

基于域通道知识鉴别框架的跨域少样本图像分类

余悦[†], 沈维杰, 陈楠

(江苏大学 计算机科学与通信工程学院, 江苏 镇江 212013)

摘要: 现有的跨领域少样本分类模型受限于域特定因素的干扰, 限制了其有效性。为此, 提出了一种基于高斯仿射的通道鉴别网络。具体来讲, 所提出的学习框架包含随机高斯仿射模块和域通道鉴别模块, 在随机高斯仿射模块中, 通过对特征的充分统计量进行高斯扰动以生成区别于源域数据分布的全新特征分布, 从而显著化训练数据特征中域不变信息; 在域通道鉴别模块中, 将经过增强前后的特征图输入到域鉴别器中引导模型区分和提取其中的域不变特征, 以达到提高模型泛化能力的目的。最后, 在两个目标数据集进行实验, 结果验证了所提出方法的可行性和有效性。

关键词: 跨域少样本图像分类; 少样本学习; 域泛化; 深度学习

中图分类号: TP391.4

文献标识码: A

Cross-domain Few-shot Image Classification Based on Domain-channel Knowledge Discriminative Network

YU Yue[†], SHEN Weijie, CHEN Nan

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang, Jiangsu 212013, China)

Abstract: Existing cross-domain few-shot classification models are limited by the interference of domain-specific factors, resulting in poor cross-domain performance. To overcome this problem, a channel knowledge discriminative network for cross-domain few-shot image classification is proposed. Specifically, the proposed learning framework contains a stochastic Gaussian affine module and a channel knowledge discrimination module. In the stochastic gaussian affine module, we salientise the domain-invariant information in the feature map by Gaussian perturbing sufficient statistics of the features to generate a new feature distribution that is distinct from the source domain data distribution. In the channel knowledge discrimination module, the feature maps before and after enhancement are fed into the domain discriminator to guide the model to distinguish and extract the domain-invariant features therein, thus improving the model generalisation capability. Finally, we conduct experiments on two target datasets and the results validate the effectiveness of the proposed method.

Key words: cross-domain few-shot image classification; few-shot learning; domain generalisation; deep learning

迄今为止, 深度学习的成功在很大程度上依赖于大规模的训练数据。但是在真实世界的某些领域中获取大量带标签的高质量数据是不现实的, 这表明了人工智能也存在一定的缺陷。研究人员受到人类快速学习特性和迁移学习的启发, 提出了一

种全新的机器学习范式——少样本学习, 以期现有的人工智能模型可以像人类那样只通过几个样例的学习就可以举一反三。少样本学习旨在使得模型从数量有限的带标签数据中学习 to 可用在未知新类上且表现良好的先验知识。少样本学习领域

诞生了许多算法和模型^[1,2],这些成果通过学习任务间归纳偏差的分布来提高泛化学习能力,从而解决少样本学习问题。大多数少样本学习方法^[3,4]要求训练数据和测试数据处于相同的分布中。然而,最近的研究表明,当模型在元训练和元测试阶段输入的任务之间存在巨大的领域偏差时,少样本学习模型的表现甚至不如传统的预训练和微调方法。因此,越来越多的研究学者开始关注跨域少样本学习领域。

跨域少样本图像分类领域起步较晚,一些工作仅使用源域数据进行训练,并在全新未知的目标域数据中进行测试,代表性工作有 FWT^[5]、URL^[6]。相比之下,一些工作在保留了基本设置的情况下引入辅助信息,即允许模型在训练时引入部分目标域数据作为辅助域。具体来说,Fu 等人^[7]提出在模型元训练阶段使用少量带标签的目标域图像数据参与训练。然而,在某些重要领域中,比如医学领域和军事遥感领域,因其数据的高隐私性导致获取数量足够且带标签的图像数据需要花费巨大的代价。因此,本文遵循 FWT^[5]所提出的单源跨域少样本设置来训练模型。

为了解决跨域偏移问题,提出了一个基于随机高斯仿射的通道鉴别网络,用于解决跨域少样本图像分类问题。具体来说,基于随机高斯仿射的通道鉴别网络包含一个随机高斯特征增强模块和域通道鉴别模块。随机高斯仿射模块用于在训练阶段扰动源域数据以模拟图像特征的不同分布,从而使得模型适应域偏移情景;域通道鉴别模块则将图片特征解构出有效的领域无关特征,用于帮助模型学习不同域中包含的显著归纳偏差。在两个不同的目标数据集上进行实验,其实验结果表明了所提出的方法可以有效提高小样本模型的跨域泛化能力。主要贡献总结如下:

(1)提出了一个随机高斯仿射模块,从充分统计扰动的视角去解决小样本模型从单一源域数据泛化到未知域数据所面临的域偏移问题。

(2)提出了一个域通道鉴别模块,用于辅助模型在学习过程中区分出特征信道中的领域相关信息和无关信息,挖掘其中的可泛化知识从而提高模型的跨域学习能力。

(3)在两个目标域图像数据集上的实验结果表明了所提出方法的有效性,本文提出的基于高斯特征增强的域不变信息鉴别网络建立了一个全新的技术状态。

1 相关工作

1.1 跨域少样本学习

作为少样本学习的一个分支,跨域少样本学习将重点集中在少样本情况下的域偏移问题。模型在元学习框架下进行训练和测试,在不同阶段中接受的数据存在明显的领域分布偏移。为了使得模型在域偏移下仍然有良好的学习能力,Sun 等^[8]引入了可解释的方法,根据可解释的结果反向优化网络。Tseng 等^[5]提出了基于超参数的特征仿射层,在元训练阶段模拟跨领域场景。Wang 等^[9]在任务层面进行增强,提出对抗性特征增强范式帮助模型学习自适应诱导偏差。Fu 等^[7]则在不违背基本定义的情况下提出辅助域设置,以帮助模型学习有效的先验知识。

但是目前所提出的工作仍存在一定的局限性,例如,它们在大部分情况下均对源数据进行加性扰动,难以模拟真正合理有效的未知数据分布。

1.2 少样本图像分类

少样本图像分类(Few-shot Image Classification)作为一种快速学习技术,旨在训练一个学习模型,该模型可以在少样本条件下学习到可推广到新类的知识。目前少样本图像分类的工作主要从基于优化的方法、基于迁移学习的方法和基于度量的方法来解决少样本问题。基于优化的方法在给定少数带标签图像的情况下,仅靠几个步骤优化学习器来解决少样本学习问题。基于度量的方法则专注于学习一个可以聚集同一样本和分离不同样本的嵌入空间。基于迁移学习的方法其核心思想在于学习一组良好的特征初始化,并使用少量任务进行微调以提高模型的精度。

然而,研究指出,当训练阶段的源域数据集和测试阶段的未知目标域数据集之间存在分布偏差时,现有算法与模型的少样本分类表现不佳。为了缓解因域偏移导致的性能下降问题,本文提出的方法在训练阶段模拟跨域情况,以解决跨域问题。

1.3 域泛化

领域泛化方法旨在学习源域中的可泛化知识,并运用于全新未知的目标领域中。领域泛化方法主要划分为域扩充方法和域不变知识提取方法。在域扩充方法中,它通过从特征角度或者任务角度多样化源数据,从而使得模型在训练阶段适应这种变化。在域不变知识提取方法中,常见的做法是通过对抗学习或者元学习方法来学习不同源域分布

中的共性知识,从而赋予模型良好的泛化能力。例如,Zhu等^[10]提出具有空间紧凑性保持的局部对抗域泛化方法来提升模型泛化精度。Wei等^[11]提出一个基于元优化的有效策略去解决域对齐和分类任务之间优化不一致问题,从而提高模型在无监督域适应任务上的性能。

然而,现有的领域泛化研究仍然会因为过度依

赖源域数据,从而学习到大量域特定知识。此外,它们侧重于在多源环境和训练数据量充足的情况下解决问题,这在实践中很难满足。

2 方法

方法框架见图1。

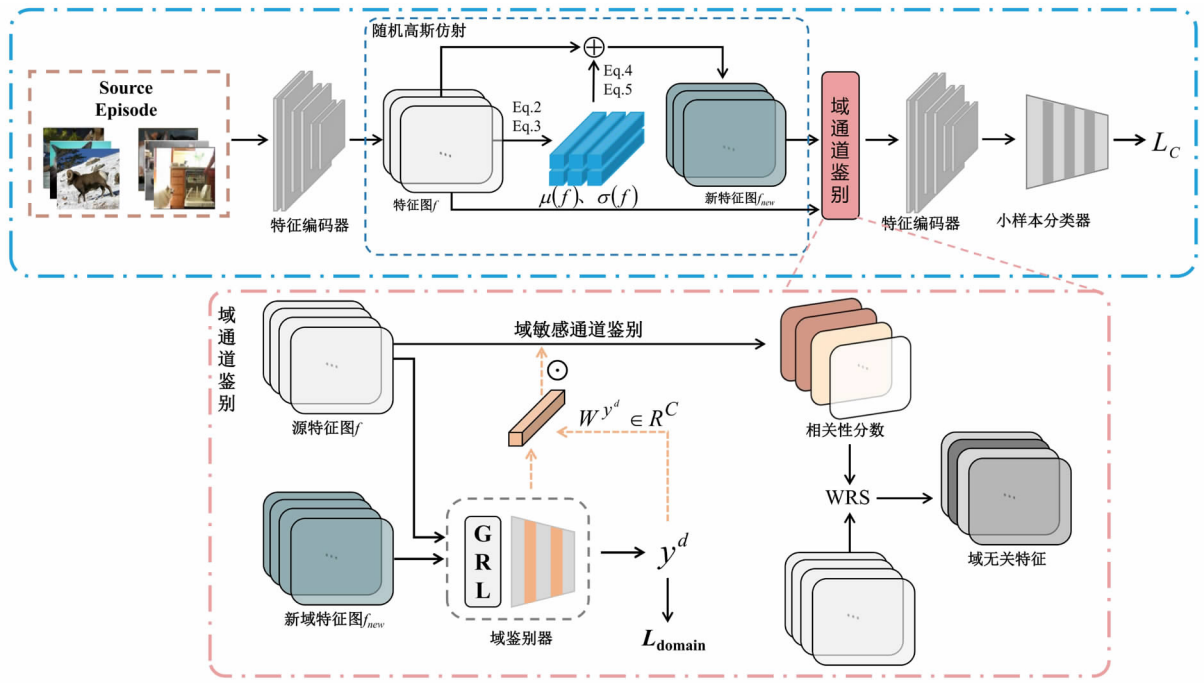


图1 方法框架

2.1 问题定义

在少样本设置中,训练和测试阶段的数据由支持集和查询集组成,模型在两个阶段使用的数据集分别来自不同的分布,并且在类别上不重叠,即 $C_{train} \cap C_{test} = \emptyset$,每一个少量分类任务都被称为 N-way K-shot 问题,具体来说,从数据集中随机抽取 N 类样本,从每一类中随机抽取 $K+m$ 个实例,从每一类中随机抽取 K 个实例作为支持集,再从每一类中抽取剩余的实例作为查询集。

2.2 方法概述

对于一个基本的跨域少样本图像分类任务,少样本学习器在元训练阶段基于支持集和特征提取器 E 来优化少样本分类器 D_c ,其中的可优化参数为 θ_f, θ_c ,在元测试阶段,模型基于学习到的先验知识最小化查询集的分类损失,即:

$$\min_{\theta_f, \theta_c} L_c = L_c(y_q^c, \hat{y}_q^c), \hat{y}_q^c = D_c[E(T_q; \theta_f); \theta_c] \quad (1)$$

所提出的基于高斯仿射的通道知识鉴别框架,包含一个特征提取器 E 、域鉴别器 D_d 、小样本分类

器 D_c 、随机高斯仿射模块和域通道知识鉴别模块。在元训练阶段对源图像数据进行高斯扰动以生成区别于源数据分布的全新分布,从而模拟跨域场景。然后,通过引入域鉴别器让模型学会区分源域特征和未知域特征(生成特征),从而学会提取不同领域之间的域无关特征来提高小样本模型的跨域泛化能力。

2.3 随机高斯扰动模块

为了缓解因训练和测试阶段中数据域分布偏差所导致的模型精度下降问题,我们在训练阶段模拟未知分布,从而使得少样本模型能够提前适应各种挑战性分布。给定输入数据的均值和方差,其正态分布将最大熵作为代表数据知识当前状态的有效展现。因此,我们通过干涉已知源域数据的特征分布的充分统计量以实现特征变换。具体来说,给定 $f \in R^{B \times C \times H \times W}$ 为输入图片到中间层的编码特征图,其中 W, H 分别为特征图的宽和高, C 为通道数, B 为批次大小。而 μ, σ 分别为特征图 f 的均值和方差。特征分布的充分统计量包含分布的所有信息。

每个批次中实例特征的平均值和方差定义为:

$$\mu(f) = \frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W f_{b,c,h,w} \quad (2)$$

$$\sigma^2(f) = \frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W [f_{b,c,h,w} - \mu(f)]^2 \quad (3)$$

特征的均值 μ 和方差 σ 是最能代表当前域分布状态的信息表示。随后,将随机高斯噪声添加到风格 (μ, σ) 中以生成区别于源域的全新特征分布,具体如下所示:

$$\mu_{\text{new}}(f) = \mu(f) + k \cdot N(0, I) \quad (4)$$

$$\sigma_{\text{new}}(f) = \sigma(f) + k \cdot N(0, I) \quad (5)$$

其中 $N(0, I)$ 为高斯噪声, k 被设置为 $16/255$ 。然后根据计算得出的新充分统计 $(\mu_{\text{new}}(f), \sigma_{\text{new}}(f))$ 生成新特征 $f_{\text{new}} \in R^{C \times H \times W}$:

$$f_{\text{new}} = \mu_{\text{new}}(f) \frac{f - \mu(f)}{\sigma(f)} + \sigma_{\text{new}}(f) \quad (6)$$

其中 C 为通道数, H 和 W 为宽和高。

2.4 域通道鉴别模块

文献[12]提出一个域鉴别器,并定义了一个极大极小对抗优化问题来提取不同域的共同特征,具体过程如下所示:

$$\min_F D_d(D_{d1}, D_{d2}) = \max_{F, h \in H} \min_{r} [h(s)] \quad (7)$$

其中 $h(\cdot)$ 为域鉴别器, H 为域鉴别器假设集。因此,在该模块中我们引入域鉴别器,源域特征 f 和生成特征 f_{new} 视为来自不同的两个域分布 D_{d1} 和 D_{d2} , 输入到域鉴别器中,通过计算对域标签预测贡献最大的信道区分其中的域敏感特征和域无关特征。在本文中,域鉴别器的更新不是随着主网络进行预测和优化而同步进行的,具体因为梯度反转层(GRL)被放置在域鉴别器之前以截断梯度,从而避免域鉴别器对主网络造成负面影响。

具体来说,在多个隐藏层中插入域鉴别器,用来鉴别域特定信息和域无关信息。将第 i 层源域中间特征 f_{ori}^i 和生成特征 f_{new}^i 输入到域鉴别器预测域标签并计算域分类损失,使用梯度反转层(GRL)来实现对域鉴别器的优化:

$$L_{\text{DC}} = \frac{1}{2N} \sum_i [-y_i^d \log(\hat{y}_i^d) - (1 - y_i^d) \log(1 - \hat{y}_i^d)], \quad 1 \leq i \leq 2N \quad (8)$$

利用域鉴别器其预测结果的加权激活值,引入相关性系数 Z_j 用来量化每个信道和域信息之间的相关性:

$$z_j = W_j^{y^d} \cdot \text{GAP}(f^j) \quad (9)$$

其中, $W_j^{y^d} \in R^C$ 为域鉴别器针对真实预测值的

FC层权重, GAP 为全局平均池化层, C 是通道数。加权激活值越高说明该通道对真实预测值的贡献越大,即域特定信息越多。为了减少特征图中的域特定信息,并提取因果特征,我们利用相关性系数计算去除第 j 个通道的概率:

$$P_j = z_j / \sum_{c=1}^C z_c \quad (10)$$

可知, z_j 的数值越高,代表相对的信道被丢弃的概率越大。随后,对于具有 z_j 的第 j 个通道,使用加权随机选择算法(WRS)生成二进制掩码 $m \in R^C$:

$$m_j = \begin{cases} 0, & \text{if } j \in \text{TOP}(\{k_1, k_2, \dots, k_C\}, M) \\ 1, & \text{otherwise} \end{cases} \quad (11)$$

其中 $k_j = r_j^{1/z_j}$ 为密钥值, r_j 为随机数, $\text{TOP}(\{\cdot\}, M)$ 代表具有键值的 M 个项。此外,我们定义超参数 $P_d = M/C$ 为要丢弃的通道数。

3 实验

3.1 数据集与实验设置

在这项工作中,实验使用 Mini-imagenet 作为源域数据集 D_S , 使用 CUB 和 Cropdisease^[13] 作为目标域数据集 D_T 。

先前的工作均使用 Resnet-10 作为特征提取器,为了公平比较,本工作所有实验均使用 Resnet-10 作为特征提取器。在实验中,Adam 作为优化器,学习率设置为 0.001,梯度反转层的权重设置为 0.26。在元训练和元测试阶段采用 5-way 1-shot 和 5-way 5-shot 的设置,以 Mini-imagenet 数据集执行 200 个历元的少样本分类任务。

3.2 主要结果

在本实验中,使用 RelationNet^[14] 和 GNN^[15] 两种少样本度量分类器,并作为少样本方法基线参与比较。参与比较的跨域少样本学习方法均分别在这两个分类框架下进行比较,参与比较的方法为 LRP^[9]、FWT^[5]、ATA^[10]、AFA^[16]。

具体实验结果如表 1 所示。从结果中,可以发现在 1-shot 和 5-shot 设置中,在 CUB 和 Cropdisease 数据集上所提出的方法精度整体均优于专门为跨域少样本任务设计的竞争对手。此外可以观察到,用于解决少样本问题的 RelationNet 和 GNN 框架在跨域分类表现上甚至比不上跨域少样本学习领域早期提出的 FWT 方法,这表明标准的少样本学习模型在跨域分类表现上仍受限于域偏

移的影响。

3.3 消融实验

3.3.1 所提出部分对跨域精度的影响

实验使用弱泛化数据集 CUB 和强泛化数据集 CropDiseases 来评估各个模块的性能。具体实验结果如表 2 所示。本次实验使用 GNN 作为基

线,即表中第一行所表现的情况。需要注意的是,在去除高斯扰动模块的方法中(第二行结果),默认使用线性扰动进行特征变换。实验结果表明,所提出方法的各个部分均能有效改进模型的学习能力,而所提出的两个部分的有效结合则能最大化激发模型的学习能力。

表 1 对比实验结果

模型/Shot	CUB		CropDisease	
	1-shot	5-shot	1-shot	5-shot
RelationNet	41.27±0.4	56.77±0.4	53.58±0.4	72.86±0.4
+FWT	44.07±0.8	59.46±0.7	57.57±0.5	75.78±0.4
+ATA	43.02±0.4	59.36±0.4	61.17±0.5	78.20±0.4
+Ours	45.39±0.5	61.38±0.4	62.51±0.4	79.08±0.4
GNN	44.40±0.5	62.87±0.5	59.19±0.5	83.12±0.4
+FWT	45.50±0.5	64.97±0.5	60.74±0.5	87.07±0.4
+ATA	45.00±0.5	66.22±0.5	67.47±0.5	90.59±0.3
+LRP	48.29±0.5	64.44±0.5	59.23±0.5	86.15±0.4
+AFA	46.86±0.5	68.25±0.5	67.61±0.5	87.06±0.3
+Ours	48.95±0.3	69.36±0.6	69.14±0.4	90.01±0.3

表 2 各部分的消融实验

随机高斯仿射	域通道鉴别	CUB		CropDiseases	
		1-shot	5-shot	1-shot	5-shot
×	×	44.40±0.5	62.87±0.5	59.19±0.5	83.12±0.4
×	✓	47.69±0.3	67.32±0.5	68.11±0.4	87.74±0.3
✓	×	48.03±0.3	68.77±0.5	68.54±0.4	88.79±0.3
✓	✓	48.95±0.3	69.36±0.6	69.14±0.4	90.01±0.3

3.3.2 超参数影响

针对域通道鉴别模块中超参数 P_d 的选取对模型精度造成的影响,我们就 P_d 分别选取 $\{0, 0.2, 0.25, 0.3, 0.35, 0.4\}$ 来探索对于模型学习最优的 P_d ,实验选取 CUB 和 CropDiseases 数据集在 1-shot 设置下的结果。具体结果如图 2 所示,其中紫色部分代表了 GNN 基线的预测精度,绿色部分则为模型在不同 P_d 参数下的表现。可以看到:(1)在 CUB 和 CropDisease 两个数据集上,模型在不同的 P_d 设置的预测精度比基线平均改进了 3.01%;(2)当 P_d 设置为 0.35 时,模型的预测精度均高于模型在其余 P_d 设置下的精度,因此我们选取 $P_d=0.35$ 为实验的默认数值。

3.4 目标域辅助任务的影响


由前文所述,部分工作会在训练阶段引入少量带标签的目标数据作为辅助,因此,本次实验移除

高斯仿射模块,引入少量目标域数据来测试所提出的方法的泛化精度是否会因辅助任务的参与而受到影响。本次实验以 Mini-ImageNet 为源域,CUB 作为目标域,以 GNN 作为基线模型进行测试,具体结果如表 3 所示。

表 3 辅助任务对模型表现的影响

模型	CUB	
	1-shot	5-shot
Baseline	44.40±0.5	62.87±0.5
Ours(引入辅助任务)	48.57±0.3	69.19±0.6
Ours(无辅助任务)	48.95±0.3	69.36±0.6

可以观察到,在 5-way 1-shot 和 5-way 5-shot 设置下,模型的精度并无较大差别,这说明引入辅助任务对模型的跨域准确度并无较大帮助。

图 2 P_0 参数对模型的影响

4 结论

现有的跨域少样本工作仍然容易受到领域特定信息的影响导致模型在跨域泛化时容易过拟合到源域分布的数据。为此,提出了一个基于通道知识鉴别的跨域少样本图像分类框架。所提出的框架包含一个随机高斯仿射模块和域通道鉴别模块,少样本模型在该框架的帮助下高效提取出域无关信息,以改进跨域泛化能力。在实验中,使用 Mini-ImageNet 为源域数据集,并在 CUB 和 CropDisease 数据集上进行实验,其实验结果表明,所提出的框架优于大多数当前领域中现有的方法。

参考文献

[1] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//International Conference on Machine Learning. PMLR, 2017: 1126–1135.

[2] ULLAH I, CARRION-OJEDA D, ESCALERA S, et al. Meta-album: multi-domain meta-dataset for few-shot image classification[J]. Advances in Neural Information Processing Systems, 2022, 35: 3232–3247.

[3] GUO Y, CODELLA N C, KARLINSKY L, et al. A broader study of cross-domain few-shot learning[C]//Computer Vision-ECCV 2020, 2020: 124–141.

[4] WANG R, ZHENG H, DUAN X, et al. Few-shot learning with visual distribution calibration and cross-modal distribution alignment[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 23445–23454.

[5] TSENG H Y, LEE H Y, HUANG J B, et al. Cross-domain few-shot classification via learned feature-wise transformation[J]. arXiv preprint arXiv:2001.08735, 2020.

[6] LI W H, LIU X, BILEN H. Universal representation learning from multiple domains for few-shot classification[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 9526–9535.

[7] FU Y, FU Y, JIANG Y G. Meta-fdmixup: cross-domain few-shot learning guided by labeled target data[C]//Proceedings of the 29th ACM International Conference on Multimedia, 2021: 5326–5334.

[8] SUN J, LAPUSCHKIN S, SAMEK W, et al. Explanation-guided training for cross-domain few-shot classification [C]//2020 25th international conference on pattern recognition (ICPR). IEEE, 2021: 7609–7616.

[9] WANG, DENG Z. Cross-domain few-shot classification via adversarial task augmentation[C]//Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. IJCAI, 2021: 1075–1081.

[10] ZHU W, LU L, XIAO J, et al. Localized adversarial domain generalization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 7108–7118.

[11] WEI G, LAN C, ZENG W, et al. Metaalign: coordinating domain alignment and classification for unsupervised domain adaptation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 16643–16653.

[12] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//International Conference on Machine Learning. PMLR, 2015: 1180–1189.

[13] MOHANTY S P, HUGHES D P, SALATHE M. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7: 1419.

[14] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: relation network for few-shot learning[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1199–1208.

[15] SATORRAS V G, ESTRACH J B. Few-shot learning with graph neural networks [C]//International Conference on Learning Representations, 2018.

[16] HU Y, MA A J. Adversarial feature augmentation for cross-domain few-shot classification[C]//European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 20–37.