method of photovoltaic cells based on lightweight convolutional neural network [J]. *Journal of Applied Optics*, 2022,43(1):87-94. (in Chinese)
- [10] 墨恺,徐林. 基于阈值均匀局部二值模式和 BP 神经网络的太阳能电池缺陷检测算法[J]. 太阳能学报,2014,35(12):2448-2454.
MO K, XU L. Defect detection of solar cell based on threshold uniform bp and bp neural network [J]. *Acta Energiae Solaris Sinica*, 2014,35(12):2448-2454. (in Chinese)
- [11] 陈海永,赵鹏,闫皓炜. 融合注意力的多尺度 Faster RCNN 的裂纹检测[J]. 光电工程,2021,48(1):61-71.

- CHEN H Y, ZHAO P, YAN H W. Crack detection based on multi-scale Faster RCNN with attention[J]. *Opto-Electronic Engineering*, 2014, 35(12): 2448-2454. (in Chinese)
- [12] 文熙. 基于生成对抗网络的太阳能电池缺陷数据增强与缺陷检测[D]. 河北:河北工业大学, 2020.
WEN X. Data augmentation and defect detection of solar cells based on generative adversarial network[D]. Hebei University of Technology, 2020. (in Chinese)
- [13] 周颖, 毛立, 张燕, 等. 改进CNN的太阳电池缺陷识别方法研究[J]. 太阳能学报, 2020, 41(12): 69-76.
ZHOU Y, MAO L, ZHANG Y, *et al.* Research on defect detection and classification for solar cells based on improved convolutional neural network [J]. *Acta Energiæ Solaris Sinica*, 2020, 41(12): 69-76. (in Chinese)
- [14] 张一平, 许盛之, 孟子尧, 等. 基于FC-ACGAN网络的太阳电池EL图像的数据增强方法[J]. 太阳能学报, 2021, 42(10): 35-41.
ZHANG Y P, XU S Z, MENG Z Y, *et al.* Data enhancement method of solar cell el image based on FC-ACGAN network [J]. *Acta Energiæ Solaris Sinica*, 2021, 42(10): 35-41. (in Chinese)
- [15] 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 Y, YE H, WANG T, *et al.* Photovoltaic module defect identification based on mulit-scale convolution neural network [J]. *Acta Energiæ Solaris Sinica*, 2022, 43(2): 211-216. (in Chinese)
- [16] 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 K, WEN X, HUANG M M, *et al.* Solar cell defect enhancement method based on generative adversarial network [J]. *Journal of Zhejiang University (Engineering Science)*, 2020, 54(4): 684-693. (in Chinese)
- [17] 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.
HE X. Electroluminescence image enhancement technology of half-cut photovoltaic module based on DCGANsP [J]. *Journal of Applied Optics*, 2023, 44(2): 314-322. (in Chinese)
- [18] 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, Cambridge: MIT Press, 2014: 2672-2680.
- [19] 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 J J, WEI J J, JIANG Z F. Generative adversarial networks GAN overview [J], *Journal of Frontiers of Computer Science & Technology*, 2020, 14(1): 1-17. (in Chinese)
- [20] RADFORD A, METZ L, CHINTALA S, *et al.* Unsupervised representation learning with deep convolutional generative adversarial networks [J/OL]. *arXiv*, 2015: 1511.06434.
- [21] ZHU J Y, PARK T, ISOLA P, *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. 2017 IEEE International Conference on Computer Vision 2017, Venice, Italy, 2017: 2242-2251.
- [22] ULYANOV D, VEDALDI A, LEMPITSKY V, *et al.* Instance normalization: the missing ingredient for fast stylization [J/OL]. *ArXiv*, 2016: 1607.08022.
- [23] HEUSEL M, RAMSAUER H, UNTERTHINER T, *et al.* GANs trained by a two time-scale update rule converge to a local NASH equilibrium [C]. *Advances in Neural Information Processing Systems 2017*. Long Beach, California USA: NIPS, 2017: 6626-6637.
- [24] 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, CA, USA, 2003: 1398-1402.

作者简介:



何翔,男,硕士,工程师,2016年于中南大学获得硕士学位,主要从事从光伏计量方面研究工作。E-mail: 315107763@qq.com