

采用坐标感知与亚像素重构的光伏组件红外缺陷 图像生成方法

刘旭江¹, 宋自文¹, 杨婷婷¹, 袁奇¹, 李东敬², 王赫², 朱光宇¹

(1. 西安交通大学能源与动力工程学院, 710049, 陕西西安

2. 内蒙古智慧运维新能源有限公司, 010010, 内蒙古呼和浩特)

摘要: 针对光伏红外图像缺陷识别任务中小样本和类别分布不均衡导致的诊断模型泛化能力不足问题, 构建了一种采用坐标感知与亚像素重构的生成对抗网络 (CPS-GAN), 并以其为核心提出面向小样本类别数据扩充的光伏组件红外缺陷图像生成方法。首先, 针对光伏组件红外图像局部热异常位置敏感、热梯度变化明显等特征, 在生成器中引入类别条件约束与 CoordConv 坐标感知模块, 建立潜在编码与几何空间之间的映射关系, 改善传统 GAN 难以准确表征局部缺陷空间位置的问题。其次, 采用基于 PixelShuffle 的亚像素重构方法替代传统转置卷积, 抑制生成图像中的“棋盘伪影”, 并保留热异常分布特征。最后, 结合 PatchGAN 判别器强化局部纹理判别。实验结果表明: CPS-GAN 在多个定量评价指标及语义评价方案上均优于 DCGAN 与 WGAN-GP 基线模型, 并在 t-SNE 特征可视化中表现出更好的特征分布对齐效果。在无需分类器架构优化的条件下, 基于 CPS-GAN 增强数据集训练的分类器获得了 84.00% 的测试准确率, 较原始数据提升了 7.05%。所提方法能够有效生成高质量、多样化的光伏组件红外缺陷样本, 为提升光伏智能诊断系统的鲁棒性提供数据支撑。

关键词: 生成对抗网络 (GAN); 数据增强; 缺陷识别; 红外热成像

中图分类号: TP183; TK519

文献标志码: A

DOI:

文章编号: 0253-987X(2026)12-0000-00

Infrared Defect Image Generation Method Based on Coordinate Awareness and Subpixel Reconstruction for Photovoltaic Modules

LIU Xujiang¹, SONG Ziwen¹, YANG Tingting¹, Li Dongjing², WANG He², ZHU guangyu¹

(1. School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. Inner Mongolia Smart O&M New Energy Co., Ltd., Hohhot, Inner Mongolia 010010, China)

Abstract: To address the insufficient generalization capability of diagnostic models caused by small sample sizes and class imbalance in photovoltaic infrared image defect recognition tasks, a generative adversarial network incorporating coordinate awareness and subpixel reconstruction (CPS-GAN) is constructed. Based on this, an infrared defect image generation method for photovoltaic modules oriented toward few-shot class data augmentation is proposed with CPS-GAN as the core. First, in view of the characteristics of photovoltaic module infrared images, such as sensitivity to the location of local thermal anomalies and significant thermal gradient variations, class-conditional constraints and a CoordConv coordinate awareness module are introduced into the generator to establish a mapping relationship between latent codes and geometric space, thereby mitigating the difficulty of conventional GANs in accurately characterizing the spatial locations of local defects. Second, a PixelShuffle-based subpixel reconstruction method is adopted to replace conventional transposed convolution, suppressing "checkerboard artifacts" in generated images while preserving the distribution characteristics of thermal anomalies. Finally, a PatchGAN discriminator is integrated to enhance local texture discrimination. Experimental results demonstrate that CPS-GAN outperforms the DCGAN and WGAN-GP baseline models across multiple quantitative evaluation metrics and semantic evaluation schemes, and exhibits superior feature distribution alignment in t-SNE feature visualization. Without optimizing the classifier architecture, the classifier trained on the CPS-GAN-augmented dataset achieves a test accuracy of 84.00%, which is 7.05% higher than

收稿日期: 2026-02-11。作者简介: 刘旭江 (1993—), 男, 博士生; 朱光宇 (通信作者), 男, 副教授, 博士生导师。基金项目: 内蒙古自治区科技计划项目 (2025YFDZ0034)。

网络出版时间:

网络出版地址:

that achieved using the original dataset. The proposed method can effectively generate high-quality and diverse infrared defect samples of photovoltaic modules, providing data support for enhancing the robustness of intelligent photovoltaic diagnostic systems.

Keywords: generative adversarial network (GAN); data augmentation; defect recognition; infrared thermal imaging

在全球低碳转型的背景下,我国正处于能源结构转型的重要阶段^[1]。按照国际能源署(IEA)的预测,到2035年光伏发电有望超越燃煤与燃气,成为全球最大的电力来源,预计贡献约30%的发电量^[2]。随着光伏产业的迅速发展,海量光伏组件将长期运行在复杂环境与多变气候条件下,不可避免地产生裂纹、热斑、积尘等类型缺陷^[3-5]。这些缺陷不仅会降低光伏发电系统的发电效率,甚至可能引发电气设备故障与火灾风险。

红外热成像技术能够快速获取工作状态下光伏板表面的热梯度信息,适用于光伏电站对光伏板的检测分析。早期光伏电站针对光伏红外图像的采集与分析大多基于人工方式,不仅效率低下,而且易造成误判或漏判,难以满足大规模光伏电站运维的实际需求。随着深度学习技术的发展,深度学习模型凭借强大的特征提取能力有效提高了缺陷识别效率及准确率^[6-10]。然而,在光伏实际运维场景下,缺陷样本获取和标注成本较高,部分缺陷在红外图像中表现出相近的热异常形态,使得模型对少数类样本的判别特征学习更加困难。因此,基于数据驱动的光伏红外缺陷识别模型仍容易受到小样本和类别不平衡问题的制约,导致模型泛化能力不足。

针对上述问题,现有研究主要集中在模型架构优化与数据平衡两个层面提升缺陷识别模型的性能。在架构优化方面,改进的ResNet、EfficientNet、YOLOv8以及针对性设计的CNN架构被用于增强类不平衡条件下红外缺陷特征的提取能力^[11-14];在数据平衡方面,直方图均衡、过采样、数据增强和超参数搜索等方法被用于缓解小样本问题^[15-17]。尽管上述研究从不同角度促进识别准确率的提升,但其主要依赖判别模型结构优化或对已有样本的重采样处理,难以有效扩展少数类缺陷的潜在分布空间。样本的稀缺性仍然是限制分类器泛化能力的重要瓶颈。

针对小样本及类别分布不平衡的问题,近年来图像生成模型为缺陷样本扩增提供了新的思路。扩散模型(diffusion models)^[18]通过前向过程与反向过程可从纯噪声中逐步生成清晰图像,但其更适用于数据分布充分的情形。生成式对抗网络(generative adversarial network, GAN)^[19]在分布拟合及流形学习方面具有较好的适应性,有利于捕捉光伏红外热像中细微的纹理结构及热异常分布特征,适用于光伏缺陷样本扩增任务。目前光伏图像生成与数据增强的研究中,DCGAN与WGAN-GP等经典GAN架构仍被广泛使用。作者前期研究^[2]在公开光伏红外数据集上系统地比较了DCGAN、WGAN-GP以及近期提出的R3GAN等代表性模型,结果表明,近期提出的

R3GAN并未在所有评价指标上稳定优于经典GAN架构。然而,上述经典GAN架构多是为三通道、特征复杂的自然图像设计,直接将其迁移到单通道的光伏红外图像时会遇到以下问题:其一,光伏缺陷的语义表征有极强的空间依赖性,例如Diode-Multi类缺陷表现为整列子串的温度异常,其空间形态具有一定的方向一致性,而传统GAN架构缺少对绝对空间坐标的显式建模能力。其二,传统转置卷积上采样时容易产生“棋盘伪影”,从而影响生成样本的纹理真实性及判别特征稳定性。

为此,本文提出了一种基于坐标感知与亚像素重构的生成式对抗网络CPS-GAN(coordinate-pixelshuffle GAN)。该模型通过引入CoordConv模块,增强模型对缺陷特征及缺陷位置的感知与定位能力;采用PixelShuffle亚像素重构模块替代传统的插值上采样方法,有效减少棋盘伪影,并更好地保留红外图像的热梯度信息;引入PatchGAN判别器,强化局部热纹理和热异常细约束。该模型旨在生成高质量且具有丰富多样性的样本,对样本数量不足的缺陷类进行数据增强。在不增加额外采集成本的前提下缓解小样本、类别不平衡对分类模型的不利影响,提高模型在复杂场景下的识别准确率及泛化能力。

1 数据集与方法

1.1 光伏组件红外图像数据集

本文采用的基础数据集是由Raptor Maps团队基于真实光伏电站巡检所构建的InfraredSolarModules数据集^[10],该数据集依据IEC TS 62446-3:2017《光伏系统户外红外热成像》标准要求采集,图像以组件为单位裁剪后统一调整至40×24像素的单通道红外图像,构成CPS-GAN的基础输入。数据集中各类别红外图像的数量分布如图1所示。




图 1 不同类别光伏组件红外图像的数量分布

Fig. 1 Distribution of the number of IR images of different categories of PV modules

本文从该数据集选取了 4 个小样本类别, 分别为: 多旁路二极管激活 (Diode-Multi) 175 张、积尘 (Soiling) 204 张、多热斑 (Hot-Spot-Multi) 246 张和单热斑 (Hot-Spot) 249 张, 作为 CPS-GAN 生成性能评估的主要对象。CPS-GAN 主要作为光伏红外缺陷识别任务中的训练数据增强模块, 而非直接替代故障分类器。在真实光伏电站巡检场景中, 针对样本数量较少的缺陷类别, 利用 CPS-GAN 进行数据增强, 将生成样本与真实训练样本共同构建增强训练集, 用于训练下游缺陷分类识别模型。

为了直观反应小样本条件下特征学习的困难, 本文利用 t-SNE 算法将这 4 类缺陷的高维特征映射至二维空间^[20], 结果如图 2 所示。原始数据集为灰度图, 为便于观察, 本文对图中示例进行着色。4 类缺陷在特征空间中具有一定的聚类趋势, 但是不同类别间的边界不够清晰, 且存在明显交叉。说明本文所研究的几类缺陷在红外图像中的表征较为相似。在样本数量不足的情况下, 模型难以充分学习到稳定且具有判别性的类别特征。因此仅凭现有小样本数据难以建立性能稳定的分类模型。




图 2 基于 t-SNE 的四种典型小样本缺陷特征聚类结果

Fig. 2 t-SNE based feature clustering display of four typical small-sample defects

1.2 CPS-GAN 模型构建

针对经典 GAN 架构缺少绝对空间坐标显式建模能力且上采样过程容易产生棋盘伪影等问题, 本文提出了基于坐标感知及亚像素重构的生成对抗网络 CPS-GAN。该模型通过类别条件注入与坐标感知、亚像素特征重构、局部判别约束、残差特征融合四个关键模块协同, 能够稳定可靠地生成高质量的光伏红外缺陷图像。CPS-GAN 的整体架构如图 3。




图 3 CPS-GAN 架构

Fig. 3 The architecture of CPS-GAN

1.2.1 类别条件注入与坐标感知机制

由于原始数据集中 4 类缺陷图像的分辨率较低且热异常形态相似, 无监督生成易出现类别混淆。本文将随机噪声向量 z 与缺陷类别独热编码向量 c 直接拼接作为生成器输入, 使生成器能够在类别条件约束下合成对应类型的缺陷样本。

不同光伏红外缺陷在空间热分布上具有一定差异, 而标准卷积的平移不变性使单纯用标准卷积的生成器难以直接感知到有位置依赖性的几何特征。因此, 本文在 CPS-GAN 生成器初始特征映射阶段引入 CoordConv 模块, 通过在特征图中显式地拼接 x 、 y 坐标通道, 将像素位置直接注入特征空间, 从而增强生成器对缺陷空间位置和几何形态的建模能力。

1.2.2 亚像素特征重构

转置卷积在上采样过程中容易因卷积核与步长配置不均产生棋盘伪影, 从而破坏光伏红外图像中热梯度的连续性, 并影响下游分类器的判别特征提取。本文以 PixelShuffle 亚像素重构模块替代转置卷积, 该模块通过将通道维度中的特征重排至空间维度完成上采样。在光伏红外缺陷图像生成任务中, 该机制能有效抑制棋盘伪影, 使生成图像具有更自然的热分布特征和更稳定的判别信息。

1.2.3 判别器设计优化

对于 40×24 像素的低分辨率光伏红外图像, 全图级标量判别器将图像整体映射为单一真假概率, 难以对局部纹理细节及热区边缘过渡等细粒度特征施加有效约束。本文采用了 PatchGAN 判别器结构, 将输入图像映射为二维 Patch 判别图。设判别器输出尺寸为 $M \times N$, 则

$$D(x) = \{D_{m,n}(x) | m=1, \dots, M; n=1, \dots, N\} \quad (1)$$

式中: $D_{m,n}(x)$ 为判别器对输入图像第 (m, n) 个局部图像块的真实判别结果。

在 PatchGAN 结构下, 本文将全图级对抗损失扩展为 Patch 级对抗损失, 并对所有局部 Patch 的判别结果取平均。设 $G(z, c)$ 表示在随机噪声 z 和类别条件 c 共同约束下生成的光伏红外缺陷图像, 则判别器与生成器的对抗损失分别为

$$L_D^{\text{Patch}} = -\frac{1}{MN} E_{x \sim p_{\text{data}}} \left[\sum_{m=1}^M \sum_{n=1}^N \log D_{m,n}(x) \right] - \quad (2)$$

$$\frac{1}{MN} E_{z \sim p_z, c \sim p_c} \left[\sum_{m=1}^M \sum_{n=1}^N \log(1 - D_{m,n}(G(z, c))) \right]$$

$$L_G^{\text{Patch}} = -\frac{1}{MN} E_{z \sim p_z, c \sim p_c} \left[\sum_{m=1}^M \sum_{n=1}^N \log D_{m,n}(G(z, c)) \right] \quad (3)$$

式中： M 和 N 分别为二维 Patch 判别图的高和宽； c 为缺陷类别条件向量。通过 Patch 级判别约束，判别器能够从局部区域层面对生成图像的真实性进行评价，促使生成器更加关注光伏红外图像中的局部热纹理及热辐射梯度等细节。

1.2.4 残差特征融合

随着生成器网络层数增加，梯度传播路径延长会增加训练的不稳定风险。此外 CoordConv 在前端引入的坐标信息也可能在逐层特征变换中被削弱，导致后续上采样模块对缺陷空间位置约束不足，使生成图像中的热异常区域发生偏移。

本文在坐标卷积及上采样模块之间地嵌入了 ResidualBlock 模块，利用其残差连接为浅层坐标特征提供更短的传递路径，缓解梯度传播困难并保留前端引入的空间位置信息。使 CPS-GAN 生成的图像能够更好地保持局部热纹理及缺陷空间结构一致性。

2 实验设置与评价指标

本文采用定量指标与语义评价相结合的方案，从生成图像的真实性及多样性两个方面对 CPS-GAN 的生成性能进行评价。所涉实验均在 PyTorch 2.0.1 深度学习框架下完成，所用硬件平台配备 Intel Core i7-13700KF 处理器及 NVIDIA GeForce RTX 4060 Ti 显卡，并采用 CUDA 11.8 进行计算加速。

2.1 定量评价指标

本文选择 FID 与 MMD 两项定量指标作为生成图像真实性评价指标。

FID (Fréchet Inception 距离) 是从生成图像和真实图像在特征空间中的距离角度来度量二者的相似性^[21]。FID 值越低，说明生成图像与真实图像的分布越接近。本文将生成图像与真实图像间的 Fréchet Inception 距离记为 D_F ，其表达式为

$$D_F = \text{Tr}(\Sigma_r + \Sigma_g - 2(\Sigma_r \Sigma_g)^{1/2}) + \|\mu_r - \mu_g\|_2^2 \quad (4)$$

式中： μ_r 及 μ_g 分别为真实图像和生成图像的特征均值； Σ_r 及 Σ_g 分别为真实图像和生成图像的特征向量的协方差矩阵。

MMD (最大均值差异) 通过比较真实图像与生成图像在再生核希尔伯特空间中的均值差异衡量二者特征分布的接近程度^[22]。MMD 值越小，说明生成样本与真实样本的分布越接近。本文将生成样本与真实样本间的最大均值差异记为 D_M ，其表达式为

$$D_M^2 = E_{x, x' \sim P_r} [k(x, x')] - 2E_{x \sim P_r, y \sim P_g} [k(x, y)] + E_{y, y' \sim P_g} [k(y, y')] \quad (5)$$

式中： $k(x, y)$ 是一个核函数，用于衡量样本 x 和 y 之间的相似度； P_r 和 P_g 分别表示真实图像和生成图像的数据分布。

本文选择 MS-SSIM 与 LPIPS 两项定量指标作为生成图像多样性评价指标。

MS-SSIM (多尺度结构相似指数) 基于不同尺度衡量两幅图像在结构、亮度、对比度等方面的一致性，判断图像之间的相似性^[23]。MS-SSIM 值越低，表示生成图像之间的结构差异更大。本文将生成图像之间的多尺度结构相似指数记为 S_M ，其表达式为

$$S_M(x, y) = [l_K(x, y)]^{\alpha_K} \prod_{k=1}^K [c_k(x, y)]^{\beta_k} [s_k(x, y)]^{\gamma_k} \quad (6)$$

式中： $l_K(x, y)$ 、 $c_K(x, y)$ 和 $s_K(x, y)$ 分别代表两幅图像在相应尺度下的亮度、对比度及结构相似性对比； α_K 、 β_K 、 γ_K 代表各尺度的权重。 K 为尺度总数， k 为尺度索引。

LPIPS (学习感知图像块相似度) 主要基于预训练卷积神经网络的不同层，提取图像的特征，然后计算这些特征的距离，以得到图像之间的相似度度量^[24]。生成图像之间的 LPIPS 值越高，表示生成图像的多样性越高。LPIPS 计算如公式为

$$d(x, x_0) = \sum_k \frac{1}{H_k W_k} \sum_{h, w} \|w_k \odot [\hat{y}_{k, h, w}(x) - \hat{y}_{k, h, w}(x_0)]\|_2^2 \quad (7)$$

式中： H_k 、 W_k 分别为第 k 层特征图的高度和宽度； w_k 表示用于第 k 层通道的权重向量； $\odot$ 表示逐元素相乘； $\hat{y}_{k, h, w}(x)$ 、 $\hat{y}_{k, h, w}(x_0)$ 分别为图像 x 和 x_0 在位置 (h, w) 上的特征激活向量。

2.2 语义评价方案

Shmelkov 等^[25]提出，生成图像的真实性可采用 GAN-test 指标进行评价。该方法是在真实图像训练集上训练分类器，在生成图像上测试准确率。如果生成图像和真实图像分布一致，那么分类器能够较好的识别出生成图像。因此 GAN-test 值越高，说明生成图像的真实性越好。

生成图像的多样性则使用 GAN-train 指标进行评价。该方法是在生成图像集上训练分类器，在真实图像上测试分类准确率。如果生成图像足够多样，能包含不同类别的真实图像特征，那么分类器就能泛化到真实图像上。因此 GAN-train 值越高，说明生成图像的多样性越好。GAN-test 与 GAN-train 指标的测试方法如图 4 所示。




图 4 GAN-test 与 GAN-train 的测试过程

Fig. 4 The testing process of GAN-test and GAN-train

3 结果与分析

3.1 生成图像的空间结构与局部纹理可视化分析

为保证实验对比的公平性, 本文选取光伏图像生成研究中常用的 DCGAN^[26]与 WGAN-GP^[27]作为对照模型, 对不同模型的网络配置进行统一设置, 如表 1 所示。各模型的生成器、判别器骨干结构保持一致, 均采用相同的特征映射维度和网络深度, 仅在上采样模块、特征注入方式和判别器输出等方面保留各方法的结构差异。

表 1 不同模型架构配置对比

Table 1 Configuration comparison of different architecture

网络阶段	特征图尺寸	DCGAN / WGAN-GP	CPS-GAN
Input	1×100	Noise z	Noise z
Reshape	10×6×256	FC + Reshape	FC + Reshape
Feature extraction	10×6×128	Standard Conv	CoordConv + ResBlock
Upsample 1	20×12×64	Deconv	PixelShuffle
Upsample 2	40×24×32	Deconv	PixelShuffle
Output	40×24×1	Conv + Tanh	Conv + Tanh
Discriminator	—	Scalar	Patch Validity
Output	—	Probability	Map

本文以空间结构特征明显的 Diode-Multi 类缺陷为例, 对比不同生成模型缺陷空间结构的保持能力, 如图 5 所示。DCGAN 和 WGAN-GP 虽能生成具有红外热分布特征的图像, 但是部分样本中存在横向热异常区域这一不合理空间结构特点。CPS-GAN 生成样本中的热异常区域与 Diode-Multi 类缺陷的典型红外表现更加一致, 说明 CoordConv 坐标感知模块有利于增强生成器对缺陷空间位置及热异常分布方向的建模能力。




图 5 空间结构对比

Fig. 5 Comparison of spatial structures

图 6 为不同生成模型生成样本的图像纹理对比

结果。采用传统转置卷积上采样方法 (DCGAN 和 WGAN-GP) 所得图像的局部区域存在明显的块状纹理伪影, 破坏了红外图像中本来连续的热辐射梯度, 也降低了所生成样本的纹理真实性。相比之下, CPS-GAN 生成图像中局部热梯度过渡连续, 块状伪影明显减弱, 纹理结构更接近真实的红外图像。说明 PixelShuffle 模块能很好地解决传统转置卷积的棋盘伪影问题, 有利于提高生成图像局部纹理的自然性。




图 6 图像纹理伪影对比(从左到右依次为: Hot-Spot-Multi、Hot-Spot、Soiling 及 Diode-Multi)

Fig. 6 Image texture artifact comparison (rom left to right: Hot-Spot-Multi, Hot-Spot, Soiling, and Diode-Multi)

3.2 生成图像质量的定量对比

为定量评价不同模型的生成图像质量, 每项指标的最终取值为 3 次独立实验的平均值^[2], 以提高评价结果的稳定性。由于要使不同指标在量纲及数值范围不同, 本文以 CPS-GAN 为参照进行比值归一化处理, 将 CPS-GAN 在某项指标上的评价结果设定为 1, 其他模型在相同指标上的结果表示为相对于 CPS-GAN 的比值。设模型 i 在第 k 个指标上的原始取值为 $q_{i,k}$, CPS-GAN 在第 k 个指标上的原始取值为 $q_{0,k}$, 则归一化后的指标值 $r_{i,k}$ 为:


$$r_{i,k} = \frac{q_{i,k}}{q_{0,k}} \quad (8)$$

图 7(a)、7(b)分别为基于 FID 与 MMD 的真实性评价结果。实验结果表明, CPS-GAN 在全部 4 类缺陷任务中均展现出最佳的生成图像真实性。为避免归一化掩盖不同模型之间的绝对数值差异, 本文进一步统计了 3 种模型在 4 类缺陷上的平均原始指标值。WGAN-GP、DCGAN 与 CPS-GAN 的平均 FID 分别为 7.4654、6.5037 及 3.1241, 平均 MMD 分别为 0.00835、0.00813 和 0.00778。由此可知, CPS-GAN


取得最低的 FID 与 MMD, 即其生成图像在统计分布上与真图像最接近。这是由于 CoordConv 坐标感知机制、PixelShuffle 亚像素重构模块及 PatchGAN 判别器协同作用, 增强了空间位置感知与局部纹理约束, 从而提升了生成样本的细节纹理真实性。

图 7(c)、7(d)分别基于 MS-SSIM 与 LPIPS 的多样性评价结果。实验结果表明, CPS-GAN 在 4 类缺陷生成任务中都取得了最优的多样性表现。具体而言, WGAN-GP、DCGAN 以及 CPS-GAN 的平均 MS-SSIM 分别为 0.7294、0.7560 及 0.6918, 平均 LPIPS 分别为 0.1271、0.1220 及 0.1373。CPS-GAN 具有最低的平均 MS-SSIM 和最高的平均 LPIPS, 说明其生成样本在保持类别语义一致性的同时具有更高的感知多样性。


图 7(e)为基于 CNN 分类结果的 GAN-test 与 GAN-train 评价结果。实验结果表明, CPS-GAN 在两个指标上均为最优, GAN-test 和 GAN-train 分别为 93.37%和 81.01%。WGAN-GP 和 DCGAN 在 GAN-test 指标上的结果为 CPS-GAN 的 74.14%和 78.98%, 在 GAN-train 指标上的结果为 CPS-GAN 的 55.36%和 67.23%。可见在小样本条件下, CPS-GAN 不仅能扩充训练数据规模, 还能为下游分类任务提供更有效的数据支撑。




(a) FID 指标




(b) MMD 指标



(c) MS-SSIM 指标



(d) LPIPS 指标



(e) GAN-Test 与 GAN-Train 指标

图 7 不同生成模型的定量评价

Fig. 7 Quantitative evaluation of different generative models

3.3 特征空间分布分析


为了分析生成样本在特征空间中的分布特性及其对真实数据流形的拟合程度, 本文采用 t-SNE 方法将高维特征映射至二维空间进行可视化, 如图 8 所示。在原始真实数据 (实心圆点) 的基础上, 分别叠加 WGAN-GP、DCGAN 及 CPS-GAN 生成的各 200 张样本 (以 “+” 标记表示)。

由 WGAN-GP 分布结果可知, 所生成样本的整体范围与真实数据有一定的重叠, 但是类簇边界有

明显的偏移, 许多生成样本没有聚集于对应的真实类簇内, 而是散布于相邻类别之间, 即存在“跨类簇扩散”的趋势。这说明 WGAN-GP 在刻画缺陷分布时仍有不足, 其生成样本未能充分对齐真实数据的高维结构特征。相比之下, DCGAN 则更接近真实图像类簇, 但在 Diode-Multi 和 Hot-Spot 等缺陷类别上其特征捕捉仍显不足。


CPS-GAN 则呈现出最优的特征分布特性, 其生成的不同类别缺陷样本可以更好的嵌入在真实样本构成的类簇内部。上述结果表明, CPS-GAN 通过采用 CoordConv 坐标感知机制、PixelShuffle 亚像素重构模块及 PatchGAN 判别器协同机制, 促使生成的图像在语义特征上与真实图像一致性更高。CPS-GAN 能够更好的学习具有判别力的图像特征, 并能够捕获不同故障类型的特征分布差异。

● Hot-Spot-Multi
● Hot-Spot
● Soiling
● Diode-Multi
+ GAN Data (Augmented)




(a) WGAN-GP

● Hot-Spot-Multi
● Hot-Spot
● Soiling
● Diode-Multi
+ GAN Data (Augmented)



(b) DCGAN



(c) CPS-GAN

图 8 不同 GAN 模型生成样本的 t-SNE 特征分布
Fig. 8 t-SNE feature distributions of samples generated by different GAN models.

本文进一步对特征空间的 Silhouette 系数与 D_B 指数进行计算, 量化评估不同模型生成图像的类内紧凑度与类间分离度^[28]。其中, Silhouette 系数兼顾了类内紧凑性及类间分离性, 其取值越大说明可分性越好, 表达式见式 9。 D_B 指数则直接反映类内距离与类间距离的相对关系, 数值越小说明类间重叠越小、判别边界越明确, 相关公式见式 10、11。

$$S_i = \frac{b_i - a_i}{\max(a_i, b_i)} \quad (9)$$

式中: a_i 为样本 i 到同簇内所有其他样本点的平均距离; b_i 为样本 i 到最近邻簇内样本的平均距离。

$$D_B = \frac{1}{K} \sum_{i=1}^K \max R_{i,j} \quad (10)$$

$$R_{i,j} = \frac{A_i + A_j}{M_{i,j}} \quad (11)$$

式中: A_i 为第 i 个簇的簇内散度; A_j 为第 j 个簇的簇内散度; $M_{i,j}$ 为簇 i 与簇 j 的中心距离; $R_{i,j}$ 为簇 i 与簇 j 的相似度。

计算结果如表 2 所示, 原始真实数据的 Silhouette 系数数值最低 (0.0319) 且 D_B 指数最高 (3.6018)。说明原始光伏红外缺陷数据中存在严重的特征混叠现象。由引入 GAN 生成数据后, 所有混合数据组的聚类指标均优于仅用真实样本的对照组, 说明生成样本在一定程度上补充了小样本缺陷类别的特征空间分布。其中, CPS-GAN 获得了最高的 Silhouette 系数 0.1219 以及最低的 D_B 指数 2.2877。该结果表明, 在样本量不足的情形下, CPS-GAN 生成的样本能够改善样本在特征空间中的类内紧凑性及类间分离度。

表 2 不同数据组的特征空间聚类性能对比
Table 2 Comparison of feature-space clustering performance among different data groups

实验组	Silhouette 系数	D_B 指数
真实数据	0.0319	3.6018
WGAN-GP 增强	0.0752	2.8663

DCGAN 增强	0.1072	2.4460
CPS-GAN 增强	0.1219	2.2877

3.4 下游分类任务的增益评估

生成红外缺陷图像的根本目的在于弥补小样本场景下分类模型训练数据的不足,从而提高缺陷识别的准确性。为进一步验证 CPS-GAN 在下游分类任务中的实用价值,本文设计数据增强对照实验,定量分析不同 GAN 生成样本对分类器性能的提升作用。实验选用经典 ResNet 作为缺陷分类的基础网络,并将原始光伏红外缺陷数据集按 7:1:2 的比例合理划分为训练集、验证集及测试集^[29]。

为了保证评估结果的可靠性,本文设置了 4 种训练集配置方案作为对照。Real-Only 为基准组,即仅用原始训练集样本训练分类模型;WGAN-GP 增强、DCGAN 增强、CPS-GAN 增强 3 个实验组均在原始训练集的基础上分别加入了相应 GAN 模型生成的图像。考虑到训练集规模、计算资源及性能增益等因素,本文在各增强组中每类缺陷的训练集统一扩充 500 张合成样本。此处 500 张/类并非生成样本与真实样本的全局最优混合比例,而是作为实验的统一增强设定,避免生成样本数量的差异成为额外干扰变量。设原始数据集样本数为 N ,各数据集划分见表 3。

表 3 数据集的划分
Table 3 Partitioning of the dataset

实验配置	训练集	验证集	测试集
Real-Only 基准组	$N \times 70\%$	$N \times 10\%$	$N \times 20\%$
GAN 增强组	$N \times 70\% + 500 \text{ 张/类}$	$N \times 10\%$	$N \times 20\%$

为避免单次随机划分产生的抽样偏差,本文在不同随机种子下将数据集划分过程独立重复 3 次^[30]。在每次独立实验中,4 种训练配置均使用相同的验证集和测试集,仅在训练集阶段采用不同的数据增强方式,以保证不同实验组之间的可比性。最终性能评价指标取 3 次独立实验测试准确率的平均值。

表 4 为不同实验组在 ResNet 分类模型上所测得的测试准确率结果。由表 4 可知,Real-Only 基准组的平均测试准确率为 $76.95\% \pm 2.38\%$ 。引入 WGAN-GP 生成样本之后测试准确率降为 $76.19\% \pm 3.15\%$,说明 WGAN-GP 生成样本中噪声及伪影较多,导致训练数据的分布偏离真实流形,进而影响了分类器的判别边界。DCGAN 增强则具有一定的提升,测试准确率达到 $79.81\% \pm 1.19\%$ 。相比之下,CPS-GAN 增强后测试准确率达到 $84.00\% \pm 0.57\%$,相较 Real-Only 基准组提升了 7.05%,较 WGAN-GP 与 DCGAN 增强分别提升了 7.81% 和 4.19%。

分类实验结果表明,相较于 DCGAN 和 WGAN-GP, CPS-GAN 生成的样本能够更有效地补充小样本缺陷类别的训练数据,提升分类模型对光伏红外缺陷的识别准确率。

表 4 不同实验组的测试准确率

Table 4 Test accuracy of different experimental groups

实验组	测试准确率/%
Real-Only 基准组	76.95 ± 2.38
WGAN-GP 增强	76.76 ± 3.81
DCGAN 增强	79.81 ± 1.19
CPS-GAN 增强	84.00 ± 0.57

考虑到需要验证所获性能提升是否具有统计学意义,本文采用双侧 Welch's t-test (显著性水平 $\alpha=0.05$) 对 4 种训练集配置下的测试准确率进行两两比较,结果见图 9。检验结果表明,虽然 DCGAN 增强的平均测试准确率高过 Real-Only 基准组,但是统计检验结果显示二者的差异并未达到显著性水平 ($p = 0.1428 > 0.05$)。相比之下,CPS-GAN 增强相较 Real-Only 基准组取得了显著提升 ($p = 0.030 < 0.05$),同时也显著优于 WGAN-GP 增强 ($p = 0.046 < 0.05$) 及 DCGAN 增强 ($p = 0.013 < 0.05$)。统计结果表明,CPS-GAN 生成样本能够带来更稳定的数据增强效果。




图 9 不同 GAN 增强数据集下的测试准确率

Fig. 9 Test accuracy under different GAN-augmented datasets

由于多分类任务中常用的总体准确率容易被多数类主导,因此本文采用逐类 F_1 值 (式 12) 对模型进行细粒度评估^[31, 32],详细对比结果如表 5 所示。

$$F_1 = \frac{2T_p}{2T_p + F_p + F_n} \quad (12)$$

式中: T_p 、 F_p 、 F_n 分别表示真正例、假正例和假负例样本数。由表 5 可知,与 Real-Only 基准组相比,引入 CPS-GAN 进行数据增强之后所得到的各缺陷类别的 F_1 值均得到了提升。对于原数据上 F_1 值最高的 Diode-Multi 类别, F_1 值从 0.8909 提高到 0.9574,表现出了较高的识别稳定性。对于原数据上 F_1 值最低的 Hot-Spot-Multi 类别, F_1 值也从 0.7188 提高到 0.7599。由此可见, CPS-GAN 不仅能够扩充训练样本规模,还能够通过引入多样化的合成样本补充特征空间分布,从而提升分类器对不同光伏缺陷类别

的判别能力。

表 5 不同缺陷类别的 F_1 值
Table 5 F_1 scores for different defect categories

缺陷类别	F_1 值	
	Real-Only 基准组	CPS-GAN 增强
Diode-Multi	0.8909 ± 0.0524	0.9574 ± 0.0135
Hot-Spot	0.7234 ± 0.0390	0.8052 ± 0.0210
Hot-Spot-Multi	0.7188 ± 0.0163	0.7599 ± 0.0349
Soiling	0.7634 ± 0.0314	0.8497 ± 0.0322

3.5 消融实验

为了探究本文提出的 CPS-GAN 模型中各关键模块对光伏红外缺陷图像生成质量的独立贡献, 本文设计了相应的消融实验。实验以最终的 CPS-GAN 为基准, 依次将坐标感知模块 (CoordConv + ResBlock)、亚像素重构模块 (PixelShuffle) 以及判别器架构 (PatchGAN) 替换为传统标准组件, 由此得到 3 种消融变体模型, 如表 6 所示。

表 6 各变体的具体网络配置
Table 6 Specific network configurations for each variant

模型	特征提取层	上采样层	判别器输出
CPS-GAN	CoordConv + ResBlock	PixelShuffle	Patch 判别图
去除坐标感知模块	标准卷积	PixelShuffle	Patch 判别图
去除 PixelShuffle	CoordConv + ResBlock	转置卷积	Patch 判别图
去除 PatchGAN	CoordConv + ResBlock	PixelShuffle	标量概率

在统一的实验条件下, 各消融变体均用于为每类小样本缺陷扩充 500 张合成图像, 并将生成图像加入原始训练集后训练下游 ResNet 分类器。各变体增强后的分类测试准确率如表 7 所示。由表 7 可知, 当坐标感知模块退化成标准卷积之后, 测试准确率从 84.00% 降至 80.95%, 说明缺少显式空间坐标引导, 会使生成的缺陷特征在空间分布上出现错位或语义混淆, 进而干扰了分类模型对缺陷类别空间规律的学习。当 PixelShuffle 模块替换成传统的转置卷积后, 测试准确率降至 80.19%, 说明转置卷积上采样很容易在光伏红外图像生成中引入棋盘伪影, 进而影响分类模型的泛化性能。当 PatchGAN 被替换为标准判别器后, 测试准确率降至 82.10%, 可见局部判别约束能促使生成器更好地生成局部纹理和热异常细节, 提升模型对细微缺陷差异的识别能力。

表 7 CPS-GAN 核心模块的消融实验结果
Table 7 Ablation study results of core modules in CPS-GAN

模型变体	测试准确率/%
CPS-GAN	84.00
去除坐标感知模块	80.95

去除 PixelShuffle	80.19
去除 PatchGAN	82.10

为了能更直观地了解各模块对生成样本质量的影响, 本文进行了不同消融变体模型生成样本的可视化对比, 见图 10。由图 10 可知, 坐标感知模块退化为标准卷积后, 生成样本中的热异常区域会更容易出现空间结构不稳定或者方向不合理的情况; PixelShuffle 模块替换成传统的转置卷积后, 生成图像中出现了明显的块状纹理扰动及棋盘伪影; PatchGAN 被替换为标准判别器后, 生成样本局部纹理细节及热区边缘过渡都变弱。相比之下, 完整的 CPS-GAN 在空间结构合理性、热梯度连续性、局部纹理自然性等方面都表现最佳, 其可视化结果可与表 7 中所列的消融结果相互印证。




图 10 不同消融变体生成样本的可视化对比 (左侧为 Hot-Spot-Multi, 右侧为 Diode-Multi)
Fig. 10 Visual comparison of samples generated by different ablation variants (Left is Hot-Spot-Multi, right is Diode-Multi)

3.6 生成样本规模对分类性能的影响分析

为探究生成样本数量对分类模型性能的影响, 并进一步验证 CPS-GAN 在数据扩充场景下的鲁棒性, 本文开展了敏感性分析实验。在保持测试集不变的前提下, 分别向原始训练集中加入 0、250、500、750、1000 及 1250 张/类由 DCGAN 与 CPS-GAN 生成的合成样本并进行分类测试, 测试准确率为 3 次独立实验结果的平均值, 结果如图 11 所示。

分析实验结果可知, DCGAN 增强方案在扩充数量为 500 张的时候达到了性能的峰值, 准确率为 79.81%, 随后准确率随着样本量的增加下降; 当扩充量到 1250 张时, 其准确率甚至低于 Real-Only 组。由此可见, DCGAN 生成的样本存在着严重的分布偏差和伪影, 随着生成图像越来越多, 这些低质量样本带来的分布噪声会抵消数据扩充带来的多样性增益, 导致分类准确率的下降。对于 CPS-GAN 增强方案, 其准确率是随着样本数量的增加而上升, 在扩充数量为 750 张达到了峰值, 准确率有 85.14%。之后随着扩充数量的增加准确率下降。然而即便在 1250 张 (大约有原始数据量的 5 倍) 这种扩充规模下, CPS-

GAN 的准确率仍能保持在 81.52%，优于 DCGAN 方案的最佳表现。

综上所述，CPS-GAN 生成的红外缺陷图像在保真度与多样性方面均优于对比模型。该实验结果验证了 CPS-GAN 作为高质量数据增强手段的可靠性。此外，生成样本规模对分类性能的影响实验结果表明，当生成样本质量不佳时，过量引入合成图像可能导致训练分布偏离真实数据流形，从而削弱分类器在真实测试集上的泛化能力。当生成样本质量较高时，适度增加生成样本数量能够扩展特征空间覆盖范围并提升分类性能，但过高比例的生成样本仍可能带来边际收益下降。




图 11 不同生成样本数量下的测试准确率变化趋势
Fig. 11 Trends of test accuracy under different numbers of generated samples

3.7 典型光伏电场巡检场景下的缺陷识别应用分析

为验证 CPS-GAN 在不同采集条件下的泛化性能，本文引入 PVF-10 数据集^[33]进行实验。该数据集源于不同地区的多个光伏电站，由 DJI H20T 与 M30T 无人机搭载长波红外摄像头在辐射照度 500 W/m^2 以上、风速 10 m/s 以下的环境条件下采集，单组件图像尺寸为 110×60 像素。该数据集与前文采用的 InfraredSolarModules 在采集设备、空间分辨率、图像尺寸及故障类别体系等方面均完全独立，可用于验证 CPS-GAN 在不同巡检数据场景下的适用性。

PVF-10 数据集中同样具有少数类故障样本数量少、不同类别间图像数量不均衡的特点。本文从 PVF-10 中选取“Dust band”377 张（对应 Soiling，由于组件积尘引起的温升）、“Substring open circuit”595 张（对应 Diode-Multi，二极管激活引起的子串温升）及健康光伏板 1519 张，3 类样本验证 CPS-GAN 在类别不平衡条件下对少数类故障识别的增强效果。本文选取了前文中在光伏红外缺陷生成任务上表现更好的 DCGAN 模型进行对比，对样本数量较少的 Dust band 及 Substring open circuit 类别缺陷进行数据增强，生成图像示例如图 12 所示。




图 12 不同模型生成样本的可视化对比(左侧为 Dust band, 右侧为 Substring open circuit)

Fig. 12 Visual comparison of samples generated by different models (Dust band, right is Substring open circuit)

数据集划分、分类模型选取以及 GAN 模型的增强方式与 3.4 节一致，PVF-10 数据集上的测试准确率及平均 F_1 结果如表 8 所示。由表 8 可知，在 PVF-10 外部数据集场景下，仅使用真实样本训练时，分类模型的测试准确率为 84.22%，平均 F_1 值为 0.7038。引入 DCGAN 生成样本后，测试准确率与平均 F_1 值均有一定的提升，分别为 85.77%、0.7541。采用 CPS-GAN 生成样本进行增强后，分类模型取得了最优结果，测试准确率达到 88.12%，平均 F_1 值达到 0.7840。

上述结果表明，在不同的红外巡检场景下，CPS-GAN 仍能够为下游分类模型提供更有效的训练样本补充。其生成样本在缺陷空间位置保持、局部热纹理重构和热异常形态表达方面更稳定，因此能够进一步提升分类器对不同巡检场景下小样本缺陷类别的识别能力。

表 8 跨数据集实验结果

实验配置	测试结果	
	测试准确率/%	F_1 值
Real-Only 基准组	84.22 ± 0.8875	0.7038 ± 0.0097
DCGAN 增强	85.77 ± 0.7211	0.7541 ± 0.0103
CPS-GAN 增强	88.12 ± 0.8915	0.7840 ± 0.0121

4 结 论

本文针对光伏红外缺陷识别任务中样本稀缺与类别分布不均衡问题，提出了一种生成对抗网络 CPS-GAN，用于小样本缺陷图像生成与数据增强，并从生成质量、特征分布和下游分类性能等方面验证了其有效性。主要结论如下。

(1) CPS-GAN 通过引入坐标感知模块增强对热斑等局部缺陷的空间定位能力，采用 PixelShuffle 亚像素重构模块及 PatchGAN 判别器的对抗约束，有效消除了传统生成模型中常见的棋盘伪影，同时强化了生成图像的局部纹理细节。并且通过消融实验证明了各核心模块在防止空间语义混淆、抑制结构性噪声方面的重要作用。

(2) 定量指标与语义评价结果表明, CPS-GAN 在 FID、MMD、MS-SSIM 与 LPIPS 这四项定量指标及 GAN-test 与 GAN-train 语义评价方案上均优于 DCGAN 与 WGAN-GP 模型。t-SNE 可视化及聚类量化指标进一步证实, CPS-GAN 生成的样本能够更为精准的拟合真实数据的分布流形。

(3) 数据增强实验表明, 通过 CPS-GAN 增强后的训练集训练 ResNet 分类器, 使四类小样本分类任务上的测试准确率由 76.95% 提高到 84.00%, 同时各缺陷类别的 F_1 值得到了全面的提升。敏感性分析结果表明, CPS-GAN 在大规模数据扩充时仍具有良好的性能稳定性, 可为构建光伏智能诊断系统提供可靠的数据支撑。外部场景验证表明, CPS-GAN 在不同光伏电场巡检数据场景下具有一定的泛化应用能力。

此外, 光伏红外图像的热辐射特征容易受到温度、辐照强度、风速等环境因素影响。本文虽然通过 PVF-10 进行了外部数据集场景验证, 但尚未进一步建立环境因素与生成稳定性之间的定量关系。未来工作将考虑引入同步气象信息和组件运行参数作为条件变量, 以进一步提升模型在不同环境工况下的泛化能力。

参考文献:

- [1] 别朝红, 潘超琼, 陈叶, 等. 能源转型下新能源电力系统概率风险评估[J]. 西安交通大学学报, 2021, 55(7): 1-11.
Bie Zhaohong, Pan Chaoqiong, Chen Ye, et al. Probabilistic risk assessment of new energy power system in the context of energy transition: a review[J]. Journal of Xi'an Jiaotong University, 2021, 55(7): 1-11.
- [2] Liu Xujiang, Zhu Guangyu, Li Zhigang, et al. A comprehensive evaluation framework using generative adversarial networks for infrared defect images in photovoltaic modules[J]. Solar Energy, 2026, 306: 114311.
- [3] Chen Xin, Karin T, Jain A. Automated defect identification in electroluminescence images of solar modules[J]. Solar Energy, 2022, 242: 20-29.
- [4] Et-Taleby A, Chaibi Y, Benslimane M, et al. Applications of machine learning algorithms for photovoltaic fault detection: a review[J]. Statistics, Optimization & Information Computing, 2023, 11(1): 168-177.
- [5] Venkatakrishnan G R, Rengaraj R, Tamilselvi S, et al. Detection, location, and diagnosis of different faults in large solar PV system—a review[J]. International Journal of Low-Carbon Technologies, 2023, 18: 659-674.
- [6] Kellil N, Aissat A, Mellit A. Fault diagnosis of photovoltaic modules using deep neural networks and infrared images under Algerian climatic conditions[J]. Energy, 2023, 263, Part C: 125902.
- [7] Zhao Shenshen, Chen Haiyong, Wang Chuhan, et al. SNCF-Net: scale-aware neighborhood correlation feature network for hotspot defect detection of photovoltaic farms[J]. Measurement, 2023, 206: 112342.
- [8] 翟金星, 王力平, 张艳辉. 基于无人机红外视觉的光伏电站热斑智能巡检[J]. 红外技术, 2026, 48(1): 95-104.
Zhai Jinxing, Wang Liping, Zhang Yanhui. Unmanned-Aerial-Vehicle Infrared-Vision-Based Intelligent Inspection of Hotspots in Photovoltaic Power Station [J]. Infrared Technology, 2026, 48(1): 95-104
- [9] 陈登峰, 刘茜茜, 刘世鹏, 等. 面向光伏组件缺陷检测的多源图像融合方法研究[J]. 太阳能学报, 2026, 47(4): 622-629.
Chen Dengfeng, Liu Qianqian, Liu Shipeng, et al. Multi-source image fusion methods for photovoltaic module defect detection [J]. Acta Energiæ Solaris Sinica, 2026, 47(4): 622-629.
- [10] 项新建, 孙思琪, 罗秋霞, 等. 基于跨层次局部特征融合的光伏热斑缺陷检测[J]. 太阳能学报, 2026, 47(3): 732-738.
Xiang Xinjian, Sun Siqi, Luo Qiuxia, et al. Photovoltaic Hotspot Defect Detection Based on Cross-Level Local Feature Fusion [J]. Acta Energiæ Solaris Sinica, 2026, 47(3): 732-738.
- [11] Le M, Luong V S, Nguyen D K, et al. Remote anomaly detection and classification of solar photovoltaic modules based on deep neural network[J]. Sustainable Energy Technologies and Assessments, 2021, 48: 101545.
- [12] Duranay Z B. Fault detection in solar energy systems: a deep learning approach[J]. Electronics, 2023, 12(21): 4397.
- [13] Korkmaz D, Acikgoz H. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network[J]. Engineering Applications of Artificial Intelligence, 2022, 113: 104959.
- [14] 孙靡尧, 孙俊海, 朱先远, 等. 基于改进 YOLOv8 的红外光伏组件缺陷检测方法[J]. 太阳能学报, 2026, 47(2): 148-184.
Sun Xieyao, Sun Junhai, Zhu Xianyuan, et al. Infrared Photovoltaic Module defect Detection Method Based on

- Improved YOLOv8 [J]. *Acta Energiæ Solaris Sinica*, 2026, 47(2): 148-184.
- [15] Sinap V, Kumtepe A. CNN-based automatic detection of photovoltaic solar module anomalies in infrared images: a comparative study[J]. *Neural Computing and Applications*, 2024, 36(28): 17715-17736.
- [16] Le M, Le D V, Ha Thi Vu H. Thermal inspection of photovoltaic modules with deep convolutional neural networks on edge devices in AUV[J]. *Measurement*, 2023, 218: 113135.
- [17] Tang Cheng, Ren Hui, Xia Jing, et al. Automatic defect identification of PV panels with IR images through unmanned aircraft[J]. *IET Renewable Power Generation*, 2023, 17(12): 3108-3119.
- [18] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models[C]//*Proceedings of the 34th International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2020: 6840-6851.
- [19] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//*Proceedings of the 28th International Conference on Neural Information Processing Systems*. Cambridge, MA, USA: MIT Press, 2014: 2672-2680.
- [20] Millendorf M, Obropta E, Vadhavkar N. Infrared solar module dataset for anomaly detection[C]//*Proceedings of the ICLR 2020 Workshop on AI for Earth Sciences*. Addis Ababa, Ethiopia: ICLR, 2020: 1-5.
- [21] Korkmaz D, Acikgoz H. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network[J]. *Engineering Applications of Artificial Intelligence*, 2022, 113: 104959.
- [22] Heusel M, Ramsauer H, Unterthiner T, et al. GANs trained by a two time-scale update rule converge to a local nash equilibrium[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2017: 6629-6640.
- [23] Gretton A, Borgwardt K M, Rasch M, et al. A kernel method for the two-sample-problem[C]//*Proceedings of the 20th International Conference on Neural Information Processing Systems*. Cambridge, MA, USA: MIT Press, 2006: 513-520.
- [24] Wang Z, Simoncelli E P, Bovik A C. Multiscale structural similarity for image quality assessment[C]//*The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers*, 2003. Piscataway, NJ, USA: IEEE, 2003: 1398-1402.
- [25] Zhang R, Isola P, Efros A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]//*2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway, NJ, USA: IEEE, 2018: 586-595.
- [26] Shmelkov K, Schmid C, Alahari K. How good is my GAN?[C]//*Computer Vision – ECCV 2018*. Cham: Springer International Publishing, 2018: 218-234.
- [27] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[C]//*Proceedings of the 4th International Conference on Learning Representations (ICLR 2016)*. San Juan, Puerto Rico: OpenReview.net, 2016. arXiv:1511.06434
- [28] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of Wasserstein GANs[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2017: 5769-5779.
- [29] Tsinganos P, Cornelis B, Cornelis J, et al. Data augmentation of surface electromyography for hand gesture recognition[J]. *Sensors*, 2020, 20(17): 4892.
- [30] 闫号, 戴佳佳, 龚小溪, 等. 基于多源图像融合的光伏面板缺陷检测[J]. *红外技术*, 2023, 45(5): 488-497.
- Yan Hao, Dai Jiajia, Gong Xiaoxi, et al. Defect Detection of Photovoltaic Panel Based on Multisource Image Fusion [J]. *Infrared Technology*, 2023, 45(5): 488-497.
- [31] Dong Chunru, Chen Linlin, Liu Yuchen, et al. An improved feature aggregation network for photovoltaic cell defect detection[J]. *Journal of Renewable and Sustainable Energy*, 2025, 17(1): 013503.
- [32] 谢雨杰, 杜友田, 张潇, 等. 面向新概念学习的图像描述生成模型[J]. *西安交通大学学报*, 2020, 54 (12): 37-44.
- Xie Yujie, Du Youyu, Zhang Xiao, et al. An Image Description Generation Model for the Learning of Novel Concepts [J]. *Journal of Xi'an Jiaotong University*, 2020, 54 (12): 37-44.
- [33] Boubaker S, Kamel S, Ghazouani N, et al. Assessment of machine and deep learning approaches for fault diagnosis in photovoltaic systems using infrared thermography[J]. *Remote Sensing*, 2023, 15(6): 1686.
- [34] Wang B, Chen Q, Wang M, et al. Photovoltaic fault classification dataset (PVF-10): A high-resolution unmanned aerial vehicle thermal infrared image dataset for fine-grained photovoltaic fault classification[J]. *Applied Energy*, 2024, 376: 124187.

(编辑 曹康莹 杜秀杰)