

控制与决策

Control and Decision

无监督域适应研究综述

马大中, 王清晨, 齐开聪, 左鑫如, 王梓鑫

引用本文:

马大中, 王清晨, 齐开聪, 等. 无监督域适应研究综述[J]. *控制与决策*, 2026, 41(3): 577-603.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0989>

您可能感兴趣的其他文章

Articles you may be interested in

一种基于池计算的宽度学习系统

A broad learning system based on reservoir computing

控制与决策. 2021, 36(9): 2203-2210 <https://doi.org/10.13195/j.kzyjc.2019.1729>

基于度量学习和典型相关分析的亲缘关系识别网络

Kinship relationship recognition network based on metric learning and canonical correlation analysis

控制与决策. 2021, 36(8): 1977-1983 <https://doi.org/10.13195/j.kzyjc.2019.1798>

行人重识别中度量学习方法研究进展

A survey on metric learning in person re-identification

控制与决策. 2021, 36(7): 1547-1557 <https://doi.org/10.13195/j.kzyjc.2020.0801>

基于DLSR的归纳式迁移学习

DLSR based inductive transfer learning method

控制与决策. 2021, 36(12): 2982-2990 <https://doi.org/10.13195/j.kzyjc.2020.0703>

迁移学习引导的变源域长短时记忆网络建筑负荷预测

Load forecasting of buildings using LSTM based on transfer learning with variable source domain

控制与决策. 2021, 36(10): 2328-2338 <https://doi.org/10.13195/j.kzyjc.2020.0215>

无监督域适应研究综述

马大中[†], 王清晨, 齐开聪, 左鑫如, 王梓鑫

(东北大学 信息科学与工程学院, 沈阳 110819)

摘要: 在实际应用中, 标注数据的稀缺与源域、目标域的分布差异导致模型泛化性受限. 无监督域适应 (UDA) 通过缩小域间分布差异, 确保模型在新的环境下性能稳定. 过去 20 年, 域适应在分布对齐、特征变换等方面得到广泛研究, 但现有综述多聚焦于域不变特征学习视角, 鲜有文献从域间类别差异角度系统性总结. 鉴于此, 以类别空间不一致为核心视角, 对域不变特征学习和跨域类别匹配两个技术手段展开全面综述. 首先介绍域适应中分布漂移的基本概念与数学定义, 并基于标签集差异划分为闭集、部分集、开集与通用域适应; 其次从域不变特征学习和跨域类别匹配两方面对现有方法进行综述, 继而阐述域适应的多种变体, 包括无源、多源、域泛化, 并首次在综述中引入时序域适应/泛化问题; 最后总结域适应在自然语言处理、计算机视觉、工业时序与推荐系统等领域的应用, 并展望未来发展方向与挑战.

关键词: 迁移学习; 域适应; 域不变特征; 跨域类匹配; 时序域泛化

中图分类号: TP181 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0989

引用格式: 马大中, 王清晨, 齐开聪, 等. 无监督域适应研究综述 [J]. 控制与决策, 2026, 41(3): 577-603.

A survey on unsupervised domain adaptation

MA Da-zhong[†], WANG Qing-chen, QI Kai-cong, ZUO Xin-ru, WANG Zi-xin

(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: In real-world applications, the scarcity of labeled data and the distributional differences between the source and target domains limit the generalization ability of models. Unsupervised domain adaptation (UDA) addresses this issue by reducing the distributional gap between domains, ensuring stable model performance in new environments. Over the past two decades, domain adaptation has been extensively studied in areas such as distribution alignment and feature transformation. However, existing surveys mostly focus on domain-invariant feature learning, with few systematically summarizing the literature from the perspective of inter-domain class differences. In response, this paper presents a comprehensive review of domain-invariant feature learning and cross-domain class matching, with a focus on the core issue of category space inconsistency. First, we introduce the basic concepts and mathematical definitions of distribution shift in domain adaptation, and categorize domain adaptation based on label set differences into closed-set, partial-set, open-set, and universal domain adaptation. Next, we provide a comprehensive review of existing methods from the perspectives of domain-invariant feature learning and cross-domain class matching. We then discuss various variants of domain adaptation, including unsupervised, multi-source, and domain generalization, and for the first time, introduce the problem of temporal domain adaptation/generalization in the survey. Finally, we summarize the applications of domain adaptation in fields such as natural language processing, computer vision, industrial time series, and recommendation systems, and outline future directions and challenges.

Keywords: transfer learning; domain adaptation; domain-invariant feature; cross-domain class matching; temporal domain generalization

0 引言

近年来, 随着深度学习在计算机视觉、自然语言处理等领域的应用取得显著进展, 如何利用大规模标注数据进行训练已成为关键. 然而, 在许多实际应用中, 获得高质量的标注数据往往成本高昂且不可

行, 这限制了模型的推广和应用^[1]. 为了解决这一问题, 迁移学习 (transfer learning) 逐渐成为一个重要的研究方向, 它通过将源域学到的知识迁移到目标域, 减少了对大规模标注数据的依赖, 提高了模型的泛化能力和适应性^[2].

收稿日期: 2025-09-19; 录用日期: 2025-12-24.

基金项目: 国家自然科学基金联合基金重点项目 (U22A20221).

[†]通信作者. E-mail: madazhong@ise.neu.edu.cn.

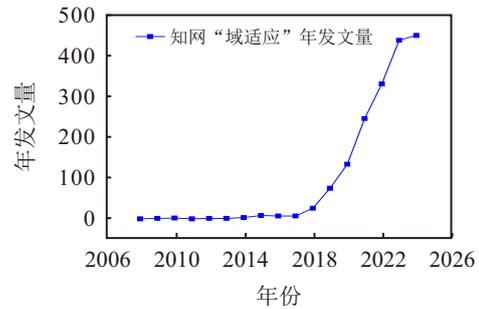
在迁移学习中,无监督域适应 (unsupervised domain adaptation, UDA) 作为一种典型的跨域迁移方法,专注于解决源域与目标域数据分布不一致且目标数据无标签的问题.为了简洁起见,本文将“域适应”(domain adaptation, DA) 视为无监督域适应.域适应的研究重点是如何缓解“域偏移”带来的性能下降问题.通过缩小源域与目标域在特征空间中的分布差异,域适应使得在源域标注数据上训练的模型能够有效地推广到目标域.因此,域适应在迁移学习中逐渐成为一个备受关注的研究领域^[3-4].

通过在中国知网 (CNKI) 和 Web of Science (WoS) 上检索“域适应”主题,得到如图 1(a)、(b) 所示的年发文量趋势.同时,依据“domain adaptation”“metric learning”“feature representation”“domain shift”等关键词通过 WoS 进行检索,将检索结果绘制出聚类图,结果如图 1(c) 所示.从图 1(a) 和 (b) 可以看出,关于域适应的发文量在 2009 ~ 2015 年间缓慢增长,聚焦于特征迁移与偏移问题;而在 2016 ~ 2020 年,随着深度学习的兴起,发文量出现了快速增长;到 2020 年后,增速趋于稳定,但域适应的比例持续上升. CNKI 的发文量在 2019 年前后出现拐点,受医疗影像、遥感、工业视觉等领域需求推动,研究逐渐从“可用”向“可部署”转变.

尽管早期研究多基于理想化的假设,但随着应用场景的复杂化,域适应的研究范式正经历从“静态闭集”向“动态开放”的深刻演进.从类别空间的角度出发,这一演进过程表现为:由源域与目标域类别完全一致的闭集域适应 (close-set DA)^[5],向存在源域私有类的部分域适应 (partial DA)^[6] 过渡,进而发展为包含目标域未知类别的开集域适应 (open-set DA)^[7];最终演化为双方均有私有类别、最具挑战性的通用域适应 (universal DA)^[8].这一演进趋势要求算法不仅能对齐分布,更需具备在开放动态类别空间下的鲁棒性.

在技术路线上, H-divergence 理论^[9] 奠定了基于分布对齐的基础,随之涌现出大量基于对抗学习的方法^[10-11].然而,随着类别空间不一致问题的凸显,跨域类别匹配 (即公有类对齐与私有类识别) 变得至关重要.私有类识别逐渐成为热点, Busto 等^[12] 由开集设定引入该问题后,基于不确定性^[13]、熵^[14] 及类原型^[15] 的方法相继提出,旨在解决非闭集场景下的负迁移难题.

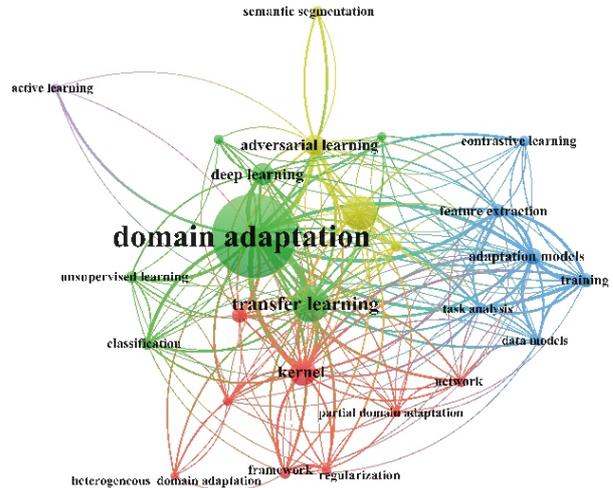
本文回顾了现有综述中的研究方向和方法 (如表 1 所示).可以发现,以往综述大多侧重于“域不变特征学习”视角,主要梳理闭集场景下的分布对齐方



(a) 中国知网“域适应”发文量趋势



(b) WoS“域适应”发文量趋势



(c) WoS“域适应”关键词聚类

图1 域适应的趋势与结构概览

法^[3-4, 16-17].然而,单纯的分布对齐无法有效解决跨域类别空间不一致的问题^[17],难以指导研究者在开集或通用场景下进行模型选型.此外,现有中文综述多聚焦于计算机视觉领域的静态图像任务,缺乏对时序域适应的系统性总结,未能覆盖工业互联网与电力系统等领域对动态时序数据跨域分析的迫切需求.

本文的结构安排如下:首先,将域适应问题根据标签分布的差异从闭集、部分集、开集到通用 4 类进行演进式梳理;然后,分别探讨域不变特征提取和跨域类别匹配两条技术路线,并构建具有实战意义的方法论框架;接着,系统阐述域适应的研究变体 (包括无源、多源、域泛化),并重点探讨时序域适应的新兴方向;最后,结合工业时序等具体场景分析应用落地,并展望未来的研究方向与挑战.

表1 现有综述总结

论文题目	发表期刊, 年份	综述逻辑总结
A survey on transfer learning ^[2]	IEEE TPAMI, 2010	按照学习设置和迁移内容进行综述
A survey of transfer learning ^[16]	Journal of Big Data, 2016	按照特征空间是否相同进行综述(同构、异构)
A comprehensive survey on transfer learning ^[17]	Proceedings of the IEEE, 2020	从数据视角、模型视角对现有迁移学习方法进行综述
A decade survey of transfer learning (2010–2020) ^[18]	IEEE Transactions on Artificial Intelligence, 2021	根据源域和目标域的标签情况及数据模态进行分类, 按照5种迁移方法作为子领域进行综述
A review of domain adaptation without target labels ^[19]	IEEE TPAMI, 2021	按照样本级、特征级、推理级进行方法综述
深度域适应综述: 一般情况与复杂情况 ^[3]	自动化学报, 2021	域不变特征学习
领域自适应研究综述 ^[4]	计算机工程, 2021	域不变特征学习
A review of single-source deep unsupervised visual domain adaptation ^[20]	TNNLS, 2022	域不变特征学习
Toward domain adaptation with open-set target data: Review of theory and computer vision applications ^[21]	Information Fusion, 2023	域不变特征学习
Generalizing to unseen domains: A survey on domain generalization ^[22]	IEEE TKDE, 2022	按照数据层、特征层、策略层进行综述
部分域适应研究综述 ^[23]	软件学报, 2023	域不变特征学习
Transfer learning in deep reinforcement learning: A survey ^[24]	IEEE TPAMI, 2023	按照奖励塑性、演示学习、策略迁移、任务间映射、表示迁移逻辑进行综述. 针对强化学习
Source-free unsupervised domain adaptation: A survey ^[25]	Neural Networks, 2024	按照源域模型参数能够访问分为“黑盒”“白盒”方法进行综述. 针对无源域适应
A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations ^[26]	Expert Systems with Applications, 2024	从11个应用领域进行全景综述(医学、工业、遥感、NLP等), 侧重应用
通用域适应综述 ^[27]	计算机研究与发展, 2024	域不变特征学习

1 问题定义

本节首先给出域适应任务中使用的基本符号与定义, 并从分布漂移问题出发, 逐步引入不同的域适应设定及其理论误差界限, 为后续方法综述建立统一的理论框架.

1.1 符号与基本定义

在域适应问题中, 一个域 \mathcal{D} 由特征空间 \mathcal{X} 、标签空间 \mathcal{Y} 及其上的联合分布 $P(X, Y)$ 构成: $\mathcal{D} = \{\mathcal{X}, \mathcal{Y}, P(X, Y)\}$, $X = \{x_1, x_2, \dots, x_n\} \in \mathcal{X}$, $Y = \{y_1, y_2, \dots, y_n\} \in \mathcal{Y}$. 当源域与目标域的分布存在差异时, 在源域上训练的模型直接迁移至目标域通常会导致性能退化^[18-19]. 为此, 域适应旨在缩小源域 $\mathcal{D}_s = \{\mathcal{X}_s, \mathcal{Y}_s, P_s(X, Y)\}$ 与目标域 $\mathcal{D}_t = \{\mathcal{X}_t, \mathcal{Y}_t, P_t(X, Y)\}$ 之间的分布差异, 从而提升模型在目标域上的泛化能力. 通常, 源域样本集表示为 $\mathcal{D}_s = \{(x_1^s, y_1^s), \dots, (x_{n_s}^s, y_{n_s}^s)\}$, 目标域样本集表示为 $\mathcal{D}_t = \{x_1^t, x_2^t, \dots, x_{n_t}^t\}$, 目标域样本缺乏标注信息^[2, 20]. 因此, 域适应问题可形式化地描述为: 在源域与目标域联合分布 $P_s(X, Y) \neq P_t(X, Y)$ 的前提下, 利用源域数据知识优化特征表示或决策边界, 使模型在目标域中仍能保持较高的性能.

1.2 分布漂移问题

在实际应用中, 源域与目标域常因采集条件、时间跨度或应用场景的不同而导致数据分布不一致, 这一现象称为分布漂移^[24, 26, 28], 它是域适应问题中知

识迁移与模型泛化的主要挑战. 形式上, 样本联合分布可写为

$$P(X, Y) = P(X) P(Y|X). \quad (1)$$

其中: $P(X)$ 为边缘分布 $P(Y|X)$ 的条件分布, $P(Y)$ 为标签分布.

根据差异来源, 常见的漂移类型包括^[18]:

1) 边缘分布差异. 在域适应问题中, 边缘分布差异通常指源域与目标域在输入样本的统计特性上存在不一致, 即输入空间的概率分布发生偏移. 其核心假设是标签生成机制保持稳定, 因此模型的判别边界在两个域中依旧成立, 只是训练样本与测试样本的覆盖范围不一致. 其数学刻画如下:

$$P_s(X) \neq P_t(X), P_s(Y|X) = P_t(Y|X). \quad (2)$$

该情形核心特点在于输入样本分布发生变化, 但标签生成机制保持不变. 例如在图像分类中, 训练样本与测试样本可能来源于不同的摄像头或拍摄环境, 导致像素分布差异, 但物体类别判定规则并未改变.

2) 条件分布差异. 另一类常见情况是条件分布差异, 其强调虽然源域与目标域在输入空间的边缘分布保持一致, 但输入与输出标签之间的映射关系发生了偏移. 这意味着即便样本特征形式相同, 对应的类别标签也可能出现不一致. 其形式化表达为

$$P_s(Y|X) \neq P_t(Y|X), P_s(X) = P_t(X). \quad (3)$$

该情形的本质是输入空间保持一致, 但输入与标签

的映射关系发生了变化. 例如, 在情感分析任务中, 某些词语在不同语境下可能对应不同的情感极性, 从而导致条件分布的变化.

3) 标签分布差异. 此外, 源域与目标域之间还可能存在着标签分布差异, 即类别先验概率不一致的情形. 在该情况下, 尽管在给定类别条件下的数据分布保持稳定, 但不同类别在整体样本中的占比发生变化, 从而对模型在目标域上的泛化性能产生显著影响. 其概率关系可表示为

$$P_s(Y) \neq P_t(Y). \quad (4)$$

该分布偏移的典型特征在于, 源域与目标域中各类别样本的相对比例不同, 而类别内部的特征分布保持一致. 例如, 在医疗诊断场景中, 源域数据往往以

表2 常见域适应场景: 闭集、部分集、开集与通用集类别空间特征对比

类型	一致	含未知类	源域 \supseteq 目标域	目标域 \supseteq 源域	典型方法	说明
闭集	√	×	×	×	DANN ^[29] , CDAN ^[11]	源域和目标域类别完全相同, 通过分布对齐实现迁移
部分集	×	×	√	×	PADA ^[6] , MSAN ^[30]	目标域只包含源域部分类别, 需避免负迁移
开集	×	√	×	√	OSBP ^[31] , STA ^[32]	目标域存在源域未见过的未知类, 需同时识别已知类与拒识未知类
通用集	×	√	×	×	UAN ^[8] , AICDA ^[33]	源域和目标域类别部分重叠, 需同时应对部分集与开集情况

1.3.1 闭集域适应

闭集域适应是最常见且研究最早的域适应设定, 其基本假设为源域与目标域在类别空间上完全一致, 即迁移过程不涉及类别空间差异, 主要挑战来源于跨域数据分布漂移问题^[5]. 形式化地, 有

$$\mathcal{Y}_s = \mathcal{Y}_t. \quad (5)$$

Ben-David 等^[34]从统计学习理论角度给出了闭集域适应中目标域风险的上界, 有

$$\epsilon_T(h) \leq \epsilon_S(h) + \frac{1}{2}d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X)) + \lambda. \quad (6)$$

其中: $\epsilon_S(h)$ 和 $\epsilon_T(h)$ 分别为假设 h 在源域与目标域上的期望风险; $d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X))$ 为源域分布 $P_s(X)$ 与目标域分布 $P_t(X)$ 间的 $\mathcal{H}\Delta\mathcal{H}$ 散度, 用于刻画两域特征分布的差异程度; $\lambda = \min_{h \in \mathcal{H}}(\epsilon_S(h) + \epsilon_T(h))$ 为假设空间 \mathcal{H} 中能同时在源域和目标域上取得最优性能的联合最小风险, 反映两域任务间的内在一致性. 该泛化界限表明, 目标域风险 $\epsilon_T(h)$ 受3方面因素共同影响: 源域风险 $\epsilon_S(h)$ 、跨域分布差异项 $d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X))$ 、联合最优误差项 λ .

闭集域适应中通常假设 λ 相对较小或近似为常数, 研究重点集中于通过分布对齐策略减小 $P_s(X)$ 与 $P_t(X)$ 之间的差异. 典型方法包括基于核均值嵌入的最大均值差异、对抗式域对齐方法以及最优传输等^[3]. 这些方法旨在学习跨域一致的域不变特征表

示, 使得在源域上训练的模型能够有效泛化至目标域, 实现不同域中同类别样本的判别边界一致性.

1.3 域适应问题与理论误差界限

表2总结了常见的域适应设置, 包括闭集、部分集、开集和通用集4类. 闭集场景假设源域与目标域类别完全一致, 通过分布对齐实现迁移; 部分集场景中目标域仅包含源域的一部分类别, 需要采取策略避免负迁移; 开集场景中目标域存在源域未见过的未知类, 需同时识别已知类并拒识未知类; 通用集场景则综合了部分集与开集的特点, 需要同时应对类别重叠与未知类问题. 典型方法及其适用场景也由表2给出, 可为不同任务的域适应方法选择提供参考.

示, 使得在源域上训练的模型能够有效泛化至目标域, 实现不同域中同类别样本的判别边界一致性.

1.3.2 部分集域适应

部分集域适应主要应对目标域类别少于源域的情况, 此时源域包含的部分类别在目标域中并未出现, 若直接迁移则可能导致负迁移风险^[6]. 假设目标域类别是源域类别的子集为

$$\mathcal{Y}_t \subset \mathcal{Y}_s. \quad (7)$$

通过对闭集域适应理论误差上限进行总结, 其误差界限可写为

$$\epsilon_t(h) \leq \epsilon_s(h) + \frac{1}{2}d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X)) + \lambda + \gamma. \quad (8)$$

在闭集误差上界基础上, 引入 γ 刻画源域特有类别带来的负迁移风险. 具体而言, γ 衡量了源域中存在但目标域缺失的类别对模型在目标域上的错误影响. 当训练过程中模型对这些源域独有类别过拟合时, 它们可能会被错误映射到目标域中真实存在的类别上, 从而增加目标域的分类误差. 因此, γ 可以理解为源域额外类别导致的风险上界, 有

$$\gamma = \sup_{h \in \mathcal{H}} \epsilon_t^{(s \setminus t)}(h), \quad (9)$$

其中 $\epsilon_t^{(s \setminus t)}(h)$ 为模型在目标域中错误对齐源域独有类别的风险. 在实际算法中, 通常通过加权源域样本、选择性对齐或拒识机制减小 γ 的影响. 部分集域适应优化需在对齐共享类别特征的同时, 抑制源域

特有类别的误对齐. 因此, 模型需自适应地削弱源域私有类别对齐的影响, 通过权重调节或类别置信度筛选, 实现对共享类别的选择性迁移. 部分集域适应的关键挑战为识别并抑制源域特有类别的影响, 仅利用共享类别知识进行迁移. 常见方法包括类别加权策略、源类别筛选机制及基于注意力的特征重构方法^[35-36]. 这类方法广泛用于目标任务涉及较少类别的场景, 如医学诊断中仅关注特定病种的预测问题.

1.3.3 开集域适应

开集域适应针对的是目标域中包含源域未见过的未知类别的情况, 这使得迁移过程不仅要对齐已知类别, 还要具备识别未知类别的能力. 假设目标域包含源域未知类别, 有

$$\mathcal{Y}_t = \mathcal{Y}_s \cup \mathcal{Y}_{\text{unk}}, \mathcal{Y}_{\text{unk}} \cap \mathcal{Y}_s = \emptyset. \quad (10)$$

其误差界限^[7, 37]为

$$\epsilon_t(h) \leq \epsilon_s(h) + \frac{1}{2}d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X)) + \lambda + \eta. \quad (11)$$

在闭集误差上界基础上, 引入 η 表示未知类对分类边界的额外风险.

开集域适应的难点在于同时保证已知类别的准确分类和未知类别的检测^[38]. 研究者提出了基于置信度阈值的样本拒识机制、开放集判别边界构建以及结合聚类的伪标签生成等方法. 这类方法在安全检测、异常识别等场景中尤为重要, 例如工业设备状态监测中的新型故障识别.

从理论角度看, 开集域适应的目标风险可进一步分解为两部分, 即

$$\epsilon_t(h) = \epsilon_t^{(K)}(h) + \epsilon_t^{(\text{unk})}(h). \quad (12)$$

其中: $\epsilon_t^{(K)}(h)$ 为已知类别 \mathcal{Y}_s 上的风险, $\epsilon_t^{(\text{unk})}(h)$ 为未知类别 \mathcal{Y}_{unk} 上的风险. 与闭集情形相比, 未知类风险项 $\epsilon_t^{(\text{unk})}(h)$ 无法通过源域监督直接优化, 因此需通过拒识机制或不确定性建模进行间接控制.

在界限分析中, 额外项 η 可形式化为

$$\eta = \sup_{h \in \mathcal{H}} \epsilon_t^{(\text{unk})}(h). \quad (13)$$

当拒识策略能够准确区分未知类与已知类时, η 近似为零, 此时开集风险界限退化为闭集形式; 反之, 当模型将未知类错误对齐到已知类别时, η 将显著增大, 导致泛化能力下降.

开集域适应的优化目标需在学习共享类别的域不变特征的同时, 有效区分并拒识未知类别样本. 模型通过已知类别对齐和未知类别分离联合优化, 确保已知类对齐准确、未知类区域具有高不确定性或被归入“未知”标签, 从而避免特征误对齐.

1.3.4 通用域适应

通用域适应是目前最一般化的设定, 它综合了部分集与开集的情形, 即目标域既可能是源域类别的子集, 也可能包含额外的未知类别, 因此需要同时应对类别空间缩减和扩展的双重挑战^[14]. 假设目标域类别空间可表示为

$$\mathcal{Y}_t = \mathcal{Y}'_s \cup \mathcal{Y}_{\text{unk}}, \mathcal{Y}'_s \subseteq \mathcal{Y}_s, \quad (14)$$

其中 \mathcal{Y}'_s 为源域独有类别. 从理论角度分析, 通用域适应的目标风险可以分解为如下3个部分:

$$\epsilon_t(h) = \epsilon_t^{(K)}(h) + \epsilon_t^{(s \setminus t)}(h) + \epsilon_t^{(\text{unk})}(h). \quad (15)$$

其中: $\epsilon_t^{(K)}(h)$ 为共享类别 $\mathcal{Y}'_s \cap \mathcal{Y}_t$ 上的风险; $\epsilon_t^{(s \setminus t)}(h)$ 为源域独有类别 $\mathcal{Y}_s \setminus \mathcal{Y}'_s$ 对目标域带来的负迁移风险; $\epsilon_t^{(\text{unk})}(h)$ 为目标域未知类别 \mathcal{Y}_{unk} 的分类风险. 相应的泛化界限可表示为

$$\epsilon_t(h) \leq \epsilon_s(h) + \frac{1}{2}d_{\mathcal{H}\Delta\mathcal{H}}(P_s(X), P_t(X)) + \lambda + \gamma + \eta. \quad (16)$$

在闭集误差上界基础上, 引入 γ 刻画源域独有类别带来的负迁移风险, 引入 η 刻画目标域未知类别带来的额外风险. 通用域适应的优化目标需要同时学习共享类别的域不变特征、抑制源域特有类别的误对齐, 并通过拒识或不确定性建模减少目标域未知类别的影响.

综上所述, 闭集、部分集、开集与通用域适应问题依次放宽了类别空间一致性的假设, 其误差界限揭示了分布差异度量与类别空间不一致性对目标域泛化性能的影响. 这些理论结果为跨域类别匹配和开放集识别方法的设计提供了基础.

2 域不变特征提取

域不变特征提取是处理域适应问题的技术手段之一, 针对域不变特征提取的方法根据对干预分布差异的对象与作用层级的不同可分为基于样本权重的方法、基于统计特征变换的方法、基于几何特征变换的方法和基于对抗学习的方法, 如图2所示.

2.1 基于样本权重的方法

基于样本权重的方法将领域差异的消减问题转化为“加权经验分布”逼近问题: 重要性采样^[39]、加权支持向量机^[40]和自适应权重调整^[41]等策略, 为源域样本赋予与密度比成正比的重要性权重, 从而在期望意义下使加权源域风险等于目标域风险, 为最小化总体误差上界提供无偏的经验风险估计.

1) 重要性采样.

重要性采样作为基于样本权重进行领域不变特征提取的方法之一, 主要通过核均值匹配 (kernel

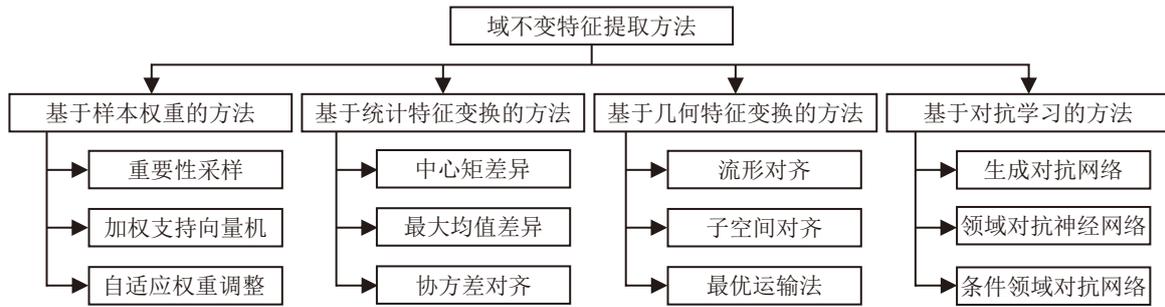


图2 域不变特征提取方法

mean matching, KMM) 进行重要性采样。

KMM 通过最小化两个分布在再生核希尔伯特空间中的均值差异直接求解权重, 为源域中每个样本赋予权重, 使加权后的源数据特征空间中的均值与目标数据均值尽可能接近目标. 首先需要考虑一个映射函数 $\phi: X \rightarrow \mathcal{H}$, 其中 \mathcal{H} 为带核函数 $K(x_1, x_2) = \langle \phi(x_1), \phi(x_2) \rangle$ 的希尔伯特空间; 在特征空间中定义分布 $p(X)$ 的均值映射 $\mu(p(X))$, 用以表示其均值, 有

$$\mu(p(X)) = \mathbb{E}_{X \sim p(X)}[\phi(X)]. \quad (17)$$

当 K 为通用核时, μ 为一个双射函数, 即可以在自身范围与域之间建立对应关系. 此时, KMM 的目标则转换为找到一个权重系列 $\beta(X)$, 使加权的源域分布均值接近目标域均值, 即 $\mu(\beta(X)p_S(X)) = \mu(p_T(X))$.

为保证权重有效, 需要满足两项约束条件: 权重为正和平均值为 1, 即 $\beta(X) \geq 0$ 和 $\mathbb{E}_{X \sim p_S(X)}[\beta(X)] = 1$. 则最小化源域加权均值与目标域均值之间的差异性, 在约束条件下表示为

$$\min_{\beta} \|\mu(p_T(X)) - \mathbb{E}_{X \sim p_S(X)}[\beta(X)\phi(X)]\|^2. \quad (18)$$

但是在实际应用中, 通常只有有限的源域样本和目标域样本, 不能直接计算其期望值, 而是需要通过使用经验均值进行近似, 因此通过求解如下优化问题得到权重 β_i :

$$\begin{aligned} \min_{\beta} \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \beta_i \phi(x_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(x_j^t) \right\|_{\mathcal{H}}^2; \\ \text{s.t. } \beta_i \in [0, B], \left| \sum_{i=1}^{n_s} \beta_i - n_s \right| \leq \epsilon. \end{aligned} \quad (19)$$

其中: ϕ 为再生核希尔伯特空间中的特征映射, B 和 ϵ 为约束参数.

此外, 从重要性采样角度, 许多学者也进行了更深入的探索. 例如, Wei 等^[42] 将不同工况视为多源域, 利用多核最大均值差异 (MK-MMD) 衡量源域与目标域之间的分布相似度, 并据此为各源域分配动

态权重, 从而筛选出与目标域更相关的样本, 构建多域判别器实现域自适应. 该方法结合 MMD 阈值机制, 能够有效避免负迁移, 提升跨工况故障诊断的准确性与鲁棒性.

2) 加权支持向量机.

加权支持向量机通过为不同的样本分配不同的权重, 降低源域与目标域之间的分布差异. 以支持向量机 (support vector machine, SVM) 为基础进行扩展, 将样本权重集成到支持向量机的优化目标中, 对高权重样本的分类错误施加更大的惩罚, 使决策边界更偏向于与目标域相似的源域样本, 实现减少领域分布差异. SVM 定义如下:

$$\begin{aligned} \min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \beta_i \xi_i; \\ \text{s.t. } y_i(w^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, \forall i. \end{aligned} \quad (20)$$

其中: w 为样本权重; b 为偏置; ξ 为松弛向量; C 为惩罚参数, 针对各个样本进行选择.

加权支持向量机当前已在样本权重层面实现了很好的领域不变特征提取, 且已有大量研究验证了其有效性. 例如, Zhang 等^[43] 提出基于类别加权对齐的迁移网络方法, 通过为不同类别赋予差异化权重, 抑制无关类对迁移过程的干扰, 同时结合全局特征对齐与域差异学习, 增强模型的跨域泛化能力. Li 等^[44] 则进一步引入实例级加权机制, 识别并降低源域中异常样本的影响, 结合双域判别模块优化分类边界, 从而提升目标域的分类性能.

3) 自适应权重调整.

在自适应权重调整中, 多通过熵加权来减少领域分布对齐. 熵加权以目标样本预测熵的负指数作为权重, 使高置信 (低熵) 样本获得更大的监督信号, 其权重公式为

$$\begin{aligned} w_j = 1 + \exp(-H(\mathbf{p}_j)), \\ H(\mathbf{p}_j) = - \sum_c p_{j,c} \log p_{j,c}. \end{aligned} \quad (21)$$

其中: \mathbf{p}_j 为模型对目标样本 x_j 的 softmax 输出, 熵越小权重越大, 实现自适应强化可靠样本、抑制不确定

样本的隐式调整.

目前, 已有诸多研究依据自适应权重方法进行领域不变特征的有效提取. 例如, Li 等^[45] 提出预测重加权域自适应方法, 利用源域分类器对目标域样本的预测置信度进行动态加权, 缓解因源-目标分布差异导致的性能下降问题. Huang 等^[46] 通过筛选多个目标域中的高置信度样本, 构建伪监督训练集, 并训练额外分类器依据域间分布差异自适应调整样本权重, 从而提升单源多目标场景下的跨域分类效果. 此外, Shin 等^[47] 提出的双加权无监督域自适应方法, 结合几何特征相似度的固定权重与工程性能相似度的动态权重, 筛选高关联源域样本, 能够有效应对 3D 设计数据中的域偏移与标注稀缺问题. Wu 等^[48] 提出一种强化重加权联合自监督适应方法: R2SA 方法, 将强化学习、SSL 和 PDA 融合在一起, 解决部分域适应中的迁移问题.

2.2 基于统计特征变换的方法

基于统计特征变换的域适应方法通过在再生核希尔伯特空间或深度特征空间中显式对齐源域与目标域的统计矩 (如均值、协方差、高阶矩或协方差算子), 以最小化统计距离, 从而在不改变样本几何结构的前提下, 使两域的边际或条件分布趋于一致, 实现领域分布差异的缩减. 常见的通过统计变换方法减少分布差异的典型方法如下.

1) 中心矩差异 (CMD).

中心矩差异作为通过统计特征变换方法提取域不变特征的典型方法, 以数据中心点 (均值) 为参考, 对数据分布进行描述, 一般常用形式包括一阶中心矩 (期望)、二阶中心矩 (方差)、三阶中心矩 (偏度)、四阶中心矩 (峰度). 为更好地描述更细微且复杂的数据分布, 多使用 k 阶中心矩, 即需要先对数据 X 进行“中心化”, 然后进行 k 次求幂, 最后求期望: $\mu_k = \mathbb{E}[(X - \mathbb{E}[X])^k]$.

通过匹配两个分布的高阶中心矩来对齐分布. 对于 k -阶中心矩, CMD^[49] 定义为

$$\text{CMD}_K(x_s, x_t) = \frac{1}{b-a} \|\mathbb{E}(x_s) - \mathbb{E}(x_t)\|_2 + \sum_{k=2}^K \frac{1}{|b-a|^k} \|C_k(x_s) - C_k(x_t)\|_2. \quad (22)$$

其中: $C_k(x) = \mathbb{E}[(x - \mathbb{E}(x))^k]$ 为 k 阶样本的中心矩, $\mathbb{E}(x)$ 为经验期望.

2) 最大均值差异 (MMD).

MMD^[50] 作为对源域 \mathcal{D}_s 与目标域 \mathcal{D}_t 分布间差异的常用度量方式, 本质是在再生核希尔伯特空间中

对齐源域与目标域的样本均值.

MMD 不需要估计分布的密度函数, 而是基于核函数, 通过将数据映射到高维特征空间, 使两个分布的均值嵌入被明确表示. 两个数据均值差异越大表明采样样本越属于不同的分布, 定义为

$$\text{MMD}^2(\mathcal{D}_s, \mathcal{D}_t) = \sup_{\|\phi\|_{\mathcal{H}} \leq 1} \|\mathbb{E}[\phi(x_s)] - \mathbb{E}[\phi(x_t)]\|_{\mathcal{H}}^2. \quad (23)$$

其中: ϕ 为映射函数, 将原数据映射到再生核希尔伯特空间中; $\|\phi\|_{\mathcal{H}} \leq 1$ 用于定义一组在再生核希尔伯特空间单位球中的函数.

在实际计算中, 由于源域与目标域的真实分布是未知的, 通常使用经验估计近似, MMD 的经验估计为

$$\widehat{\text{MMD}}^2(\mathcal{D}_s, \mathcal{D}_t) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(x_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(x_j^t) \right\|_{\mathcal{H}}^2, \quad (24)$$

其中 n_s 、 n_t 分别为源域样本数量和目标域样本数量.

为进一步提升 MMD 在实际迁移任务中的适应性与判别能力, 诸多研究对其进行了扩展与加权改进. 阎高伟等^[51] 提出了一种基于 MMD 和联合分布适配的多源域迁移学习方法, 用于解决湿式球磨机在工况变化时因数据分布不一致导致的软测量模型性能下降问题. 臧绍飞等^[52] 提出一种基于最大分布加权均值嵌入的领域适应学习算法, 通过为源域和目标域的所有样本设计分布权重系数, 并同时调整边缘分布和条件分布差异, 以提升跨领域分类精度.

3) 协方差对齐 (CORAL).

CORAL^[53] 方法通过减小两个领域协方差矩阵的差异来迁移知识, 一般通过线性变换方法将源域与目标域分布的二阶统计特征进行对齐. 假设源域训练样本 $D_s = \{x_1, x_2, \dots, x_{n_s}\}$, 无标签的目标域数据 $D_t = \{x_1, x_2, \dots, x_{n_t}\}$. 令 D_s^{ij} 、 D_t^{ij} 分别表示第 i 个源域、目标域样本的第 j 维特征, C_s 、 C_t 分别表示源域和目标域特征协方差矩阵, CORAL 为源域与目标域特征的协方差距离, 定义如下:

$$L_{\text{CORAL}} = \frac{1}{4d^2} \|C_s - C_t\|_F^2, \quad (25)$$

$$C_s = \frac{1}{n_s - 1} \left(D_s^T D_s - \frac{1}{n_s} (\mathbf{1}^T D_s)^T (\mathbf{1}^T D_s) \right), \quad (26)$$

$$C_t = \frac{1}{n_t - 1} \left(D_t^T D_t - \frac{1}{n_t} (\mathbf{1}^T D_t)^T (\mathbf{1}^T D_t) \right). \quad (27)$$

其中: $\|\cdot\|_F^2$ 为矩阵范数的平方, d 为特征维度, C_s 、 C_t 分别为源域和目标域的协方差矩阵, $\mathbf{1}$ 为全 1 列向量.

此外, 近年来研究者在基于统计特征变换的

角度探究越来越深入,围绕分布对齐的语义粒度细化、结构约束增强以及优化效率提升等方向展开进一步的探索,推动了域自适应方法在表达能力与泛化性能上的显著进步.例如, Daume 等^[54]提出了一种最大熵体适配模型方法,通过混合分布建模源-目标域关联,结合条件期望最大化 (conditional expectation maximization, CEM) 实现高效参数学习. Shu 等^[55]提出了带教师模型的决策边界迭代优化训练模型和虚拟对抗域适配模型两阶段方法,结合聚类假设与自然梯度优化,弥补传统域对抗训练缺陷. Sun 等^[56]提出了双损失协同优化的深度迁移架构,通过域混淆与任务关联约束,同时实现域分布对齐与类别知识迁移. Zhang 等^[57]提出了联合几何与统计对齐,通过双投影矩阵协同优化,同时实现几何与统计层面的域对齐,兼顾共享与域特异性特征,提升无监督域自适应的跨域鲁棒性. Abramov 等^[58]提出了特征分布匹配与直方图匹配两种轻量方法,通过对齐源-目标图像全局统计特征缩小域差距.

2.3 基于几何特征变换的方法

基于几何特征变换的域适应方法旨在将源域与目标域视为高维空间中的两个几何结构,通过流形映射、子空间对齐或测地线路径等手段实现领域自适应嵌入,通常使用流形对齐^[59-61]、子空间对齐、度量学习^[62-63]等方式减少领域分布差异,在保持数据结构完整性的前提下,寻找一个共享的表示空间,从而减小领域间分布差异.

1) 流形对齐.

以“搬土”距离 (wasserstein distance) 为代表,将两域分布看作概率测度,用来表示两个分布的相似程度,衡量将数据从分布 $\mathcal{P}(x_s)$ 移动为 $\mathcal{P}(x_t)$ 时所需要移动的平均距离最小值.

Wasserstein 距离的定义基于最优运输成本,对于给定的两个数据分布 $\mathcal{P}(x_s)$ 和 $\mathcal{P}(x_t)$, 最优成本定义为

$$C[\mathcal{P}(x_s), \mathcal{P}(x_t)] = \inf_{\gamma \in \Pi[\mathcal{P}(x_s), \mathcal{P}(x_t)]} \iint \gamma(x, y) c(x, y) dx dy. \quad (28)$$

式 (28) 中的成本矩阵 $c(x, y)$ 常选择欧氏距离的若干次方进行求解,因此,成本矩阵表示为 $c(x, y) = \|x - y\|^\rho$. 此时, Wasserstein 距离记为 $\mathcal{W}_\rho[\mathcal{P}(x_s), \mathcal{P}(x_t)] = (C[\mathcal{P}(x_s), \mathcal{P}(x_t)])^{1/\rho}$. 进而 Wasserstein 距离通过求解最优耦合实现流形上的测地线映射,定义为

$$\mathcal{W}_\rho(\mathcal{P}(x_s), \mathcal{P}(x_t)) = \left(\inf_{\gamma \in \Gamma} \int_{x_s \times x_t} d(x_s, x_t) d\gamma(x_s, x_t) \right)^{\frac{1}{\rho}}. \quad (29)$$

其中: $d(x_s, x_t)$ 为 x_s 与 x_t 之间的距离, Γ 为 $\mathcal{P}(x_s)$, $\mathcal{P}(x_t)$ 所有可能的联合概率分布.

近年来,基于几何特征变换进行领域分布对齐的研究呈现出从理论构建向方法创新与领域应用深度拓展的趋势.诸多研究围绕 Wasserstein 度量的计算效率、约束优化机制与语义一致性等关键问题展开深入探索,显著推动了域自适应理论体系的发展与实用化进程.例如, Shen 等^[64]提出 Wasserstein 距离引导的表示学习方法,使域评判器梯度惩罚满足 Lipschitz 约束,能够精准估计源-目标域特征的 Wasserstein 距离,特征提取器通过最小化 Wasserstein 距离实现域对齐,同时分类器利用源域标签监督保证特征判别性. Hu 等^[65]提出基于 Wasserstein 距离的加权领域对抗神经网络方法,通过样本加权抑制低质量样本干扰,结合 Wasserstein 距离解决梯度问题. Lee 等^[66]为提升无监督域自适应的分布对齐效果与任务通用性,提出切片 Wasserstein 差异方法,用切片 Wasserstein 差异替代传统差异度量,结合最大分类器差异 (maximum classifier discrepancy, MCD) 框架实现高效域对齐.

2) 子空间对齐.

子空间对齐法 (subspace alignment, SA) 通常假设源域和目标域数据在变换后的子空间中会有相似分布,需要通过在子空间中进行数据分布对齐,并将对齐后的数据利用传统机器学习方法构建分类器学习.

SA 通过直接学习一个线性变换矩阵 M 将源域子空间对齐到目标域子空间. 设 P_s 和 P_t 分别是通过 PCA 从源域和目标域数据中学习到的基向量矩阵,则变换矩阵 M 通过最小化如下 Frobenius 范数得到:

$$M^* = \arg \min_M \|P_s M - P_t\|_F^2, \quad (30)$$

其中 $M^* = P_s^\top P_t$ 为其闭式解.

最终,源域和目标域数据通过 $z = (P_s M^*)^\top x$ 映射到对齐后的子空间,通过直接对齐子空间基向量来实现域不变特征提取.

目前,针对通过子空间变换的方式提取领域不变特征的研究不断增多,如 Siva 等^[67]开发了一种创新的波束跟踪方法,将子空间跟踪与强化学习相结合.通过分解子空间和训练动态强化学习模型,解决不同频率下的宽带波束对准问题. Zhou 等^[68]提出了一种基于深度神经网络的 UIL 算法 (DeepLink),采

用半监督学习方式建立基于子空间学习的模型, 实现自动特征提取和表示. Shan 等^[69] 将一对一和子空间拓扑干扰对齐 (IA) 条件重铸为向量分配策略, 并利用图神经网络捕获拓扑结构和强化学习来决策 IA 波束成形矢量分配, 提出一个统一的图学习到代码 (LCG) 框架.

3) 最优运输法.

最优运输作为提取域不变特征的一种几何变换方法, 其主要问题是找到最合适的传输策略, 以 Monge 问题为初始思想, 其根据 Monge 问题定义为

$$\min_T \left\{ \sum_i c(x_i, T(x_i)) : T_*\alpha = \beta \right\}. \quad (31)$$

其中: c 为映射路线的运输代价, T 为最小运输代价的映射, α, β 为两个对应的离散测度, $\alpha = \sum_{i=1}^n a_i \delta_{x_i}$,

$$\beta = \sum_{j=1}^m b_j \delta_{y_j}, \delta \text{ 为狄拉克函数.}$$

针对 Monge 问题中不能对源域数据进行拆分的弊端, 对其进行 Kantorovich Relaxation 处理, 最优运输目标进一步演化为

$$\min_{P \in U(a,b)} \langle C, P \rangle \stackrel{\text{def}}{=} \sum_{i,j} C_{i,j} P_{i,j} + H(P). \quad (32)$$

其中: P 为符合所有行求和为向量 a 、所有列求和为向量 b 的一个映射; $P_{i,j}$ 为从第 i 行映射到第 j 行的元素值; $C_{i,j}$ 为完成 $P_{i,j}$ 元素映射 (或者运输) 的运输代价; $H(P)$ 为正则化代价函数, 表示为 $H(P) \stackrel{\text{def}}{=} - \sum_{i,j} P_{i,j} (\log(P_{i,j}) - 1)$.

最优运输问题通过 Kantorovich Relaxation 进行求解, 但大部分应用情况下求解标准的 Kantorovich Relaxation 不是必要的, 一般通过正则化求解近似解, 从而降低最优运输代价. 当前在最优运输问题的正则化问题中使用 Sinkhorn 算法的方式逐渐增多.

目前, 许多学者将最优传输与深度嵌入相结合, 将分布对齐目标嵌入网络训练过程. Damodaran 等^[70] 提出了深度联合分布最优传输方法, 将最优传输与深度特征学习相结合, 解决传统联合分布最优传输的可扩展性与表征局限性. He 等^[71] 为提升时间序列跨域泛化能力提出了 RAINCOAT 方法, 先通过时频编码器捕捉域不变信息, 再用 Sinkhorn 散度对齐源-目标域特征, 修正阶段通过目标样本重构优化编码器, 依据特征与类别原型的距离变化识别私有类别, 能够有效处理时间序列特有的时频偏移与标签偏移问题. Courty 等^[72] 提出了正则化最优传输方法, 通过最优传输实现源-目标域分布匹配, 结合类别正则化

强化传输合理性, 先以熵正则化降低最优传输计算复杂度并获得平滑传输计划, 再通过稀疏拉普拉斯正则化, 分别确保同类源样本传输一致性, 保留源域样本局部结构, 最后将源样本按传输计划映射到目标域, 训练分类器完成适配, 实现提升无监督域自适应的非线性域对齐能力与类别一致性, 有效解决了非线性域差异与类别信息利用不足问题.

2.4 基于对抗学习的方法

基于对抗学习的域适应方法通过极小-极大博弈训练域判别器与特征提取器, 使提取的特征在判别器视角下无法区分源域与目标域, 从而以“对抗混淆”的方式隐式缩小领域分布差异, 并同步保留分类器所需的判别信息. 常见的通过对抗学习方法减少分布差异的典型方法如下.

1) 生成对抗网络^[73].

生成对抗网络 (generative adversarial networks) 主要由生成器 G 与判别器 D 组成, 通过使用两个网络互相竞争形成对抗. 在训练过程中, 生成网络 G 通过生成正式数据以欺骗判别网络 D , 而 D 则需要将生成的数据与真实数据进行区分, 从而 G 和 D 构成动态“博弈”. 因此, 其优化目标为找到生成模型与判别模型之间的纳什平衡.

通过对抗训练使生成器将源域数据映射到目标域分布, 而判别器区分生成数据与真实目标域数据. GANs 目标函数定义为

$$\begin{aligned} \min_G \max_D V(D, G) = & \\ & \mathbb{E}_{x_t \sim Q} [\log D(x_t)] + \\ & \mathbb{E}_{x_s \sim P} [\log(1 - D(G(x_s)))] + \lambda \mathcal{L}_{\text{task}}(G(x_s), y_s). \end{aligned} \quad (33)$$

其中: G 为生成器, D 为判别器, $\mathbb{E}_{x_t \sim Q} [\log D(x_t)]$ 为目标域判别损失, $\mathbb{E}_{x_s \sim P} [\log(1 - D(G(x_s)))]$ 为生成数据的判别损失, λ 为权衡对抗损失与任务损失的参数, $\mathcal{L}_{\text{task}}$ 为对应任务的损失函数.

2) 领域对抗神经网络^[74].

领域对抗神经网络 (domain adversarial neural network, DANN) 的结构主要由特征提取器 G_f 、标签预测器 G_y 、域判别器 G_d 三部分组成, 其中特征提取器和标签分类器构成前馈神经网络, 并在特征提取器后添加域判别器, 中间使用一个梯度反转层进行连接. 在训练过程中, 对于来自源域的带标签数据, 网络不断最小化标签预测器的损失. 对于源域和目标域的全部数据, 网络不断最小化域判别器的损失.

标签预测器损失计算为

$$\mathcal{L}_y(G_y(G_f(x_i)), y_i) = \log \frac{1}{G_y(G_f(x))_{y_i}}. \quad (34)$$

判别器损失计算为

$$\mathcal{L}_d(G_d(G_f(x_i)), d_i) = d_i \log \frac{1}{G_d(G_f(x_i))} + (1 - d_i) \log \frac{1}{G_d(G_f(x_i))}. \quad (35)$$

DANN 减少领域分布差异, 通过在特征提取器后引入一个领域判别器, 以区分特征来自源域还是目标域. 特征提取器试图生成能够欺骗领域判别器的特征, 通过梯度反转层实现对抗训练. 对抗迁移网络的总损失由训练损失 (标签预测器损失) 和判别器损失组成, DANN 的目标函数可以表示为

$$E(\theta_f, \theta_y, \theta_d) = \sum_{i=1}^{n_s} L_y(G_y(G_f(x_i^s)), y_i^s) + \lambda \sum_{j=1}^{n_s+n_t} L_d(G_d(G_f(x_j)), d_j). \quad (36)$$

其中: G_f 、 G_y 、 G_d 分别为特征提取器、分类器和领域判别器, θ_f 、 θ_y 、 θ_d 分别为特征提取器、分类器和领域判别器的参数, y_i 为类别标签, d_i 为领域标签, λ 为权重系数.

3) 条件领域对抗网络^[75]

条件领域对抗网络 (conditional domain adversarial networks, CDAN) 的独特之处在于, 将特征和分类器输出的外积作为全新的特征输入到领域判别器中, 这种新特征可以捕捉到复杂数据分布之下隐藏的多峰结构.

在基于对抗学习的领域分布对齐研究场景下, 生成对抗网络和条件对抗训练机制被广泛应用于无监督域自适应任务, 并衍生出多种创新性方法. 如 Tzeng 等^[10] 提出了一种对抗性判别域自适应方法, 通过非对称映射和生成式对抗损失, 将源域预训练的判别模型适配到目标域. 李晨昀等^[76] 提出了一种基于深度卷积生成对抗网络数据扩充和深度多源子

域适应网络的方法, 通过多源域特征提取、局部最大均值差异子域对齐及加权模块筛选, 实现滚动轴承的小样本跨域故障诊断. Long 等^[11] 提出了条件对抗域自适应方法, 将分类器预测信息融入对抗训练过程, 通过设计多线性映射策略来显式建模特征表示与分类预测之间的复杂依赖关系. Chen 等^[77] 提出的无判别器对抗域自适应网络, 将任务专用分类器直接复用为判别器, 通过挖掘分类器预测的自相关特性构建了一种对抗学习范式. Huang 等^[78] 提出一种创新的对抗域自适应网络, 通过设计静态-动态交互特征提取网络, 解决了传统方法对样本特异性特征提取不足的问题; 其次, 提出校准原型学习机制, 通过校准判别器修正目标域伪标签的分布偏差, 并结合原型损失函数强制实现跨域类中心对齐, 在保证域不变特征的同时增强特征的类间可分性. Yang 等^[79] 提出一种双网络自编码器 Wasserstein 对抗域适应方法, 通过 CNN-LSTM 双网络结构同时提取时空特征, 并利用 Wasserstein 对抗训练对齐域间分布.

3 跨域类别匹配方法

跨域类别匹配方法是迁移学习中应对类别空间不一致问题的关键策略, 其核心思想是通过伪标签生成与未知类识别机制, 逐步实现源域与目标域类别空间的对齐. 表 3 总结了当前迁移学习中常用的类别匹配方法, 包括伪标签方法与未知类识别方法. 伪标签方法主要通过聚类、相似度或自训练生成目标域伪标签, 适合无监督或少样本场景; 未知类识别方法侧重于通过熵、置信度、开集分类器或不确定性估计区分已知类与未知类, 提高开放集与通用集域适应的可靠性.

3.1 已知类的伪标签

伪标签方法通过为目标域样本分配伪标签辅助训练, 缓解目标域缺乏标注带来的挑战. 根据伪标签生成机制的不同, 可分为基于聚类、基于相似度以及基于自训练的方法.

表3 伪标签方法与未知类识别方法对比

方法类别	思路	代表方法	适用场景/特点
已知类的伪标签方法	基于聚类	DCC ^[80] , MMT ^[81] , DCCL ^[82]	聚类生成目标域伪标签, 适合无监督域适应任务, 常结合伪标签精炼与一致性学习
	基于相似度	TPN ^[83] , PDA ^[84] , MCDA ^[85]	利用源域类别原型与目标样本相似度分配伪标签, 适用于少样本学习、多源域适应, 具备良好可解释性
	基于自训练	PSPCL ^[86] , TST ^[87] , CCL ^[88]	高置信预测作为伪标签迭代训练, 广泛用于图像分类/分割任务, 常结合对比学习、熵正则化提升可靠性
未知类识别方法	基于熵	UAN ^[14] , ROS ^[89] , RecallNet ^[90]	通过预测熵区分已知/未知类, 简单高效, 常结合熵筛选增强鲁棒性
	基于置信度	UAN ^[8] , DREAM ^[91] , IODA ^[92]	适用于开放集与通用集域适应, 可设计动态阈值提升性能
	开集分类器 不确定性估计	OVANet ^[93] , STA ^[32] UDA ^[94] , DUQ ^[95]	引入具备拒识能力的分类器, 显式拒识未知类别, 兼容部分集、开放集、通用集等设定 近似估计预测方差, 提升未知类识别可靠性, 并提供不确定性量化依据

3.1.1 基于聚类的伪标签方法

该方法在目标域特征空间中进行聚类, 并将聚类结果作为伪标签. 以 K -means 为例, 其类中心 μ_k 定义为

$$\mu_k = \frac{1}{|C_k|} \sum_{x_i \in C_k} f(x_i). \quad (37)$$

其中: $f(x_i)$ 为样本特征, C_k 为第 k 个簇. 目标域样本根据与类中心的距离分配伪标签. 已有研究表明, 聚类方法能够在无监督场景下有效提升域适应性能^[57, 80, 96]. Zhang 等^[97] 提出通过多代聚类一致性来细化伪标签, 在数据集上表现优异, 是聚类伪标签在视觉任务上被广泛引用的工作之一. Ge 等^[81] 提出互学习与伪标签精炼机制, 结合聚类和伪标签思想对无标注目标域进行自训练, 属于伪标签 + 聚类范式在通用集域适应的重要线索. Shi 等^[82] 通过双伪标签机制降低噪声, 利用聚类信息增强伪标签一致性, 适用于半监督与自训练式域自适应任务. 赵小强等^[98] 提出了一种基于特征对齐与类别对齐相结合的领域适应算法, 通过在目标域中利用聚类方式生成伪标签, 再结合特征分布对齐与类别空间对齐机制, 有效缩减源域与目标域的差异, 从而提升跨域识别性能.

3.1.2 基于相似度的伪标签方法

该方法利用源域类别原型向量, 通过相似度度量为目标域样本分配伪标签. 常见的度量方式为余弦相似度, 即

$$\hat{y} = \arg \max_k \cos(f(x), \mu_k), \quad (38)$$

其中 μ_k 为源域第 k 类原型. 此类方法在少样本学习和跨域迁移任务中均表现出良好的泛化能力.

Pan 等^[83] 构建了一个基于原型网络的端到端模型, 使源域和目标域类别原型在嵌入空间中对齐, 通过最接近的原型为目标样本分配伪标签, 并联合优化原型距离与概率分布的一致性, 首次将原型网络理念用于通用集域适应设定, 在公开数据集上取得了优异效果. Du 等^[84] 提出一种原型引导的特征学习架构, 通过源域类别原型、最近类别原型方法预测目标样本, 并采用多阶段伪标签过滤减少噪声, 围绕原型引导学习与伪标签过滤机制展开, 进一步优化了基于相似度 + 原型的方法. Dong 等^[99] 提出一种基于子领域自适应的轴承故障诊断方法, 通过引入伪标签策略对不同工况下的子领域样本进行特征对齐, 实现跨工况无监督故障识别, 有效提升了目标域诊断精度. Wu 等^[100] 提出一种原型对比学习驱动的鲁棒性关系抽取方法, 通过基于原型相似度的伪标签生成机制对未标注样本进行有效利用, 并在对比

学习框架下增强不同类别间的区分性, 从而提升关系抽取在噪声环境和跨域场景下的鲁棒性与泛化能力.

3.1.3 基于高置信预测的伪标签方法

高置信预测方法通过选择高置信度预测结果作为伪标签, 利用这些样本迭代更新模型. 典型规则为

$$\hat{y} = \arg \max_y p_\theta(y|x), \text{ if } \max_y p_\theta(y|x) > \tau, \quad (39)$$

其中 τ 为置信度阈值. 自训练被广泛应用于语义分割和目标检测等任务, 能够逐步提高目标域伪标签的可靠性^[86, 101-102]. Liu 等^[103] 提出循环自训练, 通过正向和反向训练循环提升伪标签的泛化性, 引入熵作为一种对置信度友好的正则化方式, 优化伪标签质量, 结合正反向训练过程增强伪标签可靠性, 在视觉分类与情感分析任务中效果显著优于传统自训练方法. Shin 等^[87] 针对自训练中伪标签稀疏的问题提出两阶段伪标签密化策略: 滑动窗口投票传播高置信预测到邻域; 易难样本区分策略对易样本使用完整伪标签, 对难样本采用对抗学习进行特征对齐. Marsden 等^[88] 融合对比学习与时间集成自训练, 使用类中心对齐不同域, 采用时序集成生成一致、可靠的伪标签, 对齐语义结构与提升伪标签质量的双赢策略, 在分割任务中取得领先表现.

3.2 未知类识别方法

未知类识别方法关注的是目标域中可能存在的“新类别”问题, 避免将未知类别样本错误地匹配到源域已知类. 这类方法通常基于预测不确定性建模、分类器设计或特征分布估计. 在领域自适应过程中, 未知类识别方法不仅帮助识别目标域中潜在的未知样本, 降低负迁移风险, 同时可为伪标签生成和自训练提供置信度参考, 确保跨域特征对齐和类别匹配的稳健性, 从而提升域适应模型在开放集场景下的整体性能^[104-105].

3.2.1 基于熵的方法

基于熵的方法通过计算预测概率分布的熵值来区分未知类与已知类, 有

$$H(x) = - \sum_{c=1}^C p(y=c|x) \log p(y=c|x). \quad (40)$$

其中: $H(x)$ 为样本 x 的预测熵, 用于衡量模型对该样本类别预测的不确定性; C 为类别总数; $p(y=c|x)$ 为样本 x 被模型判定为第 c 类的预测概率. 熵值越大表明模型对样本 x 的分类置信度越低, 即该样本越可能位于类间边界或属于未见类别, 当 $H(x)$ 大于阈值时, 将样本判定为未知类. 该方法直观且高效, 广泛

用于开集识别与跨域分类任务. Satio 等^[14] 使用熵驱动的特征对齐与“拒绝策略”来判断目标样本是来自已知类还是未知类, 该方法定义了一个“泛域设定”, 统一处理多种不共享类空间的域适应任务, 亮点是方法简洁有效, 使用熵来筛选未知类是开集识别中的经典引用机制. Xu 等^[89] 检测未知类样本时结合熵分布的尾部建模, 借助极值理论捕捉高熵异常值来识别潜在未知样本, 同时使用实例级重加权机制防止它们对对齐过程的不良影响, 创新性地将极值理论引入开放集域适应问题, 通过统计尾部异常识别未知类, 在多个常见数据集上实现先进效果. Nejjar 等^[90] 解决了无源域开放集域适应问题, 第1步通过合成样本强化分类器对未知类的识别, 第2步在自学习中优先使用低熵、抛弃高熵样本进行训练, 以此精确识别目标域未知类. 王帆等^[106] 通过置信度与局部一致性约束相结合的方法识别未知类, 并引入主动学习机制筛选不确定样本, 从而提升开集域自适应性能. 许清林等^[107] 基于熵值判别目标域样本是否属于未知类, 并在此基础上提出了领域上下文辅助的开放域行为识别方法, 该方法通过引入跨域上下文信息增强特征表示能力, 同时利用伪标签机制对目标域样本进行自适应学习, 从而在保证已知类识别精度的同时有效提升未知类检测性能.

3.2.2 基于置信度的方法

此类方法利用预测概率的最大值作为置信度, 当其低于阈值 τ 时, 判定样本属于未知类, 有

$$\max_c p(y = c|x) < \tau \Rightarrow x \in \text{未知类}. \quad (41)$$

其中: $p(y = c|x)$ 为样本 x 被判定为第 c 类的预测概率; $\max_c p(y = c|x)$ 为模型对样本 x 的最高类别置信度; τ 为预设的置信度阈值, 用于区分已知类与未知类. 当样本的最大预测概率低于阈值 τ , 即 $\max_c p(y = c|x) < \tau$ 时, 模型认为该样本不属于任一已知类别, 从而判定为未知类样本. 其计算简便, 能够与现有分类模型无缝结合, 被广泛应用于开集域适应研究. You 等^[8] 通过融合样本级的不确定性和源-目标域相似性, 自动识别低置信目标样本为未知类, 不依赖预设阈值, 适用于多种开放集迁移设定. Yin 等^[91] 在图域适应中利用混合增强生成样本, 同时在模型预测上施加后验约束的机制, 约束模型避免对低置信预测过度自信, 从而有效识别未知类样本. 张鸿杰等^[108] 提出风格迁移和加权自适应方法, 能够同时降低源域与目标域在像素和特征空间的差异, 并通过目标样本的未知类概率加权提升未知类识别能力, 从而使模型在开放集域自适应中准确区分已知类与

未知类. Ru 等^[92] 为目标样本设计了动态移动阈值机制, 突破了固定阈值判断的局限, 在类不平衡和标签分布偏移的开放集域适应场景中实现更高的未知类识别率.

3.2.3 基于开集分类器的方法

该方法通过引入具备拒识能力的分类器, 使模型能够显式拒绝未知类别. 例如, Satio 等^[93] 引入的 One v.s. All (OVA) 判别函数为

$$f_k(x) = \sigma(w_k^T f(x)), \quad k = 1, 2, \dots, C. \quad (42)$$

其中: $f_k(x)$ 为样本 x 属于第 k 类的预测概率; $f(x)$ 为输入样本 x 的特征表示向量; w_k 为对应第 k 类的分类权重向量; $w_k^T f(x)$ 为输入特征与第 k 类权重的线性匹配得分; $\sigma(\cdot)$ 为激活函数 (通常为 Sigmoid), 用于将线性得分映射为概率值.

若所有 $f_k(x)$ 均低于阈值, 则 x 属于未知类, 在训练阶段, 只利用已知类别的源域样本训练 OVA 子分类器, 通过熵最小化策略, 使模型能在目标域自动识别未知类, 无需预设阈值. 基于 OVA 输出概率与熵来判断是否属于未知类, 适用于多种“通用域适应”设定, 兼容开放集、部分共享集等场景, 并取得了显著性能提升. Liu 等^[32] 采用带拒识能力的分类策略, 模型在源域分类器中增加一个额外“未知类”输出, 引入粗到细的分离机制, 先用多二分类器估计目标样本与已知类别的相似度, 再选出极高/极低的样本分别作为已知/未知, 接着训练二分类器来精细划分目标样本, 在分离过程中拒绝未知样本参与域对齐, 避免“负迁移”.

3.2.4 基于不确定性估计的方法

另一类前沿方法通过贝叶斯深度学习或蒙特卡洛丢弃法对模型预测进行不确定性估计. 当模型对输入 x 的预测波动较大时, 通常意味着该样本更可能属于未知类. 在蒙特卡洛丢弃法中, 对输入 x 进行 T 次前向传播可得到一组预测分布 $\{p_t(y|x)\}_{t=1}^T$, 其不确定性可用预测方差进行度量^[109], 有

$$U(x) = \frac{1}{T} \sum_{t=1}^T p_t(y|x)^2 - \left(\frac{1}{T} \sum_{t=1}^T p_t(y|x) \right)^2, \quad (43)$$

其中 $U(x)$ 越大表示模型越不确定, 越可能为未知类样本. 基于此思想, Gal 等^[109] 提出利用丢弃法作为贝叶斯近似以获得预测不确定性; Han 等^[94] 结合熵正则化与变分贝叶斯建模提升未知类识别的稳定性; Lee 等^[110] 以蒙特卡洛不确定性量化源-目标域的差异, 引导跨域特征对齐; Roy 等^[95] 进一步基于拉普拉斯近似估计模型不确定性, 并对高不确定性目标样本进行降权处理, 从而显著增强了在强域偏移场景

下的迁移性能. 综上, 不确定性估计方法与伪标签方法在跨域类别匹配问题中具有天然互补性, 前者抑制错误迁移, 使模型具有更强的鲁棒性, 后者提供伪标签信息推动跨域特征对齐, 二者结合可在开集迁移学习场景中实现更稳健的类别空间适配.

4 域适应的变体

随着研究工作的深入, 域适应技术在复杂的实际应用场景中已演化出多种变体. 为便于统一描述, 本文设输入空间与标签空间分别为 \mathcal{X} 与 \mathcal{Y} , 分类函数为 h , 损失函数为 $\ell: \mathcal{Y} \times \mathcal{Y} \rightarrow \mathbb{R}^+$, 并将分布 P 上的期望风险定义为

$$\mathcal{R}(h; P) = \mathbb{E}_{(x,y) \sim P(X,Y)}[\ell(h(x), y)]. \quad (44)$$

其中: 域由联合分布 P_{XY} 表征, 相应的样本集记为 $D = \{(x_i, y_i)\}_{i=1}^n$, 若无标签则记为 $D = \{x_i\}_{i=1}^n$. 在此统一符号体系下本节依次介绍无源域适应、多源/多目标域适应、域泛化以及时序域适应等不同问题设定. 域适应不同变体对比如表 4 所示.

4.1 无源域适应

无源域适应 (source-free unsupervised domain adaptation, SFUDA) 的核心任务是在“无法访问任何源数据”的条件下, 仅依赖预训练源模型 Φ_s 及未标注的目标域数据 X_t , 学习得到目标域模型 Φ_t , 以最小化目标域风险^[25]. 根据是否可访问源模型的参数, SFUDA 可进一步划分为白盒与黑盒两类: 白盒 SFUDA 允许访问源模型的可学习参数 (但仍无法访问源数据), 其学习映射可表述为 $\Phi_t: \Phi_s, X_t \mapsto Y_t$; 黑盒 SFUDA 则完全无法获取 Φ_s 的内部参数, 仅能利用 Φ_s 对 X_t 的软/硬预测及 X_t 本身进行学习, 其映射形式为 $\Phi_t: \Phi_s(X_t), X_t \mapsto Y_t$.

SFUDA 的提出主要源自以下现实约束: 1) 隐私保护需求, 例如医学图像、面部数据等敏感源数据通常禁止外部共享; 2) 存储与传输代价, 大规模源数据 (如 ImageNet) 在跨域传输中存在较高成本; 3) 计算负担, 超大数据集上的再训练难以满足实时部署

的要求. 由此, SFUDA 需面临以下挑战:

- 1) 难以直接估计域偏移: 在缺少源数据的情况下, 无法显式度量 P_s 与 P_t 之间的差异;
- 2) 伪标签噪声问题: 目标域预测结果存在不确定性, 需要有效的抑噪与校准策略;
- 3) 可访信息受限: 尤其在黑盒场景下, 仅能依赖预测分布或标签, 难以在参数层面进行对齐.

针对上述挑战, 现有研究提出了多种思路.

4.1.1 白盒 SFUDA

在白盒场景下, 典型方法主要包括两类:

1) 基于数据生成的方式. 该类方法通过重建或近似源域来间接利用传统 DA 技术. 例如: Hou 等^[116] 利用生成图像的批次归一化 (batch normalization, BN) 统计量与源模型中存储的特征进行匹配, 实现风格迁移; Hong 等^[117] 通过风格补偿转换架构, 结合 BN 统计量和目标伪标签生成类源图像. 此外, 部分研究尝试直接从目标域样本中筛选构造“代理源数据”; Tian 等^[118] 提出基于样本传输规则的代理构造策略, 使伪源数据与目标伪标签交替迭代, 从而形成近似源域并提升标签可信度; Ding 等^[119] 基于原型相似性测度, 构建类别平衡的代理源域, 并引入域内与域间混合正则化以缓解噪声影响; Kurmi 等^[120] 更进一步, 利用 GAN 生成器直接模拟源数据, 实现跨域知识迁移.

2) 基于自监督与结构正则化的方式. 该类方法侧重在目标域数据上微调源模型, 而非重建源数据. Yu 等^[121] 结合风格与结构正则化及物理先验约束, 实现教师-学生知识迁移; Fan 等^[122] 提出可学习的混合因子调制 BN 统计, 从而自适应控制各域贡献; Xia 等^[123] 基于目标实例相似性划分设计对比学习模块, 提升类内紧凑性并缩小跨域差异; Li 等^[124] 通过自熵量化不确定性并设计自熵下降机制, 有效选择稳健伪标签; Yang 等^[125] 观察到目标数据天然可形成类簇结构, 并基于邻居关系估计目标样本亲密度, 从而提升适配效果; 黄超等^[126] 通过量化源知识泛化

表4 域适应不同变体对比

变体	源数据集	源数据可访问	目标数据集(无标签)	目标域可访问	是否存在时间关系
无源域适应 ^[111]	\mathcal{D}^s	No	\mathcal{D}^t	Yes	No
多源域适应 ^[112]	$\mathcal{D}_s^k, k = 1, 2, \dots, K$	Yes	\mathcal{D}^t	Yes	No
多目标域适应 ^[46]	\mathcal{D}_s	Yes	$\mathcal{D}_t^m, m = 1, \dots, M$	Yes	No
域泛化 ^[21]	$\mathcal{D}_s^k, k = 1, 2, \dots, K$	Yes	\mathcal{D}^t	No	No
时序域适应 ^[113]	\mathcal{D}_1	Yes	$\mathcal{D}_2 \rightarrow \mathcal{D}_3 \rightarrow \mathcal{D}_4 \rightarrow \dots$	Yes	目标域具有先后顺序
时序域泛化 ^[114]	$\mathcal{D}_1 \rightarrow \mathcal{D}_2 \rightarrow \mathcal{D}_3 \rightarrow \mathcal{D}_4$	Yes	$\mathcal{D}_5 \rightarrow \mathcal{D}_6 \rightarrow \dots$	No	源域、目标域有先后顺序
连续时间域泛化 ^[115]	$\mathcal{D}(t_1) \rightarrow \mathcal{D}(t_2) \rightarrow \mathcal{D}(t_3) \rightarrow \mathcal{D}(t_4)$	Yes	$\mathcal{D}(t_5) \rightarrow \mathcal{D}(t_6) \rightarrow \mathcal{D}_T$	No	域索引为连续时间变量, $t_1 < t_2 < t_3 < t_4 < t_5 < t_6 < \dots < T$

不确定性与目标域隐含信息不确定性,将样本划分为可靠/不可靠两类,分别采用自监督原型更新和对比学习策略。

4.1.2 黑盒 SFUDA

黑盒场景下,研究更侧重于构建教师-学生框架或生成式比对策略:

1) 基于知识蒸馏与伪标签校正. Liang 等^[127]提出自蒸馏框架,通过记忆库存储目标样本预测,使源模型作为教师、目标模型作为学生,保持输出一致性; Zhang 等^[128]通过噪声率估计策略,在训练早期保留更多伪标签,随后逐步剔除高噪声样本,以缓解伪标签偏差。

2) 基于生成模型的跨域分布比对. Yeh 等^[129]通过最大化变分推理下界,实现预测标签诱导先验分布与目标后验分布对齐; Yang 等^[130]进一步提出最小化预测误差上界的策略,从生成与推理双路径中实现跨域适配,有效提升模型在目标域的鲁棒性。

4.2 多域适应

在实际应用场景中,模型往往需要同时处理多个域之间的分布差异,这催生了多域适应 (multi-domain adaptation, MDA) 的研究. 根据训练与测试数据的可用性,MDA 可进一步分为多源域适应 (multi-source domain adaptation, MSDA) 与多目标域适应 (multi-target domain adaptation, MTDA)。

4.2.1 多源域适应

在 MSDA 中,给定 K 个带标签的源域数据集 $D_s^k = (x_i^k, y_i^k)_{i=1}^{n_k}, k = 1, 2, \dots, K$, 目标域数据集 $D_t = \{x_j^t\}_{j=1}^{n_t}$ 仅包含未标注样本. 由于不同源域之间及源-目标域之间均存在分布差异,学习一个在目标域上具有较强泛化能力的分类器 $f: \mathcal{X} \rightarrow \mathcal{Y}$ 成为研究核心。

现有 MSDA 方法主要分为 3 类:

1) 共享域不变特征学习. Zhao 等^[131]提出对抗式 MSDA 方法,通过域判别器实现跨源与目标域的特征对齐,从而学习共享域不变表示; Peng 等^[132]进一步对齐源-目标域特征分布的一阶与二阶统计量,并通过动态加权机制使与目标域更相近的源域在训练中获得更高权重,从而降低负迁移风险; 李晨昀等^[76]提出一种基于数据扩充的共享域不变特征学习策略,通过生成式增广目标数据、多源共享特征提取与局部最大均值差异子域对齐,在无需源数据的前提下联合学习域不变表示。

2) 加权融合策略. Xu 等^[133]提出多路对抗学习框架,计算各源域对目标样本的混淆度权重,并加权

融合多源分类器输出,再通过伪标签迭代更新特征与分类模块; 史玉皓等^[60]提出一种基于流形结构的多源自适应加权融合策略,通过可迁移性筛选、均衡分布适配与流形正则化约束,对多源分类器进行自适应加权集成,实现单源信息最大化与多源知识协同; Tian 等^[134]为每个源模型分配“可靠度权重”,并结合互信息最大化损失实现模型间的互监督,通过动态替换高置信伪标签来融合多模型的互补知识。

3) 模型聚合方法. Mancini 等^[135]提出基于图的自适应模型聚合方法,通过图结构保持各源域独立信息,同时实现通用特征的有效整合; D’Innocente 等^[136]设计了域特定聚合模块,在融合共享知识的同时保留源域差异性,进一步提升目标域的适应性能。

4.2.2 多目标域适应

与 MSDA 相对,MTDA 设定如下:给定单一有标签源域 D_s , 以及 M 个无标签目标域 $X_t^m (m = 1, 2, \dots, M)$, 各目标域分布不同,目标是在所有目标域上实现同时有效的模型适应与泛化。

现有 MTDA 方法可大致归纳为以下 3 类:

1) 统一表征学习. Gholami 等^[137]提出信息论框架,在源域与多个目标域之间学习共享潜在空间,同时保留目标域特有特征,通过共享-私有解耦实现多目标域适应; Yao 等^[138]结合联邦学习框架,利用中心源域与分布式目标域的协同对齐,兼顾通信与计算效率,并有效应对隐私约束。

2) 目标域专属适应. Sun 等^[139]提出无监督域分类方法,将单目标域适应推广至多目标场景,并构建天气不变检测框架,实现跨晴天、雨天、雾天与夜间的鲁棒检测; Lu 等^[140]针对每个源-目标对进行多重特征与分类器对齐,并结合风格迁移增强目标域数据,从而实现多源多目标联合适应; Chang 等^[141]利用域特定批归一化 (BN) 层策略,使源域与目标域共享网络参数但独立 BN 层,通过伪标签预训练与多任务优化提升跨目标适应性能。

3) 跨目标知识迁移. Isobe 等^[142]提出协同学习框架,先为每个源-目标对训练专家模型,再通过目标域间一致性正则化进行协作,并利用学生模型融合专家知识,提升多目标场景下的语义分割性能; Nguyen-Meidine 等^[143]基于多教师知识蒸馏,逐步将各目标域专家知识迁移至共享学生模型,并通过交替蒸馏保持目标域特异性,实现高效 MTDA; 马良玉等^[144]提出一种基于混合专家-多目标域对抗网络的跨目标知识迁移策略,通过动态加权专家输出并为每个目标域独立设置判别器,联合梯度反转对抗与 MMD 提取域不变特征,实现多工况同步精准迁移。

4.3 域泛化

域泛化 (domain generalization, DG) 的目标是在多个源域上训练模型, 使其能够在训练过程中从未接触过的分布中仍保持较高的预测性能^[22]. 与 DA 不同, DG 在训练阶段无法访问任何目标域数据, 因此设定更为严格. 形式化地, 给定 K 个有标签源域 D_s^k , 测试域 D^{test} 与所有 D_s^k 分布不同, 目标是学习 h 使其在未见域 D^{test} 的风险最小. 有

$$h^* = \arg \min_h \mathbb{E}_{(x,y) \sim S_{\text{test}}} [\ell(h(x), y)], \quad (45)$$

其中 $\ell(\cdot, \cdot)$ 为损失函数.

现有 DG 方法大致可分为 3 类: 基于数据操作的方法、基于表示学习的方法以及基于学习策略的方法:

1) 基于数据操作的方法. 该类方法通过数据增强或数据生成扩大域间差异覆盖范围, 从而提升模型的鲁棒性和泛化能力. 例如: Prakash 等^[145] 在随机放置对象生成数据时引入场景结构信息, 使神经网络在目标检测中能够利用上下文; Peng 等^[146] 提出在功能增强的基础上同时增强标签以提高样本多样性; Shankar 等^[147] 利用贝叶斯网络建模标签、域与输入之间的依赖关系, 提出 CrossGrad 策略, 在保持类别语义的前提下, 沿域变化方向对输入进行扰动; Qiao 等^[148] 基于对抗性训练与瓦瑟斯坦自动编码器 (Wasserstein auto-encoder, WAE)^[149], 生成既保持语义又具有挑战性的“虚拟样本”, 以提升模型在跨域测试中的表现; 童煜钧等^[150] 提出隐空间扩散增广域泛化方法, 借助分类器引导的扩散模型在隐空间条件下生成多样化源特征, 以高效采样策略快速扩充特征分布, 提升模型在不可见目标域的泛化性能.

2) 基于表示学习的方法. 该类方法旨在学习跨域不变的特征表示, 或将域共享与域特定因素解耦, 以减小分布偏移对预测性能的影响. 近年来, Blanchard 等^[151] 首次将核方法应用在域泛化领域, 以及后续的正定核学习与传递分量分析 (transfer component analysis, TCA); Li 等^[152] 提出条件不变对抗网络 (conditional invariant adversarial network, CIAN), 通过对抗学习得到域不变表示; Ding 等^[153] 设计域特定网络与共享网络相结合的解耦框架, 并通过低秩重构实现结构化对齐; Liu 等^[154] 从因果视角出发, 提出基于因果不变性的单源域泛化方法, 在理论上保证了语义可识别性与泛化误差有界; 谢刚等^[155] 提出两阶段域泛化框架, 先以大尺寸卷积提取多源初级故障特征, 再用动静双态时空图卷积网络融合时变动态与全局时空信息, 将多源数据映射至

统一判别空间, 显著提升了轴承故障诊断的跨工况泛化精度.

3) 基于学习策略的方法. 该类方法通过元学习、集成学习、梯度约束和自监督等训练范式提升模型泛化能力. Mancini 等^[156] 提出基于领域预测器的可学习加权集成方法; Snell 等^[157] 提出模型不可知元学习, 通过少量梯度更新实现对新任务的快速泛化; Li 等^[158] 将其扩展至 DG 场景, 利用双层优化约束模拟源/测试域间差异, 从而提升跨域鲁棒性. 此外, Huang 等^[159] 提出自挑战训练 (self-challenging), 通过迭代舍弃训练中最显著特征迫使模型激活潜在的判别信息, 以提升模型对困难样本的适应能力. 另外, 分布鲁棒优化 (distributionally robust optimization, DRO)^[160] 也被引入 DG 场景, 旨在最坏分布下仍保持较好性能. Jing 等^[161] 进一步提出在过参数化神经网络中结合分组 DRO 与强正则化 (如 L_2 或早停), 显著改善了最差子群的泛化性能.

4.4 时序域问题

近年来, 随着实际应用场景的复杂化与动态化, 研究者开始关注时序域问题. 与传统假设域分布静态或有限离散の設定不同, 连续域问题强调目标域分布随时间或环境条件不断演化, 更加贴近真实应用需求, 因此具有重要的发展潜力. 该类问题主要包括时序域适应 (temporal domain adaptation, TDA) 与时序域泛化 (temporal domain generalization, TDG) 两个方向.

4.4.1 时序域适应

时序域适应又称演化域适应, 旨在解决目标域分布随时间连续变化时的自适应问题. 形式化定义为: 给定带标签的源域数据集 $\mathcal{D}_s = (x_i^s, y_i^s)_{i=1}^{N_s}$, 目标域数据 $\mathcal{D}_t = \{x_i^t\}_{i=1}^{N_t}$; $t \in \mathbb{R}^+$ 随时间演化, 其分布不断漂移, 任务是在此动态场景下保持模型的持续适应能力. 现有 TDA 方法可大致分为以下几类:

1) 基于中间域的方法. Kumar 等^[162] 提出在中间域中进行自训练, 以逐步缓解大规模分布漂移; Chen 等^[163] 提出“由粗到细”的逐步适应策略, 通过递进式调整提升目标域适应性能.

2) 基于域流形的方法. Hoffman 等^[164] 利用线性变换对域流形进行连续建模; Li 等^[165] 将源域分解为多个子域, 并结合低阶支持向量机的加权预测实现连续迁移.

3) 基于对抗的方法. Wang 等^[166] 改进对抗式自适应框架, 将判别器扩展为回归域索引, 从而实现高效的域间距离度量, 但该方法依赖于域索引的可获

取性.

4) 基于元学习的方法. Liu 等^[167]引入元学习程序,使适配器能够在新域中快速调整,并保留先学到的知识. Mancini 等^[135]进一步提出利用目标域元数据作为额外监督,以减少对目标域样本的依赖.

值得注意的是,部分研究开始将 TDA 扩展至持续域泛化,即完全不依赖目标域样本的设定.这一方向更符合现实应用需求,但也更加具有挑战性.

4.4.2 时序域泛化

在动态环境中,目标域分布的统计特性随时间不断变化,这推动了时间域泛化(temporal domain generalization, TDG)的研究. TDG 假设域漂移在时间维度上存在相关性,通过将域建模为序列而非独立实体,提升模型在时变场景中的外推能力.其形式化定义为:给定顺序到达的源域序列 $S = D_1, D_2, \dots, D_T, D_t = (x_{t,i}, y_{t,i}), i = 1^{n_t}$, 目标是泛化至未来未见域 $T = D_{T+1}, D_{T+2}, \dots, D_{T+M}$, 并满足连续性约束 $0 \leq \text{dis}(D_t, D_{t+1}) \leq \varepsilon$.

现有研究多集中于离散时间域设定. Bai 等^[168]提出 DRAIN 框架,在贝叶斯建模下结合递归图生成网络,显式刻画随时间变化的数据分布漂移与模型动态,实现跨时间段的域泛化,并提供不确定性与泛化误差的理论保证; Qin 等^[114]在潜在空间中建模连续结构,区分并表征协变量漂移与概念漂移,从而在非平稳环境下实现演化域泛化,提升模型在持续变化场景中的跨域适应能力; Zeng 等^[169]利用 Koopman 神经算子在时间演化的域间建立线性转移关系,通过对齐条件分布降低泛化界,从而解决时序域泛化问题并提升跨时间域的适应能力,然而,在实际应用中,时间往往是连续且采样不规则的.

Bai 等^[115]首次提出连续时间域泛化框架:训练域来自任意时间点 $D(t_1), D(t_2), \dots, D(t_T), D(t) = (x_i^{(t)}, y_i^{(t)})_{i=1}^{N(t)}, t \in \mathbb{R}^+$, 目标是学习预测函数 $g(\cdot, \theta(t))$, 其参数随时间连续演化并可外推至未见时间点 $s \notin t_1, \dots, t_T$. 该方法利用 Koopman 算子理论将非线性动态系统线性化,对模型参数的演化过程进行建模,实现任意时刻的预测,从而有效解决连续时间场景下的域泛化问题.

5 域适应的典型应用

域适应技术的核心任务在于解决源域与目标域之间的分布差异问题,通过跨域知识迁移显著提升模型在目标场景下的泛化与适应能力.目前,域自适应方法已广泛应用于许多场景,如计算机视觉、自然语言处理、工业时序.

5.1 计算机视觉

域适应技术通过迁移已有知识来解决目标领域数据不足或分布差异的问题.在图像处理中,通过域适应实现快速精准的图像分类与目标检测. Chen 等^[170]提出一种在线域自适应 Sim2Real 解决在强化学习中的依赖大量交互数据的问题,实现具有视觉触觉感知的纵策略转移; Zhang 等^[171]通过引入一个端到端的强化框架,采用 PPO 网络及 Actor-Critic 共同激励,实现从基于视觉角度解决从不可把握的姿势中推动和抓取物体; Ding 等^[172]提出一种面向跨场景高光谱图像分类的无监督域适应方法,通过“一致性感知定制学习”策略,精细化处理不同目标样本的域偏移,实现从源域到目标域的高效知识迁移; Wu 等^[173]提出一种面向图像分类的顺序多源域适应方法,通过源域排序、局部对齐和类不平衡加权策略,有效提升跨域知识迁移的稳定性与准确性,进行图像分类; Huang 等^[174]提出了一种面向旋转目标的无监督跨域检测方法,用于解决从光学图像到合成孔径雷达(synthetic aperture radar, SAR)图像的面向对象检测; Zhao 等^[175]同样针对目标检测提出了一种融合全局-局部对比学习与协同训练的跨域目标检测方法,能够有效对齐源域与目标域特征,在无标注目标域上显著提升检测精度; 陈龙等^[176]通过利用掩膜自编码器进行图像扩充以减缓样本稀缺,设计多尺度注意力模块以突出类别相关特征,提出领域自适应模块并引入间隔损失函数以优化嵌入函数表征能力.

此外,在医学影像分析中,域适应技术能有效克服不同设备、医院之间的数据偏差,让基于少量标注数据训练的诊断模型在不同医疗机构中实现精准迁移,从而突破领域壁垒,推动人工智能在关键领域的规模化落地. Wu 等^[177]通过跨域数据增强生成双域训练集,结合双域伪标签生成器和噪声鲁棒学习策略,提升 3D 医学图像在目标域的分割精度; Xie 等^[178]提出了一种新型无监督域适应方法,通过解耦学习和自训练策略,提升跨模态医学图像分割的性能.

5.2 工业时序

在工业时序分析任务中,传统模型普遍面临“数据分布偏移”与“标注样本稀缺”的双重限制,领域自适应技术的提出为解决上述问题提供了有效途径.在实际工业生产中,设备工况切换、代际更替及工艺参数漂移等因素,导致源域与目标域的时序数据分布产生显著偏差,而传统时序模型对这种分布失配的鲁棒性较差,进而导致其在实际应用中的性能严

重下滑.例如:Wang等^[179]提出基于双偏神经网络的知识转移与强化方法,设计了领域无偏估计知识迁移子网,无偏估计目标故障的可迁移性,有效解决偏见诊断问题;Xie等^[180]通过深度域适应网络实现跨域条件下的机械故障诊断;Li等^[181]提出了一种多尺度注意力卷积子域自适应网络,用于跨域条件下的机械故障诊断;Shao等^[182]将振动信号经短时傅里叶变换为时频图像,以预训练 ResNet-50 为特征提取器,结合 MK-MMD 与域混淆函数提取域不变特征实现轴承跨域故障诊断;Su等^[183]构建目标域倾斜分类器捕捉目标域知识以克服偏向学习,设计自适应阈值优化故障区分边界,实现对旋转机械进行有效的故障诊断;Zhu等^[184]提出多对抗学习域自适应模型,借迁移权重条件对抗网络对齐特征-类别联合分布,用加权对抗学习网络实现选择性域分布对齐,通过域划分对抗网络识别未知故障,有效完成开放集故障诊断任务;Xu等^[185]通过域适应实现对设备使用寿命的预测和健康监测;Ye等^[186]针对不同工况下电池健康度下降监测问题,提出了一种基于迁移学习的新型方法多源域自适应网络;Tang等^[187]为解决滚动轴承剩余寿命预测精度低的问题,提出了多源域子域自适应网络;Qu等^[188]提出了基于扩展时间序列的域自适应算法以提升交通流短期负载预测效率与精度.

5.3 推荐系统

传统推荐系统无论是协同过滤还是内容推荐,本质上都是“在同一数据池(目标域)内挖掘规律”,一旦目标域的样本量不足或质量不高,推荐的精准度便会骤降.而领域自适应技术跳出了这一局限,通过建立源域与目标域之间的关联,将源域的训练经验、特征规律迁移到目标域,使推荐模型在数据有限的情况下依然能输出可靠结果.Wan等^[189]提出了一种基于知识追溯和强化学习的路径推荐算法,通过集成学习行为模块增强动态键值记忆网络,用于跟踪知识状态;Lin等^[190]对强化学习中的4种典型推荐场景进行概述、总结与比较,并进一步分析了在推荐系统中的局限性及未来发展趋势;Prasad等^[191]提出了融合图神经网络与域自适应的系统,提升简历筛选与职位推荐效率;Chen等^[192]提出了自适应生成门控图模型,以解决电商微视频推荐中用户交互稀疏、现有知识图谱增强图神经网络未考虑多域用户行为与序列依赖的问题,从而有效提升推荐准确率与点击率;Kanagawa等^[193]提出了一种基于内容的跨域推荐方法,将推荐作为一项极端分类任务,并将

问题视为无监督域适应实例;Nanthin等^[194]提出了一种基于生成式和判别式对抗网络的跨域推荐系统方法,通过核基迁移建模,考虑领域特异性以处理重叠实体的特征空间,采用迁移计算处理域间重叠与非重叠实体的相关性,以无监督对抗学习方式学习用户、物品及用户-物品交互的潜在表示,实现跨域知识迁移,从而缓解数据稀疏和数据不平衡问题,提升推荐性能.

6 展望与挑战

随着域适应研究的深入发展,虽然已有不少成果,但在效率、理论、多场景应用等方面仍有诸多挑战.以下是未来值得重点探索的方向.

6.1 效率与可扩展性

随着模型规模和训练任务的增大,域适应的训练和推理开销显著上升,未来需要设计轻量化、高效的网络,并结合知识蒸馏或模型压缩技术,在资源受限或实时场景中保持高性能.例如:研究提出通过自适应压缩、云边端分割和领域自适应来降低开销并提高效率^[195];实时/在线域适应也成为关键需求,近期工作提出的“Anytime Domain Adaptation”框架^[196]能够动态调整网络深度、宽度和分辨率,实现效率与准确率的平衡.因此,未来模型的微调阶段不仅应具备在少量标注或弱监督下快速适应目标域的能力,还需能够在动态环境下保持持续适应性,及时响应分布漂移、噪声或设备/场景差异带来的挑战.

6.2 理论分析与统一框架

尽管域适应已积累了丰富的实证成果,但理论支撑仍显不足.当前对于域偏差、任务差异、类别空间差异等关键指标的定义和估计尚不统一,缺乏在闭集、开集、通用域以及标签空间部分或不重叠等情形下可通用的分析框架.近年来,一些工作通过 f -散度提出新的不一致性度量并建立了目标误差界与样本复杂度界限^[197],也有研究在部分域适应和半监督域适应下推导了泛化误差的理论保证^[198],以及在开集和异构域设定中引入学习界限^[199],甚至从对抗鲁棒性角度提出基于 Rademacher 复杂度的目标误差界^[200].然而,这些结果多依赖强假设,难以全面覆盖动态或在线环境,未来研究亟需统一指标体系、拓展性能边界推导,并在分布持续演化条件下提供稳定性与收敛性的理论保证.

6.3 领域自适应与元学习结合

元学习(meta-learning)通过“学会学习”的范式,被广泛用于提升模型在少样本新域的适应能力^[158,201].传统元学习假设所有任务服从同一元分布,

但在跨度极大或异构特征的迁移场景中(如从医疗图像迁移到工业缺陷检测),该假设往往不成立^[202],导致元知识泛化失败.此外,传统元训练的高昂成本限制了其实际应用.未来应结合大模型,将研究中心从传统的参数初始化优化,转向上下文学习与提示工程(prompt learning).即如何将源域知识编码为通用的“域提示”,使冻结的大模型仅需少量目标域样本即可激活跨域推理能力,这是极具潜力的方向.

6.4 与强化学习的结合

尽管当前领域适应在缩小域间分布差异上已取得诸多进展,但由于对负迁移的量化标准、分布差异层级化建模缺乏统一认知,尚未形成覆盖多模态、动态环境的通用分析框架.一方面,现有方法多聚焦全局分布差异的粗粒度对齐,难以在“分布差异残留”与“过度对齐”之间实现动态平衡;另一方面,对领域分布的局部结构差异建模不足,未被捕捉的差异会直接影响模型在复杂场景下判别性能.在跨模态、多域迁移场景中,现有分布对齐策略缺乏针对性,不仅难以适配复杂分布差异,还易放大负迁移风险.诸多学者针对此类问题进行了进一步的研究:Chen等^[203]提出一种领域对抗强化学习(DARL)方法,通过减少领域偏移选择源实例,避免负迁移,同时学习不同领域之间的可转移特征;Zhang等^[204]提出一种特征选择方法,结合强化学习,学习选择两个域中最相关特征;Zacifi等^[205]通过引入本体对齐深度强化自适应学习(DRAL-OA),解决当前本体对齐模型的局限,完善对齐策略.然而,现有方法仍面临以下问题:1)目标域样本稀缺或交互成本高时,样本效率低、收敛不稳定;2)多聚焦视觉任务,忽视了复杂场景,如类别空间不一致和开放类别;3)当目标域与源域策略差异较大时,策略难以迁移.因此,尽管RL为域适应提供了新思路,但仍需解决样本效率、策略迁移和复杂域差异等挑战,未来研究潜力巨大.

6.5 对未知类别的深度挖掘

在现实任务中,目标域往往包含源域未覆盖的新类别,而现有大多数开集、通用域适应工作仅将这些未知样本统一视为一个“未知类”,只做“已知”vs“未知”的粗分类,缺乏对未知类别内部结构或未知子类别数量的识别.已有少数工作对“未知类细分”进行了探索,例如:Wen等^[206]通过Cluster-then-Match策略以在域漂移情形下同时识别已见类与新类别,并尝试发现对未知进行精细分类(未知-1,未知-2,...);Qu等^[111]在源无标注通用域适应中采用全局-局部聚类与对比亲合度学习来分离已知类与未知类,并在某些情形下对未知类内部做一定聚类

以提高类别识别效果.然而,这些工作大多依赖于选择最佳的K-means聚类数目(即迭代不同K值并用Silhouette^[111]或类似指标评估)来确定未知子类别的数量,这种方法既缺乏理论支撑,也计算耗时,且在高维特征空间中易受噪声影响与维度诅咒问题困扰.

未来的研究不仅应判断目标样本是否属于未知类别,还需估计未知子类别的数量并进行内部划分,以便更精细地区分不同类型的未知样本,支持增量学习.在收集少量标注数据后,逐步将其纳入已知类别集^[207-208].这在医学诊断、异常检测和自动驾驶等高风险场景中尤为重要,因为误将未知类归为已知类可能带来严重后果,而子类别的识别有助于触发安全机制,提高模型的鲁棒性与泛化能力.

6.6 跨模态域适应

在现实任务中,数据通常来自多个模态(如图像-文本、图像-点云、音频-视频等),源域与目标域的模态间可能存在显著差异,因此需要将域适应扩展至“模态迁移+域迁移”的场景.目前已有研究尝试通过模态间知识交互和多尺度融合等方法,缓解模态间与域间差异,如在动作识别^[209]和图像与点云间的迁移^[210]中取得进展.然而,现有研究多集中于特定模态或单一场景,且缺乏对异构模态(如文本-视觉、音频-传感器数据)的系统探索.未来研究应着重于设计统一的模态转移-域转移框架,发展自动化模态对齐与蒸馏机制,并探索开放类别情境下的跨模态迁移,特别是在工业推荐、医疗诊断等^[211]实际应用中的验证.

6.7 隐私保护下的域适应

在医疗诊断、跨机构学习等场景中,数据包含敏感信息且受隐私法规约束,因此,域适应需要保护数据隐私,推动“隐私保护+域适应”成为新需求.目前,已有研究探索隐私保护下的域适应.例如:Xia等^[212]提出源无访问的域适应方案;Miresghallah等^[213]通过差分隐私保护用户数据.联邦学习与域适应结合也在尝试多方协作中的隐私保护^[214],但仍面临挑战:1)隐私保护机制可能降低性能;2)现有方法聚焦单一任务,缺乏对复杂场景的研究;3)缺乏隐私保护框架下的机制适配与理论保障.未来应开发兼顾隐私与适应效能的算法,并扩展至更复杂的迁移情景.

6.8 连续域泛化

随着数据分布的不断变化,传统域适应方法在多个源域与目标域之间的泛化能力面临挑战,连续域泛化旨在解决数据分布随潜在因素(如时间、地

理、经济等)变化而持续演化的问题。目前,研究主要采用基于几何和代数结构的方法,如神经 Lie 传输算子 (NeuralLTO)^[215], 实现模型在连续域中的平滑过渡, 捕捉领域间的潜在结构变化。然而, 现有方法面临以下挑战: 1) 如何建模域间的无序变化; 2) 稀疏或不完整数据下的泛化能力不足; 3) 缺乏对复杂非线性变化的理论支持。未来研究应着重提升模型的泛化能力、处理稀疏数据的鲁棒性, 并探索普适的连续域泛化框架。

7 结 语

无监督域适应是机器学习中普遍存在的难题。由于不同任务场景下源域与目标域在分布、条件概率以及类别空间上均可能存在显著差异, 直接迁移往往导致模型在目标域性能退化。因此, 域适应不仅需要特征层面实现分布对齐, 还需要在类别层面解决共享类迁移、源域特有类抑制与目标域未知类识别等挑战。鉴于此, 研究人员提出了大量基于统计特征、几何结构、对抗学习以及跨域类别匹配的方法, 以缓解分布漂移与类别空间不一致带来的问题。本文从域类别差异视角系统梳理了近年来的域适应研究, 包括闭集、部分集、开集与通用设定下的理论与方法, 总结了分布对齐与类别匹配两条核心技术路径, 并回顾了多源、无源、连续与时序等变体问题, 以及在计算机视觉、自然语言处理、工业时序和多模态领域的应用。展望未来, 域适应仍需效率与可扩展性方面探索轻量化模型与实时适应机制, 在理论层面建立统一的分析框架并完善误差界限与复杂度保证, 同时对未知类别的深度挖掘与子类识别也亟待突破, 以支持动态环境中的增量学习和安全应用。

参考文献 (References)

- [1] 龙明盛. 迁移学习问题与方法研究[D]. 北京: 清华大学, 2014.
(Long M S. Research on problems and methods of transfer learning[D]. Beijing: Tsinghua University, 2014.)
- [2] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [3] 范苍宁, 刘鹏, 肖婷, 等. 深度域适应综述: 一般情况与复杂情况[J]. *自动化学报*, 2021, 47(3): 515-548.
(Fan C N, Liu P, Xiao T, et al. Overview of adaptation in depth domain: General situation and complex situation[J]. *Acta Automatica Sinica*, 2021, 47(3): 515-548.)
- [4] 李晶晶, 孟利超, 张可, 等. 领域自适应研究综述[J]. *计算机工程*, 2021, 47(6): 1-13.
(Li J J, Meng L C, Zhang K, et al. Review of studies on domain adaptation[J]. *Computer Engineering*, 2021, 47(6): 1-13.)
- [5] Mansour Y, Mohri M, Rostamizadeh A. Domain adaptation: Learning bounds and algorithms[J/OL]. 2009, arXiv: 0902.3430.
- [6] Cao Z J, Ma L J, Long M S, et al. Partial adversarial domain adaptation[C]. Proceedings of the European Conference on Computer Vision. Munich, 2018: 135-150.
- [7] Zhong L, Fang Z, Liu F, et al. Bridging the theoretical bound and deep algorithms for open set domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(8): 3859-3873.
- [8] You K C, Long M S, Cao Z J, et al. Universal domain adaptation[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2019: 2720-2729.
- [9] Ben-David S, Blitzer J, Crammer K, et al. Analysis of representations for domain adaptation[C]. Advances in Neural Information Processing Systems. Cambridge: The MIT Press, 2007: 137-144.
- [10] Tzeng E, Hoffman J, Saenko K, et al. Adversarial discriminative domain adaptation[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 2962-2971.
- [11] Long M S, Cao Z J, Wang J M, et al. Conditional adversarial domain adaptation[J]. Advances in Neural Information Processing Systems, 2018, 31: 1647-1657.
- [12] Busto P P, Gall J. Open set domain adaptation[C]. IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 754-763.
- [13] Xie Z J, Duan P H, Liu W, et al. Uncertainty-aware prototype learning for open-set hyperspectral image classification[C]. 2024 2nd International Conference on Pattern Recognition, Machine Vision and Intelligent Algorithms. Changsha, 2024: 145-148.
- [14] Saito K, Kim D, Sclaroff S, et al. Universal domain adaptation through self supervision[C]. Advances in Neural Information Processing Systems. Vancouver, 2020: 16282-16292.
- [15] Chang W X, Shi Y, Tuan H D, et al. Unified optimal transport framework for universal domain adaptation[J/OL]. 2022, arXiv: 2210.17067.
- [16] Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning[J]. *Journal of Big Data*, 2016, 3(1): 9.
- [17] Zhuang F Z, Qi Z Y, Duan K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2020, 109(1): 43-76.
- [18] Niu S T, Liu Y X, Wang J, et al. A decade survey of transfer learning (2010–2020)[J]. *IEEE Transactions on Artificial Intelligence*, 2020, 1(2): 151-166.
- [19] Kouw W M, Loog M. A review of domain adaptation without target labels[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(3): 766-785.
- [20] Zhao S C, Yue X Y, Zhang S H, et al. A review of

- single-source deep unsupervised visual domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 473-493.
- [21] Ghaffari R, Helfroush M S, Khosravi A, et al. Toward domain adaptation with open-set target data: Review of theory and computer vision applications[J]. *Information Fusion*, 2023, 100: 101912.
- [22] Wang J D, Lan C L, Liu C, et al. Generalizing to unseen domains: A survey on domain generalization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(8): 8052-8072.
- [23] 田青, 储奕, 孙赫阳, 等. 部分域适应研究综述[J]. *软件学报*, 2023, 34(12): 5597-5613.
(Tian Q, Chu Y, Sun H Y, et al. Survey on partial domain adaptation[J]. *Journal of Software*, 2023, 34(12): 5597-5613.)
- [24] Zhu Z D, Lin K X, Jain A K, et al. Transfer learning in deep reinforcement learning: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(11): 13344-13362.
- [25] Fang Y Q, Yap P T, Lin W L, et al. Source-free unsupervised domain adaptation: A survey[J]. *Neural Networks*, 2024, 174: 106230.
- [26] Zhao Z H, Alzubaidi L, Zhang J L, et al. A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations[J]. *Expert Systems with Applications*, 2024, 242: 122807.
- [27] 何秋妍, 邓明华. 通用域适应综述[J]. *计算机研究与发展*, 2024, 61(1): 120-144.
(He Q Y, Deng M H. Survey of universal domain adaptation[J]. *Journal of Computer Research and Development*, 2024, 61(1): 120-144.)
- [28] 孙志国, 肖硕, 吴毅杰, 等. 基于迁移学习和参数优化的干扰效能评估方法[J]. *电子与信息学报*, 2024, 46(6): 2515-2524.
(Sun Z G, Xiao S, Wu Y J, et al. Jamming effectiveness evaluation method based on transfer learning and parameter optimization[J]. *Journal of Electronics & Information Technology*, 2024, 46(6): 2515-2524.)
- [29] 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.
- [30] Zhang C C, Zhao Q J. Attention guided for partial domain adaptation[J]. *Information Sciences*, 2021, 547: 860-869.
- [31] Saito K, Yamamoto S, Ushiku Y, et al. Open set domain adaptation by back propagation[C]. *Proceedings of the European Conference on Computer Vision*. Piscataway: IEEE, 2018: 153-168.
- [32] Liu H, Cao Z J, Long M S, et al. Separate to adapt: Open set domain adaptation via progressive separation[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, 2019: 2927-2936.
- [33] Qian Q, Luo J, Qin Y. Adaptive intermediate class-wise distribution alignment: A universal domain adaptation and generalization method for machine fault diagnosis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(3): 4296-4310.
- [34] Ben-David S, Blitzer J, Crammer K, et al. A theory of learning from different domains[J]. *Machine Learning*, 2010, 79(1): 151-175.
- [35] Li S, Liu C H, Lin Q X, et al. Deep residual correction network for partial domain adaptation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(7): 2329-2344.
- [36] Li W K, Chen S C. Partial domain adaptation without domain alignment[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(7): 8787-8797.
- [37] Fang Z, Lu J, Liu F, et al. Open set domain adaptation: Theoretical bound and algorithm[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(10): 4309-4322.
- [38] 刘晓龙, 王士同. 面向开放集图像分类的模糊域自适应方法[J]. *计算机科学与探索*, 2021, 15(3): 515-523.
(Liu X L, Wang S T. Fuzzy domain adaptive method for open set image classification[J]. *Journal of Frontiers of Computer Science & Technology*, 2021, 15(3): 515-523.)
- [39] Huang J Y, Smola A J, Gretton A, et al. Correcting sample selection bias by unlabeled data[C]. *Advances in Neural Information Processing Systems*. Vancouver, 2006: 601-608.
- [40] Lin C Y, Tsai C H, Lee C P, et al. Large-scale logistic regression and linear support vector machines using spark[C]. *IEEE International Conference on Big Data*. Washington, 2015: 519-528.
- [41] Ren M Y, Zeng W Y, Yang B, et al. Learning to reweight examples for robust deep learning[J/OL]. 2018, arXiv: 1803.09050.
- [42] Wei D D, Han T, Chu F L, et al. Weighted domain adaptation networks for machinery fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2021, 158: 107744.
- [43] Zhang X, Wang J R, Jia S X, et al. Partial domain adaptation method based on class-weighted alignment for fault diagnosis of rotating machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3514414.
- [44] Li Y Q, Dong Y J, Xu M Q, et al. Instance weighting-based partial domain adaptation for intelligent fault diagnosis of rotating machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3517114.
- [45] Li S, Song S J, Huang G. Prediction reweighting for domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(7): 1682-1695.
- [46] Huang L Q, Zhao W B, Liu Y, et al. An evidential multi-target domain adaptation method based on

- weighted fusion for cross-domain pattern classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(10): 14218-14232.
- [47] Shin S, Kang N. Weighted unsupervised domain adaptation considering geometry features and engineering performance of 3D design data[J]. *Expert Systems with Applications*, 2024, 256: 124928.
- [48] Wu K Y, Chen S K, Wu M, et al. Reinforced reweighting for self-supervised partial domain adaptation[J]. *IEEE Transactions on Artificial Intelligence*, 2024, 5(9): 4813-4822.
- [49] Zellinger W, Grubinger T, Lughofer E, et al. Central moment discrepancy (CMD) for domain-invariant representation learning[J/OL]. 2017, arXiv: 1702.08811.
- [50] Long M S, Cao Y, Wang J M, et al. Learning transferable features with deep adaptation networks[J/OL]. 2015, arXiv: 1502.02791.
- [51] 阎高伟, 贺敏, 汤健, 等. 基于最大均值差异多源域迁移学习的湿式球磨机负荷参数软测量[J]. *控制与决策*, 2018, 33(10): 1795-1800.
(Yan G W, He M, Tang J, et al. Soft sensing of load parameters of wet ball mill based on maximum mean difference multi-source domain transfer learning[J]. *Control and Decision*, 2018, 33(10): 1795-1800.)
- [52] 臧绍飞, 程玉虎, 王雪松. 基于最大分布加权均值嵌入的领域适应学习[J]. *控制与决策*, 2016, 31(11): 2083-2089.
(Zang S F, Cheng Y H, Wang X S. Domain adaptive learning based on maximum distribution weighted mean embedding[J]. *Control and Decision*, 2016, 31(11): 2083-2089.)
- [53] Sun B C, Feng J S, Saenko K. Correlation alignment for unsupervised domain adaptation[C]. *Domain Adaptation in Computer Vision Applications*. Cham: Springer, 2017: 153-171.
- [54] Daume III H, Marcu D. Domain adaptation for statistical classifiers[J/OL]. 2011, arXiv: 1109.6341.
- [55] Shu R, Bui H H, Narui H, et al. A DIRT-T approach to unsupervised domain adaptation[J/OL]. 2018, arXiv: 1802.08735.
- [56] Sun B, Feng J, Saenko K. Return of frustratingly easy domain adaptation[C]. *Proceedings of the AAAI Conference on Artificial Intelligence*. Phoenix, 2016: 2058-2065.
- [57] Zhang J, Li W Q, Ogunbona P. Joint geometrical and statistical alignment for visual domain adaptation[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, 2017: 5150-5158.
- [58] Abramov A, Bayer C, Heller C. Keep it simple: Image statistics matching for domain adaptation[J/OL]. 2020, arXiv: 2005.12551.
- [59] Wang C, Mahadevan S. Heterogeneous domain adaptation using manifold alignment[C]. *Proceedings of the 22nd International Joint Conference on Artificial Intelligence*. New York: ACM, 2011: 1541-1546.
- [60] 史玉皓, 田建艳, 刘军军, 等. 基于流形结构的多源自适应迁移学习算法及应用研究[J]. *控制与决策*, 2023, 38(3): 797-804.
(Shi Y H, Tian J Y, Liu J J, et al. Research on multi-domain adaptation-manifold regularization and application[J]. *Control and Decision*, 2023, 38(3): 797-804.)
- [61] 安迪, 王姝, 关展旭, 等. 基于跨域流形正则化特征域适应的浮选工况识别[J]. *控制与决策*, 2023, 38(9): 2597-2605.
(An D, Wang S, Guan Z X, et al. Identification of flotation conditions based on cross-domain manifold regularization feature domain adaptation[J]. *Control and Decision*, 2023, 38(9): 2597-2605.)
- [62] Saenko K, Kulis B, Fritz M, et al. Adapting visual category models to new domains[C]. *Proceedings of the 11th European Conference on Computer Vision*. Berlin, Heidelberg: Springer, 2010: 213-226.
- [63] Tzeng E, Hoffman J, Saenko K, et al. Adversarial discriminative domain adaptation[J/OL]. 2017, arXiv: 1702.05464.
- [64] Shen J, Qu Y R, Zhang W N, et al. Wasserstein distance guided representation learning for domain adaptation[J/OL]. 2017, arXiv: 1707.01217.
- [65] Hu T, Guo Y M, Gu L D, et al. Remaining useful life estimation of bearings under different working conditions via Wasserstein distance-based weighted domain adaptation[J]. *Reliability Engineering & System Safety*, 2022, 224: 108526.
- [66] Lee C Y, Batra T, Baig M H, et al. Sliced Wasserstein discrepancy for unsupervised domain adaptation[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, 2019: 10265-10275.
- [67] Siva K T, Srihari M, Sethupriyan M, et al. Reinforcement learning algorithm implementation for wideband beam tracking[C]. *International Conference on Visual Analytics and Data Visualization*. Tirunelveli, 2025: 1073-1078.
- [68] Zhou F, Liu L, Zhang K P, et al. DeepLink: A deep learning approach for user identity linkage[C]. *IEEE Conference on Computer Communications*. Honolulu, 2018: 1313-1321.
- [69] Shan Z W, Yi X P, Yu H, et al. Revisiting topological interference management: A learning-to-code on graphs perspective[J]. *IEEE Transactions on Communications*, 2025, 73(12): 14275-14288.
- [70] Damodaran B B, Kellenberger B, Flamary R, et al. DeepJDOT: Deep joint distribution optimal transport for unsupervised domain adaptation[C]. *Proceedings of the European Conference on Computer Vision*. Cham: Springer, 2018: 467-483.
- [71] He H, Queen O, Koker T, et al. Domain adaptation for time series under feature and label shifts[C]. *Proceedings of the 40th International Conference on*

- Machine Learning. New York: ACM, 2023: 12746-12774.
- [72] Courty N, Flamary R, Tuia D, et al. Optimal transport for domain adaptation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(9): 1853-1865.
- [73] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[J/OL]. 2017, arXiv: 1703.10593.
- [74] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J/OL]. 2015, arXiv: 1505.07818.
- [75] Long M S, Cao Z J, Wang J M, et al. Conditional adversarial domain adaptation[J/OL]. 2017, arXiv: 1705.10667.
- [76] 李晨昀, 景旭文, 李炳强, 等. 基于深度多源子域适应网络的滚动轴承跨域故障诊断[J]. *控制与决策*, 2024, 39(3): 877-884.
(Li C Y, Jing X W, Li B Q, et al. Cross-domain fault diagnosis of rolling bearings based on deep multi-source sub-domain adaptation networks[J]. *Control and Decision*, 2024, 39(3): 877-884.)
- [77] Chen L, Chen H A, Wei Z X, et al. Reusing the task-specific classifier as a discriminator: Discriminator-free adversarial domain adaptation[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, 2022: 7171-7180.
- [78] Huang Y, Peng J T, Zhang G W, et al. Adversarial domain adaptation network with calibrated prototype and dynamic instance convolution for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5514613.
- [79] Yang J F, Zhang N, He Y L, et al. Novel dual-network autoencoder based adversarial domain adaptation with Wasserstein divergence for fault diagnosis of unlabeled data[J]. *Expert Systems with Applications*, 2024, 238: 122393.
- [80] Yang J L, Dvornik N C, Zhang F, et al. Unsupervised domain adaptation via disentangled representations: Application to cross-modality liver segmentation[J]. *Medical Image Computing and Computer-Assisted Intervention*, 2019, 11765: 255-263.
- [81] Ge Y X, Chen D P, Li H S. Mutual mean-teaching: Pseudo label refinery for unsupervised domain adaptation on person re-identification[J/OL]. 2020, arXiv: 2001.01526.
- [82] Shi J M, Zhang Y C, Yin X B, et al. Dual pseudo-labels interactive self-training for semi-supervised visible-infrared person re-identification[C]. *IEEE/CVF International Conference on Computer Vision*. Paris, 2024: 11184-11194.
- [83] Pan Y W, Yao T, Li Y H, et al. Transferrable prototypical networks for unsupervised domain adaptation[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, 2019: 2239-2247.
- [84] Du Y J, Zhou D Y, Xie Y, et al. Prototype-guided feature learning for unsupervised domain adaptation[J]. *Pattern Recognition*, 2023, 135: 109154.
- [85] Huang M, Xie Z F, Sun B, et al. Multi-source unsupervised domain adaptation with prototype aggregation[J]. *Mathematics*, 2025, 13(4): 579.
- [86] Zou Y, Yu Z D, Vijaya Kumar B V K, et al. Unsupervised domain adaptation for semantic segmentation via class-balanced self-training[C]. *Proceedings of the European Conference on Computer Vision*. Cham: Springer, 2018: 297-313.
- [87] Shin I, Woo S, Pan F, et al. Two-phase pseudo label densification for self-training based domain adaptation[C]. *Proceedings of the European Conference on Computer Vision*. Cham: Springer, 2020: 532-548.
- [88] Marsden R A, Bartler A, Döbler M, et al. Contrastive learning and self-training for unsupervised domain adaptation in semantic segmentation[C]. *International Joint Conference on Neural Networks*. Padua, 2022: 1-8.
- [89] Xu Y M, Klabjan D. Open set domain adaptation by extreme value theory[C]. *IEEE International Conference on Big Data*. Osaka, 2023: 1395-1400.
- [90] Nejjar I, Dong H, Fink O. Recall and refine: A simple but effective source-free open-set domain adaptation framework[J/OL]. 2024, arXiv: 2411.12558.
- [91] Yin N, Wang M Z, Chen Z G, et al. DREAM: Dual structured exploration with mix up for open-set graph domain adaptation[C]. *Proceedings of the 12th International Conference on Learning Representations*. Vienna, 2024: 1-22.
- [92] Ru J H, Tian J, Xiao C W, et al. Imbalanced open set domain adaptation via moving-threshold estimation and gradual alignment[J]. *IEEE Transactions on Multimedia*, 2023, 26: 2504-2514.
- [93] Saito K, Saenko K. OVANet: One-vs-all network for universal domain adaptation[C]. *IEEE/CVF International Conference on Computer Vision*. Montreal, 2022: 8980-8989.
- [94] Han L G, Zou Y, Gao R J, et al. Unsupervised domain adaptation via calibrating uncertainties[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Long Beach, 2019: 99-107.
- [95] Roy S, Trapp M, Pilzer A, et al. Uncertainty-guided source-free domain adaptation[C]. *Proceedings of the European Conference on Computer Vision*. Cham: Springer, 2022: 537-555.
- [96] Xie S A, Zheng Z B, Chen L, et al. Learning semantic representations for unsupervised domain adaptation[C]. *Proceedings of the 35th International Conference on Machine Learning*. Stockholm, 2018: 5423-5432.
- [97] Zhang X, Ge Y X, Qiao Y, et al. Refining pseudo labels with clustering consensus over generations for unsupervised object re-identification[C]. *IEEE/CVF Conference on Computer Vision and Pattern*

- Recognition. Nashville, 2021: 3435-3444.
- [98] 赵小强, 蒋红梅. 基于特征和类别对齐的领域适应算法[J]. *控制与决策*, 2022, 37(5): 1203-1210.
(Zhao X Q, Jiang H M. Domain adaptation based on feature-level and class-level alignment[J]. *Control and Decision*, 2022, 37(5): 1203-1210.)
- [99] Dong S J, Zhu P, Pei X W, et al. Fault diagnosis of rolling bearing under variable operating conditions based on subdomain adaptation[J]. *Journal of Jilin University: Engineering and Technology Edition*, 2022, 52(2): 288-295.
- [100] Wu T, Xu A Y, Tian K, et al. Robust relation extraction method based on prototypical contrastive learning[J]. *Journal of Chongqing University of Posts and Telecommunications: Natural Science Edition*, 2025, 37(1): 17-28.
- [101] Lee D H. Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks[J]. *International Conference on Machine Learning*, 2013, 3(2): 896.
- [102] Zou Y, Yu Z D, Vijaya Kumar B V K, et al. Unsupervised domain adaptation for semantic segmentation via class-balanced self-training[C]. *Proceedings of the European Conference on Computer Vision*. New York: ACM, 2018: 297-313.
- [103] Liu H, Wang J M, Long M S. Cycle self-training for domain adaptation[J]. *Advances in Neural Information Processing Systems*, 2021, 34: 22968-22981.
- [104] Fu J H, Wu X F, Zhang S F, et al. Improved open set domain adaptation with backpropagation[C]. *IEEE International Conference on Image Processing*. Taipei, 2019: 2506-2510.
- [105] Chang D, Sain A, Ma Z, et al. Mind the gap: Open set domain adaptation via mutual-to-separate framework[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 34(6): 4159-4174.
- [106] 王帆, 韩忠义, 苏皖, 等. 局部一致性主动学习的源域无关开集域自适应[J]. *软件学报*, 2024, 35(4): 1651-1666.
(Wang F, Han Z Y, Su W, et al. Local consistent active learning for source free open-set domain adaptation[J]. *Journal of Software*, 2024, 35(4): 1651-1666.)
- [107] 许清林, 乔宇, 王亚立. 基于领域上下文辅助的开放域行为识别[J]. *集成技术*, 2024, 13(6): 31-43.
(Xu Q L, Qiao Y, Wang Y L. Open domain action recognition based on domain context assistance[J]. *Journal of Integration Technology*, 2024, 13(6): 31-43.)
- [108] 张鸿杰, 李昂, 过洁, 等. 基于风格迁移及对抗加权的开放集域自适应[J]. *计算机科学技术学报*, 2023, 38(3): 644-658.
(Zhang H J, Li A, Guo J, et al. Improving open set domain adaptation using image-to-image translation and instance-weighted adversarial learning[J]. *Journal of Computer Science and Technology*, 2023, 38(3): 644-658.)
- [109] Gal Y, Ghahramani Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning[C]. *Proceedings of the 33rd International Conference on International Conference on Machine Learning*. New York: ACM, 2016: 1050-1059.
- [110] Lee J, Lee G. Model uncertainty for unsupervised domain adaptation[C]. *IEEE International Conference on Image Processing*. Abu Dhabi, 2020: 1841-1845.
- [111] Qu S Q, Zou T P, Röhrbein F, et al. GLC: Source-free universal domain adaptation through global-local clustering and contrastive affinity learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(11): 10646-10663.
- [112] Wilson G, Doppa J R, Cook D J. CALDA: Improving multi-source time series domain adaptation with contrastive adversarial learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(12): 14208-14221.
- [113] Lao Q C, Jiang X, Havaei M, et al. Continuous domain adaptation with variational domain-agnostic feature replay[J/OL]. 2020, arXiv: 2003.04382.
- [114] Qin T X, Wang S Q, Li H L. Generalizing to evolving domains with latent structure-aware sequential autoencoder[C]. *Proceedings of the International Conference on Machine Learning*. New York, 2022: 18062-18082.
- [115] Bai G J, Cai Z K, Jiang R H, et al. Continuous temporal domain generalization[C]. *Advances in Neural Information Processing Systems*. Vancouver, 2024, 37: 127987-128014.
- [116] Hou Y Z, Zheng L. Source free domain adaptation with image translation[J/OL]. 2020, arXiv: 2008.07514.
- [117] Hong J, Zhang Y D, Chen W T. Source-free unsupervised domain adaptation for cross-modality abdominal multi-organ segmentation[J]. *Knowledge-Based Systems*, 2022, 250: 109155.
- [118] Tian Q, Ma C, Zhang F Y, et al. Source-free unsupervised domain adaptation with sample transport learning[J]. *Journal of Computer Science and Technology*, 2021, 36(3): 606-616.
- [119] Ding Y H, Sheng L J, Liang J, et al. ProxyMix: Proxy-based mixup training with label refinery for source-free domain adaptation[J]. *Neural Networks*, 2023, 167: 92-103.
- [120] Kurmi V K, Subramanian V K, Namboodiri V P. Domain impression: A source data free domain adaptation method[C]. *IEEE Winter Conference on Applications of Computer Vision*. Waikoloa, 2021: 615-625.
- [121] Yu H, Huang J, Liu Y J, et al. Source-free domain adaptation for real-world image dehazing[C]. *Proceedings of the 30th ACM International Conference on Multimedia*. Lisboa, 2022: 6645-6654.
- [122] Fan J H, Zhu H Y, Jiang X Y, et al. Unsupervised domain adaptation by statistics alignment for deep sleep staging networks[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022,

- 30: 205-216.
- [123] Xia H F, Zhao H D, Ding Z M. Adaptive adversarial network for source-free domain adaptation[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, 2021: 9010-9019.
- [124] Li X F, Chen W J, Xie D, et al. A free lunch for unsupervised domain adaptive object detection without source data[C]. Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, 2021: 8474-8481.
- [125] Yang S, Van J, Herranz L, et al. Exploiting the intrinsic neighborhood structure for source-free domain adaptation[C]. Advances in Neural Information Processing Systems. Sydney, 2021, 34: 29393-29405.
- [126] 黄超, 程春玲, 王有康. 基于伪标签不确定性估计的无源域自适应方法[J]. *计算机科学*, 2025, 52(9): 212-219.
(Huang C, Cheng C L, Wang Y K. Source-free domain adaptation method based on pseudo-abel uncertainty estimation[J]. *Computer Science*, 2025, 52(9): 212-219.)
- [127] Liang J, Hu D P, He R, et al. Distill and fine-tune: Effective adaptation from a black-box source model[J/OL]. 2021, arXiv: 2104.01539.
- [128] Zhang H J, Zhang Y B, Jia K, et al. Unsupervised domain adaptation of black-box source models[J/OL]. 2021, arXiv: 2101.02839.
- [129] Yeh H W, Yang B Y, Yuen P C, et al. SoFA: Source-data-free feature alignment for unsupervised domain adaptation[C]. IEEE Winter Conference on Applications of Computer Vision. Waikoloa, 2021: 474-483.
- [130] Yang B Y, Yeh H W, Harada T, et al. Model-induced generalization error bound for information-theoretic representation learning in source-data-free unsupervised domain adaptation[J]. *IEEE Transactions on Image Processing*, 2022, 31: 419-432.
- [131] Zhao H, Zhang S H, Wu G H, et al. Adversarial multiple source domain adaptation[C]. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, 2018: 8568-8579.
- [132] Peng X C, Bai Q X, Xia X D, et al. Moment matching for multi-source domain adaptation[C]. IEEE/CVF International Conference on Computer Vision. Seoul, 2019: 1406-1415.
- [133] Xu R J, Chen Z L, Zuo W M, et al. Deep cocktail network: Multi-source unsupervised domain adaptation with category shift[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 3964-3973.
- [134] Tian L, Zhou L H, Li S F, et al. Mutual supervision multi-source-free domain adaptation of image classification[J]. *Applied Soft Computing*, 2025, 181: 113479.
- [135] Mancini M, Bulò S R, Caputo B, et al. AdaGraph: Unifying predictive and continuous domain adaptation through graphs[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2020: 6561-6570.
- [136] D'Innocente A, Caputo B. Domain generalization with domain-specific aggregation modules[C]. Pattern Recognition. Cham: Springer, 2019: 187-198.
- [137] Gholami B, Sahu P, Rudovic O, et al. Unsupervised multi-target domain adaptation: An information theoretic approach[J]. *IEEE Transactions on Image Processing*, 2020, 29: 3993-4002.
- [138] Yao C H, Gong B Q, Qi H, et al. Federated multi-target domain adaptation[C]. IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, 2022: 1081-1090.
- [139] Sun T, Chen J, Ng F. Multi-target domain adaptation via unsupervised domain classification for weather-invariant object detection[J/OL]. 2021, arXiv: 2103.13970.
- [140] Lu Y W, Huang H Y, Hu X, et al. Multiple adaptation network for multi-source and multi-target domain adaptation[J]. *IEEE Transactions on Multimedia*, 2025, 27: 5731-5745.
- [141] Chang W G, You T, Seo S, et al. Domain-specific batch normalization for unsupervised domain adaptation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, 2020: 7346-7354.
- [142] Isobe T, Jia X, Chen S J, et al. Multi-target domain adaptation with collaborative consistency learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 8183-8192.
- [143] Nguyen-Meidine L T, Belal A, Kiran M, et al. Unsupervised multi-target domain adaptation through knowledge distillation[C]. IEEE Winter Conference on Applications of Computer Vision. Waikoloa, 2021: 1338-1346.
- [144] 马良玉, 韩立凯. 融合混合专家及多目标域对抗迁移网络的锅炉汽水系统跨工况故障诊断[J]. *中国电机工程学报*, 2025: 1-13.
(Ma L Y, Han L K. Cross-condition fault diagnosis of boiler steam-water system based on mixture of experts and multi-target domain adversarial migration network[J]. Proceedings of the CSEE, 2025: 1-13.)
- [145] Prakash A, Bochoon S, Brophy M, et al. Structured domain randomization: Bridging the reality gap by context-aware synthetic data[C]. International Conference on Robotics and Automation. Montreal, 2019: 7249-7255.
- [146] Peng X, Qiao F C, Zhao L. Out-of-domain generalization from a single source: An uncertainty quantification approach[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(3): 1775-1787.
- [147] Shankar S, Piratla V, Chakrabarti S, et al. Generalizing across domains via cross-gradient training[J/OL]. 2018, arXiv: 1804.10745.
- [148] Qiao F C, Zhao L, Peng X. Learning to learn single

- domain generalization[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 12553-12562.
- [149] Tolstikhin I, Bousquet O, Gelly S, et al. Wasserstein auto-encoders[J/OL]. 2017, arXiv: 1711.01558.
- [150] 童煜钧, 王荷清, 罗悦恒, 等. 基于扩散模型数据增广的域泛化方法[J]. *智能科学与技术学报*, 2023, 5(3): 380-388.
(Tong Y J, Wang H Q, Luo Y H, et al. Data augmentation method based on diffusion model for domain generalization[J]. *Chinese Journal of Intelligent Science and Technology*, 2023, 5(3): 380-388.)
- [151] Blanchard G, Deshmukh A A, Dogan Ü, et al. Domain generalization by marginal transfer learning[J]. *Journal of Machine Learning Research*, 2021, 22(2): 1-55.
- [152] Li Y, Tian X M, Gong M M, et al. Deep domain generalization via conditional invariant adversarial networks[C]. Proceedings of the European Conference on Computer Vision. New York: ACM, 2018: 647-663.
- [153] Ding Z M, Fu Y. Deep domain generalization with structured low-rank constraint[J]. *IEEE Transactions on Image Processing*, 2018, 27(1): 304-313.
- [154] Liu C, Sun X W, Wang J D, et al. Learning causal semantic representation for out-of-distribution prediction[C]. *Neural Information Processing Systems*. Sydney, 2021, 34: 6155-6170.
- [155] 谢刚, 韩秦, 聂晓音, 等. 基于两阶段域泛化学习框架的轴承故障诊断方法[J]. *自动化学报*, 2024, 50(11): 2271-2285.
(Xie G, Han Q, Nie X Y, et al. A two-stage domain generalization learning framework for fault diagnosis of bearing[J]. *Acta Automatica Sinica*, 2024, 50(11): 2271-2285.)
- [156] Mancini M, Bulò S R, Caputo B, et al. Best sources forward: Domain generalization through source-specific nets[C]. The 25th IEEE International Conference on Image Processing. Athens, 2018: 1353-1357.
- [157] Snell J, Swersky K, Zemel R S. Prototypical networks for few-shot learning[C]. *Neural Information Processing Systems*. Long Beach, 2017: 4077-4087.
- [158] Li D, Yang Y, Song Y Z, et al. Learning to generalize: Meta-learning for domain generalization[C]. Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans, 2018: 1-8.
- [159] Huang Z Y, Wang H H, Xing E P, et al. Self-challenging improves cross-domain generalization[M]. Proceedings of the European conference on computer vision. Cham: Springer, 2020: 124-140.
- [160] Sagawa S, Koh P W, Hashimoto T B, et al. Distributionally robust neural networks for group shifts: On the importance of regularization for worst-case generalization[J/OL]. 2019, arXiv: 1911.08731.
- [161] Jing L L, Tian Y L. Self-supervised visual feature learning with deep neural networks: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(11): 4037-4058.
- [162] Kumar A, Ma T, Liang P. Understanding self-training for gradual domain adaptation[C]. Proceedings of the 37th International Conference on Machine Learning. Vienna, 2020, 119: 5468-5479.
- [163] Chen H Y, Chao W L. Gradual domain adaptation without indexed intermediate domains[C]. Proceedings of the 35th International Conference on Neural Information Processing Systems. New York: ACM, 2021: 8201-8214.
- [164] Hoffman J, Darrell T, Saenko K. Continuous manifold based adaptation for evolving visual domains[C]. Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. New York: ACM, 2014: 867-874.
- [165] Li W, Xu Z, Xu D, et al. Domain generalization and adaptation using low rank exemplar SVMs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(5): 1114-1127.
- [166] Wang H, He H, Katabi D. Continuously indexed domain adaptation[J/OL]. 2020, arXiv: 2007.01807.
- [167] Liu H, Long M, Wang J, et al. Learning to adapt to evolving domains[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 22338-22348.
- [168] Bai G J, Ling C, Zhao L. Temporal domain generalization with drift-aware dynamic neural networks[J/OL]. 2022, arXiv: 2205.10664.
- [169] Zeng Q H, Wang W, Zhou F, et al. Generalizing across temporal domains with koopman operators[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2024, 38(15): 16651-16659.
- [170] Chen R, Zhao H F, Dang R J, et al. Online domain adaption for Sim2Real transfer of high-precision manipulation with visuotactile sensing[C]. IEEE 15th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems. Shanghai, 2025: 7-12.
- [171] Zhang H, Liang H Z, Cong L, et al. Reinforcement learning based pushing and grasping objects from ungraspable poses[C]. IEEE International Conference on Robotics and Automation. London, 2023: 3860-3866.
- [172] Ding K X, Lu T, Fu W, et al. Cross-scene hyperspectral image classification with consistency-aware customized learning[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2025, 35(1): 418-430.
- [173] Wu L, Wang H, Fan J W, et al. An image classification method based on sequential multi-source domain adaption[C]. CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes. Yibin, 2023: 1-11.
- [174] Huang H L, Guo J C, Lin H X, et al. Domain adaptive oriented object detection from optical to SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5200314.

- [175] Zhao M, Wei X, Lu Y, et al. Domain adaption object detection with global-local contrastive learning and co-training network[C]. *IEEE Smart World, Ubiquitous Intelligence & Computing, Haikou*, 2023: 1373-1378.
- [176] 陈龙, 张建林, 彭昊, 等. 多尺度注意力与领域自适应的小样本图像识别[J]. *光电工程*, 2023, 50(4): 220232.
(Chen L, Zhang J L, Peng H, et al. Few-shot image classification via multi-scale attention and domain adaptation[J]. *Opto-Electronic Engineering*, 2023, 50(4): 220232.)
- [177] Wu J H, Guo D, Wang G T, et al. FPL: Filtered pseudo label-based unsupervised cross-modality adaptation for 3D medical image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2024, 43(9): 3098-3109.
- [178] Xie Q S, Li Y X, He N J, et al. Unsupervised domain adaptation for medical image segmentation by disentanglement learning and self-training[J]. *IEEE Transactions on Medical Imaging*, 2024, 43(1): 4-14.
- [179] Wang L, Zhang H G, Liu J H, et al. Knowledge transfer and reinforcement based on biunbiased neural network: A novel solution for open-set fault transfer diagnosis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(9): 15794-15806.
- [180] Xie Z L, Chen J L. Multi-scale attention convolution subdomain adaption network for cross-domain fault diagnosis of machine[C]. *Prognostics and System Health Management Conference*. Stockholm, 2024: 153-158.
- [181] Li B C, Yu W B. A domain adaption based closed-loop system for fault diagnosis of generator slot wedge[C]. *The 5th International Symposium on Autonomous Systems*. Hangzhou, 2022: 1-6.
- [182] Shao J J, Huang Z W, Zhu J M. Transfer learning method based on adversarial domain adaption for bearing fault diagnosis[J]. *IEEE Access*, 2020, 8: 119421-119430.
- [183] Su Z, Jiang W, Zhao Y, et al. Cross-domain open-set fault diagnosis based on target-domain slanted adversarial network for rotating machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3503212.
- [184] Zhu Z X, Chen G Y, Tang G. Domain adaptation with multi-adversarial learning for open-set cross-domain intelligent bearing fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3533411.
- [185] Xu S P, Yang X R, Ma G J, et al. RMDA: A regressive multiple-source domain adaption approach for early prediction of lithium-ion battery lifetime[C]. *The 42nd Chinese Control Conference*. Tianjin, 2023: 6981-6986.
- [186] Ye Z, Yu J B, Mao L. Multisource domain adaption for health degradation monitoring of lithium-ion batteries[J]. *IEEE Transactions on Transportation Electrification*, 2021, 7(4): 2279-2292.
- [187] Tang L, Hu L P, Cui C H, et al. Residual life prediction of rolling bearings based on multi-source domain sub-domain adaptive[C]. *IEEE 3rd International Conference on Power, Electronics and Computer Applications*. Shenyang, 2023: 1075-1080.
- [188] Qu Q, Xu L, Zhou Y. Domain adaptation short term load forecasting algorithm based on extended time series for traffic flow prediction[C]. *IEEE 15th International Conference on Electronic Measurement & Instruments*. Qingdao, 2021: 5-10.
- [189] Wan H, Che B L, Luo H Z, et al. Learning path recommendation based on knowledge tracing and reinforcement learning[C]. *IEEE International Conference on Advanced Learning Technologies*. Orem, 2023: 55-57.
- [190] Lin Y G, Liu Y, Lin F, et al. A survey on reinforcement learning for recommender systems[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(10): 13164-13184.
- [191] Prasad B L, Srividya K, Kumar K N, et al. An advanced real-time job recommendation system and resume analyser[C]. *International Conference on Self Sustainable Artificial Intelligence Systems*. Erode, 2023: 1039-1045.
- [192] Chen P, Tan Y S. Optimizing personalized E-commerce micro-video recommendation with self-adaption generative gating graph[C]. *The 5th International Conference on Computer Engineering and Application*. Hangzhou, 2024: 1095-1106.
- [193] Kanagawa H, Kobayashi H, Shimizu N, et al. Cross-domain recommendation via deep domain adaptation[C]. *Advances in Information Retrieval*. Cham: Springer, 2019: 20-29.
- [194] Nanthini M, Kumar K P M. Provisioning a cross-domain recommender system using an adaptive adversarial network model[J]. *Soft Computing*, 2023, 27(24): 19197-19212.
- [195] 郭斌, 仵允港, 王虹力, 等. 深度学习模型终端环境自适应方法研究[J]. *中国科学 F 辑*, 2020, 50(11): 1629-1644.
(Guo B, Wu H L, Wang H L, et al. Context-aware adaptation of deep learning models for IoT devices[J]. *Scientia Sinica Informationis*, 2020, 50(11): 1629-1644.)
- [196] Chakraborty O, Sahoo A, Panda R, et al. AnyDA: Anytime domain adaptation[C]. *International Conference on Learning Representations*. Kigali, 2023: 1-25.
- [197] Mao Y Y, Wang Z Q. On f -divergence principled domain adaptation: An improved framework[C]. *Advances in Neural Information Processing Systems*. Vancouver, 2024: 6711-6748.
- [198] Naram J, Hellström F, Wang Z, et al. Theoretical performance guarantees for partial domain adaptation via partial optimal transport[C]. *The 42nd International Conference on Machine Learning*. Seoul, 2025: 1-19.
- [199] Pham T H, Wang Y L, Yin C C, et al. Open-set

- heterogeneous domain adaptation: Theoretical analysis and algorithm[J]. *Proceedings of the AAAI Conference on Artificial Intelligence AAAI Conference on Artificial Intelligence*, 2025, 39(19): 19895-19903.
- [200] Shi L H, Liu W W. Adversarially robust unsupervised domain adaptation[J]. *Artificial Intelligence*, 2025, 347: 104383.
- [201] Vettoruzzo A, Bouguelia M R, Rögnvaldsson T. Meta-learning for efficient unsupervised domain adaptation[J]. *Neurocomputing*, 2024, 574: 127264.
- [202] Khoei A G, Yu Y N, Feldt R. Domain generalization through meta-learning: A survey[J]. *Artificial Intelligence Review*, 2024, 57(10): 285.
- [203] Chen J, Wu X X, Duan L X, et al. Domain adversarial reinforcement learning for partial domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 539-553.
- [204] Zhang Y S, Ye H, Davison B D. Adversarial reinforcement learning for unsupervised domain adaptation[C]. *IEEE Winter Conference on Applications of Computer Vision*. Waikoloa, 2021: 635-644.
- [205] Zaeifi M, Mosallanezhad A, Bansal S. Deeper and deeper: A lightweight semi-supervised deep reinforcement adaptive learning-based ontology alignment[C]. *International Conference on AI x Data and Knowledge Engineering*. Tokyo, 2025: 28-35.
- [206] Wen S, Brbić M. Cross-domain open-world discovery[C]. *Proceedings of the 41st International Conference on Machine Learning*. Vienna, 2024: 52744-52761.
- [207] Willes J, Harrison J, Harakeh A, et al. Bayesian embeddings for few-shot open world recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(3): 1513-1529.
- [208] Zhao H B, Fu Y J, Kang M T, et al. Mgsvf: Multi-grained slow versus fast framework for few-shot class-incremental learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(3): 1576-1588.
- [209] Yang L, Huang Y, Sugano Y, et al. Interact before align: Leveraging cross-modal knowledge for domain adaptive action recognition[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, 2022: 14722-14732.
- [210] Wu Y, Xing M W, Zhang Y C, et al. Cross-modal unsupervised domain adaptation for 3D semantic segmentation via bidirectional fusion-then-distillation[C]. *Proceedings of the 31st ACM International Conference on Multimedia*. Ottawa, 2023: 490-498.
- [211] Guan H, Liu M X. Domain adaptation for medical image analysis: A survey[J]. *IEEE Transactions on Biomedical Engineering*, 2022, 69(3): 1173-1185.
- [212] Xia K, Deng L F, Duch W, et al. Privacy-preserving domain adaptation for motor imagery-based brain-computer interfaces[J]. *IEEE Transactions on Biomedical Engineering*, 2022, 69(11): 3365-3376.
- [213] Mireshghallah F, Su Y, Hashimoto T, et al. Privacy-preserving domain adaptation of semantic parsers[J/OL]. 2022, arXiv: 2212.10520.
- [214] Gong K J, Gao Y, Dong W. Privacy-preserving and cross-domain human sensing by federated domain adaptation with semantic knowledge correction[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2024, 8(1): 1-26.
- [215] Cai Z K, Yao Y H, Bai G J, et al. Continuous domain generalization[J/OL]. 2025, arXiv: 2505.13519.

作者简介

马大中 (1982-), 男, 教授, 博士, 博士生导师, 主要研究方向为人工智能、信息物理系统、分布式协同控制和优化及其在能源互联系统中的应用, E-mail: madazhong@ise.neu.edu.cn;

王清晨 (2000-), 男, 博士生, 主要研究方向为域适应、域泛化及其在电力系统中的应用, E-mail: 2410276@stu.neu.edu.cn;

齐开聪 (2002-), 男, 硕士生, 主要研究方向为人工智能、电气工程, E-mail: qikaicong@mails.neu.edu.cn;

左鑫如 (2001-), 女, 硕士生, 主要研究方向为人工智能、控制工程, E-mail: zuoxr@mails.neu.edu.cn;

王梓鑫 (2002-), 女, 硕士生, 主要研究方向为人工智能、电力系统, E-mail: wangzx30@mails.neu.edu.cn.

科研团队简介

张化光教授研究团队立足于东北大学信息科学与工程学院, 以国家重大战略需求和国际前沿基础理论为目标导向, 长期专注于能源互联系统的建模与优化控制运行、复杂工业过程故障诊断技术、模糊控制与智能控制和混沌控制等领域的科学研究工作. 科研团队自成立以来, 在能源互联网优化调度、智能故障诊断方法等方面取得了一系列开创性的研究成果, 并成功应用于智能电网运行管理、工业智能制造等工业现场. 团队在人才培养、科研文化建设、国际合作拓展和创新能力提升等方面积累了丰富的成果和实践经验, 团队已培养国家级领军人才 3 人、国家级青年人才 4 人. 团队承担过包括国家重点研发计划“变革性技术关键科学问题”在内的国家级项目 30 余项, 共获各种奖励 20 余项, 其中包含国家自然科学二等奖一项、国家技术发明二等奖一项、国家科技进步二等奖一项.

团队核心成员马大中教授是国家级青年人才项目入选者; “兴辽人才计划”青年拔尖人才获得者; 辽宁省学术头雁; 沈阳市领军人才支持计划入选者. 东北大学信息科学与工程学院教授、博士生导师, 是中国自动化学会故障诊断与安全性专业委员会委员, 能源互联网专委会委员. 马大中教授及其课题组成员长期专注于人工智能、信息物理系统、分布式协同控制和优化及其在能源互联系统中的应用研究. 担任《控制与决策》以及《Journal of Control and Decision》编委.