arXiv:2302.11803v1 [cs.LG] 23 Feb 2023

无源域自适应综述

Zhiqi Yu、Jingjing Li、Zhekai Du、Lei Zhu、Heng Tao Shen

摘要——在过去十年中，域适应已成为迁移学习中受到广泛研究的一个分支，旨在通过利用源域中的知识来提升模型在目标域上的性能。传统的域适应方法通常假设可以同时访问源域和目标域数据，但由于隐私和保密性方面的考虑，这在现实场景中往往难以实现。因此，近年来无源域适应（SFDA）研究日益受到关注，该方法仅利用源域训练模型和无标签目标数据来适应目标域。尽管无源域适应研究迅速发展，但该领域尚缺乏及时且全面的综述。为填补这一空白，我们全面总结了无源域适应的最新进展，并基于迁移学习框架将其组织为统一的分类体系。我们没有分别介绍每种方法，而是将各方法的若干组成模块化，以便结合每种方法的复合特性，更清晰地阐释它们之间的关系及其机制。此外，我们在三个广受欢迎的分类基准（即 Office-31、Office-Home 和 VisDA）上比较了 30 多种具有代表性的无源域适应方法的结果，以探究不同技术路线的有效性及其组合效应。此外，我们还简要介绍了无源域适应的应用和相关领域。基于对无源域适应所面临挑战的分析，我们对未来的研究方向和潜在设置提出了一些见解。

索引词—域适应、迁移学习、计算机视觉、无数据学习。

1 引言

深度神经网络凭借其泛化能力，能够在监督学习任务中取得令人满意的表现。然而，由于成本和隐私顾虑等因素，收集足够的训练数据可能代价高昂。例如，为一张单源城市景观图像进行语义分割手动标注，可能需要长达 90 分钟。为缓解这一问题，人们提出了迁移学习 [1], [2]，以便在标签缺失条件下实现跨域知识迁移。

域适应（DA） [3], [4], 作为一个重要分支
迁移学习关注的是如何借助有标签源域数据，提高模型在无标签目标域上的性能。在独立同分布条件下，域适应面临的最大挑战是如何减少域偏移。域偏移主要可分为条件偏移、协变量偏移、标签偏移和概念偏移，这些问题已在此前的领域自适应综述中得到广泛讨论 [5], [6]。

在传统的域适应方法中，通常假设适应过程中可以访问源域和目标域的数据。然而，在许多应用场景中，实际情况并非如此。一方面，出于个人隐私、保密性和版权等问题，某些情况下无法获取原始源域数据；另一方面，在一些资源受限设备上，为训练而保存完整的源数据集并不现实。上述问题都阻碍了该领域的进一步发展。为了降低域适应方法对源数据的依赖，近年来提出了无源域适应（SFDA） [7], [8], 并迅速成为域适应领域的研究焦点，

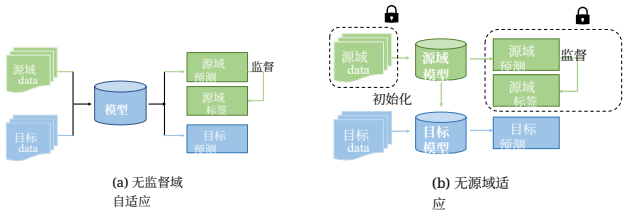


图 1. 无监督域自适应与无源域适应设定的比较。

该方法已在图像分类 [9], [10]、语义分割 [11], [12]和目标检测 [13], [14]领域得到广泛研究。

如图 1 所示，无源域适应与无监督域自适应 (UDA) [15], [16] 最显著的区别在于，无监督域自适应模型可以利用源域数据和目标域数据进行训练，而无源域适应只能利用源模型初始化目标模型，然后使用无标签目标数据对其进行更新。现有的主流无监督域自适应方法可分为两大类：一类通过设计特定的度量[3], [17], [18], 来对齐源域和目标域的域分布，另一类则通过对抗学习 [19], [20], [21]来学习域不变特征表示。然而，这些主流无监督域自适应方法并不适用于没有源域数据的场景，因此有必要研究无源域适应方法作为替代方案。尽管已有大量工作致力于无源域适应，但目前尚无对相关研究的全面综述，也缺乏对无源域适应当前进展的总结。为弥补这一空白，我们旨在通过本综述及时、全面地回顾无源域适应的最新进展。

在这项工作中，我们沿用现有的迁移学习

作者来自中国电子科技大学计算机科学与工程学院，成都，*611731*。

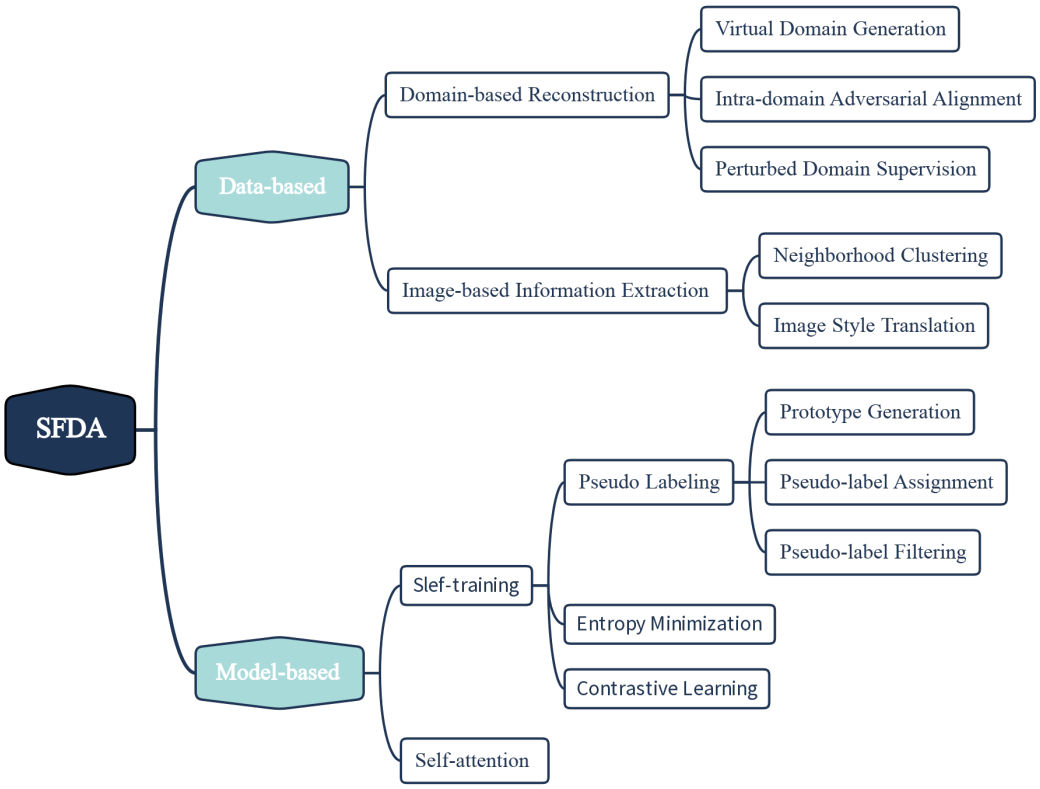


图 2. 无源域适应方法的分类体系。

综述 [2], [22]，并将无源域适应分为两个方向：基于数据的方法和基于模型的方法。此外，我们发现，传统无监督域自适应方法通过一些额外步骤，利用重构后的源域，开始适用于无源域适应场景。因此，我们将这一范式称为基于域重构的方法，以体现无监督域自适应研究的可扩展性。我们在图 2 中展示了无源域适应方法的整体结构。

从以数据为中心的视角来看，基于域的重构和图像风格迁移可以被视为无监督域自适应（UDA）的一些衍生方法。基于域的重构背后的直觉相当直接，即旨在重构一个域，或在目标域内进一步划分，以弥补缺失的源域数据，从而使无监督域自适应方法能够扩展到无源域适应（SFDA）设定。具体而言，它可以细分为虚拟域生成、域内对抗对齐和扰动域监督。图像风格迁移通过源分类器的批归一化（BN）层，将目标域数据转换为不可见的源域风格，从而使目标域数据能够更好地适配源模型。邻域聚类基于这样的观察：目标数据中潜在的内在结构嵌入在邻居关系中，即使目标域数据分布无法与源分类器进行显式对齐。一种假设是，目标域的每个类别都存在位于源模型决策边界内的邻居，因此可以通过保持邻居之间的一致性，将这些困难样本映射到源域分布。最后，局部结构聚类基于流形学习 [23], [24], [25], ，并通过选择邻居节点来执行聚类。

从模型中心视角来看，大多数方法都假设，由于源域与目标域之间存在相似性，源域预训练模型在目标域上具有一定的泛化能力。因此，可以通过探索模型在目标数据上的输出对模型进行微调。这种自训练方案源自半监督学习的思想 [26],[27], [28], ，还可进一步分为伪标签、熵最小化和对比学习。值得注意的是，由于伪标签方法在无源域适应中最为常用，我们会对其给予更多关注。伪标签通常通过先为目标域中的高置信度样本生成伪标签，再利用所得伪标签优化模型来实现。因此，如何获得高质量的伪标签是此类方法关注的核心。本文尝试围绕原型生成、伪标签分配和伪标签过滤等各个流程，对这一技术路线进行全面探讨。

此外，我们观察到，大多数无源域适应方法由多个技术组件构成，而每个组件都可能对应我们分类体系中的一个类别。因此，不同于以往将每项工作独立看待的域适应综述，我们旨在将每种无源域适应方法模块化并进行分类，以揭示不同研究方向之间的关联。本综述旨在讨论无源域适应的问题定义，总结该领域的最新进展，并突出无源域适应技术的独特组件

表 1 无源域适应与其他相关设置的比较。

	无源数据	源模型	无标签目标域	额外源域信息	无训练
无数据知识蒸馏	✔	-	-	-	✗
联邦域适应	✗	✔	✔	✗	✗
零样本域适应	✗	✔	✗	✗	✗
测试时域适应	✔	✔	✔	✗	✔
源放宽域适应	✔	✔	✔	✔	✗
无源域适应	✔	✔	✔	✗	✗

从而全面理解这一领域，并激发更多想法与应用。本综述的主要贡献可概括如下。

- 我们从以数据为中心和以模型为中心两个视角，为新兴的无源域适应设定提出了一套整体分类体系框架。本综述及时、全面地总结了最新的无源域适应方法及其应用，填补了现有文献中的空白。

- 我们将 30 多项代表性研究模块化，并在应用最广泛的分类数据集（即 Office-31、Office-Home 和 VisDA）上对结果进行了比较。我们以直观的方式呈现并对比分析了不同组件的组合，这有望为无源域适应设定下的后续研究提供借鉴。

本综述其余部分的结构如下。第 2 节介绍与无源域适应相关的符号表示和预备知识。第 3 节和第 4 节分别全面回顾以数据为中心和以模型为中心的无源域适应方法。第 5 节比较现有无源域适应方法在三个主流分类数据集上的表现。第 6 节讨论无源域适应的潜在应用，第 7 节展望无源域适应的未来方向。最后，第 8 节总结全文。

2 概述

本节介绍一些符号表示以及与无源域适应相关的预备知识，并简要描述无源域适应方法中的若干设置。

2.1 符号表示与定义

为确保文献中的一致性，我们尽可能采用与迁移学习 [22] 和深度域适应 [6], [29]相关综述中相同的符号表示，并将其汇总于表 2。下面给出一些与无源域适应问题密切相关的基本定义。

表 2 与无源域适应相关的符号表示。

符号	描述
n	实例数量
$\mathcal{D}$	域
$\mathcal{X}$	实例集
d	特征维度
$\mathcal{F}(\mathcal{X})$	特征向量
$\mathcal{Y}\|\mathcal{X}$	实例的预测 $\mathcal{X}$
Φ	域空间
$\mathbf{L}$	源标签集
$\mathcal{L}$	损失函数
δ	Softmax 操作
c	类别数
$\widetilde{z}$	噪声向量
Θ	模型参数
$\mathcal{F}$	特征提取器
$\mathcal{C}$	分类器
$\mathcal{D}$	域判别器
G	生成器
$\mathcal{M}$	待训练模型
$\mathbf{M}$	模块
$\mathcal{B}$	记忆库
μ	均值
σ	标准差
$\mathbb{E}$	数学期望
P	边缘分布
Q	查询
K	Key
V	值
$\mathcal{N}(\mu,\ \sigma^2)$	均值为 μ 、方差为 σ^2 的高斯分布

定义 ***1.***（无源域适应中的域）一个域通常包含一个数据集 Φ 和一个对应的标签集 $\mathbf{L}$，其中数据集包含从边缘分布 $\mathcal{P}(\mathcal{X})$ 中抽取的实例集 $\mathcal{X}$ ，以及对应的维度 d。在无源域适应中，源域 $\mathcal{D}^s = \{\{\mathcal{X}^s, \mathcal{P}(\mathcal{X}^s)\ d^s\}, \mathbf{L}^s\}$ 通常是完整的，但请注意它仅在预训练期间可用。目标域 $\mathcal{D}^t = \{\{\mathcal{X}^t, \mathcal{P}(\mathcal{X}^t)\ d^t\}\}$ 的标签集不可用，其边缘分布也与源域不同。在典型的无源域适应中，我们假设标签空间是封闭的，即源域和目标域的标签空间相同。

定义 ***2.***（源自由域适应任务）给定一个在源域 $\mathcal{D}^s = \{\{\mathcal{X}^s, \mathcal{P}(\mathcal{X}^s)\ d^s\}, \mathbf{L}^s\}$上训练的模型 $\mathcal{M}$ ，无源域适应过程分为两个阶段。第一阶段（预训练）中，源模型通过有标签的

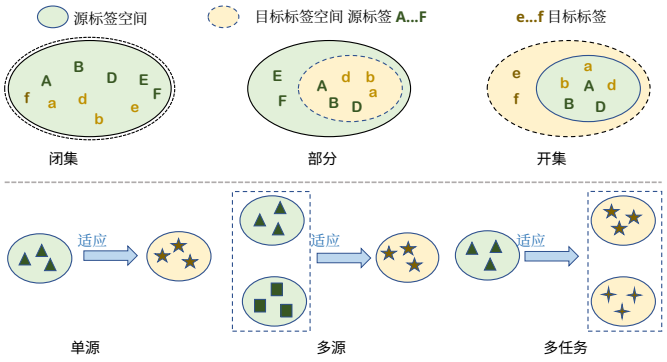


图 3. 无源域适应中不同设定的示意图。

源数据进行监督学习。在第二阶段（适应）中，源域数据不可用，无源域适应的目标是利用无标签目标数据 $\Phi^t = \{\{\mathcal{X}^t, \mathcal{P}(\mathcal{X})^t, d^t\}$将源域训练模型适应到目标域，即使输出 $\mathcal{M}(\mathcal{X}^t) = P(\mathcal{Y}^t|\mathcal{X}^t)$ 获得较高准确率，其中 $P(\mathcal{Y}^t|\mathcal{X}^t)$ 是目标数据 $\mathcal{X}^t$的预测结果。

值得注意的是，上述定义也可能涵盖一些扩展情形。对于域的定义，无源域适应可能包括多源域 [30], [31],即 $\mathcal{D}^s = \{\sum_{i=1}^{m} \mathcal{D}_i^s\}$，其中 m 是源域的数量；也可能存在非闭集情形，例如通用无源域适应 [9]。对于无源域适应中任务的定义，例如，在某些扩展的无源域适应设定中，执行任务时也可以使用少量有标签的目标域数据（即主动式无源域适应 [32],[33]）。我们将在下一节讨论无源域适应的不同变体。

2.2 无源域适应设定概述

一般而言，根据源域和目标域的特征空间是否相同，域适应可分为同质域适应和异质域适应。在异质域适应中 [34],，源域和目标域的分布空间与特征空间都可能不同，即 $P(\mathcal{X}^s) \neq P(\mathcal{X}^t)$以及 $d^s \neq d^t$，因此可能需要同时进行分布适应和特征空间适应。而在同质域适应中，源域和目标域的特征空间相同，只进行分布适应。在现有的无源域适应方法中，大多数仅涉及同质域适应，这也是本综述讨论的重点。

根据源域与目标域之间的标签集对应关系，可将设置分为闭集、部分和开集，其相互关系如图 3 所示。根据源域和目标域的数量，还可分为单源、多源和多任务设置。在本文中，我们主要关注最常见的闭集单源无源域适应设置，同时也会简要介绍其他设置。

3 基于数据的方法

这类广泛的数据方法研究可根据两种不同的动机分为两条路线。一方面，鉴于源域数据不可用，最直观的想法之一是利用模型中隐含的源域信息来模拟源域数据，或重构一个中间域或其他域，以弥补源域数据的缺失。另一方面，考虑到目标域没有标注，另一类方法可以被视为试图挖掘无标签目标域数据中的潜在数据结构或聚类信息，从而仅利用目标域数据独立执行域适应任务。在我们的分类中，分别将上述两个方向称为基于域的重构和基于图像的信息提取。下面将分别对这两个方向进行详细介绍。

3.1 基于域的重构

这类方法的核心目的是重构一个新域，以监督目标域。通常，构建新域有三个方向：一是生成虚拟源域；二是构建扰动目标域以进行鲁棒学习；三是将目标域划分为源域相似部分和目标域相似部分，然后进行域内对抗以实现对齐。

3.1.1 虚拟域生成

在无监督域自适应中，一种典型范式是在源域上监督模型，同时采用一些技术直接对齐源域和目标域的分布。该过程的整体训练目标可以表示为：

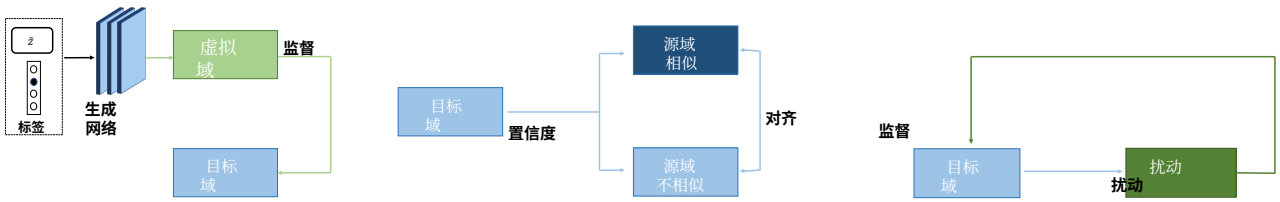
$$\mathcal{L}_{UDA_M} = \mathcal{L}_{cls}\left(\mathcal{C}\left(\mathcal{F}\left(\mathcal{X}^s\right)\right), \mathcal{Y}^s\right) + \mathcal{L}_{div}\left(\mathcal{F}\left(\mathcal{X}^s\right), \mathcal{F}\left(\mathcal{X}^t\right)\right), \tag{1}$$

其中，$\mathcal{L}_{cls}$ 表示源域上的监督损失，通常使用交叉熵。$\mathcal{L}_{div}$ 表示用于对齐的准则。然而，在无源域适应（SFDA）中，适应过程中无法获取 $\mathcal{X}^s$。因此，虚拟域生成方法试图构建一个域，以弥补源数据的缺失。上述公式可扩展如下：

$$\mathcal{L}_{SFDA} = \mathcal{L}_{gen}\left(\mathcal{C}\left(\mathcal{F}\left(\mathcal{X}^v\right)\right)\right) + \mathcal{L}_{div}\left(\mathcal{F}\left(\mathcal{X}^v\right), \mathcal{F}\left(\mathcal{X}^t\right)\right), \tag{2}$$

其中，$\mathcal{X}^v$ 表示虚拟域，$\mathcal{L}_{gen}$ 表示虚拟域的生成损失。需要注意的是，该模型已在源域上进行预训练，因此可以通过探索模型的输出模拟域分布。

可以发现，与公式 3 相比，SFDA 除了需要关注域之间的对齐，还应关注虚拟域生成的质量。由于虚拟域生成后，SDFA 的对齐问题变得与 UDA 类似，例如，ADDA [21] 被用于 VDA-DA [35]，而 MMD [36] 被用作



(a) 虚拟域生成 (b) 域内对抗对齐 (c) 扰动域监督

图 4. 域重构方法概览。

STDA [37],中的对齐度量；本节将重点讨论如何生成虚拟域。从技术上讲，虚拟域可以通过两种方式生成：基于对抗式生成或基于高斯分布。

借鉴 GAN 的思想 [38], , 对抗生成可表示为:

$$\mathcal{L}\left(\mathcal{C},\mathcal{F},\mathcal{D},G\right)=\mathcal{L}_{adv}+\mathcal{L}_{con}, \tag{3}$$

其中， $\mathcal{L}_{con}$ 是用于约束跨域语义一致性的一致性损失，并且可以包含多个视角。 $\mathcal{L}_{adv}$ 表示生成器与域判别器之间的对抗损失，通常基于以下公式:

$$\begin{aligned}\mathcal{L}_{adv}\left(G\right)&=\mathbb{E}_{y,\tilde{z}}\left[\log\mathcal{D}\left(1-G\left(y,\tilde{z}\right)\right)\right],\\ \mathcal{L}_{adv}\left(\mathcal{D}\right)&=\mathbb{E}_{x_t\sim\mathcal{X}_t}\left[\log\mathcal{D}\left(x_t\right)\right]+\mathbb{E}_{y,\tilde{z}}\left[\log\left(1-\mathcal{D}\left(G\left(y,\tilde{z}\right)\right)\right)\right],\end{aligned} \tag{4}$$

其中， $\tilde{z}$ 表示噪声向量， $G\left(y,\ \tilde{z}\right)$ 表示以预定义的有标签 y为条件的生成器，这不同于传统生成器 [39], [40]。

此类方法的重点在于$\mathcal{L}_{con}$的设计。3C-GAN [41]是该领域的开创性工作之一；对于生成器，它强调生成的 $x_v=G\left(y,\ \tilde{z}\right)$ 与标签 y之间的语义相似度。对于分类器，研究者提出了确定性约束、权重约束和基于聚类的约束，以提升其性能。此外，SDDA [42] 提出了一种基于域判别器的一致性损失，通过二分类损失引导特征提取器提取域不变特征。CPGA [43] 受 InfoNCE[44] 启发，通过添加对比损失，为每个类别生成更具代表性的原型。

虚拟域生成的另一种方式，是根据预训练模型中包含的隐式知识，基于高斯分布模拟源域的分布。一般来说，主要有两种观点。一种观点是从标准高斯分布中采样噪声，将其作为生成器的输入，此时虚拟源数据生成过程 $\tilde{x}$ 可表示为:

$$\tilde{x}=G\left(\tilde{z}\right),\tilde{z}\sim\mathcal{N}\left(0,1\right). \tag{5}$$

基于无数据知识蒸馏 [45],Liu 等[11] 提出了一种批归一化统计损失，利用源域模型 BN 层中存储的均值和方差对源域分布进行建模。

另一种观点是将源域分布视为多重高斯分布混合。例如，VDM-DA [35] 构建了一个高斯混合模型，用于表示特征空间中虚拟域的分布:

$$D^v\left(f_v\right)=\sum_{k=1}^{K}\pi_k\mathcal{N}\left(f_v|\mu_k,\sigma^2I\right), \tag{6}$$

其中， f_v 表示虚拟特征， π_k 表示混合系数，且满足 $\sum_{k=1}^{K}\pi_k\ =\ 1$。为了估计高斯混合模型的参数，VDM-DA 根据经验将 K 设为类别数量，并认为源分类器的权重隐式包含了每个类别的原型信息，从而基于源分类器推导出模型的均值和标准差。SoFA [46] 分别对推理过程和生成过程进行建模，并根据预测类别推导出高斯分布混合，作为参考分布。

然而，使用生成模型生成虚拟域不仅成本高昂，而且在底层数据模式复杂时，尤其难以实现良好的域泛化。因此，一些方法尝试采用非生成式方法，例如直接从目标域中选择一些可靠的数据来构建虚拟源域。最常见的思路之一是，将目标域图像输入源模型，预测熵较高的样本被认为更接近源域分布，因此可以在一定程度上用于表征源域分布。然而，这种方法引出的另一个关键问题是虚拟源域数据不足。例如，Du 等人 [47] 发现，可用于构建虚拟源域的样本数量仅为目标域的十分之一，无法充分支撑能够代表整个源域的数据分布。

为了解决这一问题，一系列方法着重研究如何扩充虚拟源域数据。Mixup [48]可视为一种有效技术，PS [47] 将虚拟源域中的样本彼此混合，可表示为:

$$\begin{aligned}\widetilde{x}_{s,aug}&=\lambda\widetilde{x}_s^i+\left(1-\lambda\right)\widetilde{x}_s^j,\\ \widetilde{y}_{s,aug}&=\lambda\widetilde{y}_s^i+\left(1-\lambda\right)\widetilde{y}_s^j,\end{aligned} \tag{7}$$

其中， λ 表示混合系数， $\widetilde{x}_s^i$、$\widetilde{x}_s^j$ 是从虚拟源域中根据预测熵选出的样本，$\widetilde{y}_s^i$、$\widetilde{y}_s^j$ 分别是它们对应的标签。通过这种方式，使用 $D_{aug}^s=D^s\cup D^{aug}$ 与 $D^{aug}=\{\widetilde{x}_{s,aug},\widetilde{y}_{s,aug}\}$可获得增强虚拟源域$\widetilde{\quad}$ $\widetilde{\quad}$ $\widetilde{\quad}$ $\widetilde{\quad}$。而 UIDM [49], 则先在目标域中进行 Mixup，然后以更全面的方式，不仅考虑虚拟源域样本选择中的预测熵，

还考虑 Mixup 操作带来的数据不确定性，以及 Dropout 操作带来的模型不确定性。

除了通过 Mixup 进行数据增强，另一种思路是在训练过程中持续将样本从目标域迁移到虚拟源域。Ye 等人 [50] 提出了一种非线性加权熵最小化损失，在训练过程中持续降低高置信度样本的熵值，同时不影响低置信度样本，从而获得更可靠的样本。尽管虚拟源域中的样本数量不断增加，但对于某些较难的类别，其虚拟源域样本仍可能严重不足。ProxyMix [51] 针对这一问题，使用每个原型的最近邻以及域内 Mixup，构建了一个类别均衡的代理源域。

3.1.2 域内对抗探索

在上一节中，我们介绍了通过生成虚拟域来处理源数据不可用问题的方法，该方法将无源域适应视为跨域问题。另一些方法则在目标域内进行二元划分，然后在保留源模型知识的同时，对两组数据群体进行对抗学习。因此，这些方法实现了目标域整体数据分布的一致性，并将无源域适应视为一种域内对齐。值得注意的是，前文介绍的虚拟源域方法与此类方法在置信度方面有一定的共同启发，但前者强调如何构建虚拟源域，而后者则侧重于以对抗方式进行域内分布对齐。因此，我们将前者归为虚拟域重构类。

从技术角度看，域内对抗对齐主要利用多样化分类器和特征提取器进行对抗，这可视为传统无监督域自适应中双分类器范式对抗方法的一种变体 [52], [53], [54] 。这里我们首先回顾双分类器范式的一般三步流程：

- **步骤 1**源域训练：

$$\min_{\theta_{\mathcal{F}},\theta_{\mathcal{C}_1},\theta_{\mathcal{C}_2}} \sum_{i=1}^{2} \mathcal{L}_{cls}\left(\mathcal{C}_i\left(\mathcal{F}\left(\mathcal{X}^s\right)\right),\mathcal{Y}^s\right),$$

其中， $\mathcal{L}_{cls}$ 表示交叉熵损失， $\mathcal{C}_1$ 和 $\mathcal{C}_2$分别代表两个分类器， $\theta_{\mathcal{F}}$， $\theta_{\mathcal{C}_1}$， $\theta_{\mathcal{C}_2}$ 分别是与特征提取器和分类器对应的模型参数。

- **步骤 2**最大化分类器预测差异：

$$\min_{\theta_{\mathcal{C}_1},\theta_{\mathcal{C}_2}} \mathcal{L}_{cls}\left(\mathcal{X}^s,\mathcal{Y}^s\right)-\mathcal{L}_{dis}\left(\mathcal{Y}_1^t|\mathcal{X}^t,\mathcal{Y}_2^t|\mathcal{X}^t\right),$$

其中，第一项与步骤 1 相同， $\mathcal{L}_{dis}$ 表示两个分类器预测的差异损失。

- **步骤 3**最小化分类器预测差异：

$$\min_{\theta_{\mathcal{F}}} \mathcal{L}_{dis}\left(\mathcal{Y}_1^t|\mathcal{X}^t,\mathcal{Y}_2^t|\mathcal{X}^t\right).$$

现在，我们重新审视无源域适应设定中的这一三步流程。对于第一步，源模型通常以相同的方式进行训练。对于第二步和第三步，由于缺少源数据， $\mathcal{L}_{cls}$项难以处理，而且源域知识也无法得到良好保留。因此，在这种情况下，预测差异项 $\mathcal{L}_{dis}$ 失去了锚定。

为了解决无源域适应设定中的上述问题，可以冻结一个分类器的参数，以保留源域专用分类器，并在无标签目标数据上训练目标域专用分类器。此外，可以根据源域专用分类器的预测置信度或其他标准，将目标域划分为源域相似样本和源异质样本，从而通过目标域专用分类器与源域专用分类器在这两类数据群体上的预测实现域内对抗对齐。形式上，域内对抗对齐方法可归纳为两个步骤：

步骤 1* 通过在源异质样本上最大化目标域专用分类器与源域专用分类器之间的预测差异，同时在源域相似样本上最小化相同的预测差异，来更新目标域专用分类器：

$$\min_{\theta_{\mathcal{C}_t}} \sum_{x\in\mathcal{X}_h^t} \mathcal{L}_{dis}\left(p^s\left(x\right),p^t\left(x\right)\right)-\sum_{x\in\mathcal{X}_l^t} \mathcal{L}_{dis}\left(p^s\left(x\right),p^t\left(x\right)\right), \tag{8}$$

其中， $\mathcal{X}_h^t$和 $\mathcal{X}_l^t$分别表示目标域中的高置信度（源域相似）样本和低置信度（源异质）样本， $\mathcal{X}_h^t\cup\mathcal{X}_l^t=\mathcal{X}^t$、 $p^s\left(x\right)$和 $p^t\left(x\right)$分别表示源域专用分类器和目标域专用分类器的预测。

步骤 2* 更新特征提取器，将目标特征拉入两个分类器的决策边界内：

$$\min_{\theta_{\mathcal{F}}} \sum_{x\in\mathcal{X}^t} \mathcal{L}_{dec}\left(p^s\left(x\right),p^t\left(x\right)\right), \tag{9}$$

其中， $\mathcal{L}_{dec}$ 表示用于提升特征提取器泛化能力的决策损失。

一般而言，提升域内对抗对齐效果共有三个方向，分别是 $\mathcal{L}_{dis}$ 和 $\mathcal{L}_{dec}$的选择、 $\mathcal{X}_h^t$ 与$\mathcal{X}_l^t$的划分，以及网络结构的优化。由于我们总结了域内对抗对齐的一般框架，下面将在该框架下讨论相关方法。

A^2Net [10],作为域内对抗对齐的首项工作，它基于一种投票策略，通过拼接源域专用分类器和目标域专用分类器的预测结果，并执行 Softmax 操作，对目标域进行划分。具体而言，如果源域专用分类器的投票分数高于目标域专用分类器的投票分数，则将其视为类似源域的特征，反之亦然。值得注意的是，该方法提出了一种软对抗机制，通过交换投票分数来训练目标域专用分类器和特征提取器，

可表示为:

$$\begin{aligned}
&\min_{\theta_{C_t}} -\sum_{i=1}^{n_t}\left(\alpha_i^s \log\left(\sum_{k=1}^{K} p_{(i)k}^{st}\right)+\alpha_i^t \log\left(\sum_{k=K+1}^{2K} p_{(i)k}^{st}\right)\right),\\
&\min_{\theta_{\mathcal{F}}} -\sum_{i=1}^{n_t}\left(\alpha_i^t \log\left(\sum_{k=1}^{K} p_{(i)k}^{st}\right)+\alpha_i^s \log\left(\sum_{k=K+1}^{2K} p_{(i)k}^{st}\right)\right),
\end{aligned} \tag{10}$$

其中， α_i^s、 α_i^t 分别表示源域专用分类器和目标域专用分类器的投票分数， $p^{st}=\sigma\left(\left[p^s,p^t\right]^T\right)\in\mathbb{R}^{2K}$ 表示 p^s 和 p^t 激活后的集中度。尽管式 10 的表述与式 8 不同，但其本质仍是特征提取器与目标分类器之间的对抗训练，因此我们的框架仍然适用。

BAIT [55] 是另一种典型方法，遵循域内对抗对齐范式。该方法使用KL散度作为差异损失，并采用bite损失提高两个分类器的输出熵，如下所示:

$$\begin{aligned}
&\min_{\theta_{C_t}} \sum_{x\in\mathcal{X}_h^t}\mathcal{D}_{SKL}\left(p^s(x),p^t(x)\right)-\sum_{x\in\mathcal{X}_l^t}\mathcal{D}_{SKL}\left(p^s(x),p^t(x)\right),\\
&\min_{\theta_{\mathcal{F}}} \sum_{i=1}^{n_t}\sum_{k=1}^{K}\left[-p_{i,k}^s\log p_{i,k}^t-p_{i,k}^t\log p_{i,k}^s\right],
\end{aligned} \tag{11}$$

其中 $\mathcal{D}_{SKL}(a,\ b)=\frac{1}{2}\left(\mathcal{D}_{KL}\left(a|b\right)+\mathcal{D}_{KL}\left(b|a\right)\right)$。值得一提的是，BAIT在实验中根据所选阈值发现，将源域相似集和源域不相似集划分为大小相同的集合效果更好；我们认为这是一个有启发性的结论。

KL散度是衡量两个分类器预测分布差异的较好指标，但它忽略了分类器输出的确定性，可能导致输出模糊问题。D-MCD [56] 和DAMC [57] 都关注这一问题，并采用CDD距离 [58] 同时衡量输出的一致性和确定性。此外，它们还对网络结构做出了一些改进。在D-MCD中，Chu 等人 利用模型在训练早期倾向于记住简单样本这一特点，设计了强弱范式来联合筛选样本，从而避免错误的高置信度样本。另一方面，DAMC采用包含两个以上分类器的网络结构，为分类任务中的域差距提供更紧的上界，并推导出最优分类器数量与类别数量相同。然而，所有这些额外的网络结构也增加了计算开销。

迄今为止，UDA 中的两大研究方向已在无源域适应中有所体现。在虚拟域生成类别中，可以使用某些度量或基于对抗学习的策略，对齐虚拟域与目标域的域分布。在域内对抗对齐中，可以采用双分类器范式的一种变体。这两种方法都表明了无源域适应与 UDA 之间潜在的研究联系。

3.1.3 扰动域监督

这类方法本质上基于这样一种假设：源域和目标域的特征都源自域不变特征空间 [59], ，即源域和目标域实际上是由域不变特征与一些域偏置因素共同形成的。从扰动的角度来看，在 UDA 中，可以利用目标域数据对源数据进行扰动以实现语义增强 [60]，从而引导模型学习域不变特征。随后，在缺少源域数据的情况下，也可以在模型训练期间对无标签目标数据添加一些适当的域相关扰动。如果模型能够抵抗这些域相关扰动，就有可能使模型获得域不变特征。如图4(c)所示，扰动目标域充当源域的指导，因此我们将其称为扰动目标域监督。尽管目前关于这一路线的研究方法仍然较少，但由于其鲜明的技术特征，我们将其视为基于域重构中与其他两类方法并列的一类方法。

作为这一类别中的代表性方法，SOAP [61]认为，模型的最终目标是找到域不变特征，并将模型的调整方向表示为一个向量，在 UDA 和无源域适应中体现为:

$$\begin{cases}
\overrightarrow{\epsilon}\left(\mathcal{D}^t,\mathcal{D}^I\right)_{UDA}=\overrightarrow{\epsilon}\left(\mathcal{D}^t,\mathcal{D}^s\right)+\overrightarrow{\epsilon}\left(\mathcal{D}^s,\mathcal{D}^I\right),\\
\overrightarrow{\epsilon}\left(\mathcal{D}^t,\mathcal{D}^I\right)_{SFDA}=\overrightarrow{\epsilon}\left(\mathcal{D}^{t+},\mathcal{D}^t\right),
\end{cases} \tag{12}$$

其中， $\mathcal{D}^I$ 表示域不变特征空间，而$\mathcal{D}^{t+}$ 是通过向目标域样本添加目标$\widetilde{}$特定扰动 N_T而构建的超目标域，如 $X_{T+}^i=\beta X_T^i+(1-\beta)\widetilde{N}_T$所示。

SMT [62] 也基于这一策略，动态更新扰动目标域。尽管超目标域的构想颇具吸引力，但其构建方式仍过于简单，例如取目标图像的均值，这可能不足以反映目标域的属性。

出于相同目的，FAUST [63] 从不确定性的角度解释这种数据扰动 [64], : 首先对目标图像应用随机增强，然后通过同时考虑认知不确定性和偶然不确定性，促使特征提取器在扰动前后的目标图像上提取一致的特征。与扰动目标数据不同，VMP [65] 通过变分贝叶斯推断对模型参数引入扰动，从而在执行模型适应的同时保持模型的判别能力。另一方面，AAA [66],通过设计对抗样本来攻击模型，将对抗扰动 [67] 引入域适应中，对抗样本的生成过程可表示如下:

$$\begin{aligned}
&\widetilde{x}_t=x_t+\frac{G\left(x_t\right)}{\left|\left|G\left(x_t\right)\right|\right|_2}\epsilon,\\
&\max_{\theta_G}\frac{1}{n_t}\sum_{i=1}^{n_t}\mathcal{L}_{cls}\left(\mathcal{C}\left(\mathcal{F}\left(\widetilde{x}_t\right)\right),\hat{y}_t^i\right),
\end{aligned} \tag{13}$$

其中， G 表示生成器， $||\cdot||$ 表示欧几里得范数， $\epsilon>0$ 表示扰动幅度，用于控制扰动不会破坏样本原有的语义信息，而$\hat{}y_t^i$是与 $\widetilde{x}_t$对应的伪标签。作者认为，如果模型能够抵御这些攻击，那么模型的泛化能力将在这一过程中得到显著提升。该防御过程可表示为：

$$\max_{\theta_{\mathcal{F}},\theta_C}\frac{1}{n_t}\sum_{i=1}^{n_t}\mathcal{L}_{cls}\left(\mathcal{C}\left(\mathcal{F}\left(\widetilde{x}_t\right)\right),\hat{y}_t^i\right). \tag{14}$$

一般而言，这类方法的关键在于如何设计扰动。首先，扰动的幅度应当适宜，也就是说，在增强模型泛化能力的同时，不应破坏数据或模型的原有特性。其次，扰动最好能够体现目标域的特征，以便在目标域上完成自适应任务。

3.2 基于图像的信息提取

一幅图像所包含的信息主要可分为两部分 [68]：一部分是与图像标签相关的内容信息，另一部分是通常具有域特异性的风格信息。邻域聚类从目标图像的内容信息入手，并基于这样的观察：目标数据本身具有清晰的结构和聚类特性。因此，需要提高特征空间中相邻节点之间的一致性，以增大类内距离、缩小类间距离，从而降低分类难度，因为错误分类大多出现在模型的决策边界处 [69]；图像风格迁移则从图像的风格信息入手，在不改变内容信息的前提下，将目标图像转换为源域风格，使其能够被源分类器更好地识别。

3.2.1 邻域聚类

邻域聚类的核心思想是：尽管目标域中的特征分布可能偏离源域中的特征分布，但它们仍能在特征空间中形成清晰的簇，并且同一簇中的特征来自同一类别。因此，如果促使特征空间中邻居节点之间保持一致性，就能使来自同一簇的特征点共同朝着同一类别移动。

G-SFDA [70] 是该类别中的开创性工作，提出使用局部结构聚类来施加一致性约束。其方法可表示如下：

$$\begin{aligned}\mathcal{L}_{LSC}&=-\frac{1}{n}\sum_{i=1}^{n}\sum_{k=1}^{K}\log\left[p\left(x_i\right)\cdot\mathcal{B}_S\left(\mathcal{N}_k\right)\right]+\sum_{c=1}^{C}\mathrm{KL}\left(\overline{\mathrm{p}}_{\mathrm{c}}||\mathrm{q}_{\mathrm{c}}\right),\\ \mathcal{N}_{\{1,\cdots,K\}}&=\{\mathcal{B}_F^j|top-K\left(cos\left(\mathcal{F}\left(x_i\right),\mathcal{B}_F^j\right),\forall\mathcal{B}_F^j\in\mathcal{B}_F\right)\},\\ \overline{p}&=\frac{1}{n}\sum_{i=1}^{n}p_c\left(x_i\right),\text{and }\mathrm{q}_{\{\mathrm{c}=1,\cdots,\mathrm{C}\}}=\frac{1}{\mathrm{C}}.\end{aligned} \tag{15}$$

根据公式 15，LSC 首先通过计算余弦相似度，在特征库 $\mathcal{B}_F$ 中找到与 x_i 最相似的前 K 个特征，然后使用 x_i约束分数库 $\mathcal{B}_S$ 中这 K 个特征的预测分数的一致性。 $\mathcal{L}_{LSC}$ 的第二项用于避免退化解 [71], [72] ，以促进预测平衡。CPGA [43]将这一步简化为仅通过辅助损失约束邻居节点之间的归一化相似度，这也有助于提高准确率。

基于此，NRC [73] 进一步根据邻居节点是否互为最近邻，将其细分为互惠邻居和非互惠邻居，即（$j\in\mathcal{N}_K^i$）$\cap$（$i\in\mathcal{N}_K^j$），并构建扩展邻域以聚合公共结构中的更多信息，从而对不同邻居的亲和度进行加权，如下所示：

$$\begin{aligned}\mathcal{L}_{\mathcal{N}}&=-\frac{1}{n_t}\sum_{i}\sum_{k\in\mathcal{N}_K^i}A_{ik}\mathcal{B}_{S,k}^Tp_i,\\ \mathcal{L}_E&=-\frac{1}{n_t}\sum_{i}\sum_{k\in\mathcal{N}_K^i}\sum_{m\in E_M^k}r\mathcal{B}_{S,m}^Tp_i,\end{aligned} \tag{16}$$

其中， $A_{ik}=1$ 而 i 和 k 是互惠节点，否则为$A_{ik}=r=0.1$。类似地，Tang等人 [74]在流形上构建语义邻居，以描绘更完整的几何信息；Tian等人 [75] 结合伪标签技术，通过对邻居节点的预测进行加权平均，获得保留结构的伪标签。然而，以往方法只考虑维持同一簇的一致性（减小类内距离），却忽略了不同簇之间的不相似性（增大类间距离）。AaD [76] 通过定义两个似然函数实现了这一点：

$$\begin{aligned}P\left(\mathbb{C}_i\right)&=\prod_{j\in\mathbb{C}_i}p_{ij}=\prod_{j\in\mathbb{C}_i}\frac{e^{p_i^Tp_j}}{\sum_{k=1}^{N_t}e^{p_i^Tp_k}},\\ P\left(\mathbb{B}_i\right)&=\prod_{j\in\mathbb{B}_i}p_{ij}=\prod_{j\in\mathbb{B}_i}\frac{e^{p_i^Tp_j}}{\sum_{k=1}^{N_t}e^{p_i^Tp_k}},\end{aligned} \tag{17}$$

其中，邻居集 $\mathbb{C}_i$ 包含节点 i的 K个最近邻，而背景集 $\mathbb{B}_i$ 包含不是节点 i邻居的节点。得到这两个似然函数后，可以通过负对数似然对簇内和簇间施加约束，形式如下： $L_i(\mathbb{C}_i,\mathbb{B}_i)=-\log{}^{P}{}_{(\mathbb{C}_i)P(\mathbb{B}_i)}$。

此外，邻域聚类也广泛应用于一种称为主动式无源域适应的新设定中，即选择性地标注少量数据，这有两大主要优势：（1）可以通过构建邻居图，选择性地标注少量难以处理的数据。例如，ELPT [77] 基于K近邻选择无法构图的数据；MHPL [32] 则将满足邻居混乱、个体差异和目标域相似特性的数据视为最有效的选择；（2）还可以通过在邻居节点之间进行标签传播[78], [79] 来提升目标域的可判别性。总体而言，邻域聚类方法的关键在于如何从无标签目标数据中挖掘更多结构信息；由于无监督聚类本质上适用于

源数据不可用的无源域适应设定，因此这类方法在未来仍有广阔的发展空间。

3.2.2 图像风格迁移

图像风格迁移 [80], [81] 旨在将相同内容呈现为不同风格，通常包含两个损失函数。第一个称为内容损失，用于确保迁移前后语义信息一致。另一个称为迁移损失，基于多个中间层的特征统计量执行风格迁移。然而，在以往的方法中，大多数特征统计量都以格拉姆矩阵 [68] 或实例归一化 [82], 的形式表示，这需要访问源域风格数据，但这在无源域适应设定下不可行。因此，SoHou 等人 将批归一化（BN）层 [83] 中存储的图像批次第 n 层的均值μ_{stored}^{n} 和方差σ_{stored}^{n} 作为源域风格的代表，并提出了如下无源图像风格迁移方法:

$$\begin{aligned}\mathcal{L}_{content} &= ||\mathcal{F}^{N}\left(\widetilde{x}_{t}\right)-\mathcal{F}^{N}\left(x_{t}\right)||_{2},\\ \mathcal{L}_{style} &= \frac{1}{N}\sum_{n=1}^{N}||\mu_{current}^{n}-\mu_{stored}^{n}||_{2}+||\sigma_{current}^{n}-\sigma_{stored}^{n}||_{2},\end{aligned} \tag{18}$$

其中，源分类器中的特征图有 N层， $\widetilde{x}_{t}$ 表示经过生成器生成的源域风格图像。

另一方面，CPSS [84], 在训练期间基于自适应实例归一化 [82]，通过使用多种风格增强样本，着重提升模型的鲁棒性。由此可以获得对图像风格变化不敏感的模型，从而具备较强的泛化能力。训练损失可表示为:

$$\begin{aligned}\mathcal{L}_{intra} &= \sigma\left(\widetilde{F}_{i,j}\right)\left(\frac{F_{i,j}-\mu\left(F_{i,j}\right)}{\sigma\left(F_{i,j}\right)}\right)+\mu\left(\widetilde{F}_{i,j}\right),\\ \mathcal{L}_{inter} &= \sigma\left(\widetilde{F}_{k,i,j}\right)\left(\frac{F_{k,i,j}-\mu\left(F_{k,i,j}\right)}{\sigma\left(F_{k,i,j}\right)}\right)+\mu\left(\widetilde{F}_{k,i,j}\right),\end{aligned} \tag{19}$$

其中， $\mathcal{L}_{intra}$ 和 $\mathcal{L}_{inter}$ 分别表示图像内风格~交换和图像间风格交换，作用于 k 图像。$F_{i,\ j}$ 和 $F_{k,\ i,\ j}$ 表示~提供风格特征的打乱图像块，一张图像可被划分为 $n_h \times n_w$ 个图像块，如下所示:

$$F=\begin{bmatrix}F_{1,1} & \cdots & F_{1,n_w}\\ \vdots & \ddots & \vdots\\ F_{n_h,1} & \cdots & F_{n_h,n_w}\end{bmatrix}$$

与 CPSS 类似，SI-SFDA [85] 通过随机将一些图像块遮盖为黑色背景，模拟在医学图像分割中从受损图像学习表征。如何更好地利用 BN 层也是这类方法关注的问题。Ishii 等人 [86] 通过使 BN 层中的统计数据与目标域分布对齐，隐式地实现了风格迁移。目前，这类方法仍然相对少见，主要应用于语义分割。

4 基于模型的方法

与关注数据生成或探索数据属性的基于数据的方法不同，基于模型的方法将模型拆分为若干子模块，然后调整其中部分子模块的参数以实现域适应。在这一类别中，自训练是占主导地位的范式，甚至也是整个无源域适应研究中最受欢迎的方法。自训练方法通常结合其他方法，利用辅助模块提升模型鲁棒性并保留源域知识。为了体现本综述将方法模块化、以便清晰洞察的意图，我们将这类方法单独归类。

4.1 自训练

由于无法获取源数据的监督信息，自训练（也称为自监督学习）利用模型对无标签目标域的预测，以自监督的方式改进模型。在无源域适应中，大多数自训练方法基于伪标签、熵最小化和对比学习的思路开展。

4.1.1 伪标签

在没有监督的情况下，最直观的思路是根据源模型的预测为目标样本赋予标签，然后基于这些伪标签进行自监督学习，例如 SHOT [7]。具体而言，这一过程可分为三个步骤：第一步**原型生成**，根据部分高置信度样本或所有样本生成类别原型；第二步**伪标签分配**，根据其他样本与类别原型之间的距离或相似度指定伪标签；第三步**伪标签过滤**，最终筛除部分噪声标签，以保证标签的纯度。值得注意的是，这一过程中的第一步和第三步并非必不可少。例如，可以直接根据源分类器预测的最可能类别为样本赋予伪标签，但我们认为这两步彼此密切相关。下面将详细阐述每个步骤。

原型生成。 最简单的方法之一是根据自熵选择类别原型 [87], [88], ，即选择每个类别中自熵高于某一阈值的样本。Ding 等人 [51] 将源分类器的权重定义为类别原型，并发现其平均准确率高于采用熵准则的方法。然而，以这种方式选出的类别原型可能缺乏代表性。类似地，一些方法 [77], [89] 受到主动学习的启发，认为自由能较高的目标样本更能代表目标域分布，因此可将其用作类别原型。另一种常见方法是基于 DeepCluster [93],计算每个类别的质心 [7], [90], [91], [92] ，其公式如下:

$$c_{k}=\frac{\sum_{x_{t}\in\mathcal{X}_{t}}\delta_{k}\left(\mathcal{F}\circ\mathcal{G}_{t}\left(x_{t}\right)\right)\mathcal{G}_{t}\left(x_{t}\right)}{\sum_{x_{t}\in\mathcal{X}_{t}}\delta_{k}\left(\mathcal{F}_{t}\left(x_{t}\right)\right)}, \tag{20}$$

其中， c_k 表示第 k类的质心， δ_k 表示 Softmax 操作中的第 k个元素。一些近期

研究 [51], [94] 认为，仅使用一个原型无法充分表征该类别，因此会为每个类别生成多个原型。一般而言，这一步的目的是获得一个类别原型 p_k，以表示目标域中每个类别的分布。

伪标签分配。获得类别原型后，可以通过将每个样本与不同类别原型进行比较，依据特征空间中的相似度或距离来获取其伪标签：

$$y_{\tilde{t}} = \arg\min_k \mathcal{L}_{pse}\left(\mathcal{G}\left(x_t\right), p_k\right), \tag{21}$$

其中，$\mathcal{L}_{pse}$ 表示用于生成伪标签的度量函数。需要注意的是，如果未生成类别原型，该公式将退化为

$$y_{\tilde{t}} = \arg\min_k \mathcal{F} \circ \mathcal{G}\left(x_t\right), \tag{22}$$

此时，模型输出中置信度最高的类别会被直接指定为伪标签。此外，伪标签的生成方式也值得探讨。在开创性工作 SHOT [7], 中，为了分配伪标签而遍历所有数据耗时较长。基于此，BMD [91]提出了一种动态伪标签策略，在域适应过程中更新伪标签。Shen 等人 [95] 仅对目标域中的部分数据进行标注，以确保准确性。在这一标注过程中，如何维持类别间的平衡也是一个主要问题。Qu 等人 [91]利用多实例学习的思想 [96], [97]形成了一种平衡的全局采样策略。You 等人 [98]设置类别专属阈值，以尽可能保持不同类别的样本数量一致。Li 等人 [99]注意到模型可能会偏向多数类别，因此提出了一种采用二次标签校正的不平衡无源域适应策略。

伪标签过滤。由于存在域偏移，模型的输出不可避免地包含噪声，即错误的伪标签，如图 5 所示。因此，错误标签过滤 [56], [87], [100] 和噪声标签学习 [94], [101], [102] 是提升伪标签准确性的两个重要方向。错误标签过滤主要通过设计合理的机制来剔除不可靠的伪标签。一种方法是设计特定的规则机制，例如，Kim等人 [87] 提出了一种端到端过滤机制：只有当样本与最相似类别原型之间的豪斯多夫距离小于其与

第二个相似类别原型；另一种方法是设计经过优化的网络机制来执行过滤，例如，Chu 等人 [56]利用弱模型更有可能识别困难样本的优势 [103], ，并提出额外训练一个弱网络，用于过滤错误的伪标签。Yang 等人 [100] 研究了负学习的稳定性，并提出一种多类别负学习策略，以自适应地学习伪标签选择的过滤阈值。另一方面，噪声标签学习不再只是过滤错误的伪标签，还要从噪声标签中学习有用信息，以实现自我精炼。SHOT++ [102] 是对 SHOT [7],的扩展，旨在通过在高置信度样本和低置信度样本之间应用 MixMatch [104] 进行信息传播，提高低置信度样本的可靠性。

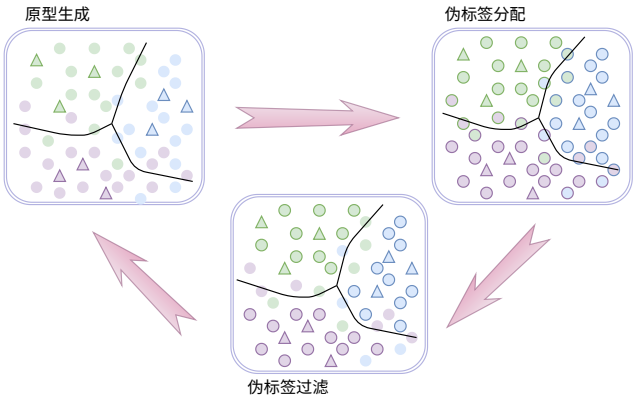


图 5. 伪标签方法中各个处理环节的示意图。不同颜色的圆圈表示不同类别的样本。实线边框的圆圈表示带有伪标签的样本（边框颜色与填充颜色不一致表示伪标签错误），三角形表示类别原型。首先，根据特征空间中样本的分布生成类别原型；然后，根据类别原型为每个样本分配伪标签；最后，过滤噪声标签。具体而言，部分方法会在第一步中根据结果再次调整类别原型的位置。

NEL [94] 将集成学习 [105], [106] 引入无源域适应设定，首先基于输入和反馈，从多个角度对目标域样本进行数据增强，然后通过多个版本间的负集成学习来精炼伪标签。从伪标签方法的整体流程来看，伪标签过滤是提高伪标签准确率的关键步骤，但也会带来额外的资源开销，因此，高效的伪标签过滤技术仍值得探讨。

4.1.2 熵最小化

熵最小化在半监督学习 [107], [108] 和无监督学习[16], [109] 方法中有着广泛的应用，并由 [7]首次引入无源域适应设定。以往的无监督域自适应主要通过对齐源域和目标域中的特征分布，来提升模型在目标域中的适应能力，但在缺少源域数据的情况下，这种方法不可行。因此，另一种思路是直接从结果出发，假设已经获得了具有适应能力的模型，那么每个样本的模型输出就应当是确定的，即实现熵最小化；随后，可以反向利用这一理想结果约束来指导模型的优化。熵最小化损失可表示为：

$$\mathcal{L}_{ent} = -\mathbb{E}_{x_t \in \mathcal{X}_t} \sum_{k=1}^{K} \delta_k\left(p_t\left(x_t\right)\right) \log \delta_k\left(p_t\left(x_t\right)\right), \tag{23}$$

其中，p_t 表示模型对样本 x_t的预测。由于熵最小化损失易于实现，也易于与伪标签方法等其他方法结合用作损失函数，因此它已迅速应用于被动设定下的图像分类、图像分割、医学图像分析和盲图像质量评估中，并已迅速应用于图像分类 [110], [111], 和图像分割 [12], [112],

在无源域适应设定下的医学图像分析 [113] 和盲图像质量评估 [114] 中。然而，一些研究[115], [116] 发现，熵最小化损失可能会导致训练期间出现平凡解，即所有预测都偏向某个特定类别，因此也可以使用批次熵最大化损失来确保预测的多样性:

$$\mathcal{L}_{div} = \sum_{k=1}^{K} p_k \log p_k, \tag{24}$$

其中 $p_k = \mathbb{E}_{x_t \in \mathcal{X}_t} \left[\delta \left(p_t^k \left(x_t \right) \right) \right]$表示先在一个批次中按类别累加输出，然后执行 softmax 操作。这样做的原因是，在一个批次内，每个类别的样本数量应保持均衡，从而使均匀分布具有最大的熵值。在许多无源域适应方法中，公式 23 和公式 24 被结合起来，构成信息最大化损失:

$$\mathcal{L}_{IM} = \mathcal{L}_{ent} + \mathcal{L}_{div}. \tag{25}$$

基于 $\mathcal{L}_{IM}$，Ahmed 等人 [31] 在多源域设置中对不同源域赋予权重，以实现加权信息最大化；Mao等人[111] 则将邻居节点信息纳入图自适应。然而，除了信息最大化之外，目前基于熵最小化的创新相对较少，更多方法只是直接将其用作辅助损失来提高准确率。熵最小化的关键在于根据结果，判断如何从个体与整体、确定性与多样性等不同层面约束模型在目标域上的输出，以及哪些输出更为合理；这或许是未来值得深入、详细探讨的课题。

4.1.3 对比学习

自监督对比学习 [117], [118] 是无监督表征学习中常用的一种途径，其重点是通过增大负样本对之间的距离，同时拉近正样本对，来学习判别性表征。这种方法的特点是围绕同一样本构造正负样本对，主要可分为基于记忆库的 [119], 基于编码器的 [117]和基于小批次的 [120], [121]。最典型的一种对比损失是 InfoNCE 损失 [44], [117]:

$$\mathcal{L}_{Info} = -\sum_{v^+ \in V^+} \log \frac{\exp\left(u^T v^+ / \tau\right)}{\exp\left(u^T v^+ / \tau\right) + \sum_{v^- \in V^-} \exp\left(u^T v^- / \tau\right)}, \tag{26}$$

其中， V^+、V^- 分别是关于同一样本 u 的正样本对和负样本对集合， τ 是温度参数。在无监督域自适应中，通常以目标域样本作为键值、源域样本作为查询，来构造正负样本对。然而，在无源设置下，无法获取后者，因此如何构造能够代表源域的查询，是这类无源域适应方法的核心问题

，这类方法主要可分为 3 种。第一种方法是将源分类器的权重用作源域样本各类别的原型特征 [90]:

$$\mathcal{L}_{cdc}^{1} = -\sum_{m=1}^{M} \mathbb{I}_{\hat{y}_u = m} \log \frac{\exp\left(u^T w_s^m / \tau\right)}{\sum_{j=1}^{M} \exp\left(u^T w_s^j / \tau\right)}, \tag{27}$$

其中，分类器权重 $W_s = [w_s^1, \cdots, w_s^M]$, $\mathbb{I}_{\hat{y}_t{}^i = m}$是目标样本 u上的伪标签指示矩阵。类似地， [43] 使用生成的原型进行对比学习，并引入权重损失以提高伪标签的可靠性。第二种方法是提高当前批次中正样本对的相似度，以进行对比匹配 [10]:

$$\mathcal{L}_{cdc}^{2} = -\log \frac{\exp\left(s_{ij}\right)}{\sum_{v=1}^{b} \mathbb{I}_{v \neq i} |\gamma_{iv}| \exp\left(s_{iv}\right)}, \tag{28}$$

其中， $s_{ij} = [\sigma(p_i)]^T \sigma(p_v)$ 表示第 i 个样本与第 v 个样本的相似度，并对其模型输出执行 Softmax 操作； p_i、 p_v、 γ_{iv} 是一个阈值函数，用于确定两个样本是否属于同一类别。最后一类方法会保留一个记忆库，用于存储历史模型的输出，从而构造正负样本对 [122], [123]。HCID [122]使用当前模型将当前批次中的样本编码为查询 $q^t = M^t\left(x_q\right)$，然后使用历史模型将先前存储的样本编码为键$k_n^{t-m} = M^{t-m}\left(x_{k_n}\right)$:

$$\mathcal{L}_{cdc}^{3} = -\sum_{x_q \in X_t} \log \frac{\exp\left(q^T k_+^{t-m} / \tau\right) \gamma_+^{t-m}}{\sum_{i=0}^{N} \exp\left(q^t k_i^{t-m} / \tau\right) \gamma_i^{t-m}}, \tag{29}$$

其中， N 是存储的键的数量， γ 是用于衡量这些键可靠性的参数，一种实现方式是使用分类熵。总体而言，这类无源方法的部分处理过程与基于数据的源自由域适应的基本思想相似，即使用生成式或非生成式方法来弥补源数据缺失。

4.2 自注意力

在计算机视觉任务中，定位目标区域在域适应中发挥着重要作用 [124], ，但传统的 CNN 模型倾向于捕获局部的特定于域的信息，例如背景信息，而这些信息可能不利于聚焦于我们真正关心的目标。因此，自注意力机制 [125], [126] 被引入无源域适应设定:

$$\mathcal{L}_{Attn_{self}}(Q, K, V) = softmax(\frac{QK^T}{\sqrt{d_k}})V, \tag{30}$$

其中， Q、 K、 V分别表示查询、键和值， d_k是 K的维度。为缓解源域中的上下文丢失问题，一些方法 [77], [112], [124] 直接将自注意力模块与传统的

特征提取器结合。公式 30 还可以扩展为跨域注意力 [127]:

$$\mathcal{L}_{Attn_{cross}}(Q_s, K_t, V_t) = softmax(\frac{Q_s K_t^T}{\sqrt{d_k}})V_t, \quad (31)$$

其中， Q_s 来自源域， K_t 和 V_t 来自目标域，三者共同构成一个样本对。基于此，CADX [128]在无源设置下将目标域图像划分为支持图像和查询图像，并将原有的块对块操作改为图像到图像，以捕获整体表征并减轻计算负担。此外，一些方法 [11], [129] 进一步从空间注意力和通道注意力两个角度处理特征，以丰富表征的上下文语义。目前，基于注意力的无源域适应方法仍然相对少见，尤其是基于 Transformer 的无源域适应方法。

5 比较

由于分类任务构成了现有无源域适应方法的主体，本节将在三个应用最广泛的分类数据集上比较当前领先的无源域适应方法。具体而言，我们依据第 3 节和第 4 节对这些方法进行模块化，以体现不同模块的有效性。

5.1 对比数据集

本文使用的分类数据集包括 Digits[39], VisDA-C [130], Office-31 [131], Office-Home [132], 和 DomainNet [133], , 其统计数据汇总于表 3。然而，由于 Digits 数据集的提升空间很小（ [7]中为 98.9%），且 DomainNet 数据集难度较大，另外三个数据集在学界更为常用。因此，我们主要总结这三个数据集上的实验结果，以代表大多数研究。以下是这三个数据集的详细介绍。

Office-31 是视觉迁移学习中占主导地位的基准数据集，其中包含 4,652 张图像，涵盖 31 类办公环境中常见的目标物体，例如笔记本电脑、文件柜、键盘等。这些图像主要来自 Amazon（在线电商图像）、Webcam（由网络摄像头拍摄的低分辨率图像）和 DSLR（由数码单反相机拍摄的高分辨率图像）。Amazon数据集包含 2,817 张图像，平均每个类别有 90 张图像，且背景统一；Webcam数据集包含 795 张图像，这些图像存在明显的噪声、色彩和白平衡伪影；DSLR数据集包含 498 张图像，每个类别有 5 个物体，每个物体从不同视角平均拍摄 3 次。

Office-Home 是一个用于域适应的基准数据集，包含 4 个域，每个域由 65 个类别组成。这四个域分别是 Art（绘画、绘画作品、装饰品等形式的艺术图像）、Clipart（剪贴画图像集合）、Products（没有背景的物体图像）和 Real World（用普通相机拍摄的物体图像）。该数据集包含 15,500 张图像，平均每个类别约有 70 张图像，每个类别最多有 99 张图像。

表3 无源域适应中数据集的统计信息。

数据集	域	样本	类别
Digits	街景门牌号数据集 (S) MNIST (M) 美国邮政服务手写数字数据集 (U)	1797	10
Office	Amazon (A) DSLR (D) Webcorn（W）	4652	31
Office-Home	艺术图像（Ar） 剪贴画（Cl） 产品图像（Pr） 真实世界图像（Rw）	15500	65
VisDA-C	Real 合成	207785	12
DomainNet	剪贴画(clp) 信息图(inf) 绘画(pnt) 快速绘图(qdr) 真实(rel) 素描(skt)	569010	365

VisDA-C 是一个大型数据集，用于研究从模拟器到真实环境的域适应。它包含 12 个常见类别，这些类别由三个公开数据集共享：Caltech-256 (C)、ImageNet ILSVRC2012 (I) 和 PASCALVOC2012 (P)。源域样本和目标域样本分别是通过渲染三维模型生成的合成图像和真实图像。

为了更好地呈现每种方法所包含的模块，我们将无源域适应方法分为四类：基于域的重构（DR）、基于图像的信息提取（IIE）、自训练（ST）和自注意力（SA）。进一步细分后，我们将这四类方法划分为九个模块，分别是虚拟域生成（$\mathbf{M}_{vdg}$）、域内对抗对齐（$\mathbf{M}_{iaa}$）、扰动域监督（$\mathbf{M}_{pds}$）、邻域聚类（$\mathbf{M}_{nc}$）、图像风格迁移（$\mathbf{M}_{ist}$）、伪标签（$\mathbf{M}_{pl}$）、熵最小化（$\mathbf{M}_{em}$）、对比学习（$\mathbf{M}_{cl}$）和自注意力（$\mathbf{M}_{sa}$）。

5.2 比较结果

我们在表 4、表 5 和表 6 中汇总了 Office、Office-Home 和 VisDA-C 数据集上的分类准确率结果。需要注意的是，所有方法均统一设定为单源同质闭集源自由领域自适应，并且我们引用原论文中报告的最佳结果。表格顶部列出了仅源域模型 [134] （Office 和 Office-Home 上使用 ResNet-50, VisDA-C 上使用 ResNet-101）以及目标域监督模型的准确率，随后用横线从上到下划分了 2020年、2021年和 2022年的研究成果。下面将对比较结果进行分析。

无源域适应领域的研究工作正在迅速增加。自2020年以来，无源域适应研究论文数量呈爆发式增长趋势。在这三个

表 4 Office-31 数据集（ResNet-50）上无源域适应方法的分类准确率（%）对比。

方法（源域→目标）	DR	IIE	ST	SA	模块	A →W	D →W	W →D	A →D	D →A	W →A	Avg.
仅源域 [134]	-	-	-	-	-	68.4	96.7	99.3	68.9	62.5	60.7	76.1
目标域监督 [102]	-	-	-	-	-	98.7	98.7	98.0	98.0	98.7	86.0	94.3
SHOT [7]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	90.1	98.4	99.9	94.0	74.7	74.3	88.6
3C-GAN [41]	✓				$\mathbf{M}_{iaa}$	93.7	98.5	99.8	92.7	75.3	77.8	89.6
BAIT [55]	✓				$\mathbf{M}_{iaa}$	94.6	98.1	**100.0**	92.0	74.6	75.2	89.4
SHOT++ [102]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	90.4	98.7	99.9	94.3	76.2	75.8	89.2
Kim等人 [87]			✓		$\mathbf{M}_{pl}$	91.1	98.2	99.5	92.2	71.0	71.2	87.2
A^2网络 [10]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}_{cl}$	94.0	99.2	**100.0**	94.5	76.7	76.1	90.1
NRC [73]		✓			$\mathbf{M}_{nc}$	90.8	99.0	**100.0**	96.0	75.3	75.0	89.4
ASL [135]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	94.1	98.4	99.8	93.4	76.9	75.0	89.5
TransDA [124]			✓	✓	$\mathbf{M}_{pl}+\mathbf{M}_{sa}$	95.0	**99.3**	99.6	**97.2**	73.7	**79.3**	**90.7**
CPGA [43]		✓	✓		$\mathbf{M}_{nc}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	94.1	98.4	99.8	94.4	76.0	76.6	89.9
AAA [66]	✓		✓		$\mathbf{M}_{pds}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	94.2	98.1	99.8	95.6	75.6	76.0	89.9
VDM-DA [35]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}_{em}$	94.1	98.0	**100.0**	93.2	75.8	77.1	89.7
HCL+SHOT [122]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{cl}$	92.5	98.2	**100.0**	94.7	75.9	77.7	89.8
AaD [76]		✓			$\mathbf{M}_{nc}$	92.1	99.1	**100.0**	96.4	75.0	76.5	89.9
U-SFAN [136]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}_{em}$	92.8	98.0	99.0	94.2	74.6	74.4	88.8
CoWA-JMDS [137]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	95.2	98.5	99.8	94.4	76.2	77.6	90.3
CDCL [90]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{cl}$	92.1	98.5	**100.0**	94.4	76.4	74.1	89.3
D-MCD [56]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}^{pl}$	93.5	98.8	**100.0**	94.1	76.4	76.4	89.9
BMD + SHOT++ [91]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	94.2	98.0	**100.0**	96.2	76.0	76.0	90.1
ProxyMix [51]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	**96.7**	98.5	99.8	95.4	75.1	75.4	85.6
UTR [138]			✓		$\mathbf{M}_{pl}$	93.5	99.1	**100.0**	95.0	76.3	78.4	90.3
SCLM [74]		✓	✓		$\mathbf{M}_{nc}+\mathbf{M}^{pl}$	90.0	98.9	**100.0**	95.8	75.5	76.0	89.4
Jing等人 [65]	✓				$\mathbf{M}_{pds}$	93.3	98.6	**100.0**	96.2	75.4	76.9	90.0
Kundu等人 + SHOT++ [139]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	93.2	98.9	**100.0**	94.6	**78.3**	78.9	**90.7**

数据集上，无源域适应方法取得的最高准确率仅比目标监督（预言机）下的准确率低3.6%（Kundu 等 + SHOT ++ [139] [140] 在Ofiice上）、2.7%（TransDA [124] 在Office-Home上）和0.9%（BMD +SHOT++ [91] 在VisDA-C上）。从某种程度上说，无源域适应在研究工作数量和准确率方面均呈现出超越无监督域自适应方法的趋势。这不仅反映了该领域的巨大潜力，也表明有必要对无源域适应进行全面综述。

自训练目前仍是最受欢迎的研究方向。大多数无源域适应方法都采用自训练策略。此外，将熵最小化 [7], [63], [91], [102], [136] 作为辅助损失，可以轻松地与大多数无源域适应方法结合，以提升目标域表示的可判别性。此外，对比学习 [10], [43], [66] 通常与伪标签模块协同工作，发挥域对齐的作用。在缺少源数据和目标标签的情况下，通过对目标数据进行伪标签自监督是最常见的方法。然而，这不可避免地会引入噪声标签和错误累积问题。对此，一些方法将无源域适应问题转化为噪声标签学习问题 [56], [94]，以提升模型性能。还有一些方法 [138],[140] 试图绕过噪声标签问题，并对目标域的自训练方向进行隐式正则化，从而取得了令人满意的结果。在三个数据集中的两个数据集上的实验结果表明，达到最高准确率的方法都采用了伪标签方法以 SHOT++ [102]作为基线。例如，Kundu 等人[139] 在 Office 上达到了 90.7%，而 BMD [91]在 VisDA 上达到了 88.7%。这些观察结果表明，伪标签是一种通用且有效的技术，同时也是改进模型的强基线。

基于域的重构在无源域适应中十分常见。基于域的重构背后的无源域适应方法，其思路相当明确：旨在重构一个新的源域或目标域，以替代缺失的源域进行监督。在这类方法中，域内对抗对齐方法是最早出现的一批方法，例如 BAIT [55] 和 3C-GAN [41]。然而，它们的影响力并不突出，可能是因为从目标域中选出的源域相似样本包含大量噪声，且代表性不足；这也是 D-MCD [56] 旨在解决去噪问题的原因。虚拟域生成日益受到关注，可能是因为虚拟域生成方法 [35], [51], [137], [139] 能够与发挥目标域监督作用的自训练方法紧密结合，从而进一步提升效果，例如在 Office- 31 数据集上达到 90.7% 的最高准确率（Kundu 等 [139]）。

邻域聚类似乎对基于图像的信息提取十分有效。与图像风格转换方法 [141], 相比，邻域聚类显然更加有效。例如，SCLM [74]在 Office-Home 的 Cl→Ar 和 Cl→Rw 迁移任务上取得了最高准确率。其原因可能是，邻域聚类能够更好地保留底层结构信息

表 5 Office-Home 数据集（ResNet-50）上无源域适应方法的分类准确率（%）对比。

方法	DR	IIE	ST	SA	模块	Ar → Cl	Ar →Pr	Ar →Rw	Cl →Ar	Cl →Pr	Cl →Rw	Pr →Ar	Pr → Cl	Pr →Rw	Rw →Ar	Rw →Cl	Rw →Pr	Avg.
仅源域 [134]	-	-	-	-	-	34.9	50.0	58.0	37.4	41.9	46.2	38.5	31.2	60.4	53.9	41.2	59.9	46.1
目标域监督 [102]	-	-	-	-	-	77.9	91.4	84.4	74.5	91.4	84.4	74.5	77.9	84.4	74.5	77.9	91.4	82.0
SHOT [7]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	57.1	78.1	81.5	68.0	78.2	78.1	67.4	54.9	82.2	73.3	58.8	84.3	71.8
BAIT [55]	✓				$\mathbf{M}_{iaa}$	57.4	77.5	82.4	68.0	77.2	75.1	67.1	55.5	81.9	73.9	59.5	84.2	71.6
SHOT++ [102]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	57.9	79.7	82.5	68.5	79.6	79.3	68.5	57.0	83.0	73.7	60.7	84.9	73.0
A^{2}网络 [10]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}_{cl}$	58.4	79.0	82.4	67.5	79.3	78.9	68.0	56.2	82.9	74.1	60.5	85.0	72.8
NRC [73]		✓			$\mathbf{M}_{nc}$	57.7	80.3	82.0	68.1	79.8	78.6	65.3	56.4	83.0	71.0	58.6	85.6	72.2
TransDA [124]			✓	✓	$\mathbf{M}_{pl}+\mathbf{M}_{sa}$	**67.5**	**83.3**	**85.9**	**74.0**	**83.8**	**84.4**	**77.0**	**68.0**	**87.0**	**80.5**	**69.9**	**90.0**	**79.3**
G-SFDA [70]		✓		✓	$\mathbf{M}_{nc}+\mathbf{M}_{sa}$	57.9	78.6	81.0	66.7	77.2	77.2	65.6	56.0	82.2	72.0	57.8	83.4	71.3
CPGA [43]		✓	✓		$\mathbf{M}_{nc}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	59.3	78.1	79.8	65.4	75.5	76.4	65.7	58.0	81.0	72.0	64.4	83.3	71.6
AAA [66]	✓		✓		$\mathbf{M}_{pds}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	56.7	78.3	82.1	66.4	78.5	79.4	67.6	53.5	81.6	74.5	58.4	84.1	71.8
PS [47]	✓				$\mathbf{M}_{vdg}$	57.8	77.3	81.2	68.4	76.9	78.1	67.8	57.3	82.1	75.2	59.1	83.4	72.1
AaD [76]		✓			$\mathbf{M}_{nc}$	59.3	79.3	82.1	68.9	79.8	79.5	67.2	57.4	83.1	72.1	58.5	85.4	72.7
U-SFAN [136]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}_{em}$	57.8	77.8	81.6	67.9	77.3	79.2	67.2	54.7	81.2	73.3	60.3	83.9	71.9
CoWA-JMDS [137]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	56.9	78.4	81.0	69.1	80.0	79.9	67.7	57.2	82.4	72.8	60.5	84.5	72.5
D-MCD [56]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}^{pl}$	59.4	78.9	80.2	67.2	79.3	78.6	65.3	55.6	82.2	73.3	62.8	83.9	72.2
Kundu等人 [140]			✓		$\mathbf{M}_{pl}$	61.0	80.4	82.5	69.1	79.9	79.5	69.1	57.8	82.7	74.5	65.1	86.4	74.0
BMD + SHOT++ [91]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	58.1	79.7	82.6	69.3	81.0	80.7	70.8	57.6	83.6	74.0	60.0	85.9	73.6
ProxyMix [51]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	59.3	81.0	81.6	65.8	79.7	78.1	67.0	57.5	82.7	73.1	61.7	85.6	72.8
UTR [138]			✓		$\mathbf{M}_{pl}$	59.8	81.2	83.2	67.2	79.2	80.1	68.4	56.4	83.0	73.7	61.2	85.9	73.2
FAUST [63]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	61.4	79.2	79.6	63.3	76.9	75.2	65.3	59.4	79.0	74.7	64.2	86.1	72.0
DAMC [57]	✓				$\mathbf{M}_{iaa}$	57.9	78.5	81.1	66.7	77.7	77.9	66.5	54.3	81.5	73.2	58.9	84.7	71.6
SCLM [74]		✓	✓		$\mathbf{M}_{nc}+\mathbf{M}^{pl}$	58.2	80.3	81.5	69.3	79.0	80.7	69.0	56.8	82.7	74.7	60.6	85.0	73.1
Jing等人 [65]	✓				$\mathbf{M}_{pds}$	57.9	77.6	82.5	68.6	79.4	80.6	68.4	55.6	83.1	75.2	59.6	84.7	72.8
Kundu等人 + SHOT++ [139]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	61.8	81.2	83.0	68.5	80.6	79.4	67.8	61.5	85.1	73.7	64.1	86.5	74.5

表 6
分类准确率 （%）在 VisDA-C 数据集上对比无源域适应方法（ResNet-101） .

方法	DR	IIE	ST	SA	模块	飞机	自行车	bus	car	马	刀	摩托车	人	工厂	滑板	火车	卡车	Avg.
仅源域 [134]	-	-	-	-	-	55.1	53.3	61.9	59.1	80.6	17.9	79.7	31.2	81.0	26.5	73.5	8.5	52.4
目标域监督 [102]	-	-	-	-	-	97.0	86.6	84.3	88.7	96.3	94.4	92.0	89.4	95.5	91.8	90.7	68.7	89.6
SHOT [7]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	94.3	88.5	80.1	57.3	93.1	94.9	80.7	80.3	91.5	89.1	86.3	58.2	82.9
3C-GAN [41]	✓				$\mathbf{M}_{iaa}$	95.7	78.0	69.0	74.2	94.6	93.0	88.0	87.2	92.2	88.8	85.1	54.3	83.3
BAIT [55]	✓				$\mathbf{M}_{iaa}$	-	-	-	-	-	-	-	-	-	-	-	-	83.0
Hou等人 [141]		✓	✓		$\mathbf{M}_{ist}+\mathbf{M}_{em}$	-	-	-	-	-	-	-	-	-	-	-	-	63.5
SHOT++ [102]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	97.7	88.4	**90.2**	86.3	**97.9**	**98.6**	**92.9**	84.1	**97.1**	92.2	93.6	28.8	87.3
Kim 等人 [87]			✓		$\mathbf{M}_{pl}$	86.9	81.7	84.6	63.9	93.1	91.4	86.6	71.9	84.5	58.2	74.5	42.7	76.7
A^{2}网络 [10]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}_{cl}$	94.0	87.8	85.6	66.8	93.7	95.1	85.8	81.2	91.6	88.2	86.5	56.0	84.3
NRC [73]		✓			$\mathbf{M}_{nc}$	96.8	91.3	82.4	62.4	96.2	95.9	86.1	80.6	94.8	94.1	90.4	68.2	85.9
G-SFDA [70]		✓		✓	$\mathbf{M}_{nc}+\mathbf{M}_{sa}$	96.1	88.3	85.5	74.1	97.1	95.4	89.5	79.4	95.4	92.9	89.1	42.6	85.4
ASL [135]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	97.3	85.3	86.9	70.7	96.4	72.8	93.0	80.1	95.5	78.1	87.7	50.3	82.8
TransDA [124]			✓	✓	$\mathbf{M}_{pl}+\mathbf{M}_{sa}$	97.2	91.1	81.0	57.5	95.3	93.3	82.7	67.2	92.0	91.8	92.5	54.7	83.0
CPGA [43]		✓	✓		$\mathbf{M}_{nc}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	95.6	89.0	75.4	64.9	91.7	97.5	89.7	83.8	93.9	93.4	87.7	69.0	86.0
AAA [66]	✓		✓		$\mathbf{M}_{pds}+\mathbf{M}_{pl}+\mathbf{M}_{cl}$	94.4	85.9	74.9	60.2	96.0	93.5	87.8	80.8	90.2	92.0	86.6	68.3	84.2
VDM-DA [35]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}_{em}$	96.9	89.1	79.1	66.5	95.7	96.8	85.4	83.3	96.0	86.6	89.5	56.3	85.1
PS [47]	✓				$\mathbf{M}_{vdg}$	95.3	86.2	82.3	61.6	93.3	95.7	86.7	80.4	91.6	90.9	86.0	59.5	84.1
AaD [76]		✓			$\mathbf{M}_{nc}$	97.4	90.5	80.8	76.2	97.3	96.1	89.8	82.9	95.5	93.0	**92.0**	64.7	88.0
U-SFAN [136]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}_{em}$	-	-	-	-	-	-	-	-	-	-	-	-	82.7
HCL+SHOT [122]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{cl}$	93.3	85.4	80.7	68.5	91.0	88.1	86.0	78.6	86.6	88.8	80.0	74.7	83.5
CoWA-JMDS [137]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	96.2	89.7	83.9	73.8	96.4	97.4	89.3	86.8	94.6	92.1	88.7	53.8	86.9
NEL [94]			✓		$\mathbf{M}_{pl}$	94.5	60.8	92.3	87.3	87.3	93.2	87.6	**91.1**	56.9	83.4	93.7	**86.6**	84.2
CDCL [90]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{cl}$	97.3	90.5	83.2	59.9	96.4	98.4	91.5	85.6	96.0	95.8	92.0	63.8	87.5
D-MCD [56]	✓		✓		$\mathbf{M}_{iaa}+\mathbf{M}^{pl}$	97.0	88.0	90.0	81.5	95.6	98.0	86.2	88.7	94.6	92.7	83.7	53.1	87.5
Kundu等人 [140]			✓		$\mathbf{M}_{pl}$	-	-	-	-	-	-	-	-	-	-	-	-	88.2
BMD + SHOT++ [91]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	96.9	87.8	90.1	**91.3**	97.8	97.8	90.6	84.4	96.9	**94.3**	90.9	45.9	**88.7**
ProxyMix [51]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	95.4	81.7	87.2	79.9	95.6	96.8	92.1	85.1	93.4	90.3	89.1	42.2	85.7
UTR [138]			✓		$\mathbf{M}_{pl}$	**98.0**	**92.9**	88.3	78.0	97.8	97.7	91.1	84.7	95.5	91.4	91.2	41.1	87.3
FAUST [63]			✓		$\mathbf{M}_{pl}+\mathbf{M}_{em}$	96.7	77.6	87.6	73.3	95.5	95.4	**92.9**	83.6	95.3	89.5	87.7	46.9	85.2
DAMC [57]	✓				$\mathbf{M}_{iaa}$	95.4	86.9	87.2	79.7	94.6	95.7	91.2	84.9	95.7	91.5	81.9	41.7	86.0
SCLM [74]			✓	✓	$\mathbf{M}_{nc}+\mathbf{M}^{pl}$	97.1	90.7	85.6	62.0	97.3	94.6	81.8	84.3	93.6	92.8	88.0	55.9	85.3
Kundu等人 + SHOT++ [139]	✓		✓		$\mathbf{M}_{vdg}+\mathbf{M}^{pl}$	-	-	-	-	-	-	-	-	-	-	-	-	87.8

在剪贴画图像中。此外，AaD [76] 仅使用一个损失函数，便在 VisDA 上取得了 88% 的第二高分类准确率，因此可以作为一种简单但强大的基线。

自注意力很有前景，尤其是基于 Transformer 的无源域适应方法。尽管基于自注意力的无源域适应方法较少用于图像分类 [70],[124]，且大多见于语义分割 [11],[112], [129]，，但基于 Transformer 的方法 TransDA [124]在 Office-Home 数据集上取得了最高的 79.3% 准确率，比排名第二的方法高出 4.8% [139]。这在一定程度上表明，促使模型将注意力转向物体区域，可能相当有助于减少域偏移。不过，TransDA [124] 只是将 Transformer 引入卷积网络，而如何让 Transformer 与无源域适应设定更好地结合，或许是一个值得探讨的课题。

6 应用

域适应旨在降低标注目标域数据的成本，而无源域适应则更进一步，旨在保护源域数据的隐私。因此，无源域适应与无监督

域自适应方法 [5], [6], [29] 在应用领域上高度重叠。目前，大多数无源域适应方法应用于计算机视觉和自然语言处理领域。

6.1 计算机视觉

大多数无源域适应方法侧重于图像分类，这是计算机视觉中的基础任务。随着 VisDA [130] 和 Domain-Net [142]，等大规模数据集日益普及，对适应能力的需求也不断增加。图像分类还可拓展至多种应用场景，例如真实世界图像去雾 [143]，、跨场景高光谱图像分类 [144],和盲图像质量评估 [114]。语义分割方法 [11], [12], [50], [100], [129], [145], [146]也迅速涌现并得到广泛应用，包括多器官分割 [113],、跨模态分割 [147], [148],、跨设备 [100],、跨中心域分割 [85], 、多站点全生命周期脑颅骨剥离 [77],和道路分割 [98], [149]。其他应用，如目标检测 [13], [14], [62], 、行人重识别 [150],和视频分析 [88], [144] ，也能从无源域适应中受益。

6.2 自然语言处理

无源域适应在自然语言处理（NLP）中的应用仍相对有限。自然语言处理领域相关的设置和研究包括连续学习 [151], [152] 以及预训练模型的泛化能力 [153]。Laparra等人基于两项任务（即否定检测和时间表达式识别）设计了 SemEval 2021 任务10数据集 [154] 。Su等人 [33] 将自训练 [155], 、主动学习 [156] 和数据增强[157] 基线扩展到无源设置，以进行系统比较。

6.3 其他相关问题

域泛化（DG） [158], [159],使模型能够适用于此前未见过的目标域，可视为域适应的一种相关设置；此外，也出现了一些无源域泛化方法 [160], [161] ，可视为基于数据的源自由域适应方法的变体。提出无源零样本域适应 [162],[163] ，旨在缓解测试时域适应 [164]对小批量流式数据和类别分布的要求。Ondrej [128]等人研究了前馈式无源域适应，该方法无需反向传播，既能进一步保护用户隐私，也能降低开销。此外，还有一些方法将无源域适应设置与联邦学习 [149], 、黑盒测试 [165], 或鲁棒迁移 [166]相结合，以适应不同的实际场景。

7 未来研究方向

尽管无源域适应研究迅速发展，相关方法和性能也不断演进，但无源域适应所研究的问题设定和目标仍在一定程度上较为有限且同质化。具体而言，分类任务主导着无源域适应的研究，其发展速度大幅超过了无源域适应在其他计算机视觉任务上的发展。下面我们将讨论无源域适应的研究格局可能在哪些方面得到拓展。

7.1 拓展研究薄弱环节

尽管本文讨论了许多无源域适应方法，但其中大多数都侧重于伪标签。根据图 2 的分类，某些方法仍未得到充分探索，例如扰动域监督、邻域聚类，以及自注意力，尤其是基于 Transformer 的自注意力机制。对比学习 [167]和图像风格迁移 [168] 目前仍以相对同质且简单的方式构建，值得引入各自领域中的一些最新方法 [169], [170] 。此外，尽管熵最小化在无源域适应中得到广泛应用，但它大多只是直接以熵损失或信息损失的形式用作辅助损失，缺乏进一步创新。总体而言，无源域适应的方法论仍有很大的拓展空间。

7.2 进一步的理论支持

Ben-David 等人 [15]提出了一种通用的无监督域自适应理论，该理论根据源域和目标域的分布差异、模型在源域上的误差以及理想联合误差，对预期目标域误差给出了上界。然而，在无源设置下，域差异难以衡量。目前大多数无源域适应方法都基于直觉提出，并在现有数据集上取得了经验性成功。Liang 等人 [7]提出通过信息最大化实现确定性和去中心化输出。尽管已有一些无源域适应理论分析聚焦于伪标签 [56], 多源域 [30], [31], 和模型平滑性 [171],，但这些方法仅适用于特定的方法。因此，建立普遍适用于无源域适应的理论支持将大有裨益。

7.3 更多应用

对于计算机视觉任务，目前大多数无源域适应方法都专注于图像分析，而视频数据包含明显更多的空间和时间语义信息，因此带来了更大的处理挑战。因此，专门针对视频分析设计的方法仍然很少。此外，无监督域自适应已在自然语言处理 [172], [173], [174],时间序列数据分析 [175], [176], 推荐系统 [177],[178], 和地球科学 [179], [180]中得到广泛应用。然而，这些应用尚未扩展到无源设置，这表明无源域适应可能会在这些领域发挥其潜力。

7.4 综合数据集与评估

目前用于无源域适应评估的大多数数据集类别均衡、数据干净；然而，一些无源域适应研究指出，类别不平衡 [99] 和噪声 [166] 会显著影响模型准确率。此外，一些现有数据集的规模有限，

已不足以为评估现代域适应方法的能力提供充分挑战。例如，在 Office-31 分类数据集 [131] 上，W 到 D 任务的准确率已达到 100%。因此，要推动无源域适应研究，需要更多样且更具挑战性的数据集。此外，采用更全面的评估方案（包括模型鲁棒性和开销），有助于更完整地了解模型特性，并提升无源域适应在各种场景（例如边缘设备）中的适用性。

7.5 扩展设定

本文主要涵盖无源域适应的单源闭集设定，这也是研究最为广泛的情形。然而，如图 3 所示，根据源域与目标域之间的关系，域适应可分为部分域适应、开放集域适应、多源域适应和多任务域适应。此外，根据不同的实际情境，无源域适应设定还可以与测试时域适应 [164], 联邦域适应 [181], 以及主动域适应 [182]相结合。未来，随着研究人员探索不同的设定和场景，无源域适应研究有望变得更加多样化。

8 结论

无监督域自适应是迁移学习的重要组成部分，可将从一个有标签域获取的知识迁移到另一个无标签域，从而减少对神经网络进行大规模标注的需求。无源设置无法访问源域数据，满足现实场景中的隐私与安全要求，自其出现以来便迅速受到关注。本文全面概述了现有的无源适应方法，并提出了统一的分类框架。我们分析了三种最常用数据集（Office-31、Office-Home 和 VisDA）上 30 多种代表性无源域适应方法的实验结果，并对每种方法进行了模块化处理，以便开展比较。最后，基于我们的分析以及当前无源域适应研究的进展，我们提出了一些可能有益于该领域的研究方向。

参考文献

[1] D. N. Perkins 和 G. Salomon，《学习迁移：对牛津、英格兰国际教育百科全书的贡献》，*Pergamon Press*。检索日期：*12*月，第 31 卷，2009 年，1992 页。[2] S. J. Pan 和 Q. Yang，《迁移学习综述》，*IEEE*知识与数据工程汇刊，第 22 卷，第 10 期，第 1345–1359 页，2009 年。[3] J. Li、E. Chen、Z. Ding、L. Zhu、K. Lu 和 H. T. Shen，《用于域适应的最大密度散度》，*IEEE*模式分析与机器智能汇刊，第 43 卷，第 11 期，第 3918–3930 页，2020年。[4] M. Jing、L. Meng、J. Li、L. Zhu 和 H. T. Shen，《用于无监督域自适应的对抗性混合比例混淆》，*IEEE*多媒体汇刊，2022年。[5] G. Wilson 和 D. J. Cook，《无监督深度域适应综述》，*ACM*智能系统与技术汇刊（*TIST*），第 11 卷，第 5 期，第 1–46 页，2020年。

[6] X. Liu、C. Yoo、F. Xing、H. Oh、G. El Fakhri、J.-W. Kang、J. Woo 等，“深度无监督域适应：近期进展与展望综述”，APSIPA信号与信息处理汇刊，第11卷，第1期，2022年。[7] J. Liang、D. Hu 和 J. Feng，“我们真的需要访问源数据吗？用于无监督域适应的源假设迁移”，载于国际机器学习会议。PMLR，2020年，第6028–6039页。[8] B. Chidlovskii、S. Clinchant 和 G. Csurka，“缺少源域数据时的域适应”，载于第22届ACM SIGKDD国际知识发现与数据挖掘会议论文集，2016年，第451–460页。[9] J. N. Kundu、N. Venkat、R. V. Babu 等，“通用无源域适应”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2020年，第4544–4553页。[10] H. Xia、H. Zhao 和 Z. Ding，“用于无源域适应的自适应对抗网络”，载于IEEE/CVF国际计算机视觉会议论文集，2021年，第9010–9019页。[11] Y. Liu、W. Zhang 和 J. Wang，“面向语义分割的无源域适应”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2021年，第1215–1224页。[12] M. Bateson、H. Kervadec、J. Dolz、H. Lombaert 和 I. B. Ayed，“面向图像分割的无源域适应”，Medical Image Analysis，第82卷，第102617页，2022年。[13] L. Xiong、M. Ye、D. Zhang、Y. Gan 和 Y. Liu，“面向Faster R-CNN的无源数据域适应”，模式识别，第124卷，第108436页，2022年。[14] C. Saltori、S. Lathuili´ere、N. Sebe、E. Ricci 和 F. Galasso，“Sf-uda 3d：面向基于激光雷达的三维目标检测的无源无监督域自适应”，载于2020年国际三维视觉会议（3DV）。IEEE，2020年，第771–780页。[15] S. Ben-David、J. Blitzer、K. Crammer、A. Kulesza、F. Pereira 和 J. W. Vaughan，“跨域学习理论”，机器学习，第79卷，第1期，第151–175页，2010年。[16] M. Long、H. Zhu、J. Wang 和 M. I. Jordan，“采用残差迁移网络的无监督域适应”，神经信息处理系统进展，第29卷，2016年。[17] M. Long、Y. Cao、J. Wang 和 M. Jordan，“利用深度适应网络学习可迁移特征”，载于国际机器学习会议。PMLR，2015年，第97–105页。[18] S. Cui、S. Wang、J. Zhuo、L. Li、Q. Huang 和 Q. Tian，“迈向可判别性与多样性：标签不足情形下的批量核范数最大化”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2020年，第3941–3950页。[19] Y. Ganin 和 V. Lempitsky，“通过反向传播实现无监督域自适应”，载于国际机器学习会议。PMLR，2015年，第1180–1189页。[20] M. Long、Z. Cao、J. Wang 和 M. I. Jordan，“条件对抗域适应”，神经信息处理系统进展，第31卷，2018年。[21] E. Tzeng、J. Hoffman、K. Saenko 和 T. Darrell，“对抗判别域适应”，载于IEEE计算机视觉与模式识别会议论文集，2017年，第7167–7176页。[22] F. Zhuang、Z. Qi、K. Duan、D. Xi、Y. Zhu、H. Zhu、H. Xiong 和 Q. He，“迁移学习综合综述”，IEEE会刊，第109卷，第1期，第43–76页，2020年。[23] J. Huang、F. Nie 和 H. Huang，“一种用于衡量数据相似度以进行聚类的新型单纯形稀疏学习模型”，载于第二十四届国际人工智能联合会议，2015年。[24] X. Li、H. Zhang、R. Zhang、Y. Liu 和 F. Nie，“用于无监督特征选择的自适应图广义非相关回归”，IEEE神经网络与学习系统汇刊，第30卷，第5期，第1587–1595页，2018年。[25] E.-H. S. Han、G. Karypis 和 V. Kumar，“使用权重调整的K近邻分类进行文本分类”，载于亚太知识发现与数据挖掘会议。Springer，2001年，第53–65页。[26] K. Saito、D. Kim、S. Sclaroff、T. Darrell 和 K. Saenko，“通过极小极大熵实现半监督域自适应”，载于IEEE/CVF国际计算机视觉会议论文集，2019年，第8050–8058页。[27] A. Kumar、A. Saha 和 H. Daume，“基于协正则化的半监督域适应”，神经信息处理系统进展，第23卷，2010年。

[28] L. Li 和 Z. Zhang，“通过协方差匹配实现半监督域自适应”，IEEE模式分析与机器智能汇刊，第41卷，第11期，第2724–2739页，2018年。[29] M. Wang 和 W. Deng，“深度视觉域自适应：综述”，Neurocomputing，第312卷，第135–153页，2018年。[30] J. Dong、Z. Fang、A. Liu、G. Sun 和 T. Liu，“置信锚点诱导的多源无源域适应”，神经信息处理系统进展，第34卷，第2848–2860页，2021年。[31] S. M. Ahmed、D. S. Raychaudhuri、S. Paul、S. Oymak 和 A. K. Roy-Chowdhury，“无需访问源数据的无监督多源域适应”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2021年，第10 103–10 112页。[32] F. Wang、Z. Han、Z. Zhang 和 Y. Yin，“主动无源域自适应”，arXiv预印本 arXiv:2205.10711，2022年。[33] X. Su、Y. Zhao 和 S. Bethard，“ 无源域适应策略比较 ”，载于计算语言学协会第 60 届年会论文集（第1卷：长篇论文），2022年，第8352–8367页。[34] O. Day 和 T. M. Khoshgoftaar，“异构迁移学习综述”，Journal of Big Data，第4卷，第1期，第1–42页，2017年。[35] J. Tian、J. Zhang、W. Li 和 D. Xu，“VDM-DA：面向无源数据域适应的虚拟域建模”，IEEE视频技术电路与系统汇刊，2021年。[36] A. Gretton、K. Borgwardt、M. Rasch、B. Sch¨olkopf 和 A. Smola，“用于双样本问题的核方法”，神经信息处理系统进展，第19卷，2006年。[37] Q. Tian、C. Ma、F.-Y. Zhang、S. Peng 和 H. Xue，“通过样本传输学习实现无源无监督域自适应”，Journal of Computer Science and Technology，第36卷，第3期，第606–616页，2021年。[38] I. Goodfellow、J. Pouget-Abadie、M. Mirza、B. Xu、D. Warde-Farley、S. Ozair、A. Courville 和 Y. Bengio，“生成对抗网络”，ACM通讯，第63卷，第11期，第139–144页，2020年。[39] J. Hoffman、E. Tzeng、T. Park、J.-Y. Zhu、P. Isola、K. Saenko、A. Efros 和 T. Darrell，“Cycada：循环一致对抗域适应”，载于国际机器学习会议。PMLR，2018年，第1989–1998页。[40] M.-Y. Liu 和 O. Tuzel，“耦合生成对抗网络”，神经信息处理系统进展，第29卷，2016年。[41] R. Li、Q. Jiao、W. Cao、H.-S. Wong 和 S. Wu，“模型适应：无需源数据的无监督域适应”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2020年，第9641–9650页。[42] V. K. Kurmi、V. K. Subramanian 和 V. P. Namboodiri，“域印象：一种无源数据域适应方法”，载于IEEE/CVF冬季计算机视觉应用会议论文集，2021年，第615–625页。[43] Z. Qiu、Y. Zhang、H. Lin、S. Niu、Y. Liu、Q. Du 和 M. Tan，“通过化身原型生成与适应实现无源域适应”，arXiv预印本 arXiv:2106.15326，2021年。[44] A. v. d. Oord、Y. Li 和 O. Vinyals，“利用对比预测编码进行表示学习”，arXiv预印本 arXiv:1807 03748，2018年。[45] H. Yin、P. Molchanov、J. M. Alvarez、Z. Li、A. Mallya、D. Hoiem、N. K. Jha 和 J. Kautz，“以梦境蒸馏：通过DeepInversion实现无数据知识迁移”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2020年，第8715–8724页。[46] H.-W. Yeh、B. Yang、P. C. Yuen 和 T. Harada，“SOFA：面向无监督域自适应的无源数据特征对齐”，载于IEEE/CVF冬季计算机视觉应用会议论文集，2021年，第474–483页。[47] Y. Du、H. Yang、M. Chen、J. Jiang、H. Luo 和 C. Wang，“生成、增强与对齐：一种基于伪源域的无源域适应方法”，arXiv预印本 arXiv:2109.04015，2021年。[48] H. Zhang、M. Cisse、Y. N. Dauphin 和 D. Lopez-Paz，“mixup：超越经验风险最小化”，arXiv预印本 arXiv:1710.09412，2017年。[49] N. Ma、J. Bu、Z. Zhang 和 S. Zhou，“用于无源数据半监督域适应的不确定性引导Mixup”，arXiv预印本 arXiv:2107.06707，2021年。[50] M. Ye、J. Zhang、J. Ouyang 和 D. Yuan，“面向语义分割的无源数据无监督域适应”，载于第29届ACM多媒体国际会议论文集，2021年，第2233–2242页。[51] Y. Ding、L. Sheng、J. Liang、A. Zheng和R. He，“ProxyMix：采用标签精炼的基于代理的mixup训练，用于无源域适应”，arXiv预印本 arXiv:2205.14566，2022年。[52] K. Saito、K. Watanabe、Y. Ushiku和T. Harada，“用于无监督域自适应的最大分类器差异”，载于IEEE计算机视觉与模式识别会议论文集，2018年，第3723–3732页。[53] C.-Y. Lee、T. Batra、M. H. Baig和D. Ulbricht，“用于无监督域自适应的切片Wasserstein差异”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2019年，第10 285–10 295页。[54] Z. Yu、J. Li、L. Zhu、K. Lu和H. T. Shen，“用于无监督域自适应的分类确定性最大化”，IEEE视频技术电路与系统汇刊，2023年。[55] S. Yang、Y. Wang、J. van de Weijer、L. Herranz和S. Jui，“为离线与在线无源域自适应投放诱饵”，arXiv预印本 arXiv:2010.12427，2020年。[56] T. Chu、Y. Liu、J. Deng、W. Li和L. Duan，“用于无源无监督域自适应的去噪最大分类器差异”，载于第三十六届AAAI人工智能会议（AAAI-22），第2卷，2022年。[57] Z. Zong、J. He、L. Zhang和H. Huan，“使用多个分类器估计无源无监督域自适应的域差距”，arXiv预印本 arXiv:2207.05785，2022年。[58] S. Li、F. Lv、B. Xie、C. H. Liu、J. Liang和C. Qin，“用于无监督域自适应的双分类器确定性最大化”，载于AAAI，第2卷，2021年，第5页。[59] J. Hoffman、S. Gupta、J. Leong、S. Guadarrama和T. Darrell，“用于RGB-D检测的跨模态自适应”，载于2016年IEEE机器人与自动化国际会议（ICRA）。IEEE，2016年，第5032–5039页。[60] S. Li、M. Xie、K. Gong、C. H. Liu、Y. Wang和W. Li，“用于域适应的可迁移语义增强”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2021年，第11 516–11 525页。[61] L. Xiong、M. Ye、D. Zhang、Y. Gan、X. Li和Y. Zhu，“通过域特定扰动实现目标检测器的无源数据域适应”，《国际智能系统杂志》，第36卷，第8期，第3746–3766页，2021年。[62] D. Zhang、M. Ye、L. Xiong、S. Li和X. Li，“用于无源数据目标检测的源域风格迁移均值教师”，载于ACM亚洲多媒体会议，2021年，第1–8页。[63] J. Lee和G. Lee，“通过不确定性和自训练进行特征对齐，以实现无源无监督域自适应”，arXiv预印本 arXiv:2208.14888，2022年。[64] A. Kendall和Y. Gal，“计算机视觉的贝叶斯深度学习需要哪些不确定性？”，《神经信息处理系统进展》，第30卷，2017年。[65] M. Jing、X. Zhen、J. Li和C. G. Snoek，“用于无源域适应的变分模型扰动”，arXiv预印本 arXiv:2210.10378，2022年。[66] J. Li、Z. Du、L. Zhu、Z. Ding、K. Lu和H. T. Shen，“通过对抗攻击实现与散度无关的无监督域自适应”，IEEE模式分析与机器智能汇刊，2021年。[67] C. Szegedy、W. Zaremba、I. Sutskever、J. Bruna、D. Erhan、I. Goodfellow和R. Fergus，“神经网络的奇妙特性”，arXiv预印本 arXiv:1312.6199，2013年。[68] L. A. Gatys、A. S. Ecker和M. Bethge，“使用卷积神经网络进行图像风格迁移”，载于IEEE计算机视觉与模式识别会议论文集，2016年，第2414–2423页。[69] X. Chen、S. Wang、M. Long和J. Wang，“可迁移性与可判别性：用于对抗域适应的批次谱惩罚”，载于国际机器学习会议。PMLR，2019年，第1081–1090页。[70] S. Yang、Y. Wang、J. van de Weijer、L. Herranz和S. Jui，“广义无源域自适应”，载于IEEE/CVF国际计算机视觉会议论文集，2021年，第8978–8987页。[71] K. Ghasedi Dizaji、A. Herandi、C. Deng、W. Cai和H. Huang，“通过联合卷积自编码器嵌入和相对熵最小化进行深度聚类”，载于IEEE国际计算机视觉会议论文集，2017年，第5736–5745页。

[72] Y. Shi和F. Sha，“用于无监督域自适应的判别性簇的信息论学习”，arXiv预印本 arXiv:1206.6438，2012年。[73] S. Yang、J. van de Weijer、L. Herranz、S. Jui等，“利用内在邻域结构实现无源域适应”，《神经信息处理系统进展》，第34卷，第29 393–29 405页，2021年。[74] S. Tang、Y. Zou、Z. Song、J. Lyu、L. Chen、M. Ye、S. Zhong和J. Zhang，“流形上的语义一致性学习，用于无源数据无监督域自适应”，《神经网络》，2022年。[75] L. Tian、L. Zhou、H. Zhang、Z. Wang和M. Ye，“用于无源域适应的鲁棒自监督学习”，2022年。[76] S. Yang、Y. Wang、K. Wang、S. Jui等，“吸引与分散：一种简单的无源域适应方法”，载于《神经信息处理系统进展》，2022年。[77] X. Li、Z. Du、J. Li、L. Zhu和K. Lu，“通过基于能量的局部性保持迁移实现无源主动域自适应”，载于第30届ACM多媒体国际会议论文集，2022年，第5802–5810页。[78] A. Iscen、G. Tolias、Y. Avrithis和O. Chum，“用于深度半监督学习的标签传播”，载于IEEE/CVF计算机视觉与模式识别会议论文集，2019年，第5070–5079页。[79] N. Ma、J. Bu、L. Lu、J. Wen、Z. Zhang、S. Zhou和X. Yan，“用于无源域适应的半监督假设迁移”，arXiv预印本 arXiv:2107.06735，2021年。[80] F. Luan、S. Paris、E. Shechtman和K. Bala，“深度照片风格迁移”，载于IEEE计算机视觉与模式识别会议论文集，2017年，第4990–4998页。[81] J. Johnson、A. Alahi和L. Fei-Fei，“用于实时风格迁移和超分辨率的感知损失”，载于欧洲计算机视觉会议。Springer，2016年，第694–711页。[82] X. Huang和S. Belongie，“通过自适应实例归一化实现实时任意风格迁移”，载于IEEE国际计算机视觉会议论文集，2017年，第1501–1510页。[83] S. Ioffe和C. Szegedy，“批归一化：通过减少内部协变量偏移加速深度网络训练”，载于国际机器学习会议。PMLR，2015年，第448–456页。[84] Y. Zhao、Z. Zhong、Z. Luo、G. H. Lee和N. Sebe，“语义分割中的无源开放复合域自适应”，IEEE视频技术电路与系统汇刊，第32卷，第10期，第7019–7032页，2022年。[85] Y. Ye、Z. Liu、Y. Zhang、J. Li和H. Shen，“缓解风格敏感性后再进行适应：用于医学图像分割的无源域适应”，载于第30届ACM多媒体国际会议论文集，2022年，第1935–1944页。[86] M. Ishii和M. Sugiyama，“通过匹配批归一化统计量进行分布对齐，实现无源域适应”，arXiv预印本 arXiv:2101.10842，2021年。[87] Y. Kim、D. Cho、K. Han、P. Panda和S. Hong，“无源数据域适应”，IEEE人工智能汇刊，第2卷，第6期，第508–518页，2021年。[88] Y. Huang、X. Yang、J. Zhang和C. Xu，“用于无源多模态视频域自适应的相对对齐网络”，载于第30届ACM多媒体国际会议论文集，2022年，第1652–1660页。[89] B. Xie、L. Yuan、S. Li、C. H. Liu、X. Cheng和G. Wang，“域适应的主动学习：一种基于能量的方法”，载于AAAI人工智能会议论文集，第36卷，第8期，2022年，第8708–8716页。[90] R. Wang、Z. Wu、Z. Weng、J. Chen、G.-J. Qi和Y.-G. Jiang，“用于无监督域自适应的跨域对比学习”，IEEE多媒体汇刊，2022年。[91] S. Qu、G. Chen、J. Zhang、Z. Li、W. He和D. Tao，“BMD：一种通用的类别均衡多中心动态原型策略，用于无源域适应”，arXiv预印本 arXiv:2204 02811，2022年。。[92] P. Chen和A. J. Ma，“用于视频动作识别的无源时序注意域自适应”，载于2022年国际多媒体检索会议论文集，2022年，第489–497页。[93] M. Caron、P. Bojanowski、A. Joulin和M. Douze，“用于无监督视觉特征学习的深度聚类”，载于欧洲计算机视觉会议（ECCV）论文集，2018年，第132–149页。[94] W. Ahmed、P. Morerio和V. Murino，“通过负集成学习清理噪声标签，以实现无源无监督域适应”，载于《IEEE/CVF冬季计算机视觉应用会议论文集》，2022年，第1616–1625页。[95] M. Shen、Y. Bu和G. Wornell，“无监督多源无数据域适应中伪标签选择性的益处”，arXiv预印本 arXiv:2202.00796，2022年。[96] T. G. Dietterich、R. H. Lathrop和T. Lozano-P´erez，“利用轴平行矩形解决多实例问题”，《人工智能》，第89卷，第1-2期，第31–71页，1997年。[97] W. Li和N. Vasconcelos，“通过顶层实例对软包进行多实例学习”，载于《IEEE计算机视觉与模式识别会议论文集》，2015年，第4277–4285页。[98] F. You、J. Li、L. Zhu、Z. Chen和Z. Huang，“无源数据的域自适应语义分割”，载于第29届ACM多媒体国际会议论文集，2021年，第3293–3302页。[99] X. Li、J. Li、L. Zhu、G. Wang和Z. Huang，“不平衡无源域适应”，载于第29届ACM多媒体国际会议论文集，2021年，第3330–3339页。[100] C.-Y. Yang、Y.-J. Kuo和C.-T. Hsu，“通过分布迁移和自适应类别平衡自训练实现语义分割的无源域适应”，载于2022年IEEE多媒体与博览会国际会议（ICME）。IEEE，2022年，第1–6页。[101] W. Chen、L. Lin、S. Yang、D. Xie、S. Pu、Y. Zhuang和W. Ren，“面向无源无监督域自适应的自监督噪声标签学习”，arXiv预印本 arXiv:2102.11614，2021年。[102] J. Liang、D. Hu、Y. Wang、R. He和J. Feng，“通过假设迁移和标签迁移实现无源数据的无监督域适应”，《IEEE模式分析与机器智能汇刊》，2021年。[103] D. Arpit、S. Jastrzebski、N. Ballas、D. Krueger、E. Bengio、M. S. Kanwal、T. Maharaj、A. Fischer、A. Courville、Y. Bengio等，“深入探究深度网络中的记忆”，载于《国际机器学习会议》。PMLR，2017年，第233–242页。[104] D. Berthelot、N. Carlini、I. Goodfellow、N. Papernot、A. Oliver和C. A. Raffel，“Mixmatch：一种全面的半监督学习方法”，《神经信息处理系统进展》，第32卷，2019年。[105] N. C. Garcia、S. A. Bargal、V. Ablavsky、P. Morerio、V. Murino和S. Sclaroff，“面向多模态动作识别的蒸馏多选学习”，载于《IEEE/CVF冬季计算机视觉应用会议论文集》，2021年，第2755–2764页。[106] X. Dong、Z. Yu、W. Cao、Y. Shi和Q. Ma，“集成学习综述”，《计算机科学前沿》，第14卷，258，2020年2，第241页。[107] Y. Grandvalet和Y. Bengio，“通过熵最小化进行半监督学习”，《神经信息处理系统进展》，第17卷，2004年。[108] H. Jain、J. Zepeda、P. P´erez和R. Gribonval，“Subic：一种用于图像检索的监督式结构化二进制编码”，载于《IEEE国际计算机视觉会议论文集》，2017年，第833–842页。[109] J. T. Springenberg，“利用类别生成对抗网络进行无监督和半监督学习”，arXiv预印本 arXiv:1511.06390，2015年。[110] H. Jeon、S. Lee和U. Kang，“在无可观测源数据的条件下进行无监督多源域适应”，《PLOS ONE》，第16卷，第7期，文章编号e0253415，2021年。[111] H. Mao、L. Du、Y. Zheng、Q. Fu、Z. Li、X. Chen、H. Shi和D. Zhang，“无源无监督图域适应”，arXiv预印本 arXiv:2112.00955，2021年。[112] D. Kothandaraman、R. Chandra和D. Manocha，“SS-SFDA：面向危险环境道路分割的自监督无源域适应”，载于《IEEE/CVF国际计算机视觉会议论文集》，2021年，第3049–3059页。[113] J. Hong、Y.-D. Zhang和W. Chen，“面向跨模态腹部多器官分割的无源无监督域适应”，《基于知识的系统》，第109155页，2022年。[114] J. Liu、X. Li、S. An和Z. Chen，“面向盲图像质量评估的无源无监督域适应”，arXiv预印本 arXiv:2207.08124，2022年。[115] A. Krause、P. Perona和R. Gomes，“通过正则化信息最大化进行判别式聚类”，《神经信息处理系统进展》，第23卷，2010年。[116] M. Jabi、M. Pedersoli、A. Mitiche和I. B. Ayed，“深度聚类：判别模型与k均值之间的联系”，《IEEE模式分析与机器智能汇刊》，第43卷，第6期，第1887–1896页，2019年。

[117] K. He、H. Fan、Y. Wu、S. Xie和R. Girshick，“用于无监督视觉表征学习的动量对比”，载于《IEEE/CVF计算机视觉与模式识别会议论文集》，2020年，第9729–9738页。[118] T. Chen、S. Kornblith、M. Norouzi和G. Hinton，“用于视觉表征对比学习的简单框架”，载于《国际机器学习会议》。PMLR，2020年，第1597–1607页。[119] Z. Wu、Y. Xiong、S. X. Yu和D. Lin，“通过非参数实例判别进行无监督特征学习”，载于《IEEE计算机视觉与模式识别会议论文集》，2018年，第3733–3742页。[120] Y. Tian、D. Krishnan和P. Isola，“对比多视图编码”，载于《计算机视觉—ECCV 2020：第16届欧洲计算机视觉会议》，英国格拉斯哥，2020年8月23–28日，论文集，第XI部分，第16卷。Springer，2020年，第776–794页。[121] M. Ye、X. Zhang、P. C. Yuen和S.-F. Chang，“通过不变与扩散实例特征进行无监督嵌入学习”，载于《IEEE/CVF计算机视觉与模式识别会议论文集》，2019年，第6210–6219页。[122] J. Huang、D. Guan、A. Xiao和S. Lu，“模型适应：用于无源数据无监督域适应的历史对比学习”，《神经信息处理系统进展》，第34卷，第3635–3649页，2021年。[123] X. Zhao、R. Stanislawski、P. Gardoni、M. Sulowicz、A. Glowacz、G. Krolczyk和Z. Li，“利用标签一致性的自适应对比学习，实现无源数据的无监督域适应”，《传感器》，第22卷，第11期，文章编号4238，2022年。[124] G. Yang、H. Tang、Z. Zhong、M. Ding、L. Shao、N. Sebe和E. Ricci，“基于Transformer的无源域自适应”，arXiv预印本 arXiv:2105.14138，2021年。[125] A. Vaswani、N. Shazeer、N. Parmar、J. Uszkoreit、L. Jones、A. N. Gomez、Ł. Kaiser和I. Polosukhin，“注意力就是你所需要的一切”，《神经信息处理系统进展》，第30卷，2017年。[126] A. Dosovitskiy、L. Beyer、A. Kolesnikov、D. Weissenborn、X. Zhai、T. Unterthiner、M. Dehghani、M. Minderer、G. Heigold、S. Gelly等，“一张图像胜过16×16个词：用于大规模图像识别的Transformer”，arXiv预印本 arXiv:2010.11929，2020年。[127] T. Xu、W. Chen、P. Wang、F. Wang、H. Li和R. Jin，“CD-Trans：用于无监督域适应的跨域Transformer”，arXiv预印本 arXiv:2109.06165，2021年。[128] O. Bohdal、D. Li、S. X. Hu和T. Hospedales，“通过交叉注意力实现前馈式无源潜在域自适应”，arXiv预印本 arXiv:2207.07624，2022年。[129] D. Kothandaraman、S. Shekhar、A. Sancheti、M. Ghuhan、T. Shukla和D. Manocha，“SALAD：用于分类、分割和检测的无源主动式无标签域适应”，载于《IEEE/CVF冬季计算机视觉应用会议论文集》，2023年，第382–391页。[130] X. Peng、B. Usman、N. Kaushik、J. Hoffman、D. Wang和K. Saenko，“VisDA：视觉域自适应挑战”，arXiv预印本 arXiv:1710.06924，2017年。[131] K. Saenko、B. Kulis、M. Fritz和T. Darrell，“将视觉类别模型适应到新域”，载于《计算机视觉—ECCV 2010：第11届欧洲计算机视觉会议》，希腊克里特岛伊拉克利翁，2010年9月5–11日，论文集，第IV部分，第11卷。Springer，2010年，第213–226页。[132] H. Venkateswara、J. Eusebio、S. Chakraborty和S. Panchanathan，“用于无监督域适应的深度哈希网络”，载于《IEEE计算机视觉与模式识别会议论文集》，2017年，第5018–5027页。[133] X. Peng、Q. Bai、X. Xia、Z. Huang、K. Saenko和B. Wang，“面向多源域适应的矩匹配”，载于《IEEE/CVF国际计算机视觉会议论文集》，2019年，第1406–1415页。[134] K. He、X. Zhang、S. Ren和J. Sun，“用于图像识别的深度残差学习”，载于《IEEE计算机视觉与模式识别会议论文集》，2016年，第770–778页。[135] H. Yan、Y. Guo和C. Yang，“面向无源无监督域适应的增强自标注”，载于NeurIPS 2021分布偏移研讨会：连接方法与应用，2021年。[136] S. Roy、M. Trapp、A. Pilzer、J. Kannala、N. Sebe、E. Ricci和A. Solin，“不确定性引导的无源域自适应”，载于《计算机视觉—ECCV 2022：第17届欧洲计算机视觉会议》，以色列特拉维夫，2022年10月23–27日，论文集，第XXV部分。Springer，2022年，第537–555页。

[137] J.《无源无监督域自适应的重新审视：一项综合分数》，载于国际机器学习会议。PMLR，2022年，第12 365–12 377页。[138] J. Pei、Z. Jiang、A. Men、L. Chen、Y. Liu和Q. Chen，《不确定性诱导的可迁移性表征：用于无源无监督域自适应》，arXiv预印本 arXiv:2208.13986，2022年。[139] J. N. Kundu、A. R. Kulkarni、S. Bhambri、D. Mehta、S. A. Kulkarni、V. Jampani和V. B. Radhakrishnan，《平衡无源域自适应中的可判别性与可迁移性》，载于国际机器学习会议。PMLR，2022年，第11 710–11 728页。[140] J. N. Kundu、S. Bhambri、A. Kulkarni、H. Sarkar、V. Jampani和R. V. Babu，《用于无监督无源域自适应的并发辅助监督》，载于《计算机视觉—ECCV 2022：第17届欧洲计算机视觉会议》，特拉维夫，以色列，2022年10月23—27日，论文集，第三十部分。Springer，2022年，第177–194页。[141] Y. Hou和L. Zheng，《利用图像转换实现无源域适应》，arXiv预印本 arXiv:2008.07514，2020年。[142] A. Leventidis、L. Di Rocco、W. Gatterbauer、R. J. Miller和M. Riedewald，《DomainNet：用于数据湖消歧的同形词检测》，arXiv预印本 arXiv:2103.09940，2021年。[143] H. Yu、J. Huang、Y. Liu、Q. Zhu、M. Zhou和F. Zhao，《面向真实世界图像去雾的无源域适应》，载于第30届ACM多媒体国际会议论文集，2022年，第6645–6654页。[144] Z. Xu、W. Wei、L. Zhang和J. Nie，《面向跨场景高光谱图像分类的无源域适应》，载于IGARSS 2022—2022年IEEE国际地球科学与遥感研讨会。IEEE，2022年，第3576–3579页。[145] V. Prabhu、S. Khare、D. Kartik和J. Hoffman，《Augco：增强一致性引导的自训练，用于无源域自适应语义分割》，arXiv预印本 arXiv:2107.10140，2021年。[146] M. Bateson、H. Kervadec、J. Dolz、H. Lombaert和I. Ben Ayed，《用于图像分割的源数据宽松域自适应》，载于国际医学图像计算与计算机辅助干预会议。Springer，2020年，第490–499页。[147] X. Liu、F. Xing、G. El Fakhri和J. Woo，《面向源数据宽松医学图像分割的记忆一致无监督现成模型自适应》，Medical Image Analysis，第83卷，文章编号102641，2023年。[148] S. Kondo，《通过范数与形状约束实现医学图像分割的无源无监督域自适应》，arXiv预印本 arXiv:2209.01300，2022年。[149] D. Shenaj、E. Fan`ı、M. Toldo、D. Caldarola、A. Tavera、U. Michieli、M. Ciccone、P. Zanuttigh和B. Caputo，《跨域和跨设备学习：聚类联邦学习中的风格驱动无源域自适应》，载于IEEE/CVF冬季计算机视觉应用会议论文集，2023年，第444–454页。[150] Y. Ding、Z. Duan和S. Li，《通过代理任务实现无源无监督多源域适应，用于行人重识别》，The Visual Computer，第1–12页，2022年。[151] C. de Masson D’Autume、S. Ruder、L. Kong和D. Yogatama，《终身语言学习中的情景记忆》，神经信息处理系统进展，第32卷，2019年。[152] R. Sahoo、D. Shanmugam和J. Guttag，《在缺少源数据时进行无监督域适应》，arXiv预印本 arXiv:2007.10233，2020年。[153] D. Hendrycks、X. Liu、E. Wallace、A. Dziedzic、R. Krishnan和D. Song，《预训练变换器提升分布外鲁棒性》，arXiv预印本 arXiv:2004.06100，2020年。[154] E. Laparra、X. Su、Y. Zhao、O. Uzuner、T. A. Miller和S. Bethard，《SemEval-2021任务10：用于语义处理的无源域适应》。计算语言学协会（ACL），2021年。[155] D. Yarowsky，《可与监督方法媲美的无监督词义消歧》，载于第33届计算语言学协会年会，1995年，第189–196页。[156] X. Su、Y. Zhao和S. Bethard，《亚利桑那大学在SemEval-2021任务10中的参赛工作：将自训练、主动学习和数据增强应用于无源域适应》，载于第15届国际语义评测研讨会（SemEval-2021）论文集，2021年，第458–466页。[157] Z. Miao、Y. Li、X. Wang和W.-C. Tan，《Snippext：结合增强数据的半监督观点挖掘》，载于《The Web Conference 2020》论文集，2020年，第617–628页。

《结合增强数据的半监督观点挖掘》，载于《The Web Conference 2020》论文集，2020年，第617–628页。[158] K. Zhou、Z. Liu、Y. Qiao、T. Xiang和C. C. Loy，《视觉领域的域泛化：综述》，arXiv预印本 arXiv:2103 02503，2021年。[159] K. Muandet、D. Balduzzi和B. Sch¨olkopf，《通过不变特征表示实现域泛化》，载于国际机器学习会议。PMLR，2013年，第10–18页。[160] H. Niu、H. Li、F. Zhao和B. Li，《用于无源域泛化的统一域提示表示》，arXiv预印本 arXiv:2209.14926，2022年。[161] A. Frikha、H. Chen、D. Krompaß、T. Runkler和V. Tresp，《迈向无数据域泛化》，arXiv预印本 arXiv:2110.04545，2021年。[162]M. Yazdanpanah和P. Moradi，《视觉域桥：一种用于跨域少样本学习的无源域适应方法》，载于IEEE/CVF计算机视觉与模式识别会议论文集，2022年，第2868–2877页。[163] W. Zhang、L. Shen、C.-S. Foo和W. Zhang，《无源少样本域适应》。[164] T. Varsavsky、M. Orbes-Arteaga、C. H. Sudre、M. S. Graham、P. Nachev和M. J. Cardoso，《测试时无监督域适应》，载于《医学图像计算与计算机辅助干预—MICCAI 2020：第23届国际会议》，利马，秘鲁，2020年10月4—8日，论文集，第一部分23。Springer，2020年，第428–436页。[165] Q. Peng、Z. Ding、L. Lyu、L. Sun和C. Chen，《迈向更优的无源和黑盒域适应目标表示》，arXiv预印本 arXiv:2208.10531，2022年。[166] P. Agarwal、D. P. Paudel、J.-N. Zaech和L. Van Gool，《无需源数据的无监督鲁棒域适应》，载于IEEE/CVF冬季计算机视觉应用会议论文集，2022年，第2009–2018页。[167] P. Khosla、P. Teterwak、C. Wang、A. Sarna、Y. Tian、P. Isola、A. Maschinot、C. Liu和D. Krishnan，《监督式对比学习》，神经信息处理系统进展，第33卷，第18 661–18 673页，2020年。[168] X. Huang、M.-Y. Liu、S. Belongie和J. Kautz，《多模态无监督图像到图像转换》，载于《欧洲计算机视觉会议（ECCV）论文集》，2018年，第172–189页。[169] F. Zhan、Y. Yu、R. Wu、J. Zhang、K. Cui、A. Xiao、S. Lu和C. Miao，《用于多功能图像转换与操作的双层特征对齐》，载于《计算机视觉—ECCV 2022：第17届欧洲计算机视觉会议》，特拉维夫，以色列，2022年10月23—27日，论文集，第十六部分。Springer，2022年，第224–241页。[170] C.-H. Yeh、C.-Y. Hong、Y.-C. Hsu、T.-L. Liu、Y. Chen和Y. LeCun，《解耦对比学习》，载于《计算机视觉—ECCV 2022：第17届欧洲计算机视觉会议》，特拉维夫，以色列，2022年10月23—27日，论文集，第二十六部分。Springer，2022年，第668–684页。[171] W. Li、M. Cao和S. Chen，《用于无源域自适应的雅可比范数》，arXiv预印本 arXiv:2204 03467，2022年。[172] G. Rotman和R. Reichart，《面向低资源依存句法分析的深度上下文化自训练》，计算语言学协会会刊，第7卷，第695–713页，2019年。[173] S. Desai、B. Sinno、A. Rosenfeld和J. J. Li，《自适应集成：用于政治文档分析的无监督域适应》，arXiv预印本 arXiv:1910.12698，2019年。[174] G. Rocha和H. L. Cardoso，《无监督语言适应方法的比较分析》，载于第二届低资源自然语言处理深度学习方法研讨会（DeepLo 2019）论文集，2019年，第11–21页。[175] L. Shen、J. Li、J. Liu、L. Zhu和H. T. Shen，《用于锂离子电池跨域荷电状态估计的温度自适应迁移网络》，IEEE电力电子学汇刊，第38卷，第3期，第3857–3869页，2022年。[176] K. Wu、J. Li、L. Zuo、K. Lu和H. T. Shen，《用于机器剩余使用寿命预测的加权对抗域适应》，IEEE仪器与测量汇刊，第71卷，第1–11页，2022年。[177] X. Zhang、J. Li、H. Su、L. Zhu和H. T. Shen，《用于双向跨域推荐的多层注意力域解耦》，ACM信息系统汇刊。[178] H. Su、Y. Zhang、X. Yang、H. Hua、S. Wang和J. Li，《通过对抗式适应实现跨域推荐》，载于论文集第*31*届*ACM*信息与知识管理国际会议论文集，2022年，第1808–1817页。[179] B. Lucas、C. Pelletier、D. Schmidt、G. I. Webb和F. Petitjean，“用于卫星图像时间序列分类的无监督域自适应技术”，载于*IGARSS 2020-2020 IEEE*国际地球科学与遥感研讨会。IEEE，2020年，第1074–1077页。[180] M. Q. Nasim、T. Maiti、A. Srivastava、T. Singh和J. Mei，“地震相分析：一种深度域适应方法”，*IEEE*地球科学与遥感汇刊，第60卷，第1–16页，2022年。[181] X. Peng、Z. Huang、Y. Zhu和K. Saenko，“联邦对抗域适应”，*arXiv*预印本 *arXiv:1911.02054*，2019年。[182] J.-C. Su、Y.-H. Tsai、K. Sohn、B. Liu、S. Maji和M. Chandraker，“主动对抗域适应”，载于*IEEE/CVF*冬季计算机视觉应用会议论文集，2020年，第739–748页。