

# 面向电力缺陷场景的小样本图像生成适应

杨 岚<sup>1</sup> 赵金雄<sup>1</sup> 李志茹<sup>1</sup> 张 驯<sup>1</sup> 狄 磊<sup>1</sup> 蔡云婕<sup>2</sup> 张和慧<sup>1</sup>

<sup>1</sup> 国网甘肃省电力公司电力科学研究院 兰州 730070

<sup>2</sup> 华东理工大学信息科学与工程学院 上海 200237

(245485572@qq.com)

**摘要** 在电力系统的运行与维护中,及时准确地检测电力缺陷对保障系统安全稳定至关重要。然而,由于电力缺陷场景图像数据难以获取,深度学习模型常面临训练样本不足的问题。为解决这一难题,将扩散模型应用于电力缺陷图像生成,并提出了一种基于纹理调制和 EMA 参数更新的小样本生成适应方法,以扩展电力缺陷图像数据集。具体而言,在扩散模型中引入了纹理调制模块,通过两阶段注入机制,提升了图像的细节捕捉能力与空间结构对齐能力。此外,设计了一种 EMA 参数更新的跨域适应训练策略,结合风格损失与扩散损失,平滑了模型训练过程,提升了生成图像的质量与稳定性。实验结果表明,该方法在多个电力设备缺陷小样本数据集上表现出色,生成图像具有较高的空间结构一致性与细节还原能力,展现了其在电力缺陷检测中的应用潜力。

**关键词:** 电力缺陷;小样本图像生成;生成适应;扩散模型;纹理调制;指数移动平均

**中图分类号** TP391

## Few-shot Image Generative Adaptation for Power Defect Scenes

YANG Lan<sup>1</sup>, ZHAO Jinxiong<sup>1</sup>, LI Zhiru<sup>1</sup>, ZHANG Xun<sup>1</sup>, DI Lei<sup>1</sup>, CAI Yunjie<sup>2</sup> and ZHANG Hehui<sup>1</sup>

<sup>1</sup> Electric Power Research Institute, State Grid Gansu Electric Power Company, Lanzhou 730070, China

<sup>2</sup> School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200237, China

**Abstract** In the operation and maintenance of power systems, timely and accurate detection of power defects is crucial to ensure the safety and stability of the system. However, due to the difficulty in obtaining image data of power defect scenes, deep learning models often face the problem of insufficient training samples. To solve this problem, this paper applies the diffusion model to power defect image generation and proposes a few-shot generative adaptation method based on texture modulation and EMA parameter update to expand the power defect image dataset. Specifically, this paper introduces a texture modulation module into the diffusion model, and improves the image's detail capture ability and spatial structure alignment ability through a two-stage injection mechanism. In addition, this paper designs a cross-domain adaptive training strategy for EMA parameter update, which combines style loss and diffusion loss to smooth the model training process and improve the quality and stability of generated images. Experimental results show that this method performs well on multiple few-shot datasets of power equipment defects, and the generated images have high spatial structure consistency and detail restoration capabilities, showing its application potential in power defect detection.

**Keywords** Power defect, Few-shot image generation, Generative adaptation, Diffusion model, Texture modulation, Exponential moving average

## 1 引言

电力设备在现代社会中扮演着至关重要的角色,其运行的可靠性和安全性不仅直接影响到社会的正常运转,还对经济的可持续发展具有深远的影响。因此,及时准确地检测和诊断电力设备中的缺陷,是保障电力系统稳定运行的重要任务。通过有效的缺陷检测,可以预防潜在故障的发生,减少因设备故障带来的停电事故,进一步延长设备的使用寿命,降低设备维护和更换成本<sup>[1-3]</sup>。然而,在实际操作中,电力缺陷检

测却面临着诸多挑战。电力系统通常在复杂且危险的环境中运行,这使得电力缺陷图像的获取过程不仅成本高昂,还会伴随着一定的安全风险<sup>[4-6]</sup>。此外,电力设备缺陷的发生概率较低,导致实际收集到的缺陷图像样本数量极为有限。数据稀缺性成为了应用传统数据驱动的机器学习方法进行缺陷检测的主要障碍<sup>[7]</sup>。这种稀缺性限制了模型的训练效果,使得在实际应用中难以达到理想的检测精度。

针对上述问题,面向电力缺陷场景的小样本图像生成技术逐渐成为新的研究方向。这一技术旨在通过合成缺陷图像

基金项目:甘肃省科技计划项目青年科技基金(23JRRA1358);国家电网有限公司科技项目(SGGSKY00XTJS2400108)

This work was supported by the Youth Science and Technology Fund of Gansu Provincial Science and Technology Program(23JRRA1358) and Science and Technology Program of State Grid Corporation Limited(SGGSKY00XTJS2400108).

通信作者:赵金雄(jxzhao1229@163.com)

来补充实际样本,从而缓解数据稀缺的问题。这不仅有助于提高缺陷检测模型的训练效果,还为提升电力系统的智能化检测能力提供了新的思路。通过发展电力缺陷场景的图像生成技术,可以为电力设备的维护和管理提供更强大的技术支持,从而更好地保障电力系统的可靠性和安全性。在当前的研究领域中,主要的图像生成方法包括生成对抗网络<sup>[8]</sup>(GAN)、变分自编码器<sup>[9]</sup>(VAE),以及基于迁移学习的生成方法。这些方法各自具备独特的优势和应用场景。生成对抗网络因其生成逼真图像的能力,已成为图像生成技术的前沿工具<sup>[10]</sup>。通过对抗训练,生成对抗网络能够在复杂的电力缺陷场景中生成高度仿真的合成图像。

例如,Zhang 等<sup>[11]</sup>提出的 Defect-GAN,专注于高保真度缺陷图像的合成,显著提高了自动化缺陷检测系统的可靠性。Shi<sup>[12]</sup>提出的 DefectDiffu 技术,通过一致性建模,解决了在少样本条件下生成高质量缺陷图像的难题,从而增强了生成图像的质量和多样性。Chen 等<sup>[13]</sup>则利用 MVSA-GAN 框架,结合自注意力机制与全局-局部融合策略,在电力系统数据匮乏的情况下,成功生成了多样化且逼真的缺陷图像,缓解了模型训练中的数据不足问题。DFMGAN<sup>[14]</sup>等方法通过在预训练的 StyleGAN2<sup>[15]</sup>模型上增加缺陷感知残差块,生成高保真度和多样化的电力缺陷图像。这些方法不仅保留了无缺陷图像的生成能力,还通过细化网络的不同层次,实现了对缺陷区域的精准操控。此外,WaveGAN<sup>[16]</sup>通过频率感知的生成对抗网络架构,进一步提升了生成图像的细节和真实性,适用于电力缺陷场景中的复杂环境。尽管上述基于 GAN 的方法在一定程度上缓解了数据不足的问题,但它们也存在一些明显的缺点。首先,GAN 模型在实际训练过程中往往面临着训练不稳定的问题,生成器和判别器之间难以实现良好的同步。其次,GAN 模型的训练过程往往不稳定,容易出现模式崩溃等问题,需要大量的计算资源和经验调整。此外,在小样本数据条件下,GAN 模型的泛化能力常常不足,难以生成具有高度真实性和丰富多样性的图像。

针对 GAN 方法的这些不足,基于扩散模型的图像生成方法近年来引起了研究人员的广泛关注。扩散模型是一类新兴的生成模型,通过模拟图像从噪声到清晰的过程来生成图像,在图像生成领域展现了广泛的应用潜力。例如,Ho 等<sup>[17]</sup>提出的扩散模型(Denoising Diffusion Probabilistic Models, DDPM)模型成功应用于高保真度图像生成,并在多项基准测试中取得了领先的性能。此外,Nichol<sup>[18]</sup>通过改进扩散模型的采样策略,不仅加快了生成速度,还显著提升了图像质量。扩散模型的应用范围非常广泛,包括自然场景生成、医学影像合成以及复杂纹理的生成和艺术风格迁移等领域。在这些应用中,扩散模型展示了优越的生成能力和广泛的适应性。

尽管扩散模型在多个领域取得了显著进展,但在电力缺陷场景中仍然缺乏应用。为了填补这一空白,将扩散模型引入电力缺陷图像生成场景中,并提出了一种创新的基于纹理调制和 EMA 参数更新的小样本图像生成适应方法。首先,在扩散模型结构中加入纹理调制模块,通过两阶段注入机制,将外部的电力设备语义信息有效地融合到内部的缺陷纹理特征中,以捕捉图像中的细节信息。在第一阶段,通过两层卷积将缺陷的纹理特征与电力设备的语义特征进行融合,实现更细粒度的纹理调制,以增强对缺陷区域的准确识别。在第二

阶段,为防止纹理信息被过多的语义信息所覆盖,对调制特征进行归一化,并将其与第一阶段的纹理调制结果进行融合,从而实现更细粒度的纹理表示,确保电力设备缺陷的准确表达。此外,本文设计了一种 EMA 参数更新的跨域适应训练策略,利用指数移动平均方法,结合风格损失和扩散损失,平滑参数更新过程。这种策略不仅提升了扩散模型生成电力缺陷图像的质量,还显著提高了模型的稳定性。最后,通过一系列定性和定量实验,验证了所提出方法在多个电力设备缺陷小样本数据集上的有效性和泛化性,证明了其在电力设备缺陷检测中的应用潜力和优势。

本文的主要贡献包括:

1)提出了基于纹理调制的扩散模型,用于电力缺陷图像的小样本生成。通过将电力设备的语义信息与缺陷纹理特征相结合,实现了更细粒度的纹理调制,从而提升了生成图像的细节表现力;

2)设计了一种 EMA 参数更新的跨域适应训练策略,结合指数移动平均方法与风格损失、扩散损失,有效平滑了模型参数的更新过程,进一步提高了生成图像的质量和模型的稳定性;

3)通过定量和定性的实验评估,全面验证了所提方法在多个小样本数据集上的性能表现,证明了其在电力缺陷图像生成中的有效性和泛化能力;

4)对电力缺陷图像进行了数据增强并进行不同风格的生成适应,成功构建了一套数据增强样本库,为电力设备缺陷检测提供了更加丰富和多样化的训练数据资源。

## 2 相关工作

### 2.1 小样本图像生成适应

小样本生成适应的核心任务是将预训练的大规模源域生成模型的知识有效转移到数据有限的目标域<sup>[19]</sup>。与传统的迁移学习类似,小样本生成适应旨在快速高效地应用从大规模数据集中学到的知识转移到目标域(如仅有少量样本的特定图像类别)中。这一任务的关键挑战在于,确保模型在适应过程中既能继承源域模型的结构和多样性,又能捕捉目标域的特性。

迁移学习与微调策略是常用的技术之一。迁移学习通过在较大的数据集上预训练模型<sup>[20]</sup>,然后将其部分或全部权重迁移到小样本目标数据集上,再通过微调使其适应新的任务。然而,这种方法容易导致生成图像的多样性和真实性下降,因为模型可能会过度拟合小样本数据特征。研究者为此引入了风格适应和内容保持等技术,在保持图像内容一致性的同时增强模型的适应性。数据增强技术通过在原始小样本数据上进行旋转、缩放、裁剪等变换,可以扩大训练数据的多样性,改善模型的泛化能力。在电力缺陷场景中,数据增强有助于生成更多样化的缺陷图像,从而更好地捕捉不同类型的缺陷。但在一些复杂的电力缺陷场景下,简单的几何变换可能不足以捕捉缺陷的核心特征。正则化技术如 dropout 和权重衰减,通过抑制模型的过拟合倾向,提升了模型在新数据上的泛化能力。在电力缺陷图像生成中,正则化可以防止模型在小样本数据上过度拟合,确保生成图像的高保真度和多样性。然而,过强的正则化可能削弱模型的学习能力,进而影响生成图像的质量。最近,扩散模型成为小样本生成适应领域的

新兴技术。扩散模型通过逐步去噪生成图像,具有较高的稳定性和适应性,特别是在小样本数据条件下,能够有效避免传统GAN中的模式崩溃问题。然而,扩散模型的计算开销大,训练时间长,特别是在需要适应新领域时,其收敛速度较慢,这在实际应用中仍是一大挑战。

## 2.2 扩散模型

扩散模型近年来在图像生成领域中取得了显著的进展,并迅速成为生成模型研究中的热点。其核心思想是通过模拟图像从噪声到清晰图像的逐步去噪过程,来生成高质量的图像。在正向扩散阶段,数据点  $x_0$  被逐步加入噪声生成一系列中间变量  $x_1, x_2, \dots, x_T$ , 其中  $T$  表示扩散过程的总步数。该过程通常采用加权的高斯噪声进行建模,每一步的转移概率为  $q(x_t | x_{t-1})$ 。随着步数的增加,数据点逐渐变得无关紧要并趋于高斯分布。在逆向扩散阶段,模型学习从噪声  $x_T$  到数据点  $x_0$  的逆转过程。通过学习参数化的逆向扩散过程  $p_\theta(x_t | x_{t-1})$ , 模型能够一步一步地将噪声还原为接近真实数据分布的样本。该逆向过程的训练通常采用变分推断技术,目标是 minimized 数据点和模型生成样本之间的差异。

与传统的生成对抗网络相比,扩散模型避免了生成器和判别器之间的对抗训练,因而表现出更高的稳定性和生成图像的多样性。早期的扩散模型如DDPM,通过定义一个正向扩散过程和一个逆向去噪过程,成功实现了高质量的图像生成。DDPM<sup>[17]</sup> 在多种图像生成任务中表现出色,成为扩散模型研究的基础。随着研究的深入,许多改进的扩散模型被提出。例如,IDDPM<sup>[18]</sup> 通过改进网络结构和优化过程,进一步提升了图像生成的效果。隐扩散模型<sup>[21]</sup> (Latent Diffusion

Model, LDM) 通过在潜在空间进行扩散过程,显著减少了计算成本,同时保持了生成图像的高质量。扩散模型已被广泛应用于图像修复、图像超分辨率、图像合成等任务。例如,SR3<sup>[22]</sup> (Super-Resolution via Repeated Refinement) 通过多次迭代的去噪过程,实现了图像的超分辨率重建。

## 3 方法

### 3.1 数据预处理

为在训练中更加容易提取数据的相关信息,本文对目标域的数据进行了预处理。数据预处理包括归一化技术与数据增强。

数据归一化处理是数据挖掘的一项基础工作,不同评价指标往往具有不同的量纲和量纲单位,这样的情况会影响到数据分析的结果,为了消除指标之间的量纲影响,需要进行数据标准化处理,以解决数据指标之间的可比性。原始数据经过数据标准化处理后,各指标处于同一数量级,适合进行综合对比评价。其中最典型的就是数据的归一化处理,即将数据统一映射到  $[0, 1]$  区间上。

$$x^* = \frac{x - \min}{\max - \min} \quad (1)$$

其中,  $\max$  为样本数据的最大值,  $\min$  为样本数据的最小值。

为了扩充数据集,对电力设备缺陷图像进行了多种数据增强操作,以解决小样本问题并提高模型的泛化能力。数据增强是一种有效的技术,通过对现有数据进行变换和处理生成新的样本,从而增加数据集的多样性和规模。这些操作包括水平翻转、垂直翻转、旋转、缩放、裁剪和高斯模糊,如图1所示。




图1 数据增强示例

Fig. 1 Example of data augmentation

### 3.2 整体框架

本文提出了一种基于纹理调制扩散模型的小样本图像生成适应方法,其总体流程如图2所示。

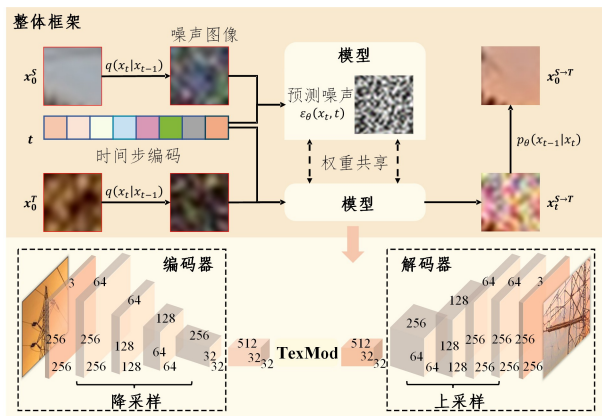


图2 模型整体框架

Fig. 2 Overall framework of the proposed model

该方法首先在源域图像  $x_0^s$  上进行模型训练,通过添加噪声  $q(x_t | x_{t-1})$  逐步生成噪声图像  $x_t$ 。每个时间步  $t$  被嵌入高

维空间,生成时间步嵌入向量并输入模型中,Diffusion模型负责在每个时间步预测噪声  $\epsilon_\theta(x_t, t)$ 。其中,纹理调制模块(TexMod)使用编码器从目标图像中提取参考特征  $\mathcal{F}_{\text{ref}}$  和调制特征  $\mathcal{F}_{\text{mod}}$ , 通过多个卷积层和归一化层处理并应用适当的权重  $\alpha$  和  $\beta$  进行组合,生成调制后的特征  $\hat{\mathcal{F}}_{\text{mod}}$ 。最后,解码器将这些调制后的特征用于生成最终的目标域图像  $x_0^{s-T}$ 。在目标域的适应过程中,通过指数移动平均跨域适应策略,能够有效平滑参数的更新过程,缓解了小样本跨域适应中的不稳定性。通过这种方式,本文模型不仅保留了源域结构特征,同时赋予了生成图像目标域的纹理和风格,从而实现了高质量的小样本图像生成。

### 3.3 纹理调制

纹理调制模块用于将外部语义信息注入到内部特征中,从而增强生成模型的表现。图3展示了纹理调制方法的具体流程。首先,从编码器提取  $K$  ( $K=3$ ) 个特征  $\mathcal{F} = \{\mathcal{F}_k |_{k=1}^K\}$ ,  $\mathcal{F}_k \in \mathbb{R}^{w \times h \times c}$ , 其中  $w, h, c$  表示特征维度。接着随机选择一个特征  $\mathcal{F}_{\text{mod}}$  作为调制特征,剩余的参考特征  $\mathcal{F}_{\text{ref}}$  用于信息注入。最终,通过两阶段注入机制获得调制后的特征  $\hat{\mathcal{F}}_{\text{mod}}$ 。

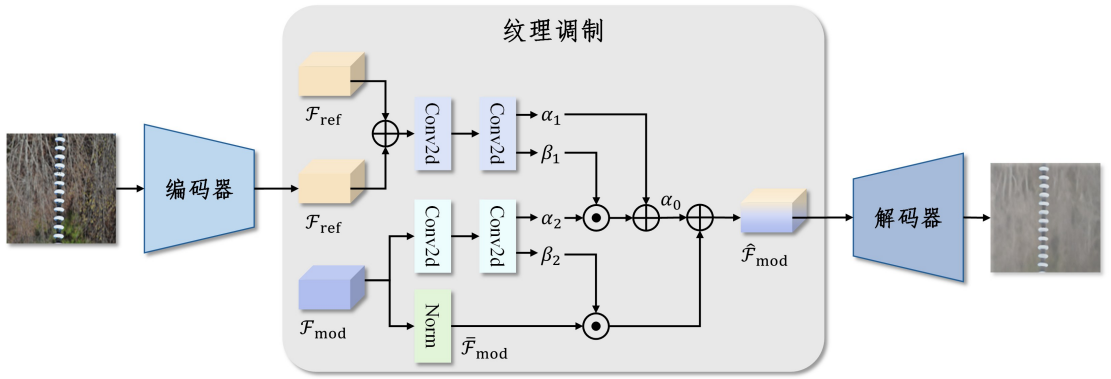


图3 纹理调制模块示意图

Fig. 3 Texture modulation module diagram

### 第一阶段注入

为了获得合理的纹理调制权重,在选定的调制特征  $\mathcal{F}_{\text{mod}}$  和参考特征  $\mathcal{F}_{\text{ref}}$  的和上分别执行两个卷积操作,得到两组调制参数  $(\alpha_1, \beta_1)$  和  $(\alpha_2, \beta_2)$ 。二维卷积不仅编码本地特征的语义信息,还生成可学习参数,使得融合过程更加可控和细致。第一阶段的纹理调制通过式(2)实现:

$$\alpha_0 = (1 + \beta_1) \odot \alpha_2 + \alpha_1 \quad (2)$$

其中,  $\odot$  表示逐元素相乘,  $\alpha_0$  是用于第二阶段调制的参数。所有参数与选择的特征  $\mathcal{F}_{\text{mod}}$  共享相同的维度。

### 第二阶段注入

在第一阶段中,参考特征的语义表示已注入到选定特征  $\mathcal{F}_{\text{mod}}$  中。然而,整体纹理可能会被语义融合所覆盖。因此,首先对选定特征进行归一化,获得归一化特征  $\bar{\mathcal{F}}_{\text{mod}}$ 。然后,利用调制参数  $\alpha_0$  和  $\beta_2$  进行第二阶段的注入:

$$\hat{\mathcal{F}}_{\text{mod}} = (1 + \beta_2) \odot \bar{\mathcal{F}}_{\text{mod}} + \alpha_0 \quad (3)$$

其中,  $\bar{\mathcal{F}}_{\text{mod}}$  是归一化后的调制特征,  $\hat{\mathcal{F}}_{\text{mod}}$  是输出特征,其保持了  $\mathcal{F}_{\text{mod}}$  的纹理,同时编码了参考特征  $\mathcal{F}_{\text{mod}}$  的丰富语义细节。此外,调制特征在每个训练回合中随机选择,涉及更多的语义变异以进行注入。最终,调制后的特征  $\hat{\mathcal{F}}_{\text{mod}}$  被传递到解码器,用于合成新图像。

至此,通过所提出的两阶段调制机制,可以实现更细粒度的纹理调制。这是因为所有参考特征的语义信息都被整合到语义融合中,从而显著提高了生成图像的多样性。此外,调制权重根据模型的反馈进行优化,确保了图像保真度不受影响。这种反馈机制使得生成的图像不仅在语义上更加丰富,而且在视觉上也保持高质量。

### 3.4 EMA 参数更新

在小样本域适应图像生成中,由于源域和目标域数据分布的差异,直接训练的模型可能难以在目标域上取得良好的生成效果。为此,本文引入了基于 EMA 的方法来进行跨域训练,以提升模型的适应性和生成效果。EMA 是一种平滑技术,通过对模型参数进行加权平均,使得更新后的模型参数不仅包含当前迭代的梯度信息,还保留了之前若干步迭代的历史信息。具体来说,EMA 的更新公式为:

$$\theta_t = \mu \theta_{t-1} + (1 - \mu) \theta_0 \quad (4)$$

其中,  $\theta_t$  为时间  $t$  步迭代的参数,  $\theta_{t-1}$  为时间  $t-1$  步迭代的参数,  $\mu$  为平滑系数,通常取值在  $(0, 1)$ 。通过这种 EMA 参数更

新方式,能够在一定程度上缓解模型在目标域训练初期的不稳定性,从而提高生成结果的质量和一致性。

在跨域训练中,首先在源域数据上预训练一个基础模型,获取初始模型参数  $\theta_0$ 。在目标域数据上进行微调时,每次迭代中使用目标域数据计算当前模型参数  $\theta$  的梯度,并更新参数。然后按照 EMA 更新公式,更新 EMA 后的参数。在每次迭代中,使用  $\theta_t$  参数进行目标域图像的生成。这样,通过在目标域数据上的逐步调整和 EMA 的平滑效果,模型能够更好地捕捉目标域的特征分布。

为了实现小样本域适应,本文设计了一种综合性的目标函数,结合了多种损失函数来优化模型性能。首先,使用 CLIP<sup>[23]</sup> 作为编码器 E 来嵌入图像。CLIP 已被证明能够从不同域中提取特征,帮助区分域特定和域无关的特征。为了更好地捕捉风格信息,引入了基于 Gram 矩阵的风格损失函数。该损失函数通过计算生成图像  $x_0^{S \rightarrow T}$  和目标图像集合  $T$  之间的风格差异来实现:

$$L_{\text{style}} = \frac{1}{m} \sum_{i=1}^m \omega_i \| \mathbf{G}^l(x_0^{S \rightarrow T}) - \mathbf{G}^l(x_i^T) \|^2 \quad (5)$$

其中,  $\mathbf{G}^l$  表示 Gram 矩阵,  $m \leq 10$  表示目标图像的数量。此外,本文采用了来自 DDPM 的扩散损失函数,在没有内容融合模块的情况下,在目标域  $T$  上训练本文扩散模型:

$$L_{\text{dif}} = \| \epsilon_\theta(x_i^T, t) - \epsilon \|^2 \quad (6)$$

最终的损失函数表示为:

$$L = (1 - \omega(t)) L_{\text{style}}(x_0^{S \rightarrow T}, x^T) + \omega(t) L_{\text{dif}}(x^T) \quad (7)$$

其中,  $\omega(t)$  是平衡函数,用于动态调节不同损失项的权重。

## 4 实验结果

### 4.1 实验设置

#### 1) 实验环境

本研究的实验在一台配备 NVIDIA GeForce RTX 3090 GPU 的服务器上进行,服务器硬件包括 8 核心 CPU、20 GB 内存和 1 张 GPU,运行环境为 Ubuntu 20.04 操作系统。深度学习框架采用 PyTorch 1.12,结合 CUDA 11.4 实现 GPU 加速支持,代码开发基于 Python 3.9。

#### 2) 参数设置

在本研究的实验中,训练过程中的批量大小为 4,随机种子固定为 42,以确保结果的可复现性。优化器选择了 Adam,其学习率设为  $1 \times 10^{-4}$ 。Diffusion 模型的时间步数  $T$  设置为 1000 步,模型网络结构基于 UNet 架构,特征维度为 64,

并采用(1,2,4,8)的特征倍增因子以支持两阶段样式条件生成,超参数阶段步数设置为300步,特征一致性损失权重和样式损失权重均设为1。

### 3)数据集

本研究使用源域数据集为非公开数据集,共采集了4600张来自输电线路中的缺陷图像,包括绝缘子破损、绝缘子缺失、绝缘子闪络等10种缺陷类型,具体缺陷类型如表4所列。

表1 不同指标定量评估结果

Table 1 Quantitative evaluation results of different indicators

指标	方法	黄昏		覆冰		雾霾	
		10 样本	5 样本	10 样本	5 样本	10 样本	5 样本
IS ↑	WeditGAN	<b>4.369</b>	<b>4.820</b>	4.679	4.511	10.436	10.650
	PCF	3.958	4.741	4.858	4.325	9.791	9.503
	Ours	3.721	4.616	<b>5.287</b>	<b>4.822</b>	<b>10.894</b>	<b>10.774</b>
SCS ↑	WeditGAN	0.495	0.533	0.562	0.470	0.660	0.675
	PCF	0.566	0.603	0.625	0.577	0.762	0.786
	Ours	0.630	0.693	<b>0.720</b>	<b>0.625</b>	<b>0.823</b>	<b>0.826</b>
IC-LPIPS ↑	WeditGAN	0.629	0.624	0.548	0.564	0.640	0.641
	PCF	0.634	0.617	0.578	<b>0.591</b>	0.634	0.659
	Ours	<b>0.638</b>	<b>0.636</b>	<b>0.597</b>	0.581	<b>0.655</b>	<b>0.673</b>




图4 源域和目标域数据集图像

Fig. 4 Source domain and target domain dataset images

### 4.2 定性分析

对提出的网络进行了定性分析,从生成图像的视觉效果来证明本文方法的优越性。通过将不同目标域场景的类别图像输入训练好的图像生成模型,模型根据输入的图像生成一系列的虚拟图片。图5为模型在目标域图像上的生成结果图,可以观察到,生成的不同风格的目标域图像具备真实性和多样性,同时对不同场景下的缺陷图片都具有较好的处理效果,具有较强的鲁棒性。模型不仅保留了原始缺陷的主要特征,还结合了在其他缺陷类别图像上学习到的特征。结果显示,生成的其他场景电力缺陷图像在视觉上与真实图像较相似,能够有效捕捉电力缺陷的特征。

图5给出了提出的扩散模型在不同目标域电力缺陷场景(包括雾霾、黄昏、覆冰)下的图像生成效果。通过对比源域图

目标域数据集则包含少量不同风格的电力缺陷图像,如黄昏、覆冰和雾霾场景。图4为源域和目标域数据集的图像示例。根据设备缺陷情况在图中的位置,将背景滤除,仅保存包含电力设备缺陷的部分,其好处在于,滤除对模型训练无关的背景信息,加快模型的训练速度。数据预处理步骤包括图像归一化、裁剪和数据增强等,预处理后的图片分辨率统一设定为256×256。

像和生成的目标域图像,可以清晰地看出模型的生成能力。在雾霾场景下,生成的电力缺陷图像能够很好地模拟低能见度条件下的特征。




图5 模型在目标域上的生成图

Fig. 5 Model generated images on the target domain

与源域图像相比,生成图像整体色调更为灰暗,物体边缘呈现轻微模糊,但电力设备的关键细节依然清晰可辨。这表明本文模型在处理复杂的雾霾条件时,能够保持缺陷信息的完整性,并生成与实际雾霾环境较一致的图像。黄昏场景的生成图像则展现了典型的光照变化特征。通过与源域图像对比可以发现,生成图像在黄昏时段的光照条件下,成功地再现了自然的橙红色背景光,并在电力设备的结构上保留了清晰的细节。同时,生成图像中的光影效果也较为自然,设备表面反射出柔和的光线,进一步验证了本文模型在应对复杂光照变化时的鲁棒性。在覆冰场景下,生成的图像准确地表现了冬季冰冻环境中电力设备的特征。绝缘子和导线上附着了明显的冰层,场景整体色调呈现出寒冷的氛围。尽管冰层覆盖了一部分细节,生成图像依然能够精确还原电力设备的结构,说明本文模型在极端天气条件下,在处理细节纹理方面具有良好的适应性。通过对比这些场景下的生成结果,定性分析显示出

提出的扩散模型在多种环境条件下都能生成高质量且具备一致性的电力缺陷图像。

#### 4.3 定量分析

与最新生成适应模型 PCF<sup>[24]</sup> 和 WeditGAN<sup>[25]</sup> 进行了 10 样本和 5 样本场景的对比实验。在定量评估中,采用了 IS (Inception Score), SCS<sup>[26]</sup> (Structural Consistency Score) 和 IC-LPIPS<sup>[27]</sup> (Intra-cluster pairwise LPIPS distance) 等指标衡量生成图像的质量。IS 用于评估生成图像的质量,其值越高表示生成图像质量越好。IC-LPIPS 通过衡量生成图像在相同集群内的 LPIPS 距离来评估其多样性。具体而言,如果某个方法完全重现了原始图像,其得分将为零。所以较高的 IC-LPIPS 值表明生成的图像更加多样化,视觉上更加独特。SCS 则用于评估模型生成的目标域图像与源域图像之间的空间结构一致性。值得注意的是,过拟合模型的 SCS 会非常低,因为它不能生成与源域图像空间结构相似的图像。表 1 为模型生成图像的不同评估指标的评估结果。

实验结果表明,经过目标域生成适应后的扩散模型在电力缺陷图像生成任务中表现出优异的性能,特别是在 IS, SCS 和 IC-LPIPS 等指标上均取得了良好的结果。与基线模型相比,尤其是 SCS 和 IC-LPIPS 指标的分数有显著提高,表明本文方法能够有效提升生成图像的空间结构一致性和数据多样性。IS 分数的提升反映了本文方法在生成图像的局部细节上也表现出较强的保真度,生成的图像不仅在宏观结构上与目标域一致,还能够在微观层面显示出细致的纹理信息。SCS 分数的显著提高则进一步证明了生成图像与源域图像在空间结构上的一致性。本文生成模型能够更好地捕捉电力设备缺陷的空间特征,并有效对齐源域和目标域的空间结构,使生成的图像在全局和局部结构上更接近真实分布。此外,IC-LPIPS 分数的提升突显了本文模型在保留目标域特征的同时,具有生成更为真实且多样化的缺陷图像的能力。该效果得益于提出的纹理调制模块,该模块能够从目标域中提取精确的视觉特征,并通过两阶段调制机制将这些特征逐步注入生成过程中。第一阶段进行粗粒度的纹理调制,确保全局结构的对齐;而第二阶段则通过细粒度的调制机制,进一步增强局部细节的表现力。这种逐层细化的纹理调制过程,使得生成的电力缺陷图像在视觉上更加真实,能够有效地反映出真实设备缺陷的特征。

#### 4.4 消融实验

为了评估提出的方法中各个模块的有效性,针对黄昏风格的 10 样本和 5 样本场景设置了消融实验。具体来说,分析了 EMA 参数更新模块、纹理调制模块 (TexMod) 在小样本图像生成框架中的贡献。表 2 为消融实验的结果。消融实验结果表明,EMA 和 TexMod 各自都对所有指标的性能提升有所贡献。然而,EMA 和 TexMod 两个模块的结合提供了最高的得分,证实了将这两种技术整合到本文模型中的有效性。EMA 通过平滑参数更新,稳定了训练过程,提升了生成图像的质量;而 TexMod 通过参考特征和调制特征语义的注入与融合,提高了生成图像的纹理细节和空间结构一致性。这种协同效果在 5 样本设置中尤为显著,突显了本文方法在小样本环境下的鲁棒性。

表 2 消融实验结果

Table 2 Ablation experiment results

指标	方法	黄昏	
		10 样本	5 样本
IS ↑	EMA	3.231	3.924
	TexMod	3.624	3.983
	EMA+TexMod	<b>3.721</b>	<b>4.616</b>
SCS ↑	EMA	0.587	0.620
	TexMod	0.612	0.644
	EMA+TexMod	<b>0.630</b>	<b>0.693</b>
IC-LPIPS ↑	EMA	0.614	0.619
	TexMod	0.629	0.629
	EMA+TexMod	<b>0.638</b>	<b>0.636</b>

#### 4.5 计算效率对比实验

同时设置了计算效率的对比实验,结果如表 3 所列,涵盖了训练时间、模型参数量、GPU 显存占用以及 FLOPs(浮点操作数)等指标。所有实验均在相同的硬件和软件环境下进行。实验结果显示,相较于基线模型,本文方法的训练时间和模型参数量略微有所增长,但所带来的 GPU 显存占用和计算量的增长幅度均处于可接受范围内。这表明本文方法在引入附加模块时仅增加了少量的计算开销,在保持计算资源需求可控的同时,增强了模型的表现能力。

表 3 计算效率对比实验

Table 3 Computational efficiency comparison experiment

方法	训练时间/h	参数量	GPU/MB	FLOPs/GMac
Baseline	12.18	45.69×10 <sup>6</sup>	16395	117.07
Ours	12.36	50.41×10 <sup>6</sup>	16515	121.91

#### 4.6 数据增广样本库

为了进一步验证提出的方法在电力缺陷小样本生成中的有效性,并为相关研究提供高质量的训练和测试数据,本文利用模型合成了一套电力缺陷图像样本库。该样本库包含 3 种不同场景下的缺陷图像,具体包括:雾霾场景下生成的 3829 张图像,以及黄昏场景和覆冰场景下各 1150 张图像,具体类别如表 4 所列。这些场景涵盖了电力设备在实际环境中常见的恶劣天气和光照条件,能够为电力缺陷检测和诊断算法提供多样化的样本数据。这些合成图像不仅在视觉上逼真,保留了真实电力缺陷的细节纹理,还在不同场景中展示了丰富的纹理和环境特征,使其能够广泛应用于小样本学习、生成适应等研究领域。研究人员可以在缺少大规模标注数据的情况下,开展更加广泛的电力缺陷检测研究,提升算法的泛化能力和鲁棒性。

表 4 生成的数据增广样本库

Table 4 Generated data augmentation sample library

分类	黄昏	覆冰	雾霾
绝缘子破损	200	200	728
绝缘子遮盖	200	200	160
绝缘子缺失	200	200	192
绝缘子闪络	200	200	730
均压环倾斜	50	50	243
避雷针悬挂腐蚀	50	50	272
绝缘子异物	100	100	211
绝缘子上卸扣腐蚀	50	50	670
可变握具腐蚀	50	50	360
悬架腐蚀	50	50	263
总计	<b>1150</b>	<b>1150</b>	<b>3829</b>

为了证明数据增广样本库的有效性,将增广后的样本库加入到原数据集中进行小样本图像缺陷分类,并在 3-way K-shot 和 5-way K-shot 上进行了实验。如表 5 所列,在增广数据集上进行微调后,模型在 3-way 1-shot 和 3-way 5-shot 上平均准确率分别提升了 1.53% 和 1.13%,在 5-way 1-shot 和 5-way 5-shot 上平均准确率分别提升了 1.2% 和 1.72%,这主要是因为原数据集的电力缺陷图像场景较为单一,通过使用生成适应模型得到其他不同场景的电力缺陷图片,在清晰度、光线等环境条件下为模型提供了更丰富的信息,提升模型学习难度的同时,也增加了模型的泛化能力,最终提升了模型的分

表 5 引入增广数据在小样本任务上的对比结果

Table 5 Comparison results of augmented data on few-shot tasks

平均准确率/%	3-way 1-shot	3-way 5-shot	5-way 1-shot	5-way 5-shot
原数据集	64.51	73.87	<b>47.55</b>	57.03
增广数据集	<b>66.04</b>	<b>75.00</b>	<b>48.75</b>	<b>58.75</b>

**结束语** 在电力系统的运行和维护过程中,及时准确地检测和识别电力缺陷对于保障电力系统的安全和稳定至关重要。然而,电力缺陷场景的图像数据通常难以获取,导致深度学习模型难以获得足够的训练样本。为了解决这一问题,本文首次将扩散模型应用于电力缺陷图像生成场景,并提出了一种基于纹理调制和 EMA 参数更新的小样本生成适应方法,以扩展电力缺陷图像数据集。首先,在扩散模型的基础结构中引入纹理调制模块,并通过两阶段注入机制,能够精确捕捉缺陷图像中的细节信息,同时提高生成图像的空间结构对齐能力。此外,设计了一种 EMA 参数更新的跨域适应训练策略,通过引入指数移动平均方法,结合风格损失和扩散损失,平滑了参数的更新过程。这一策略不仅提升了扩散模型生成电力缺陷图像的质量,还增强了模型的训练稳定性。通过一系列的定性和定量实验,在多个电力设备缺陷小样本数据集上验证了所提出方法的有效性和泛化能力。实验结果表明,本文方法在生成电力缺陷图像方面表现出色,具备较高的空间结构一致性和细节生成能力,展示了其在电力设备缺陷检测中的应用潜力。在未来的研究中,将进一步探究生成样本逼真度与模型检测精度的关系,从而研究更加有效的小样本图像生成方法。

## 参 考 文 献

- [1] ZHAO Z B,JIANG Z G,LI Y X,et al. A review of visual defect detection of power transmission line components[J]. Journal of Image and Graphics,2021,26(11):2545-2560.
- [2] QI D L,HAN Y F,ZHOU Z Q,et al. External defect detection technology of power transmission and transformation equipment based on video images and its application status[J]. Journal of Electronics & Information Technology,2022,44(11):3709-3720.
- [3] HE Y H,SONG Y H,HE S,et al. Small sample image generation method for power defect scenes[J]. Zhejiang Electric Power,2024,43(1):126-132.
- [4] YE F,LUO X Z,SONG Y C,et al. Research on improved RCNN defect detection method for power small metal fittings based on dual feature fusion[J]. Journal of Electronic Measure-
- [5] WANG L,HAO Y T,PAN M R,et al. Research on defect detection algorithm of improved YOLOv5s in power inspection[J]. Computer Engineering and Applications,2024,60(10):256-265.
- [6] HAN R,DAI Z R,JIANG P,et al. Universal defect detection model for power scenarios based on improved YOLOv8[J]. Zhejiang Electric Power,2024,43(4):113-120.
- [7] WANG Y L,FENG T B,SUN N,et al. Power insulator defect detection method integrating attention and multi-scale features[J]. High Voltage Engineering,2024,50(5):1933-1942.
- [8] GOODFELLOW I,POUGET-ABADIE J,MIRZA M,et al. Generative adversarial networks[J]. Communications of the ACM,2020,63(11):139-144.
- [9] KINGMA D P. Auto-encoding variational bayes[J]. arXiv:1312.6114,2013.
- [10] FAN L. Research and application of image data enhancement technology based on generative adversarial network[D]. Hangzhou:Zhejiang University,2022.
- [11] ZHANG G,CUI K,HUNG T Y,et al. Defect-GAN:High-fidelity defect synthesis for automated defect inspection[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision,2021:2524-2534.
- [12] SHI Q,WEI J,SHEN F,et al. Few-shot Defect Image Generation based on Consistency Modeling[J]. arXiv:2408.00372,2024.
- [13] CHEN Y,YAN Y,WANG X,et al. Iot-enabled few-shot image generation for power scene defect detection based on self-attention and global-local fusion[J]. Sensors,2023,23(14):6531-6546.
- [14] DUAN Y,HONG Y,NIU L,et al. Few-shot defect image generation via defect-aware feature manipulation[C]// Proceedings of the AAAI Conference on Artificial Intelligence,2023:571-578.
- [15] KARRAS T,LAINE S,AITTALA M,et al. Analyzing and improving the image quality of stylegan[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,2020:8110-8119.
- [16] YANG M,WANG Z,CHI Z,et al. Wavegan:Frequency-aware gan for high-fidelity few-shot image generation[C]// European Conference on Computer Vision,2022:1-17.
- [17] HO J,JAIN A,ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems,2020,33(1):6840-6851.
- [18] NICHOL A Q,DHARIWAL P. Improved denoising diffusion probabilistic models[C]// International conference on machine learning,2021:8162-8171.
- [19] YANG C,SHEN Y,ZHANG Z,et al. One-shot generative domain adaptation[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision,2023:7733-7742.
- [20] WANG Y,WU C,HERRANZ L,et al. Transferring gans:generating images from limited data[C]// Proceedings of the European Conference on Computer Vision(ECCV),2018:218-234.
- [21] ROMBACH R,BLATTMANN A,LORENZ D,et al. High-resolution image synthesis with latent diffusion models[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,2022:10684-10695.

- [22] SAHARIA C, HO J, CHAN W, et al. Image super-resolution via iterative refinement[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(4): 4713-4726.
- [23] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision[C]// *International Conference on Machine Learning*. 2021: 8748-8763.
- [24] HU T, ZHANG J, LIU L, et al. Phasic Content Fusing Diffusion Model with Directional Distribution Consistency for Few-Shot Model Adaption[C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023: 2406-2415.
- [25] DUAN Y, NIU L, HONG Y, et al. Weditgan: Few-shot image generation via latent space relocation[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2024: 1653-1661.
- [26] XIAO J, LI L, WANG C, et al. Few shot generative model adaption via relaxed spatial structural alignment[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022: 11204-11213.
- [27] OJHA U, LI Y, LU J, et al. Few-shot image generation via cross-domain correspondence[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021: 10743-10752.



**YANG Lan**, born in 1996, postgraduate. Her main research interest is artificial intelligence.



**ZHAO Jinxiong**, born in 1991, Ph.D. His main research interest is electricity artificial intelligence.