

DOI:10.19651/j.cnki.emt.2107139

基于 Tw_Cycle Gan 的绝缘子缺陷样本自动生成技术*

闫志杰¹ 张凌浩² 贾振堂¹ 苏育均³ 赵 琰¹

(1.上海电力大学 电子与信息工程学院 上海 201303; 2.国网四川省电力公司电力科学研究院 成都 610000;
3.国网四川省电力公司凉山供电公司 西昌 615000)

摘要: 生成对抗网络(Gan)被应用于电力巡检缺陷样本生成工作以解决缺陷样本不足问题。目前基于 Gan 的绝缘子缺陷样本生成技术存在如下不足:依赖大量缺陷样本训练且生成量不足;生成质量较差,尺寸较小,难以供目标检测神经网络训练使用。针对上述问题,提出一种基于 Starganv2 的风格迁移目标加权循环一致(Tw_Cycle)Gan 网络,其可借助非缺陷样本训练,并依据非缺陷样本实现一对多缺陷样本生成。为保证缺陷语义不变,加入 Unet 分割网络,使用目标循环一致及目标掩码损失加强绝缘子目标物的约束。通过定性与定量评估,Tw_Cycle Gan 取得了更好的结果。为了验证生成样本的有效性,设计了一种基于真实样本的缺陷检测实验评估方法。结果表明,使用生成缺陷样本扩增训练的同一 YOLOv3 目标检测算法,AP 平均提升 5%左右,Precision 平均提升 4.6%左右,Recall 平均提升 10%左右,F1 平均提升 0.083。

关键词: 生成对抗网络;小样本缺陷数据;分割网络;目标循环一致损失;目标掩码损失
中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Automatic generation technology of insulator defect samples based on Tw_Cycle Gan

Yan Zhijie¹ Zhang Linghao² Jia Zhentang¹ Su Yujun³ Zhao Yan¹

(1. College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 201303, China;
2. State Grid Sichuan Electric Power Company Electric Power Research Institute, Chengdu 610000, China;
3. State Grid Sichuan Electric Power Company Liangshan Power Supply Company, Xichang 615000, China)

Abstract: Generative adversarial network(Gan) is applied to the generation of defect samples for power inspection to solve the problem of insufficient defect samples. The current Gan-based technology of insulator defect sample generation has the following limitations: a large number of defect samples are required for training and the number of generations is insufficient; the quality of the generated samples is poor, the size is small, making it difficult to use for target detection neural network model training. To address the above limitations, a style transfer a target weighted Cycle consistent (Tw_Cycle) Gan is proposed based on Starganv2. The network can use non-defective samples for training, and realize one-to-many defect sample generation based on non-defective samples. In order to ensure the semantics of defects remain unchanged, the Unet segmentation network is added, and the Roi_cyc Loss and the Roi_mask Loss are used to strengthen the constraint of the insulator target. Through qualitative and quantitative evaluation, Tw_Cycle Gan has achieved better results. In order to verify the validity of the generated samples, an experimental evaluation method for defect detection based on real samples is designed. The results show that the same YOLOv3 target detection algorithm that uses synthetic defect samples to amplify training, the AP, increased by about 5% on average, Precision increased by about 4.6% on average, Recall increased by about 10% on average, and F1 increased on average by 0.083.

Keywords: Gan; small sample defect data; segmentation network; Roi_cyc Loss; Roi_mask Loss

0 引言

为实现电网智能化巡检目标,电网尝试引进人工智能

技术来代替巡检过程中人员劳动密集的工作^[1]。目标检测^[2]、分割及识别^[3]在其他领域已经有大量成熟的案例^[4-6]。在电力巡检领域,使用深度学习对电力设备进

收稿日期:2021-07-02

* 基金项目:国家自然科学基金(61802250)项目资助

行缺陷检测的研究也逐渐增多,且取得了不错的成绩^[7-8],但人工智能技术对电力缺陷识别的精度仍然离实用有一定差距。近年来,国家电网有限公司开展了电力缺陷人工智能检测技术的验证工作,结果显示,检测准确率普遍较低,泛化能力很差,难以实际应用^[9]。受光照、背景等影响,相同缺陷在不同环境下表现出的特征并不相同,在缺少多样数据情况下训练的目标检测模型,泛化能力难以保障。而在实际电网巡检中,部分缺陷出现的频率较低,导致缺陷样本难以收集。如何基于当前有限样本,生成大量多样环境风格下的缺陷样本,并能通过样本扩充有效提高缺陷目标检测模型的性能是本文的出发点。

在电力缺陷样本生成相关工作中,Tao 等^[10]提取缺陷绝缘子串掩码,通过人工干预的手段将其与新的背景融合从而实现样本扩增;孙慧等^[11]通过场景建模的方法生成类似的合成缺陷样本。上述方法一定程度上能增加缺陷样本数量,但生成样本并不符合电网真实语义特征,且本质上没有增加样本多样性。生成对抗网络 Gan^[12]凭借生成效果逼真、生成样本丰富的优点被应用到电力图像数据增强领域。当前基于 Gan 的数据增强以两大方向为主,一是生成类数据增强方式,特点是通过学习目标数据分布,从隐空间生成新的数据,但对数据量要求较大。何佳美^[13]使用 DCGAN 进行耐张线夹数据生成,并通过数据扩充提升了分类精度。二是迁移类数据增强方式,特点是通过风格迁移的方式,实现同一图像在不同光照、背景下的迁移。王金娜等^[14]和陆继翔等^[15]使用基于 Cycle-Gan^[16]的方法,实现了不同风格域之间的缺陷绝缘子样本迁移生成,并通过样本扩充提升了分类精度。但 Cycle-Gan 进行图像域之间的迁移,只能生成一倍数据量,且生成样本较为单一。

本文针对小样本缺陷绝缘子数据展开研究,为解决当前缺陷生成模型普遍存在的缺陷样本过度依赖、生成转换比低、生成质量差、生成缺陷样本难以供目标检测神经网络模型训练使用的问题,提出了一种 Tw_Cycle Gan 方法,重点解决了 Starganv2^[17]方法在缺陷样本生成方面不能充分考虑局部目标偏重的问题,为解决绝缘子缺陷样本不足的问题提供一种新的思路,主要创新点如下。

1)该网络以 Starganv2 为基础架构,借助非缺陷样本训练风格迁移器,可将小样本缺陷数据进行大量扩增,且能保证生成样本的多样性。

2)为提升生成质量,保证缺陷在迁移过程中形态不变,加入区域分割网络,同时加入目标循环一致(Roi_cyc Loss)及目标掩码损失(Roi_mask Loss),约束缺陷样本生成。

3)设计了基于 YOLOv3 的真实缺陷检测评估办法来验证生成缺陷样本的真实性及有效性。

1 相关知识

1.1 图像域、风格与风格迁移

风格迁移首先需要进行图像域的划分,而 Starganv2

对域概念的解释如下:域意味着一组图像,其可被分组为一个视觉上有区别的类别,并且域内每个图像都有一个独特的外观,称之为风格^[17]。从一种图像域样本生成其他图像域样本的过程可称为风格迁移。代表性的风格迁移数据集有 horse2zebra、cat2dog、summer2winter 等,其根据外观特征、季节性特征来划分图像域。我们的任务使用真实野外采集的绝缘子数据,其多为无人机俯航拍摄获取。参考 summer2winter 数据集,依据绝缘子图像背景呈现出的季节性特征,可将图像划分为 A 风格域(春夏时期、植被茂盛)与 B 风格域(秋冬时期、植被稀疏)。如图 1 所示,其中 Input 属于 A 风格域下的图像,Ref 则属于 B 风格域下的图像。

1.2 生成对抗网络 Gan

本文核心方法使用 Gan 网络,其包含一对生成器与判别器,二者均由神经网络构成。通过生成器与判别器博弈训练,最终使判别器无法辨别生成器的输出结果,即达到纳什均衡状态。本文方法通过生成器接收源域图像,生成目标域图像,从而实现风格迁移。

2 Tw_Cycle Gan 方法

本节介绍 Tw_Cycle Gan 方法的框架、损失函数以及改进措施。该方法包括 Starganv2 风格迁移器,其用来生成风格迁移的缺陷样本;同时包含一个 Unet 区域分割网络,用来提取绝缘子目标掩码,配合 Roi_cyc Loss、Roi_mask Loss 来约束绝缘子缺陷语义。

2.1 Starganv2 风格迁移器

如图 1 所示,Starganv2 风格迁移网络由生成器 G、映射器 F、编码器 E、判别器 D 4 部分组成。对于输入缺陷样本 Input,给定一非缺陷参考样本 Ref,通过一个风格编码器 E,获取风格编码 $s = E(\text{Ref})$,生成器 G 接收缺陷样本 Input 及 s ,生成基于 Ref 风格下的缺陷样本即 $\text{Output} = G(\text{Input}, s)$,只需更换不同的 Ref,便可生成多种风格下的缺陷样本,达到数据扩充的目的。

Stargan^[18]方法实现了单生成器多域转换的任务,而 Starganv2 则是在 Stargan 的基础上,引入了映射器与编码器用来提取图像风格编码,并可以依据参考图像实现跨域风格迁移工作。考虑到缺陷与非缺陷样本在风格上的差异较小,借助大量非缺陷样本训练风格迁移器,可以获取到许多绝缘子真实场景风格,使缺陷绝缘子样本参考非缺陷样本的场景风格进行迁移,以此可以生成许多较为符合真实场景的缺陷样本。

1) Starganv2 架构

Starganv2 各部分网络均由卷积残差单元与全连接网络构成。实例归一化残差单元如图 2(a)所示、自适应实例归一化残差单元如图 2(b)所示。

(1)生成器:生成器设置下采样、上采样、中间采样 3 部分。下采样过程使用图 2(a)所示的实例归一化残差单元

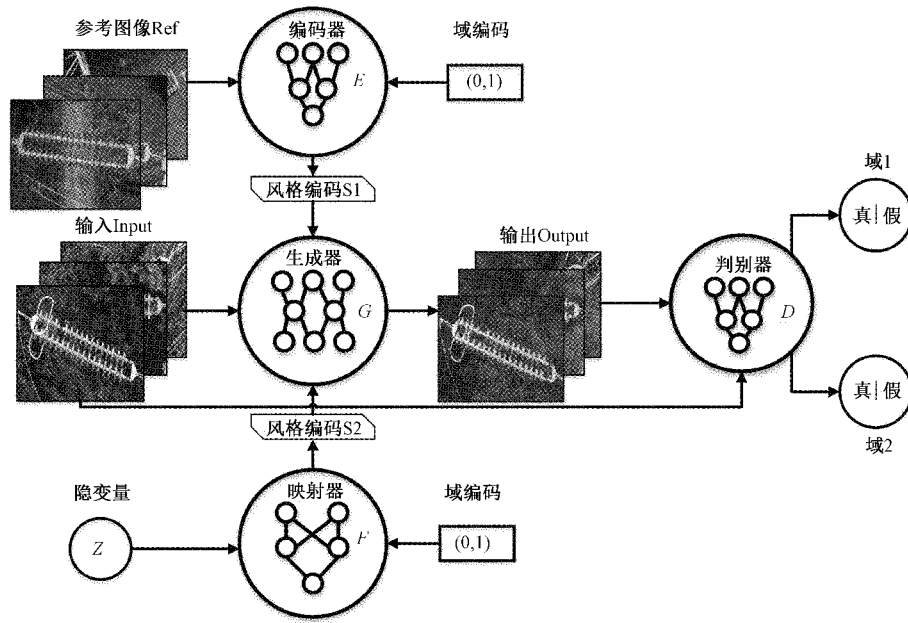


图 1 Starganv2 风格迁移网络

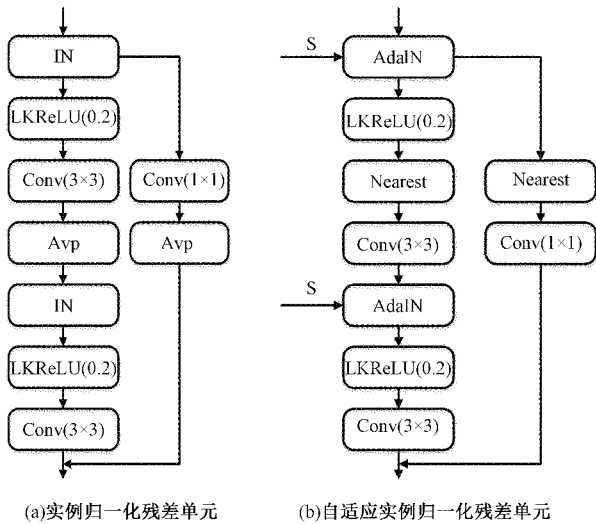


图 2 残差单元结构

(IN Resblock)。其中干路通道使用实例归一化(instance normalization, IN),可以保证样本风格的独立性;使用非线性激活函数(LeakyReLU)激活,通过 3×3 卷积提取特征,并使用平均池化(Avp)实现图像尺寸降低。支路通过一个 1×1 卷积与 Avp 模块调整输出与干路保持一致。上采样部分使用图 2(b)所示自适应实例归一化残差单元(AdaIN Resblock)。其中干路中使用自适应实例归一化(adaptive instance normalization, AdaIN)^[19] 模块将风格 s 嵌入进图像特征中;同样使用 LeakyReLU 激活,不同的是,上采样使用最近邻插值(Nearest)实现图像尺寸扩大,再使用卷积提取特征,而支路使用最近邻插值与 1×1 卷积调整尺寸与干路相同。为保证输出有足够大的分辨率(512×512)

供目标检测模型训练使用,下采样使用 7 组 IN Resblock,上采样使用 7 组 AdaIN Resblock,同时中间采样使用 2 组 IN Resblock、2 组 AdaIN Resblock,去掉 Avp 与 Nearest 模块。

(2)映射器:映射器由 4 层域间共享全连接层,4 层独立全连接层组成。映射器接收随机高斯隐变量 z 以及目标域标签 y ,生成目标域风格编码 $s = F_y(z)$ 。基于隐变量的生成模式能增加生成编码的多样性。将此 s 作为生成器的输入条件可以有效防止模式崩塌,从而不会出现基于不同 s 却生成相同的结果现象。

(3)编码器:编码器使用 7 组 IN Resblock 残差单元,使用全连接层调整输出为每个域对应的一维风格编码的形状。给定参考图像 Ref 及目标域标签 y ,编码器生成 Ref 的风格编码 s 。编码器类似于映射器,不同的是其可提取特定 Ref 的风格编码,将此风格编码输入进生成器,可允许生成器合成反映 Ref 风格的输出图像。

(4)判别器:判别器使用 7 组 IN Resblock 残差单元,去掉所有掉归一化模块,并通过 LeakyReLU 激活函数及卷积操作,将输出调整为每个域对应的真假概率。

2)Starganv2 Loss

为提高生成图像的真实性,使用生成对抗损失来实现 G 与 D 纳什平衡;使用风格重建损失确保 G 使用风格编码;使用风格多样性损失鼓励多样性输出;使用循环一致损失实现不成对图像的迁移。其中生成对抗损失可以描述为:

$$L_{adv} = \log D_y(x) + \log(1 - D_y(G(x, \hat{s}))) \quad (1)$$

式中:给定一个绝缘子图像 x ,其属于绝缘子样本空间 X ,且它的自身域编码为 y , y 属于域编码集合 $Y(0,1)$,其中 0

代表第 0 个域,1 代表第 1 个域。随机生成符合高斯分布的隐变量 z ,并提供一个目标域编码 \hat{y} ,由 F 或 E 产生此域的一个风格编码 \hat{s} 。将 \hat{s} 与 x 同时输入进生成器 G ,得到输出图像 $G(x, \hat{s})$,并由判别器 D 判别生成图像的真假 $(0, 1)$ 。判别器期望生成器的输出为假,而生成器期望此输出为真。值得注意的是,判别器可以判断不同域图像的真假。风格重建损失可以描述为:

$$L_{sty} = \|\hat{s} - E_y(G(x, \hat{s}))\|_1 \quad (2)$$

式中:由 F 或 E 生成风格编码 \hat{s} ,并给定图像 x ,得到输出 $G(x, \hat{s})$,通过风格编码器 E ,将生成图像进行再次编码为 $E_y(G(x, \hat{s}))$ 。损失计算并缩小 $E_y(G(x, \hat{s}))$ 与 \hat{s} 之间的差距,同时强迫生成器使用风格编码进行迁移。风格多样性损失可以描述为:

$$L_{da} = \|G(x, \hat{s}_1) - G(x, \hat{s}_2)\|_1 \quad (3)$$

式中: \hat{s}_1, \hat{s}_2 分别由隐变量 z_1, z_2 经 F 产生。为确保生成图像的多样性,期望使 $G(x, \hat{s}_1), G(x, \hat{s}_2)$ 二者之间差距尽量大,因而在计算总损失时,其前面添加负号。循环一致性损失可以描述为:

$$L_{cyc} = \|x - G(G(x, \hat{s}), \bar{s})\|_1 \quad (4)$$

式中: \hat{s} 仍由 F 或 E 提供; $\bar{s} = E_y(x)$ 为原始域 y 下 x 本身的风格编码,其由编码器 E 提取。 $G(x, \hat{s})$ 再经过 G 得到的循环输出 $G(G(x, \hat{s}), \bar{s})$ 应该与输入 x 保持一致。Starganv2 总损失可描述为:

$$L_{star} = \min_{G, F, E} \max_D L_{adv} + \lambda_{sty} L_{sty} - \lambda_{da} L_{da} + \lambda_{cyc} L_{cyc} \quad (5)$$

式中: λ 为各自损失权重系数,生成对抗损失权重为 1。

2.2 缺少约束的绝缘子样本风格迁移缺点

通过进行 Starganv2 风格迁移训练,生成样本阶段可将缺陷样本参考非缺陷样本的风格进行迁移。但是在实际的风格迁移过程中,如图 3 所示,生成的缺陷绝缘子金具连接处出现了部分玻璃片,缺陷语义遭到改变。出现上述现象原因是风格特征属于全局信息,并包含了参考图像一定的内容信息,由于 Starganv2 设置的损失函数缺乏对绝缘子本身的约束,以此风格为参考进行迁移,难免导致图像本身内容发生一定变化。要想生成多样风格下的缺陷样本,同时保证绝缘子及缺陷形态的尽量保留,就需要对缺陷绝缘子本身加以一定的约束。于是我们引入区域分割网络、Roi_cyc Loss 及 Roi_mask Loss 尝试解决这个问题。

2.3 Unet 区域分割网络

在计算 Roi_cyc Loss 及 Roi_mask Loss 之前,需要提取绝缘子掩码 mask。自爆、掉串的缺陷绝缘子图像,与完好的绝缘子图像相比,只存在局部缺陷差异,几乎不存在额外像素偏差。而对于目标分割而言,是对目标进行逐像素级别的归类,故分割网络能提取缺陷与非缺陷样本的




图 3 缺少约束风格迁移效果

mask。本文采用 Unet 网络提取目标 mask。Unet 是由多层卷积块构成的 encoder-decoder 网络,加入跳跃链接使得网络获取多尺度特征,而且 Unet 支持少量数据来训练模型,一定程度上减少了标注工作量。如图 4 所示,Unet 提取掩码并进行掩码操作的结果。




图 4 绝缘子分割掩码图

2.4 Roi_cyc Loss、Roi_mask Loss

为减小风格迁移过程中参考图像风格内容信息对缺陷绝缘子的影响,保证缺陷语义不变,提出目标循环一致损失 Roi_cyc Loss,同时再添加一个目标掩码损失 Roi_mask Loss,以此来约束绝缘子。目标循环一致损失可以描述为:

$$L_{RoiC} = \|(x - G(G(x, \hat{s}), \bar{s}))mask\|_1 \quad (6)$$

式中:mask 为输入图像 x 的分割掩码图,由预训练好的区域分割网络 Unet 获取。整体损失基于式(4),计算输入 x 、循环输出 $G(G(x, \hat{s}), \bar{s})$ 分别与 mask 做矩阵对应元素相乘后的 L1 距离,期望二者距离尽量小。Roi_cyc Loss 更像是循环一致对抗损失的感兴趣区域加权损失,以此加强局部目标物绝缘子的约束,使其变化减小。目标掩码损失可以描述为:

$$L_{RoiM} = \|(x - G(x, \hat{s}))mask\|_1 \quad (7)$$

式中:生成器 G 将输入 x 生成为目标风格下的图像 $G(x, \hat{s})$,计算输入 x 、输出分别与 mask 做矩阵对应元素相乘后 L1 的距离,期望二者距离尽量小。通过两个损失的加入,可实现在尽量保证缺陷语义特征不变的情况下进行多样风格迁移。Tw_Cycle Gan 网络整体损失可以描述为:

$$L_{total} = \lambda_{star} L_{star} + \lambda_{RoiC} L_{RoiC} + \lambda_{RoiM} L_{RoiM} \quad (8)$$

式中: L_{star} 为 Starganv2 总损失, λ 为各自损失权重系数。

3 实 验

样本组成如表 1 所示。样本由航拍获取,为四川境内真实杆塔线路,多为俯视野外绝缘子图像,风格依据 Starganv2 对域的假设,根据季节性特征呈现出的背景差异划分为两类,A 风格域(春夏时期、植被茂盛)、B 风格域(秋冬时期、植被稀疏)。样本生成实验基于 A、B 风格样本 160 张及大量非缺陷样本 1 220 张。绝缘子为玻璃材质,缺陷类型为典型的绝缘子自爆缺失,同时 90 张其他风格的缺陷样本(其他电力线路获取)不参与样本生成。

表 1 样本组成

风格	缺陷样本	非缺陷样本
A	83	673
B	77	547
其他	90	0
合计	250	1 220

本实验基于 Tensorflow 及 Pytorch 框架,实验使用 1 台 2 路服务器,CPU 为 Intel Xeon Silver 4208,两块 RTX 2080Ti GPU,显存为 11 G。Unet 与 Tw_Cycle Gan 分别在不同 GPU 上运行,整个样本生成模型迭代 80 000 次的时间约为 3 天。本文实验设计主要分两部分:

1)为验证本文方法改善了缺陷样本的生成质量,基于小样本缺陷数据,进行多倍样本生成,将本文方法与原始 Starganv2 方法及其他多模态风格迁移方法做了生成样本定性及定量评估实验。

2)为验证本文方法生成缺陷样本的有效性及真实性,设计了一种基于 YOLOv3 真实样本的缺陷检测实验评估方法。

3.1 生成样本质量对比实验

本文使用 83 张 A 风格、77 张 B 风格缺陷样本,1 220 张非缺陷样本作为训练数据,以此训练 Tw_Cycle Gan。设置 Batch Size 大小为 2,根据实验多次调整 Roi_cyc Loss、Roi_mask Loss 权重系数为 2,Starganv2 原始损失权重设为 1,使用 Adam 优化器, β_1 、 β_2 设为 0.99。生成器、判别器和编码器的学习速率设置为 0.000 1,而映射器的学习速率设置为 0.000 001。

1)生成样本定性评估

图 5 为 Tw_Cycle Gan 基于 2 张 A、2 张 B 风格的非缺陷样本生成的缺陷样本结果;图 6 为 Tw_Cycle Gan 方法与未改进 Starganv2 方法比较结果;图 7 为 Tw_Cycle Gan 方法与其他多模态风格迁移方法比较结果。

如图 5 所示,(a)为真实缺陷样本,(b)为参考非缺陷 A 图,(c)为生成风格 A 缺陷样本,(d)为参考非缺陷 B 图,(e)为生成风格 B 缺陷样本,每张图像尺寸为 512×512 。可以看到每一行的生成结果与参考图像具有相同的风格,

直观上呈现出明暗程度保持一致,同时部分内容物也与参考图像保持一致,如背景的植被情况;每一列的生成结果也包含了真实缺陷样本的内容信息,同时绝缘子会因环境风格不同呈现出不同的外观特征,但绝缘子轮廓变化不大,绝缘子缺陷基本被保留,缺陷语义并未发生改变。风格迁移不仅可以实现域间切换,还可以实现域内切换,即真实缺陷样本可同时参考 A、B 两种风格域内的非缺陷样本进行迁移,增加生成多样性。




图 5 Tw_Cycle Gan 生成缺陷样本

如图 6 所示,(a)为真实输入源图,(b)为参考图像,(c)为 Starganv2 生成结果,(d)为 Tw_Cycle Gan 生成的结果。在 Starganv2 结果中,绝缘子变化程度相对较大,缺陷处生成了部分绝缘子片,缺陷语义被改变;在 Tw_Cycle Gan 结果中,绝缘子变化程度相对较小,缺陷发生部分变化,但缺陷语义并未被破坏。




图 6 改进效果比较

如图 7 所示,将 Tw_Cycle Gan 与其他多模态风格迁移方法 Unit^[20]、Munit^[21] 进行比较,其中(a)为生成源图,(b)为 Unit 生成结果,(c)为 Munit 生成结果,(d)为

Tw_Cycle Gan 生成结果。Unit 生成效果比较差,图像整体模糊严重,绝缘子变化程度较大;Munit 生成效果相对较好,绝缘子及背景保留较为完整,但图像发生模糊;Tw_Cycle Gan 生成结果中绝缘子也较为完整,图像更清晰,同时能将背景做替换。




图 7 与其他方法比较

2) 生成样本定量评估

本文进行消融实验,来评估新添加损失的作用,使用 FID^[22] 距离及 LPIPS^[23] 分数来衡量生成样本的质量与多样性。FID 距离通过使用一个预训练好的 inceptionv3 网络来提取特征,计算生成样本特征与真实目标样本特征的差距,数值小说明样本质量越高,越符合真实样本分布。LPIPS 分数使用预训练 Alexnet 网络,计算生成图像两两之间的相似度,得分越高说明生成样本多样性越丰富。

本文依据 4 种不同参考图像生成样本用以评价,得到结果如表 2 所示。与原始 Starganv2 方法相比,只添加目标循环一致损失,FID 分数有了一定下降,LPIPS 分数有轻微提升;只添加目标掩码损失,FID 分数也有一定下降,但 LPIPS 却也降低了;同时加入两个损失,得到了最好的 FID 分数,但 LPIPS 分数基本不变,同时本文的方法比 Unit、Munit 的 FID 分数更低,比 Munit 的 LPIPS 分数更高。

表 2 生成样本定量评估

方法	FID	LPIPS
Unit	152.32	—
Munit	97.67	0.245 3
Starganv2	89.34	0.292 6
Starganv2+ L_{Roi_cyc}	82.57	0.303 1
Starganv2+ L_{Roi_mask}	85.31	0.282 4
Tw_Cycle Gan	78.26	0.291 8

3.2 基于真实缺陷样本目标检测实验

为了评估生成样本的有效性,使用生成缺陷样本进行数据扩充来训练 YOLOv3 目标检测模型,把检测模型在真

实图像测试集上的性能指标作为评价标准,来验证生成样本的扩充是否有效。将表 1 所示的 250 张真实缺陷样本随机选择 50 张作为测试集,测试集图像不参与任何样本生成,也不作为样本生成过程中的参考图像。随机选择剩余样本中 A 风格、B 风格样本共 50 张,分别以非缺陷样本为参考图像并按照 1:1、1:2、1:3 的比例生成 50、100、150 张合成样本用以数据扩充,数据组成如表 3 所示。

表 3 实验样本组成

组别	样本组成
	200 张真实样本
训练集	200 张真实样本+50 张生成样本
	200 张真实样本+100 张生成样本
	200 张真实样本+150 张生成样本
测试集	50 张真实样本

对于目标检测模型,使用 keras 版本 YOLOv3 目标检测模型,设置 Batch Size 大小为 8,训练集 90% 用于训练,10% 用于训练时验证,学习率余弦退火逐渐降低。为了提高模型的特征提取能力,加速训练,使用基于 CoCo 数据集预训练模型(416×416 尺寸),同时使用镜像翻转、平移变换、图像缩放、色彩抖动数据增强手段。检测模型评价指标使用平均精确率(average precision, AP)、精确率(Precision, Pre)、召回率(Recall, Rec)、以及精确率与召回率的调和平均数(F1-score, F1)。上述评价指标均在预测回归框经过非极大值抑制并且交并比(IOUS)取 0.5 的前提下得出。

在后续测试集验证工作中,选择相同迭代次数的模型进行对比。如图 8 所示,通过获取不同置信度阈值下精确率及召回率分数,绘制得到真实测试集上的 PR 曲线。PR 曲线与坐标轴包围的面积分数代表模型的 AP 值。可以发现,经过扩充数据的训练组,PR 曲线均在未扩充组右上方,AP 值均有提升。




图 8 PR 曲线对比

如表 4 所示,得到真实测试集上的 AP、Pre、Rec、F1 分数。测试结果可以看出,经过扩充样本后的训练集训练,能有效提升检测模型性能。其中扩充数据模型 AP 得分平均提升 5% 左右,Pre 得分平均提升 4.6% 左右,Rec 得分平均提升 10% 左右,F1 分数平均提升 0.083。上述结果表明本文的生成样本切实可以提高检测模型的性能。

表 4 真实样本测试集结果

组别	AP/%	Pre/%	Rec/%	F1
+0	83.57	94.59	63.34	0.76
+50	88.94	97.50	70.91	0.82
+100	88.52	100.00	74.55	0.85
+150	87.50	100.00	75.52	0.86

同时为进一步验证生成缺陷样本的真实性,又做了如下实验:考虑到若是生成缺陷样本一定程度上符合真实样本的分布,则直接使用真实样本训练,用生成样本做测试集,仍然可以取得一定的检测准确率。本文使用 50 张生成缺陷样本作为测试集,使用原始 200 张缺陷样本作为训练集 A 组,考虑到生成源图与生成样本存在相似性关系,于是剔除掉生成源图,将剩余部分作为训练集 B 组,结果如表 5 所示。结果显示,A 组取得了较高的分数,说明改变风格后的生成图像,很大程度上也能保留源图缺陷的语义特征,而剔除生成源图后进行训练的 B 组,得分有了较大程度下降。这是由于剔除掉源图后,训练集数据减少导致多样性变差,因而训练集与测试集差异增大致使性能降低。但仍然可以取得一定的性能指标,证明本文生成的样本是具有一定真实性的,而下降的部分为训练数据多样性欠缺导致。结合表 4,多种风格样本的加入可以弥补这一多样性欠缺。

表 5 生成样本测试集结果

组别	AP/%	Prc/%	Rcc/%	F1
A	94.92	95.61	76.92	0.85
B	66.45	66.75	56.16	0.61

使用真实缺陷样本训练,使用生成样本测试效果如图 9 所示。可以看到,模型仍然可以检测出大部分生成缺陷样本,而对于缺陷不明显的样本,存在漏检现象。

3.3 实验结果分析

实验 3.1 显示,通过生成样本定性评估得出, Tw_Cycle Gan 改进方法一定程度上改善了原始模型缺少局部偏重的问题,更有助于保存缺陷绝缘子样本的语义特征,具有一定真实性。该模型与其他多模态风格迁移模型相比,其生成的样本质量更好,效果更逼真且多样性丰富。但由于需要生成 512×512 大尺寸图像,大大增加了样本生成难度,因而生成样本与真实样本还存在一定的差距。通




图 9 目标检测效果

过生成样本 FID 距离及 LPIPS 分数定量评估得出,改进方法能较大程度提升生成样本质量,这是由于掩码约束使得生成样本目标物细节更贴近原始输入。但多样性与原始方法差异不大,这是由于目标循环一致损失约束二次生成结果,而目标掩码损失直接约束一次生成目标与输入保持一致,因此目标掩码损失会降低一些生成样本的多样性。实验 3.2 显示,虽然生成的缺陷样本并不能达到以假乱真的效果,但使用了生成样本扩充训练的模型,明显提升了检测模型在真实测试集样本上的 AP、Precision、Recall 及 F1 分数。这是由于可以基于真实非缺陷样本的风格进行风格迁移,一定程度上增加了生成样本的真实性及有效性,而将此生成样本加入进训练数据后,增加了训练数据的多样性,提高了检测模型对各式样本的接受能力,扩大了检测边界范围,因而能提高模型的泛化能力。同时直接将合成样本作为测试集,以真实样本为训练集训练模型,仍然取得了一定的评价得分,也能说明生成样本具有的真实性。

4 结 论

本文考虑到绝缘子电力缺陷样本稀缺的现状,借助正负样本全局风格差异较小的特点,使用基于 Starganv2 的 Tw_Cycle Gan 方法,引入非缺陷样本作为辅助训练,减少了模型对缺陷样本的依赖量,并能将缺陷样本按照真实非缺陷样本的环境进行风格迁移,可以实现一对多生成。由于局部缺陷形态特征易在迁移过程中被破坏,本文加入区域分割网络提取目标物掩码,并使用 Roi_cyc Loss 及 Roi_mask Loss 对目标加以强约束。Tw_Cycle Gan 方法能更好地保留缺陷语义特征,比 Unit、Munit 真实性更高,且多样性丰富。同时 Tw_Cycle Gan 方法可生成 512×512 尺寸图像供目标检测模型训练使用。使用合成样本扩充训练的模型,能明显提升其以真实样本为测试集的性能。但该方法目前仍然存局限性:由于当前对图像风格并没有十分严谨的解释,大多数风格域的划分标准具有一定的主

观性,本文按照季节特征划分的 A 风格域、B 风格域并不能涵盖电网所有样本。

在后续工作中计划增加更多风格的电力缺陷样本,且不局限于绝缘子样本,并寻找更合理的数据域划分方式;进行更多检测模型的扩充验证工作,试图寻找样本最佳扩充比例。

参考文献

- [1] 陈庆,闫斌,叶润,等. 航拍绝缘子卷积神经网络检测及自曝识别研究[J]. 电子测量与仪器学报,2017,31(6): 942-953.
- [2] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [3] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [4] 曹红燕,沈小林,刘长明,等. 改进的 YOLOv3 的红外目标检测算法[J]. 电子测量与仪器学报,2020,34(8): 188-194.
- [5] 蔡彪,沈宽,付金磊,等. 基于 Mask R-CNN 的铸件 X 射线 DR 图像缺陷检测研究[J]. 仪器仪表学报,2020, 41(3):61-69.
- [6] 张培培,王昭,王菲. 基于深度学习的图像目标检测算法研究[J]. 国外电子测量技术,2020,39(8):34-39.
- [7] 董召杰. 基于 YOLOv3 的电力线关键部件实时检测[J]. 电子测量技术,2019,42(23):173-178.
- [8] KANG G, GAO S, YU L, et al. Deep architecture for high-speed railway insulator surface defect detection: Denoising autoencoder with multitask learning[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 68(8): 2679-2690.
- [9] 缪希仁,刘志颖,鄢齐晨. 无人机输电线路智能巡检技术综述[J]. 福州大学学报(自然科学版),2020,48(2): 198-209.
- [10] TAO X, ZHANG D, WANG Z, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 50(4): 1486-1498.
- [11] 孙慧,李喆,江一,等. 基于场景建模的电力巡检异物检测样本扩充方法[J]. 电网技术,2021,45(3): 1175-1180.
- [12] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [13] 何佳美. 基于生成对抗网络的电力设备图像扩充模型及算法研究[D]. 成都:电子科技大学,2020.
- [14] 王金娜,苏杰,杨凯,等. 基于 Cycle-GAN 的绝缘子图像生成方法[J]. 广东电力,2020,33(1):100-108.
- [15] 陆继翔,李昊,徐康,等. 基于迁移学习的小样本输电线路巡检图像处理方法[J]. 全球能源互联网,2019, 2(4):409-415.
- [16] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [17] CHOI Y, UH Y, YOO J, et al. Stargan v2: Diverse image synthesis for multiple domains[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 8188-8197.
- [18] CHOI Y, CHOI M, KIM M, et al. Stargan: Unified generative adversarial networks for multi-domain image-to-image translation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8789-8797.
- [19] HUANG X, BELONGIE S. Arbitrary style transfer in real-time with adaptive instance normalization[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 1501-1510.
- [20] LIU M Y, BREUEL T, KAUTZ J. Unsupervised image-to-image translation networks[C]. Advances in Neural Information Processing Systems, 2017: 700-708.
- [21] HUANG X, LIU M Y, BELONGIE S, et al. Multimodal unsupervised image-to-image translation[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 172-189.
- [22] HEUSEL M, RAMSAUER H, UNTERTHINER T, et al. Gans trained by a two time-scale update rule converge to a local nash equilibrium[J]. Advances in Neural Information Processing Systems, 2017: 6629-6640.
- [23] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 586-595.

作者简介

闫志杰,硕士研究生,主要研究方向为深度学习、图像处理。

E-mail:1217229291@qq.com

贾振堂(通信作者),博士,副教授,主要研究方向为深度学习、视频监控、机器视觉。

E-mail:462458081@qq.com