

DOI: 10.19650/j.cnki.cjsi.J2514171

# 少样本跨域混合迁移输电线路绝缘子缺陷检测方法<sup>\*</sup>

王亚茹,屈卓,杨春旺,赵顺,张诗吟  
(华北电力大学自动化系 保定 071003)

**摘要:** 绝缘子缺陷检测是输电线路智能巡检中的重要任务,目前存在图像样本不足的问题,通过生成人工样本进行数据扩增是一种有效的解决办法,但人工样本与真实样本的域特征分布不可避免的存在差异。为了解决此问题,提出了一种少样本跨域混合迁移有监督领域自适应模型,通过将大量有标注的人工图像作为源域,少量的真实图像作为目标域,实现人工样本的有效利用与跨域特征分布的优化对齐,提高少样本情形下绝缘子缺陷检测性能。首先对源域图像进行类目标域分布匹配,并利用其对目标域图像进行前景-背景混合增强,以提升目标域样本的质量和多样性。其次,对源域图像进行跨域混合风格扰动,进一步拉近其与目标域的域特征分布,最后通过基于对抗性训练的域分类器,对齐源域和目标域的跨域不变特征,增强模型在不同域上的泛化能力。该模型在仅使用8张真实绝缘子缺陷图像样本参与训练的情况下,相较于基础检测模型,AP50指标提升了9.3%,且通过消融实验验证了各模块的有效性。此外,该模型在不同绝缘子缺陷数据集上与同类型有监督领域自适应模型的对比下均取得了更高的检测性能,例如,在自建绝缘子缺陷数据集上与同类最优模型相比AP50提高了3.9%,在公共绝缘子缺陷数据集IDID上与同类最优模型相比AP50提高了2.4%。

**关键词:** 无人机输电线路巡检;绝缘子缺陷检测;有监督领域自适应;跨域风格迁移;跨域数据增强

**中图分类号:** TH39      **文献标识码:** A      **国家标准学科分类代码:** 520.20

## Few-shot cross-domain hybrid transfer learning method for transmission

Wang Yaru, Qu Zhuo, Yang Chunwang, Zhao Shun, Zhang Shiyin

(Department of Automation, North China Electric Power University, Baoding 071003, China)

**Abstract:** Insulator defect detection is a crucial task in the intelligent inspection of transmission lines. Currently, there is a shortage of image samples, and generating synthetic samples for data augmentation is an effective solution. However, synthetic samples inevitably exhibit domain distribution differences from real samples. To address this issue, a few-shot cross-domain hybrid transfer supervised domain adaptation model is proposed. This approach utilizes a large number of labeled synthetic images as the source domain and a small number of real images as the target domain, enabling effective use of synthetic samples and optimized alignment of cross-domain feature distributions, thereby improving the performance of insulator defect detection under few-shot scenarios. First, source domain images are adapted to match the target-like class distribution and are used to perform foreground-background hybrid augmentation on target domain images, improving the quality and diversity of target samples. Secondly, cross-domain style perturbation is applied to source images to further reduce the domain distribution gap with the target domain. Finally, a domain classifier based on adversarial training is employed to align cross-domain invariant features between the source and target domains, enhancing the model's generalization ability across domains. Under the condition of using only 8 real insulator defect images for training, the proposed model achieves a 9.0% improvement in AP50 compared to the baseline detection model. Ablation experiments further evaluate the effectiveness of each module. In addition, the proposed model consistently outperforms other supervised domain adaptation approaches across different insulator defect datasets. For instance, it achieves a 3.6% AP50 improvement over the best competing model on a self-constructed insulator defect dataset, and a 2.4% AP50 improvement on the public insulator defect dataset IDID.

收稿日期:2025-06-17 Received Date: 2025-06-17

\*基金项目:国家自然科学基金青年科学基金(62303184,62403199)、河北省自然科学基金青年科学基金(F2024502006)、中央高校基本科研业务费专项资金(2024MS138,2025MS150)项目资助

**Keywords:** UAV inspection of power transmission lines; insulator defect detection; supervised domain adaptation; domain style transfer; cross-domain data augmentation

## 0 引言

随着我国电力系统的不断发展,输电网络迅速扩张至环境和地形都更为苛刻复杂的地区。绝缘子作为输电线路中起电气绝缘和支撑作用的重要部件,其完好与否关系着输电线路能否安全稳定运行。由于绝缘子裸露在外,在暴晒,雷雨,冰雹等恶劣天气的影响下可能会出现自爆,破损等缺陷,因此绝缘子的缺陷检测成为输电线路运维检修的重要组成之一。近年来,基于深度学习的目标检测技术和无人机技术发展迅速<sup>[1]</sup>,并被逐渐运用在绝缘子缺陷检测领域<sup>[2-5]</sup>。但由于绝缘子缺陷数据难以获取,针对绝缘子缺陷的目标检测模型往往面临着训练数据不足的问题,这很大程度地限制了基于深度学习的绝缘子缺陷目标检测方法的发展。

针对数据不足的问题,常用的解决办法是进行数据扩增。在通用目标检测领域,最基本的数据扩增方法包括:加噪、翻转、旋转、比例缩放、裁剪、移位、改变颜色及亮度等<sup>[6]</sup>。Cut Mix<sup>[7]</sup>在两张随机不同图像之间剪切并交换部分区域,来生成新的训练图像。Copy-Paste Contrastive Pretraining<sup>[8]</sup>将图像(前景)随机裁剪后复制粘贴到不同的背景图像上,并对模型进行预训练。在绝缘子目标检测领域,文献[9]构建了一个绝缘子数据集—中国输电线路绝缘子数据集(Chinese power line insulator dataset, CPLID),其中大部分缺陷绝缘子图像是通过将绝缘子目标粘贴到不同的背景图像中人工合成的。文献[10]为解决在雾天检测绝缘子缺陷困难的问题,设计了一种基于 McCarney 大气散射模型的中心点合成雾算法对 CPLID 数据集绝缘子数据集进行增强。这些基于现有数据进行修改变换的方法已经较为成熟,但这些方法不能产生新的语义信息,因此无法实质性的解决缺陷样本不足的问题。使用生成式人工智能模型生成样本可以改变图像语义,目前主流的方法是对抗生成网络<sup>[11]</sup>( generative adversarial network, GAN) 和扩散模型<sup>[12]</sup>( diffusion model)。文献[13]通过优化生成对抗网络的训练过程,引入指导网络来生成自爆绝缘子。文献[14]使用多种生成对抗网络来生成绝缘子图像,并对生成的图像进行评分筛选,最终选出 Projected GAN 来进行电力设备数据集的生成。但这类方法需要依赖大量的真实样本训练,在真实样本不足的情况下,生成的图像质量较差,因此在输电线路缺陷检测任务中应用很少。此外,还有通过 3D 空间建模生成人工样本的方法,例如,文献[15]提出一种基于域随机化的缺损样本自动生成框

架,来生成大量结构多样,纹理逼真,背景丰富的绝缘子破损图像,并能自动生成标注信息。这种方法可生成新的语义且人工图像清晰度很高,但生成的人工样本与真实拍摄的样本分布存在一定的差异,如何更好的利用这些人工缺陷样本是一个关键问题。在电力领域,目前的研究多将人工样本作为扩增数据与真实缺陷样本混合,然后对检测模型进行训练,例如,文献[16]探索了一种基于混合数据增强的玻璃绝缘子自爆状态智能识别方法。文献[17]利用人工绝缘子图像数据扩充方法,通过 3D 建模创建人工绝缘子图像优化检测模型。但是人工样本与真实样本之间存在域差异,如果真实样本的数量占比较低,将导致检测模型的性能提升十分有限,甚至不升反降。

为解决上述问题,使用人工绝缘子缺陷图像作为源域,真实拍摄的绝缘子缺陷图像作为目标域,提出一种少样本跨域混合迁移(few-shot cross-domain hybrid transfer, FCDHT)有监督领域自适应方法,主要贡献可总结为 3 点:

1) 构建了一个跨域匹配动态优化模块(cross-domain matching dynamic optimization module, CMDO),对源域中的数据进行类目标域分布匹配,滤除与目标域数据分布差异较大的源域数据;并对数量稀缺的目标域样本进行前景-背景混合增强,增强目标域图像的多样性。

2) 设计了一个自适应扰动迁移对抗模块(adaptive perturbation transfer adversarial module, APTA),对源域样本进行跨域混合风格扰动对抗性训练,显著提升检测模型对跨域不变特征的学习能力。

3) 上述 2 个模块均适用于各类基础检测模型。在输电线路绝缘子缺陷检测实验中,该方法在仅有 8 张真实样本的情况下,显著提升了绝缘子缺陷的检测性能;相较于其他同类型方法,在检测精度和鲁棒性方面均表现出明显优势,为小样本场景下的缺陷检测提供方法参考。

## 1 相关技术和理论

对于深度学习模型,在某一种数据分布上训练的模型并不适用于另一种不同数据分布的数据集,而在现实应用中,这个需求非常常见。领域自适应(domain adaptation, DA)方法用于对齐不同域的数据分布,从而使训练出来的深度学习网络具有良好的泛化性能。目前 DA 被广泛应用于通用领域的分类、检测、分割等任务中,但在输电线路部件及其缺陷检测领域鲜有应用。

关于 DA 的研究方法种类为:1) 通过基于跨域混合的数据增强来提高域适应能力。文献[18]基于跨域风

格迁移提出一种数据增强方法 MixStyle 来提高不同域样本的域适应能力;文献[19]提出一种名为 XDomainMix 的跨域特征增强方法,将不同域间的样本按照类特征和域特征进行拆解后重组,得到更具多样性且具备域适应能力的新数据。2)通过拉进不同域之间特征分布的距离来匹配跨域特征,如最大平均差异(maximum mean difference, MMD)<sup>[20]</sup>,中心矩差异(central moment difference, CMD)<sup>[21]</sup>和 Wasserstein 距离<sup>[22]</sup>。3)基于对抗性的域不变学习,通过使用域分类器实现跨域特征匹配,如域对抗神经网络训练(domain-adversarial training of neural networks, DANN)<sup>[23]</sup>,对抗式判别领域自适应(adversarial discriminative domain adaptation, ADDA)<sup>[24]</sup>。在针对检测任务的领域自适应方法中,域自适应快速区域卷积神经网络(domain adaptive faster region-based convolutional neural network, DAF)<sup>[25]</sup>是一项开创性工作,其通过对抗性学习从图像级和实例级两个层面对齐不同域间的不变特征。文献[26]基于自适应师生框架,提出了一种掩码重训练师生框架(masked retraining teacher-student framework, MRT),有效克服了低质量伪标签的问题。对于输电线路绝缘子缺陷检测,文献[27]提出一种跨域多级特征对齐的区域卷积神经网络,利用无监督域适应方法对齐人工和真实图像。但这类无监督域适应方法依赖于较为充足的目标域数据,这在某些类别缺陷的检测任务中应用受限,因此针对有监督的少样本域适应(few-shot domain adaptive, FDA)检测方法进行研究。

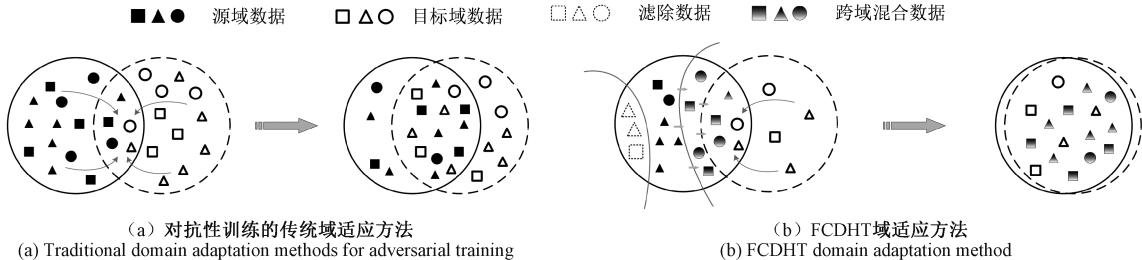


图 1 域适应方法的训练流程

Fig. 1 Training process schematic for domain adaptation

## 2 研究方法

FCDHT 网络结构如图 2 所示。将由大量人工绝缘子图像构成的数据集作为源域,表示为  $D_s = \{X_s^i, y_s^i, b_s^i\}_{i=1}^{N_s}$ ,其中  $X_s^i$  表示第  $i$  张源域图像,  $y_s^i$  表示其标注信息,  $b_s^i$  代表边界框。并且源域的域标签  $d = 0$ ;将由真实图像构成的数据集作为目标域,表示为  $D_t = \{X_t^j, y_t^j, b_t^j\}_{j=1}^{N_t}$ ,其中  $X_t^j$  表示第  $j$  张目标域图像,  $y_t^j$  表示其标注信息,  $b_t^j$  代表

FDA 希望模型能够利用足够的有标注源域数据和少量有标注目标域数据来解决域偏移导致的性能下降问题。目前 FDA 方法在车辆、行人等目标的检测任务中广泛使用。文献[28]在 YOLOv5 模型中引入对抗性学习方法,提出针对跨域目标检测的 YOLO-G 模型;文献[29]为了弥补目标域数据的不足,提出一种实例级原型学习网络,来融合 2 个域中标记图像的裁剪实例;文献[30]提出了一种多级域感知数据增强,以提高 FDA 方法中数据增强的多样性和合理性;此外,针对 FDA 方法中源域和目标域之间数据极度不平衡的问题,文献[31]提出一种不对称的适应范式,通过异步对齐来解决传统特征对齐中的过度适应。

输电线路图像的场景多变,且绝缘子缺陷图像难以获取,在拥有大量人工生成样本的前提下,十分符合 FDA 方法的应用场景。但将上述现有方法直接应用于输电线路绝缘子缺陷检中时,暴露出 2 个显著的问题:1)数据增强方式不合理,如交换不同域的目标实例,会破坏绝缘子串本身的结构,从而降低模型的检测性能。2)人工生成的绝缘子破损图像与真实绝缘子图像存在的域差异较大,使用单一的基于对抗性学习的域分类器往往很难完全对齐跨域不变特征。针对这些问题,提出了一种少样本跨域混合迁移方法 FCDHT,其中的“少样本”代表真实缺陷样本(目标域)数量稀少。该方法通用于其他一阶段和二阶段目标检测架构,与仅采用对抗性训练的传统域适应方法的对比如图 1 所示。

边界框,目标域的域标签  $d = 1$ 。

FCDHT 主要由 3 部分组成:基础检测模型,跨域匹配动态优化模块 CMDO 和自适应扰动迁移对抗模块 APTA。CMDO 首先对源域图像进行类目标域分布匹配,筛选更适合进行跨域对齐的源域样本,并将其用于对目标域的前景-背景混合增强当中,从而缓解源域和目标域间样本数量的极度失衡而带来的负面影响,初步减小域差异;APTA 对源域图像进行跨域风格混合扰动,进一步消除域差异带来的影响,再使用基于对抗性训练的域分类器对齐跨域不变特征。

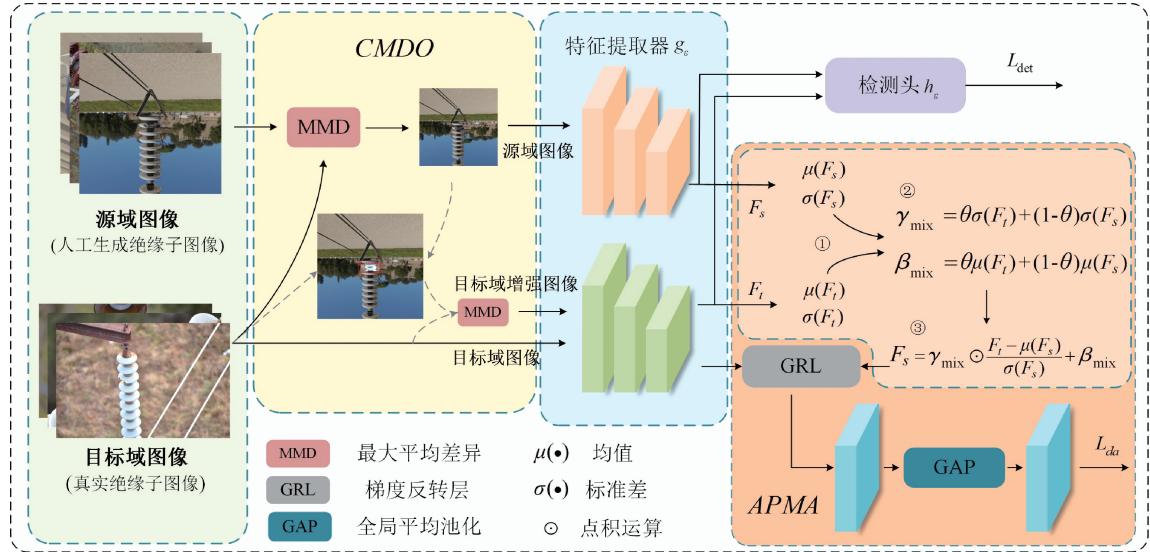


图 2 FCDHT 结构

Fig. 2 FCDHT network architecture

## 2.1 基础检测器

基础的目标检测器  $f_e(g_e, h_e)$  由一组参数  $e$  定义, 其由特征提取器  $g_e$  和检测头  $h_e$  组成, 考虑到人工生成图像与真实图像不可避免的域差异, FCDHT 的目标是训练一个自适应跨域检测器  $f_e(g_e, h_e): X_s \rightarrow X_t$ , 以缓解检测模型因域差异而导致的性能下降, 其损失如式(1)所示。

$$L_{det} = L_{cls} + L_{reg} \quad (1)$$

其中,  $L_{cls}$  和  $L_{reg}$  分别表示分类损失和边界框回归损失。

## 2.2 跨域匹配动态优化模块

在将人工生成样本作为源域的少样本域适应场景中, 一方面, 人工生成图像的质量参差不齐, 源域数据  $D_s$  中的部分数据与目标域存在较大的域差异; 另一方面, 可供训练的目标域数据  $D_t$  数量有限, 检测器  $f$  很难通过  $D_t$  来捕获跨域不变特征, 因此设计了一个跨域匹配动态优化模块 CMDO 初步对齐域特征, 先筛选出与目标域数据  $D_t$  分布更为接近的源域数据, 再利用前景-背景混合增强方法对有限的目标域数据  $D_t$  进行扩充, 从而解决源域中部分图像与目标域分布差异较大的问题, 并在一定程度上缓解样本数量极度失衡带来的负面影响。具体来讲, CMDO 模块首先计算每个批次中源域图像和目标域图像分布的距离, 滤除与目标域图像分布差异大的源域图像。MMD 是域适应方法中常用的一种函数, 其主要用来度量再生希尔伯特空间 (reproducing kernel hilbert space, RKHS) 中 2 个分布的距离。源域图像和目标域图像的分布距离可以用 MMD 定义, 如式(2)所示。

$$dist_{(D_s, D_t)} = MMD^2(D_s, D_t) =$$

$$\left\| \frac{1}{n_t} \sum_{i=1}^{n_t} g_e(\mathbf{x}_i^t) - \frac{1}{n_s} \sum_{j=1}^{n_s} g_e(\mathbf{x}_j^s) \right\|_2^2 \quad (2)$$

其中,  $g_e(\mathbf{x})$  表示样本经过特征提取器的输出。 $dist_{(D_s, D_t)}$  越大, 则代表两个分布的差距越大, 剔除每个批次中与目标域图像分布差异较大的源域图像。然后, 将批次中剩余的源域图像和目标域图像的边界框目标  $b_s$  和  $b_t$  与背景进行分离, 并调整其宽度  $W$  和高度  $H$  以便交换它们来组合彼此的特征, 以此来得到增强后的目标域标注框数据  $b_{aug}$ 。组合过程如式(3)所示。

$$b_{aug}(u, v) = \alpha_{(u, v)} b_s(u, v) + (1 - \alpha_{(u, v)}) b_t(u, v) \quad (3)$$

其中,  $u = 1, 2, \dots, W, v = 1, 2, \dots, H$  表示标注框  $b_s$  和  $b_t$  中像素的索引,  $\alpha_{(u, v)} \in [0, 1]$  为权重, 根据式(3) CMDO 提供 2 种混合模式, 当  $\alpha_{(u, v)}$  设置为 0 时, 表示源域和目标域标注框目标进行直接交换模式; 当  $\alpha_{(u, v)} \sim Beta(a_1, a_1)$ ,  $a_1 \in (0, \infty)$  时, 表示源域和目标域标注框目标进行目标混合模式, 其中  $a_1$  是一个超参数。当  $\alpha_{(u, v)}$  设置为 1 时, 则表示不使用该数据增强。图 3 为 2 种扩充模式的效果示意图。

通过该方法能够有效的对目标域数据进行扩充, 并且在一定程度上拉进源域和目标域的数据分布, 但由于绝缘子串本身的结构特点, 这样简单的跨域数据增强方法可能会破坏绝缘子串的结构, 从而降低模型

性能, 因此对于扩增后的目标域数据  $D_t^{aug}$ , 同样使用 MMD 函数进行筛选, 增强数据  $D_t^{aug}$  与未增强前的源域数据  $D_s$  的距离定义如式(4)所示。

$$dist_{(D_t^{aug}, D_s)} = MMD^2(D_t^{aug}, D_s) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} g_e(\mathbf{x}_i^t) - \frac{1}{n_t^{aug}} \sum_{j=1}^{n_t^{aug}} g_e(\mathbf{x}_j^{aug}) \right\|_2^2 \quad (4)$$

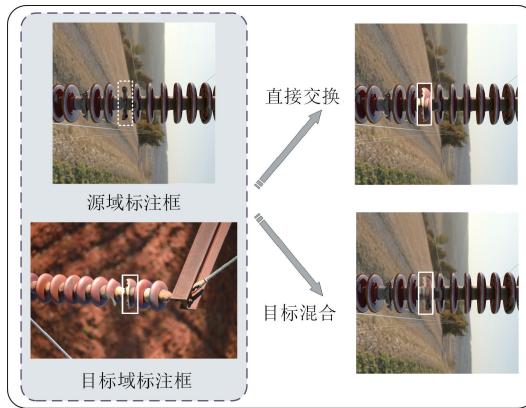


图3 目标域扩充效果

Fig. 3 Illustration of the effect of target domain augmentation

最终选择分布距离较小的扩增数据  $D_t^{aug}$  作为目标域扩充数据参与训练。

### 2.3 自适应扰动迁移对抗模块

基于风格迁移的自适应扰动迁移对抗模块 APTA 用于在图像级层面进一步消除源域和目标域间的域差异。该模块的输入为特征提取器最后一层的整个特征图  $\mathbf{F} = g_e(\mathbf{x})$ , 首先对源域和目标域的特征图使用一种跨域风格扰动迁移方法, 减小不同域间的域差异。该方法通过在训练过程中对源域的风格特征进行跨域扰动来改变源域数据的风格信息, 从而减小源域与目标域之间的域差异。在以往的工作中<sup>[32]</sup>已经证明, 特征统计量与图像的风格信息密切相关, 对给定的一组目标域图像特征图  $\mathbf{F}_t$  和源域图像特征图  $\mathbf{F}_s$ , 计算它们在每个特征通道  $c \in \{1, \dots, C\}$  的均值  $\mu(\mathbf{F})_c$  和标准差  $\sigma(\mathbf{F})_c$ , 如式(5)和(6)所示。

$$\mu(\mathbf{F})_c = \frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W \mathbf{F}_{c,h,w} \quad (5)$$

$$\sigma(\mathbf{F})_c = \sqrt{\frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W (\mathbf{F}_{c,h,w} - \mu(\mathbf{F})_c)^2} \quad (6)$$

其中,  $H$  和  $W$  分别表示特征图的高度和宽度。

然后对两组特征图的特征统计量进行混合, 如式(7)和(8)所示。

$$\gamma_{mix} = \theta \sigma(\mathbf{F}_t) + (1 - \theta) \sigma(\mathbf{F}_s) \quad (7)$$

$$\beta_{mix} = \theta \mu(\mathbf{F}_t) + (1 - \theta) \mu(\mathbf{F}_s) \quad (8)$$

其中,  $\theta$  是从 Beta 分布中采样的特定实例的随机混合权重,  $\theta \sim Beta(a_2, a_2)$ ,  $a_2 \in (0, \infty)$ , 其中  $a_2$  是一个超参数。

最后将混合后的特征统计量进行风格归一化, 得到风格迁移后的源域特征图  $\mathbf{F}'_s$ , 如式(9)所示。

$$\mathbf{F}'_s = Mix(\mathbf{F}_s, \mathbf{F}_t) = \gamma_{mix} \odot \frac{\mathbf{F}_t - \mu(\mathbf{F}_s)}{\sigma(\mathbf{F}_s)} + \beta_{mix} \quad (9)$$

其中,  $\odot$  表示点积运算。

通过对源域进行跨域风格混合迁移, 能够有效减小源域和目标域之间的域差异。在此基础上, 进一步引入基于对抗性训练的图像级域分类器对齐跨域不变特征。域分类器只区分特征向量的域类别, 由梯度反转层 (gradient reversal layer, GRL)、2 个卷积层和全局平均池化层 (global average pooling, GAP) 组成。

梯度反转是一种常用的域适应训练方法, 其基本思想是最大限度地减少分类器的损失, 也就是混淆分类器的分类能力, 让其无法正确的对输入的特征向量进行分类。梯度反转层在正向传播和反向传播期间设置特征向量的相反权重。当分类器正向训练时, 引导分类器减小分类误差, 当参数在反向传播中更新时, 应用相反的权重因子, 以此来最大限度的增大分类器的分类误差。

使用二分类损失作为域分类器的损失函数, 如式(10)所示。

$$L_{da} = - \sum_{k,i,j} [d_k \log p_k(i,j) + (1 - d_k) \log(1 - p_k(i,j))] \quad (10)$$

其中,  $d_k$  是一个批次中第  $k$  个样本的域标签,  $p_k(i,j)$  表示域分类器的预测概率, 并且由于引入了梯度反转层, 添加了一个负号。

最终的总损失如式(11)所示。

$$Loss = L_{det} + \eta L_{da} = L_{cls} + L_{reg} + \eta L_{da} \quad (11)$$

其中,  $L_{da}$  表示域分类器损失函数,  $\eta$  代表域分类器损失权重, 实验中设置为 0.1。

## 3 实验与结果分析

### 3.1 数据集

使用某电厂提供的 94 张无人机拍摄的绝缘子破损图像作为目标域。实验遵循 FDA 的一般规则, 并且为了与现有方法相匹配, 随机选择 8 张目标域图像参与模型训练, 剩下的 86 张图像作为测试集, 所有目标域图像均有标注。采用上海交通大学智能输电研究所发布的人工绝缘子破损图像数据集<sup>[13]</sup> (<https://github.com/liu-qingzhen/Insulator-defect-dataset>) 作为源域, 该数据集采用仿真建模的方式, 在虚拟三维空间中生成不同背景、不同光照、不同拍摄角度等不同工况下的绝缘子破损图像。

由于现有同类方法多采用 YOLOv5 作为基础检测模型, 为方便进行对比, FCDHT 也采用 YOLOv5 作为基础检测模型。需说明的是, 所提出的少样本域适应方法不依赖于基础检测模型, 可以移植到其他检测模型上。为了验证源域数据的有效性, 并且探究应选择的源域图像数量, 从源域数据集中分别选取 600、800、1 000、1 200、1 400、1 600、1 800、2 000 张图像作为 YOLOv5 模型的训

练集,选用上述 86 张目标域图像作为测试集,进行绝缘子破损检测实验。实验结果如表 1 所示。

表 1 不同数量人工样本训练下的模型检测结果

Table 1 Model detection results under different quantities of synthetic training samples

源域图像数量/张	AP50/%
600	54. 3
800	55. 7
1 000	59. 6
1 200	65. 3
1 400	65. 8
1 600	64. 9
1 800	65. 0
2 000	65. 5

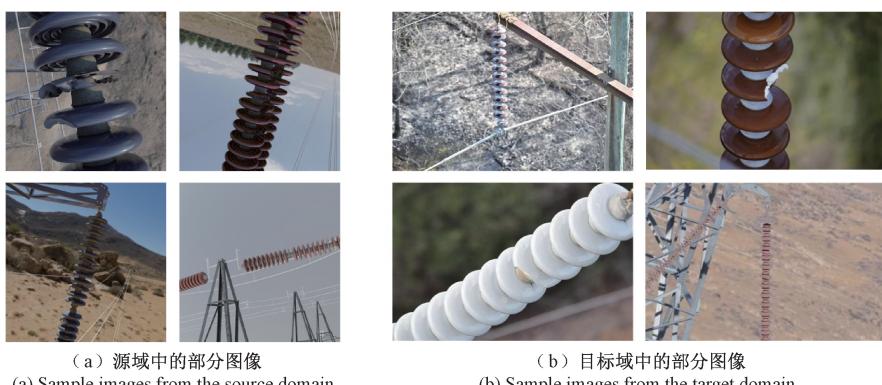


图 4 部分绝缘子缺陷图像

Fig. 4 Partial insulator defect images

$$P = \frac{TP}{TP + FP} \quad (12)$$

$$R = \frac{TP}{TP + FN} \quad (13)$$

其中,  $TP$ 、 $FP$ 、 $FN$  分别表示 True Positive、False Positive、False Negative 的数量,由准确率和召回率构成的 PR 曲线的曲线下面积定义为 AP,计算公式如式(14)所示。

$$AP = \int_0^1 P(R) dR \quad (14)$$

AP50 即为置信度阈值为 0.5 时的 AP 值。

实验中每批次输入 8 张图片,其中 7 张源域图片,1 张目标域图片。在 CMDO 模块中,为避免引入不必要的噪声,将  $\alpha_{(u,v)}$  设置为 0,即采用直接交换模式;在 APTA 模块中,对于超参数  $a_2$ ,选取一些 Beta 函数中常用

实验结果验证了用源域图像进行模型训练是有效的,并且随着训练集中源域图像数量增多,模型检测效果越好,但当数量达到一定数值后,模型的性能不再提升,例如,源域图像数量从 1 200 增加到 1 400,检测结果仅提升了 0.005,当源域图像数量为 1 600 甚至更多时,相比 1 200 时有所下降。因此,考虑到训练成本,在后续的实验中,选用 1 200 张源域图像和上述介绍的 8 张目标域图像作为训练集。部分源域和目标域图像如图 4 所示。

### 3.2 实验参数及评价指标

实验硬件配置环境为 NvidiaGeForce RTX3090 显卡,软件环境为 Ubuntu20.04,在 Pytorch1.11、Torchvision 0.12.0、Python3.8.12、CUDA12.6 的开发环境下进行训练。检测模型基于 YOLOv5 检测框架。

以往关于领域自适应的研究多使用 AP50 作为评估标准,平均精度(average precision, AP)是衡量检测模型性能的指标,由准确率( $P$ )和召回率( $R$ )共同决定, $P$  和  $R$  的计算方式如式(12)和(13)所示。

参数进行测试,如表 2 所示,最终选取  $a_2 = 0.5$  作为后续实验参数。

表 2 超参数  $a_2$  对于检测模型结果的影响

Table 2 Impact of hyperparameters  $a_2$  on detection model performance

$a_2$	AP50/%
0.1	70.3
0.2	73.9
0.5	<b>74.8</b>
1.0	72.5
2.0	71.0
5.0	69.1

注:加粗数据为最优值。

### 3.3 消融实验

为了验证所提出的 CMDO 和 APTA 模块的有效性, 进行不同模块的消融实验。以 YOLOv5l 检测模型为基础检测模型, 增加不同的模块来测试模型的检测性能, 实验结果如表 3 所示, 表 3 中 A1 代表 APTA 中的跨域风格混合迁移部分, A2 代表 APTA 中的域分类器部分。通过实验可以看到, YOLOv5l+CMDO 使模型的 AP50 提升了 4.9%, YOLOv5l+APTA 使模型的 AP50 提升了 5.4%, 证明所设计的域适应模块是有效的。即便仅使用 APTA 模块中的域分类器功能, 即 YOLOv5l+CMDO+A2, 也可以使模型的检测精度有较大提升, AP50 提升了 7.1%。当使用完整的 APTA, 即 YOLOv5l + CMDO + APTA, 模型的 AP50 相比基线提高了 9.3%。

表 3 不同模块对于检测模型结果的影响

Table 3 Impact of different modules on detection model performance

方法	CMDO	APTA		AP50/%
		A1	A2	
基础检测模型	✓			65.5
		✓	✓	70.4
	✓		✓	70.9
	✓	✓	✓	<b>72.6</b>

注: 加粗数据为最优值。

### 3.4 对比试验

为了验证 CMDO 模块中使用不同分布差异度量方法对于模型性能的影响, 选取常用的 3 种分布差异度量

方法: MMD、CMD、Wasserstein, 并分别将每批次中的扩增图片数设置为 1、2、3, 以此来验证每批次中扩增图片数量对结果的影响, 实验结果如表 4 所示。

表 4 不同分布差异度量方法的性能对比

Table 4 Performance comparison of different distribution discrepancy measurement methods

方法	扩增图片数/批次	AP50/%
MMD	1	71.2
	2	<b>74.8</b>
	3	72.5
CMD	1	70.4
	2	72.3
	3	72.1
Wasserstein	1	72.3
	2	72.9
	3	74.5

注: 加粗数据为最优值。

当每批次中扩增图片仅有 1 张时, 其多为如图 5(b) 所示的结构未受损绝缘子图像, 但由于数量较少, 并不能很好的缓解由于源域图像和目标域图像数量不平衡带来的负面影响; 当每批次扩增图片数量增加时, 如图 5(a) 所示的结构受损绝缘子图像明显增多。每批次中扩增图片增加为 2 或 3 张时, 3 种分布差异度量方法所展示的检测效果均有提升, 其中扩增图片为 2 张时, 使用 MMD 的模型检测效果最好, AP50 为 74.8%, 扩增图片为 3 张时, 使用 Wasserstein 的模型检测效果最好, AP50 为 74.5%。



(a) 结构受损绝缘子图像  
(a) Image of structurally damaged insulator



(b) 结构未受损绝缘子图像  
(b) Image of a structurally intact insulator

图 5 部分扩增图像

Fig. 5 Examples of partially augmented images

为了验证所提出的域适应方法在绝缘子缺陷检测上的优越性能, 将其与多种普通检测模型、无监督域适应检测方法、半监督域适应检测方法及有监督域适应检测方

法进行对比, 其中普通检测模型使用源域图像和 8 张有标注的目标域图像进行训练, 无监督域适应检测方法使用有标注的源域图像和无标注的目标域, 半监督域适应

检测方法使用有标注的源域图像和部分标注的目标域图像,数量均保持一致。对每种方法都进行了5次实验,选取5次实验结果的平均值列于表5中。

可以看到,对于绝缘子破损缺陷检测,选取的几种无监督域适应检测方法,由于目标域样本数量很少,训练过程中难以捕捉跨域不变特征,因此检测效果并不理想;半监督域适应检测方法在目标域样本很少的情况下,并没有较为显著的优势,而专门用于少样本域适应的有监督方法取得了不错的检测效果,FCDHT在与上述多种方法的对比中取得了最好的结果。进一步地,在公开绝缘子数据集—绝缘子缺陷图像数据集(the insulator defect image dataset, IDID)进行对比实验。IDID由高质量的输电线路绝缘子标记图像构成,随机选用其中的8张破损绝缘子图像与之前实验中的1 200张源域图像一同参与训练,选择243张破损绝缘子图像进行模型测试。在该训练条件下,与其他有监督域适应方法进行对比,结果如表6所示,FCDHT在与其他同类领域自适应方法的对比中依旧取得了最好的效果。

**表5 各类域适应检测方法的性能比较**  
**Table 5 Performance comparison of domain adaptation detection methods**

方法	算法	AP50/%
普通检测模型	YOLOv5 <sup>[33]</sup>	65.5
	YOLOv8 <sup>[34]</sup>	67.2
	YOLOv11 <sup>[35]</sup>	67.9
无监督域	DAF <sup>[25]</sup>	51.6
	TIA <sup>[36]</sup>	56.8
适应检测方法	CR-DR-DET <sup>[37]</sup>	53.6
	SWDA <sup>[38]</sup>	52.7
半监督域	SSDA-YOLO <sup>[39]</sup>	66.7
	VT <sup>[40]</sup>	58.3
有监督域	MS-DAYOLO <sup>[41]</sup>	64.2
	AcroFOD <sup>[30]</sup>	70.9
	AsyFOD <sup>[31]</sup>	69.1
	YOLO-G <sup>[28]</sup>	67.1
FCDHT		<b>74.8</b>

注:加粗数据为最优值。

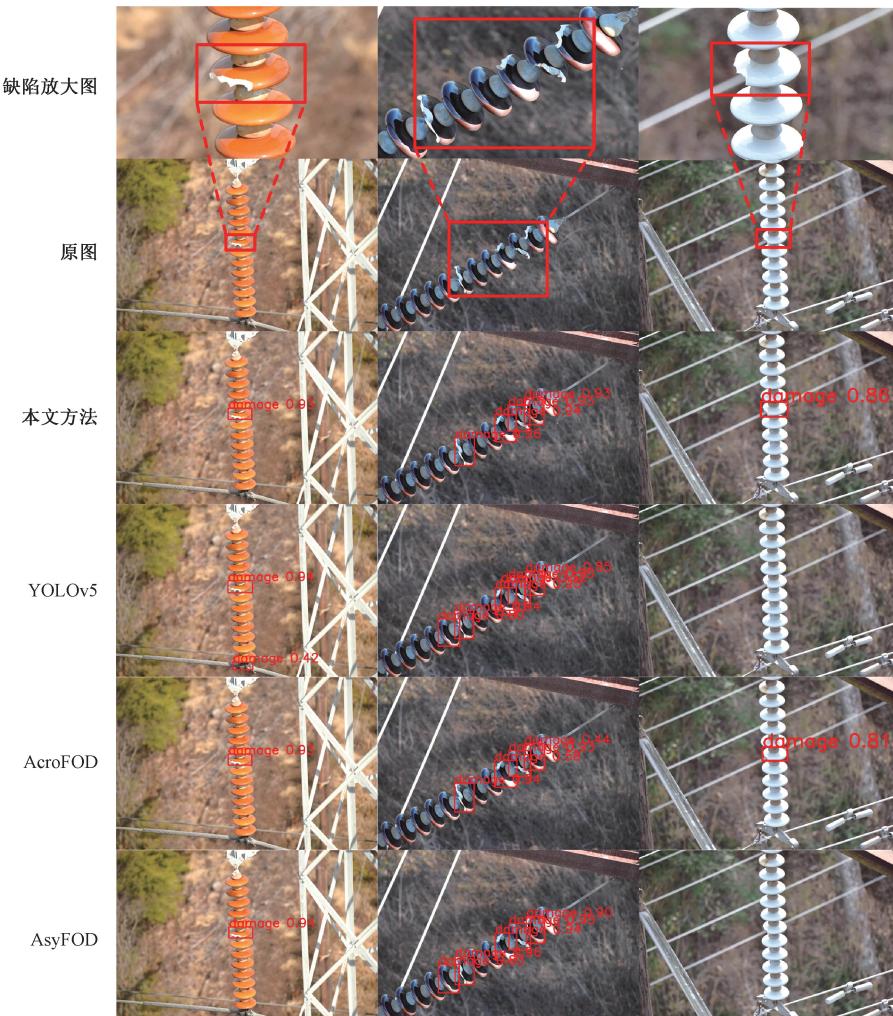


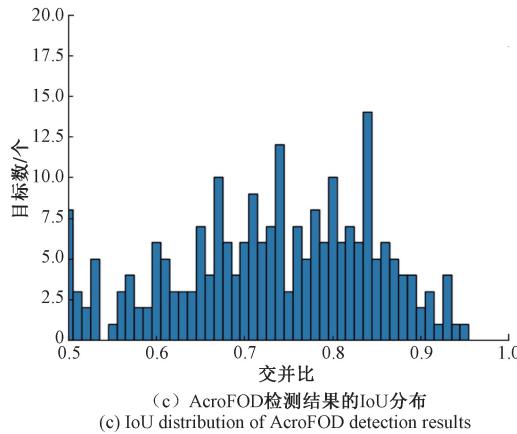
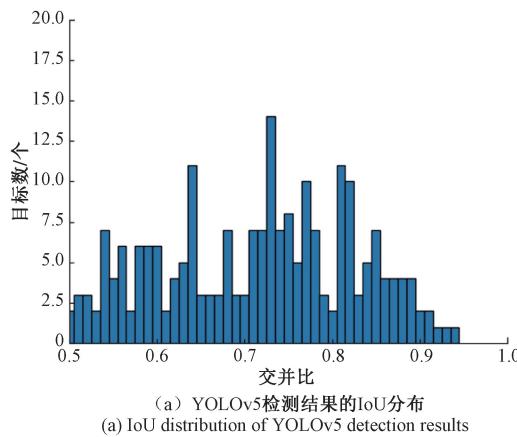
图6 不同方法之间的检测结果比较

Fig. 6 Comparison of detection results among different methods

**表 6 在 IDID 数据集上与有监督域适应方法的性能比较****Table 6 Performance comparison with supervised domain adaptation methods on the IDID dataset**

方法	算法	AP50/%
有监督域适应 检测方法	YOLOv5l	55.6
	MS-DAYOLO	56.2
	AcroFOD	62.7
	AsyFOD	61.3
	YOLO-G	60.4
	FCDHT	<b>65.1</b>

注:加粗数据为最优值。



### 3.5 检测结果可视化对比

选取表 5 中的 Yolov5 和性能较好的 2 种有监督域适应方法与 FCDHT 的部分检测结果进行可视化对比,如图 6 所示,并对其进行交并比(intersection over union, IoU)分布统计,如图 7 所示。FCDHT 方法在漏检率和误检率上都显著低于其他对比方法,同时展现出更强的缺陷定位能力和更高的检测准确率。这一结果验证了 FCDHT 在少样本跨域检测方面的优越性,表明 FCDHT 能够更有效的提取人工绝缘子缺陷样本的域不变特征,能够更加高效的利用人工绝缘子缺陷样本进行真实场景缺陷检测。

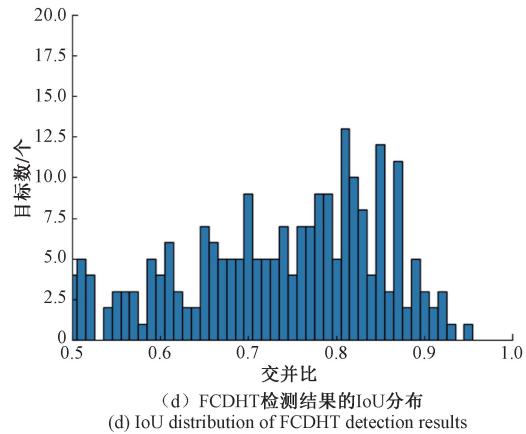
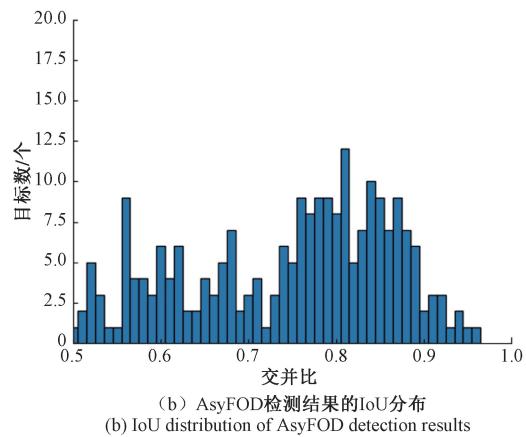
**图 7 不同方法检测结果的 IoU 分布**

Fig. 7 IoU distribution of detection results from different methods

## 4 结 论

为探索如何更高效的利用人工绝缘子缺陷图像,在仅有几张真实绝缘子缺陷的情况下,提出了一种少样本跨域混合迁移方法。该方法能够在目标域数据极度缺乏时有效对齐跨域不变特征,减小域差异,提高绝缘子缺陷

检测性能。通过 CMDO 模块对源域图像进行类目标域分布匹配,并利用其对目标域图像进行前景-背景混合增强,缓解由源域数据质量参差不齐和目标域数据匮乏带来的负面影响;通过 APTA 模块对源域进行跨域混合风格扰动来拉进域分布,并采用对抗训练策略进一步减小域间隙。采用上海交大发布的人工绝缘子破损数据集、自建的真实拍摄绝缘子破损数据集和公共数据集 IDID

进行消融实验和对比实验。消融实验结果显示,提出的两个模块级联使用时,模型的检测性能最佳。对比实验结果显示,不论在自建数据集上还是公共数据集上,FCDHT 的 AP50 均优于多个现有有监督领域自适应方法,验证了在真实样本极度匮乏的情况下,FCDHT 可更高效的利用人工样本,具有较高的绝缘子缺陷检测准确性和较好的泛化性。

然而,FCDHT 仍然受领域自适应方法所固有的训练稳定性问题所限制,未来的工作重点会集中于此。此外,收集多类别、高质量、多样性的多源数据或多模态数据,尝试多源域适应方法或融合跨模态学习方法,提高训练的稳定性及检测模型的准确性和泛化性也是未来工作的重点。

## 参考文献

- [ 1 ] 孙晓永,孙备,郭润泽,等.面向多无人机协同的多模态目标检测方法[J].仪器仪表学报,2025,46(2):209-220.  
SUN X Y, SUN B, GUO R Z, et al. Multimodal target detection method for multi-UAV coordination[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 209-220.
- [ 2 ] 赵振兵,韩钰,唐辰康.基于改进 YOLOv8 的配电线路绝缘子缺陷级联检测方法[J].图学学报,2025,46(1):1-12.  
ZHAO ZH B, HAN Y, TANG CH K. Cascade detection method for insulator defects in distribution lines based on improved YOLOv8 [ J ]. Journal of Graphics, 2025, 46(1): 1-12.
- [ 3 ] 俞俊,武丽,付相为,等.基于改进 SSD 的高空绝缘子缺陷检测算法[J].信息技术,2024(12):72-79.  
YU J, WU L, FU X W, et al. High-altitude insulator defect detection algorithm based on improved SSD [ J ]. Information Technology, 2024(12): 72-79.
- [ 4 ] 翟永杰,王璐瑶,郭聪彬.基于 Faster R-CNN 的复杂背景下绝缘子目标检测[J].电子测量技术,2023,46(16):187-194.  
ZHAI Y J, WANG L Y, GUO C B. Insular object detection in complex background based on Faster R-CNN[ J ]. Electronic Measurement Technology, 2023, 46(16): 187-194.
- [ 5 ] 刘航,李明,刘志坚,等.基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法[J].电子测量与仪器学报,2025,39(1):57-69.  
LIU H, LI M, LIU ZH J, et al. Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n[ J ]. Journal of Electronic Measurement and Instrumentation, 2025, 39 ( 1 ): 57-69.
- [ 6 ] 杨锁荣,杨洪朝,申富饶,等.面向深度学习的图像数据增强综述[J].软件学报,2025,36(3):1390-1412.  
YANG S R, YANG H CH, SHEN F R, et al. Image data augmentation for deep learning: A survey[ J ]. Journal of Software, 2025, 36(3): 1390-1412.
- [ 7 ] YUN S, HAN D, CHUN S, et al. CutMix: Regularization strategy to train strong classifiers with localizable features [ C ]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 6022-6031.
- [ 8 ] WANG F, WANG H, WEI C, et al. CP2: Copy-paste contrastive pretraining for semantic segmentation [ J ]. ArXiv preprint arXiv: 2203. 11709, 2022.
- [ 9 ] TAN 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.
- [ 10 ] CHEN K, CHEN J, ZHANG M, et al. A fast and high-precision insulator defect detection method [ C ]. 2023 2nd Asia Power and Electrical Technology Conference , 2023: 89-93.
- [ 11 ] KRICHEN M. Generative adversarial networks [ C ]. 2023 14th International Conference on Computing Communication and Networking Technologies, 2023: 1-7.
- [ 12 ] COUAIRON G, VERBEEK J, SCHWENK H, et al. Diffedit: Diffusion-based semantic image editing with mask guidance[ J ]. ArXiv preprint arXiv: 2210.11427, 2022.
- [ 13 ] 及浩然,侯春萍,杨阳,等.基于生成对抗网络的自爆绝缘子检测模型设计[J].现代电力,2022,39(5):587-596.  
JI H R, HOU CH P, YANG Y, et al. New design of self-explosive insulator detection model based on generative adversarial network [ J ]. Modern Electric Power, 2022, 39(5): 587-596 .
- [ 14 ] FANG Y X, ZHANG X Q, CAO H, et al. Insulator image dataset generation based on generative adversarial network [ C ]. 2023 4th International Conference on Computer Vision, Image and Deep Learning, 2023: 103-108.
- [ 15 ] 刘庆臻,刘亚东,严英杰,等.基于域随机化的绝缘

- 子缺损数据自动生成与评价方法[J]. 高电压技术, 2024, 50(5): 1900-1912.
- LIU Q ZH, LIU Y D, YAN Y J, et al. Automatic generation and evaluation method of insulator broken defect data based on domain randomization [J]. High Voltage Engineering, 2024, 50(5): 1900-1912.
- [16] DING L J, PENG S. Research on intelligent recognition method for self-blast state of glass insulator based on mixed data augmentation [C]. 2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications, 2022: 434-440.
- [17] 王亚茹, 杨凯, 翟永杰, 等. 基于人工图像数据扩充的输电线路绝缘子识别[J]. 系统仿真学报, 2022, 34(11): 2337-2347.
- WANG Y R, YANG K, ZHAI Y J, et al. Transmission line insulator recognition based on artificial images data expansion [J]. Journal of System Simulation, 2022, 34(11): 2337-2347.
- [18] ZHOU K Y, YANG Y X, QIAO Y, et al. Domain generalization with mixstyle [J]. ArXiv preprint arXiv: 2104.02008, 2021.
- [19] LIU Y N, ZOU Y T, QIAO R, et al. Cross-domain feature augmentation for domain generalization[J]. ArXiv preprint arXiv: 2405.08586, 2024.
- [20] LONG M SH, ZHU H, WANG J M, et al. Unsupervised domain adaptation with residual transfer networks [J]. Advances in Neural Information Processing Systems, 2016, 136-144.
- [21] KALISCHEK N, WEGNER J D, SCHINDLER K. In the light of feature distributions: Moment matching for neural style transfer [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 9377-9386.
- [22] BALAJI Y, CHELLAPPA R, FEIZI S. Normalized wasserstein for mixture distributions with applications in adversarial learning and domain adaptation [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 6499-6507.
- [23] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. Journal of Machine Learning Research, 2016, 17(59): 1-35.
- [24] TZENG E, HOFFMAN J, SAENKO K, et al. Adversarial discriminative domain adaptation [C]. 2017 IEEE Conference on Computer Vision And Pattern Recognition, 2017: 2962-2971.
- [25] CHEN Y H, LI W, SAKARIDIS C, et al. Domain adaptive faster r-cnn for object detection in the wild [C]. 2018 IEEE Conference on Computer Vision And Pattern Recognition, 2018: 3339-3348.
- [26] ZHAO Z J, WEI S T, CHEN Q CH, et al. Masked retraining teacher-student framework for domain adaptive object detection [C]. 2023 IEEE/CVF International Conference on Computer Vision, 2023: 19039-19049.
- [27] WANG Y R, QU ZH, HU ZH D, et al. Cross-domain multi-level feature adaptive alignment R-CNN for insulator defect detection in transmission lines[J]. IEEE Transactions on Instrumentation and Measurement, 2025: 1-12.
- [28] WEI J, WANG Q ZH, ZHAO Z X. YOLO-G: Improved YOLO for cross-domain object detection[J]. Plos One, 2023, 18(9): e0291241.
- [29] ZHANG L, ZHANG B, SHI B T, et al. Few-shot cross-domain object detection with instance-level prototype-based meta-learning[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024: 9078-9089.
- [30] GAO Y P, YANG L X, HUANG Y M, et al. Acrofod: An adaptive method for cross-domain few-shot object detection [C]. Computer Vision-ECCV 2022, 2022: 673-690.
- [31] GAO Y P, LIN K Y, YAN J, et al. Asyfod: An asymmetric adaptation paradigm for few-shot domain adaptive object detection[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 3261-3271.
- [32] HUANG X, BELONGIE S. Arbitrary style transfer in real-time with adaptive instance normalization[C]. 2017 IEEE International Conference on Computer Vision, 2017: 1501-1510.
- [33] 张恒, 程成, 袁彪, 等. 基于YOLOv5-EA-FPNs的芯片缺陷检测方法研究[J]. 电子测量与仪器学报, 2023, 37(5): 36-45.
- ZHANG H, CHENG CH, YUAN B, et al. Research on chip defect detection method based on YOLOv5-EA-FPNs[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 36-45.
- [34] 王迎龙, 孙备, 丁冰, 等. BG-YOLO: 复杂大视场下低慢小无人机目标检测方法[J]. 仪器仪表学报, 2025, 46(2): 255-266.
- WANG Y L, SUN B, DING B, et al. BG-YOLO: A low-altitude slow-moving small UAV targets detection method in complex large field of view [J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 255-266.

- [35] 张彪,荀荣科,许家忠.基于深度学习的工业轴承缺陷检测算法研究[J].仪器仪表学报,2025,46(4):136-149.  
ZHANG B, XUN R K, XU J ZH. Research on industrial bearing defect detection algorithm based on deep learning[J]. Chinese Journal of Scientific Instrument, 2025, 46(4):136-149.
- [36] ZHAO L, WANG L M. Task-specific inconsistency alignment for domain adaptive object detection[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 14217-14226.
- [37] XU CH D, ZHAO X R, JIN X, et al. Exploring categorical regularization for domain adaptive object detection[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11721-11730.
- [38] SAITO K, USHIKU Y, HARADA T, et al. Strong-weak distribution alignment for adaptive object detection[C]. 2019 IEEE/CVP Conference on Computer Vision and Pattern Recognition, 2019: 6956-6965.
- [39] ZHOU H Y, JIANG F, LU H T. SSDA-YOLO: Semi-supervised domain adaptive YOLO for cross-domain object detection[J]. Computer Vision and Image Understanding, 2023, 229: 103649.
- [40] YANG R N, TIAN T, TIAN J W. Versatile Teacher: A class-aware teacher-student framework for cross-domain adaptation[J]. Pattern Recognition, 2025, 158: 111024.
- [41] HNEWA M, RADHA H. Multiscale domain adaptive YOLO for cross-domain object detection[C]. 2021 IEEE International Conference on Image Processing, 2021: 3323-3327.

### 作者简介



**王亚茹**,2013 年于燕山大学获得学士学位,2016 年于天津大学获得硕士学位,2020 年于天津大学获得博士学位,现为华北电力大学自动化系副教授,主要研究方向为电力视觉。

E-mail: wangyaru@ncepu.edu.cn

**Wang Yaru** received her B.Sc. degree from Yanshan University in 2013, her M.Sc. and Ph.D. degrees from Tianjin University in 2016 and 2020, respectively. She is currently an associate professor at North China Electric Power University. Her main research interest is power computer vision.



**张诗吟**(通信作者),2016 年于河北工业大学获得学士学位,2023 年于北京交通大学获得博士学位,现为华北电力大学自动化系讲师,主要研究方向为电力视觉、输电线路巡检和视觉知识推理。

E-mail: qianmingwang@ncepu.edu.cn

**Zhang Shiyin** (Corresponding author) received her B.Sc. degree from Hebei University of Technology in 2016, and her Ph.D. degree from Beijing Jiaotong University in 2023. She is currently a lecturer at North China Electric Power University. Her main research interests include power computer vision, transmission line inspection, and visual knowledge reasoning.