arXiv:2603.14238v1 [cs.LG] 15 Mar 2026

结合特征解耦与校准的域偏斜联邦学习

Huan Wang[1,2] Jun Shen[1*] JunYan[1] GuansongPang[2*]计算与信息技术学院，伍伦贡大学，澳大利亚[2]计算与信息系统学院，新加坡管理大学，新加坡hw226@uowmail.edu.au, jshen@uow.edu.au, jyan@uow.edu.au, gspang@smu.edu.sg

摘要

联邦学习（*FL*）允许分布式客户端以保护隐私的方式协同训练全局模型。然而，其中一个主要挑战是域偏斜，即客户端的数据源自不同领域，可能阻碍聚合后的全局模型学习一致的表征空间，从而导致其在多个领域中的泛化能力较差。在本文中，我们认为域偏斜体现在每个客户端的域特定偏置特征中，导致本地模型的表征坍缩到狭窄的低维子空间。随后，我们提出***F**ederated**F**eature **D**ecouplingand **C**alibration*（F^2*DC*），通过校准域特定偏置特征，释放有价值的类别相关信息，从而实现跨领域更加一致的表征。我们首先在 F^2*DC*中引入一个新颖的组件——域特征解耦器（*DFD*），用于确定每个特征单元的鲁棒性，进而将局部特征分离为域鲁棒特征和域相关特征。随后提出域特征校正器（*DFC*），通过显式关联判别信号来校准这些域相关特征，捕获能够补充域鲁棒特征的额外类别相关线索。最后，对本地模型执行域感知聚合，以促进客户端之间形成共识。在三个广泛使用的多域数据集上的实验证明了所提出的 F^2*DC*及其两个模块的有效性。代码可在 https://github.com/mala-lab/F2DC获取。

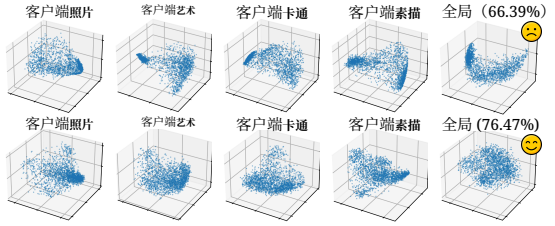


图 1. PACS [19] 数据集中，原始联邦学习 [31]（上）与我们方法（下）的特征协方差矩阵奇异值可视化。在域偏斜联邦学习中，原始方法会遭受严重的维度坍塌，即，表示在很大程度上存在偏差，并处于特定领域的低维子空间中。我们的方法有效缓解了这种坍塌，其表现为奇异值分布更加均匀，且趋近于零的值显著减少。

1. 引言

联邦学习 (FL) [22, 31] 正逐渐成为一种保护隐私的技术，用于在多个客户端之间协作训练共享的全局模型，同时避免隐私泄露。联邦学习方法以 FedAvg [31], 等关键基石算法为代表，其中每个客户端执行随机梯度下降迭代，以最小化本地经验目标函数，随后所有参与客户端的本地模型都会发送至服务器，由服务器对参数进行全局聚合。联邦学习范式固有的一项挑战是客户端之间本地数据分布可能存在差异，这被称为数据异质性[16, 21, 22, 58]。具体而言，客户端从不同来源收集的数据偏好存在显著差异，导致数据分布不满足独立同分布（non-iid） [21, 58]。这种数据异质性导致全局模型的表现不佳 [23, 25]。

为缓解数据异质性问题，后续研究着重于稳定本地训练 [17, 23, 43] 或规范全局聚合 [42, 47, 51] ，以降低联邦学习优化中的方差。值得注意的是，这些方法主要考虑标签偏斜问题即，客户端之间的数据类别分布不同，但所有数据均来自同一领域。然而，在许多现实场景中（例如，从不同车辆在多种天气条件下采集的驾驶数据），数据异质性主要由域偏斜造成：不同客户端的本地数据来自不同域，但类别分布相似。这往往会导致严重的维度崩

*通讯作者：Jun Shen、Guansong Pang

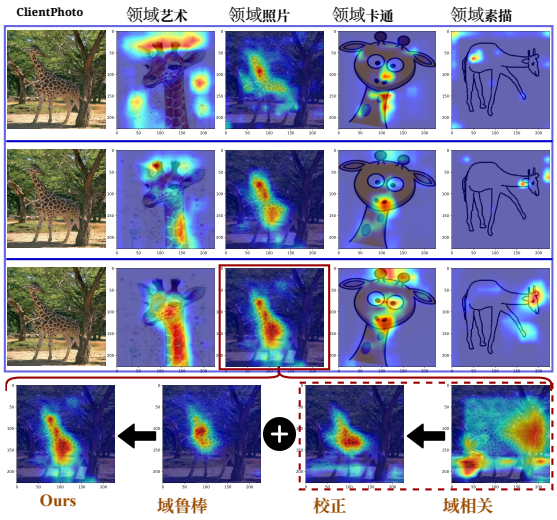


图 2. Grad-CAM [35] 可视化了三种方法——原始方法 [31] **(顶部)**、域偏斜方法 FDSE [48] **(中部)** 和 F^2DC **(底部)** 对随机选取的、来自不同领域的客户端样本所提取的特征$_{Photo}$，该客户端属于照片域。对于我们的方法 F^2DC，我们还提供了一个定性示例，说明其两个模块如何工作：首先通过 DFD 将局部特征解耦为域鲁棒特征和域相关特征。然后，通过 DFC 对域相关特征（其中纠缠着有价值的类别相关信息与领域偏差）进行校准，从而得到校正特征。通过结合域鲁棒特征与校正后的特征，F^2DC 能够捕获更全面的类别相关线索，使本地模型对不同领域中语义相同的样本做出更一致的决策。

塌，因为本地模型训练时只拟合各个客户端中各个域的特征，导致每个客户端的表征主要位于狭窄的低维子空间中，而忽略其他子空间中的相关特征。这一问题表现为每个客户端的特征协方差矩阵存在较小（接近零）的奇异值，如图1-**顶部**所示。对这类域偏置本地模型进行聚合，会导致全局模型难以获得共识更新，从而无法有效泛化到来自不同域的数据；图2-**顶部**中各域间关注特征的显著差异便是一个例证。这引出了一个问题：在域偏斜联邦学习场景下，我们能否推动本地训练摆脱对客户端特定域的偏好？

为应对这一挑战，近期先进的联邦学习方法 [7, 48] 旨在消除并停用本地参数中的领域特定偏差，以提升性能并促进共识更新。然而，这些“基于消除”的方法可能会丢弃与类别相关的额外信息，而这些信息与领域特定特征纠缠在一起，中，例如，FDSE [48] 在图 2-中部的卡通域和素描域中遗漏了卡通长颈鹿和素描长颈鹿的鹿角与头部2-**中部**。这促使我们提出**核心问题**：我们能否纠正领域特定偏差，以捕获更多与类别相关的特征，从而促进具有更强领域泛化能力的全局模型？

为解决这一域偏斜问题，我们提出 F²DC，即联邦特征解耦与校准，旨在校正域特定偏置特征，以提升本地训练的泛化能力。 F^2DC 由两个新颖模块组成：域特征解耦器（DFD）和域特征校正器（DFC）。DFD 经过优化，可将局部特征解耦为域鲁棒特征和域相关特征：前者关注具有判别性的跨域类别相关信息，后者则承载客户端特定域上下文。如图 1 底部所示，这可以防止 F^2DC 对域偏置特征过拟合。此外，域相关特征本身会将域偏差（例如素描域的笔触风格）与类别相关信息（例如素描所勾勒的“物体轮廓”）纠缠在一起。为捕捉这些能够补充域鲁棒特征的额外类别相关线索，我们设计了 DFC，通过显式关联正确的语义信号来校准这些域相关特征。最后，我们对本地模型进行域感知聚合，将域差异纳入全局模型，从而进一步促进客户端之间达成共识。如图 2 底部所示，与 [31, 48] 相比，F^2DC 能够在不同域中更稳定地获得具有判别性的特征；以照片域为例， F^2DC 中的 DFD 能准确地将域鲁棒特征（长颈鹿身体上部）与域相关特征解耦，并通过 DFC 从带噪的域相关特征中进一步捕捉额外的类别相关线索（例如，校正特征重新捕捉到长颈鹿腰部）。主要贡献如下：

- 我们认为，近期的域偏斜联邦学习方法试图消除域特定偏差，而这些偏差实际上与有价值的类别相关信息密不可分；经过适当校准后，它们可以用于在不同域之间产生更加一致的决策。
- 我们提出了 F^2DC，这是一种针对域偏斜联邦学习的新方法。该方法通过两个创新模块 DFD 和 DFC 对局部特征进行解耦和校正，从而提升跨域性能；同时，它采用域感知聚合，促进客户端之间形成更多共识。
- 在三个多域数据集上进行的大量实验表明， F^2DC 的性能始终优于最先进的方法。全面的消融研究也证实了这两个模块的贡献。

2. 相关工作

异构联邦学习。 联邦学习已成为一种新兴课题，它通过协作训练一个

共享的全局模型，同时不共享私有数据 [21, 23,31]。然而，由于数据异质性，这种范式面临收敛不稳定且缓慢的问题 [9, 14, 21, 25, 58]。为了解决这一问题，先前的研究要么对客户端侧的本地训练进行正则化 [12, 13, 44, 45, 49]，要么调整服务器端的全局聚合 [11, 42, 47, 51, 52]。然而，这些方法大多忽视了域偏斜，导致模型在多个域上的性能受损 [5, 13]。

域偏斜联邦学习。域偏斜数据容易削弱全局模型的泛化能力，因此推动了域偏斜联邦学习 [5, 6, 13, 37, 48, 54, 57]的发展。缓解域偏斜主要有两个方向：增强客户端之间的一致性 [5, 13, 15, 57]，以及对全局模型进行个性化 [27, 28, 38]。FedSA [57] 构建了基于锚点的正则化，以确保不同领域之间的边界保持一致。FedHEAL [5] 利用选择性参数本地更新和公平聚合目标，促进公平性并提升性能。FDSE [48]将每个模型层解耦为领域无关提取器和领域特定擦除器，从而实现全局共识与本地个性化。然而，这些方法旨在丢弃或禁用本地训练中受领域偏差影响的参数更新，忽视了领域上下文中可能存在的有用线索。相比之下，我们认为，经过适当校正后，每个客户端的域相关特征能够重新发掘额外的有用指导信息，从而提升跨领域泛化能力。

解耦表示学习。解耦表示学习（DRL）旨在学习一种机制，在特征级别识别并解耦数据中隐藏的潜在因素 [8, 46, 56]。以往的研究主要致力于为下游任务分离通用特征与个体特征，例如步态识别 [26, 56]，推荐 [30]，图分析 [32, 55]，等。也有一些研究将解耦学习融入联邦学习 [1, 2, 4, 39, 50]，以辅助联邦学习中的本地训练并取得更高性能。然而，这些方法关注的是单一领域的性能。在域偏斜的联邦学习场景下，必须考虑不同领域之间的泛化能力。我们的工作阐明了如何利用解耦学习（即本地特征解耦与校正）来应对联邦学习中的域偏斜挑战。

3. 问题陈述

接下来，我们聚焦于标准的域偏斜联邦学习场景，其中有 K 个参与客户端，对应的数据划分为 $\{\mathcal{D}_1, \dots, \mathcal{D}_k, \dots, \mathcal{D}_K\}$；每个客户端的数据样本 $\mathcal{D}_k = \{x_i, y_i\}|_{i=1}^{n_k}$，$y_i \in \{1, \dots, \mathbb{C}\}$ 仅属于单个领域，n_k 表示客户端 k的本地数据规模，$\mathbb{C}$表示类别数量。令 n_k^c 为客户端 k上类别 c的样本数量，我们进一步将 $\mathcal{D}_k^c = \{(x_i, y_i) \in \mathcal{D}_k | y_i = c\}$ 定义为客户端 k上类别 c 的样本集合，其中 $n_k^c = |\mathcal{D}_k^c|$。所有客户端中类别 c的样本总数为 $n^c = \sum_{k=1}^K n_k^c$。形式上，域偏斜联邦学习的优化目标为：

$$w^* = \arg\min_w \mathcal{L}(w) = \sum_{k=1}^K \frac{n_k}{N} \mathcal{L}_k(w; \mathcal{D}_k), \quad (1)$$

其中，w 是全局模型的参数，$\mathcal{L}_k$ 表示客户端 k上的经验目标函数，$N = \sum_{k=1}^K n_k$表示所有客户端的样本总数。式（1）中的优化目标是学习一个具有泛化能力的全局模型 w^*，使其在联邦学习过程中于多个领域上呈现良好性能。在联邦学习的训练设置中，对于每个客户端 k，我们考虑参数为 $w_k = \{\Phi_k, \theta_k\}$的本地模型。该模型包含两个模块：特征提取器$r(\Phi_k; \cdot)$：$x \to \mathbb{R}^d$，将每个样本 x 编码为一个 d 维嵌入 $z = r(\Phi_k; x)$；分类器 $h(\theta_k; \cdot)$：$\mathbb{R}^d \to \mathbb{R}^{\mathbb{C}}$，将该嵌入 z 映射为一个 $\mathbb{C}$ 维逻辑值 $\ell = h(\theta_k; z)$。

域偏斜。在异构联邦学习场景中，即使 $\mathbb{P}(y)$保持一致，不同客户端之间的特征分布 $\mathbb{P}(x|y)$仍然存在差异，从而导致域偏斜问题 [13]：

$$\mathbb{P}_{k_1}(x|y) \neq \mathbb{P}_{k_2}(x|y), \text{ s.t. } \mathbb{P}_{k_1}(y) = \mathbb{P}_{k_2}(y). \quad (2)$$

4. 方法

为提升域偏斜联邦学习中的跨域泛化能力，我们提出了 F^2DC。如图3所示，F^2DC由两个主要模块组成：域特征解耦器（DFD）和域特征校正器（DFC）。首先，DFD确定每个特征单元的鲁棒性，从而将局部特征划分为域鲁棒特征和域相关特征（第4.1节）。随后，DFC对域相关特征进行校准，使本地模型能够捕获更多有用线索，从而改进跨域决策（第4.2节）。最后，我们以域感知方式进行全局聚合，以促进本地客户端之间达成共识（第4.3节）。

4.1 域特征解耦器（DFD）

我们的核心见解是在本地训练过程中校准存在偏差的域相关特征。为此，我们首先将这些域相关特征与本地特征分离；本地特征能够捕捉客户端特定的领域上下文，以便后续进行校准。根据第3节中的上述定义，对于客户端 k，我们进一步将特征提取器 $r(\Phi_k; \cdot)$细化为骨干层 r_k^{B} 和展平层 r_k^{F}：以 ResNet-10 [10]为例，r_k^{B} 包含 4 个骨干层 $L_1 \sim L_4$，r_k^{F} 由一个池化层和一个展平操作组成。给定一个实例 $(x_i, y_i) \in \mathcal{D}_k$，我们首先计算特征图 $f_i = r_k^{\mathsf{B}}(x_i) \in \mathbb{R}^{C \times H \times W}$（例如，对于 PACS [19]上的 ResNet-10 [10]，$f_i \in \mathbb{R}^{512 \times 16 \times 16}$）。

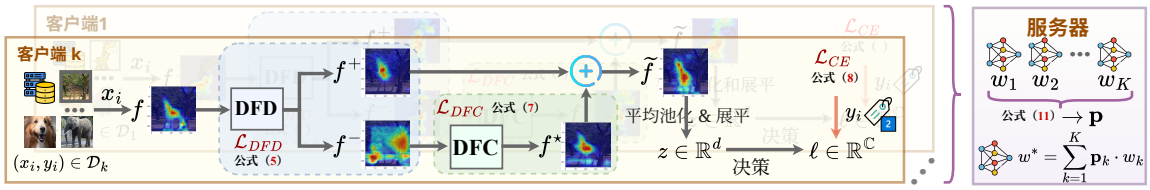


图3。 **所提出的** DC 方法概述 F^2。在客户端本地训练期间，我们首先通过域特征解耦器（DFD）（第 4.1节）将局部特征分离为域鲁棒特征和域相关特征，然后通过域特征校正器（DFC）（第 4.2节）校正域相关特征。在服务器端全局聚合期间，我们结合每个客户端的域差异 4.3（第 ）对全局模型执行域感知聚合，以促进本地客户端之间达成更多共识 $\mathbf{p}_k$。

为了确定 f_i 中的哪些特征单元具有域鲁棒性，哪些具有域相关性，我们引入域特征解耦器（DFD） $\mathcal{A}_D$，构建归因图 $\mathcal{S}_i = \mathcal{A}_D(f_i) \in \mathbb{R}^{C\times H\times W}$，以量化 f_i中每个特征单元的跨领域鲁棒性分数。我们将解耦器 $\mathcal{A}_D$ 实现为一种包含批归一化和 ReLU激活的两层卷积神经网络架构。为了以互补的方式分解 f_i，我们进一步根据 $\mathcal{S}_i$生成二值掩码矩阵 $\mathcal{M}_i = \{0,1\}^{C\times H\times W}$。一种直接的策略是将 $\mathcal{S}_i$ 中的每个元素二值化为 0 或 1，但这种硬离散化会导致训练过程中的不可微性 [3]。为避免这一问题，我们利用 Gumbel-Concrete分布 [29] 生成 $\mathcal{M}_i$，其定义如下：

$$\mathcal{M}_i = \frac{\mathrm{e}^{\frac{1}{\sigma}(\log(\epsilon(\mathcal{S}_i))+\mathbf{g}_a)}}{\mathrm{e}^{\frac{1}{\sigma}(\log(\epsilon(\mathcal{S}_i))+\mathbf{g}_a)} + \mathrm{e}^{\frac{1}{\sigma}(\log(1-\epsilon(\mathcal{S}_i))+\mathbf{g}_b)}}, \tag{3}$$

其中$\mathbf{g}$ 是 Gumbel 噪声 $\mathbf{g} = \log(u) - \log(1-u)$ 和$u \sim \mathcal{U}(0,\mathbf{I})$，$\sigma$ 用于调整$\mathbf{g}_a$ 和$\mathbf{g}_b$ 的平滑度（$\sigma \to 0$, $\mathcal{M}_i$ 近似于硬离散化），ϵ 是 Sigmoid 函数，而 e 表示指数函数。

根据公式（3），基于 $\mathcal{M}_i$的 Gumbel 得分生成伪二值掩码矩阵 $\mathcal{S}_i$，其中 $\mathcal{M}_i$ 接近1 表示域鲁棒特征单元，接近0则表示域相关特征单元。随后，我们通过 f_i 借助 $\mathcal{M}_i$ 将局部特征图解耦如下：

$$f_i^+ = \mathcal{M}_i \odot f_i, \quad f_i^- = (1-\mathcal{M}_i) \odot f_i, \tag{4}$$

其中，$\odot$ 表示逐元素乘积算子，f_i^+和 f_i^-分别表示域鲁棒特征和域相关特征。

一方面，我们希望确保 f_i^+与 f_i^-之间有足够的区分度，以提供类别相关信息和偏置域上下文。另一方面，我们强调保持判别能力。因此，我们通过以下方式促进 $\mathcal{A}_D$ 的学习：

$$\begin{aligned}\mathcal{L}_{DFD} = &\underbrace{\log(\exp(\mathbf{s}(l_i^+, l_i^-)/\tau))}_{\textbf{Separability}} - \\ &\underbrace{(y_i \cdot \log(\delta(\mathbf{m}(l_i^+))) + \widehat{y}_i \cdot \log(\delta(\mathbf{m}(l_i^-))))}_{\textbf{Discriminability}}, \\ \text{s.t.}\quad & l_i^+ = r_k^{\mathrm{F}}(f_i^+) \in \mathbb{R}^d,\ l_i^- = r_k^{\mathrm{F}}(f_i^-) \in \mathbb{R}^d, \\ \text{s.t.}\quad & \mathbf{s}(l_i^+, l_i^-) = (l_i^+ \cdot l_i^-)/(\|l_i^+\|_2 \times \|l_i^-\|_2),\end{aligned} \tag{5}$$

其中，r_k^{F} 由一个池化层和一个展平操作组成，如 $\mathbb{R}^{C\times H\times W} \to \mathbb{R}^d$所示；$\mathbf{s}$ 表示计算余弦相似度；$\mathbf{m}$是一个可训练的单层 MLP 架构，如 $\mathbb{R}^d \to \mathbb{R}^{\mathbb{C}}$所示，用于预测 f_i^+和 f_i^-的逻辑值；$\widehat{y}_i$表示除真实标签 y_i之外置信度最高的错误标签；τ 用于控制表征 [41] 的集中强度，以帮助适当地分离 f_i^+和 f_i^-；δ表示 Softmax 函数。

通过最小化公式（5），我们优化 $\mathcal{A}_D$，使其通过公式（3）中的 $\mathcal{M}_i$ 为f_i^+ 分配更高的元素值，从而促使 $\mathbf{m}$ 做出正确的决策。同时，$\mathcal{A}_D$ 降低了域相关特征 f_i^-对语义对象的关注，将焦点转向可能导致错误决策的客户端特定域上下文。值得注意的是，该领域上下文可能包含一些内在纠缠的类别相关信息和嘈杂的域偏差；对于这些信息，$\mathcal{A}_D$ 无法将所有判别信号完美地隔离到f_i^+中，即 $\mathcal{A}_D$不可避免地会将这些“混合”特征归入 f_i^-。因此，最终得到的 f_i^- 通常是域伪影与有价值的类别相关线索的复杂混合体。这一点从两个方面得到了实证验证：1）强制进行过于激进的分离，例如使用较小的 τ（$\tau = 0.02$）将所有判别信号学习到f_i^+ 中，并不会带来更优的性能，如图 6 所示；2）最终得到的 $f_i^\star$（由 f_i^-校准而来）带来了显著的性能提升，证明 f_i^- 中蕴含着丰富的纠缠类别相关线索，如表7所示。

4.2. 域特征校正器（DFC）

接下来，我们旨在校准域相关特征 f_i^-，以捕捉可能补充 f_i^+ 的其他判别性线索，从而促使本地模型对跨域的同类别样本做出更加一致的决策。为此，我们设计了一个领域特征校正器（DFC） $\mathcal{A}_C$，以域相关特征 f_i^- 为输入，并生成其校正特征 $f_i^\star$。我们将校正器 $\mathcal{A}_C$ 实现为与解耦器 $\mathcal{A}_D$ 相同的双层 CNN 架构。具体而言，$\mathcal{A}_C$ 学习残差项 [10]，以实现更灵活的训练：

$$f_i^\star = f_i^- + (1-\mathcal{M}_i) \odot \mathcal{A}_C(f_i^-), \tag{6}$$

其中 $\mathcal{M}_i$ 是公式（3）中的伪二值掩码矩阵，且$\odot$ 表示逐元素乘积算子。

我们的校正器旨在使校正特征 $f_i^\star$能够提供有用线索，引导本地模型做出更准确的决策。因此，我们通过显式注入正确的判别性语义信号来优化校正器 $\mathcal{A}_C$，其形式如下：

$$\mathcal{L}_{DFC} = -y_i \cdot \log(\delta(\mathbf{m}(l_i^\star))), \quad \text{s.t.} \quad l_i^\star = r_k^{\mathrm{F}}(f_i^\star), \tag{7}$$

其中 r_k^{F} 由一个池化层和一个展平操作组成，用于将 $f_i^\star$编码为 $l_i^\star \in \mathbb{R}^d$， δ 是 Softmax 函数，而 $\mathbf{m}$ 与公式（5）中的单层多层感知机相同。通过最小化公式（7），我们促使校正器 $\mathcal{A}_C$ 将域相关特征 f_i^- 调整为校正特征 $f_i^\star$，从而捕获额外的类别相关信息。随后，我们将域鲁棒特征 f_i^+ 与校正特征 $f_i^\star$相结合，得到最终的特征图$\widetilde{f}_i = (f_i^+ + f_i^\star) \in \mathbb{R}^{C\times H\times W}$，并将其传递给本地模型的后续层。

此外，在逻辑值 ℓ_i 上使用标准交叉熵 [34] 损失，并通过 y_i 来优化本地模型：

$$\mathcal{L}_{CE} = -\mathbf{1}_{y_i} \log(\delta(\ell_i)), \quad \text{s.t.} \quad \ell_i = h(\theta_k; r_k^{\mathrm{F}}(\widetilde{f}_i)), \tag{8}$$

其中， δ 表示 Softmax 函数， $h(\theta_k;\cdot)$ 是本地模型的分类器。总体而言，我们将每个客户端 k 本地训练的目标函数定义如下：

$$\mathcal{L} = \mathcal{L}_{CE} + \frac{1}{|L|}\sum_{j=1}^{|L|}(\lambda_1 \cdot \mathcal{L}_{DFD}^{L_j} + \lambda_2 \cdot \mathcal{L}_{DFC}^{L_j}), \tag{9}$$

其中， $\mathcal{L}_{DFD}^{L_j}$和 $\mathcal{L}_{DFC}^{L_j}$分别表示在本地模型特征提取器的第 L_j 个骨干层之后计算的损失 $\mathcal{L}_{DFD}$和 $\mathcal{L}_{DFC}$。默认情况下，对于每个客户端，我们仅在特征提取器的最后一个骨干层（$|L| = 1$）之后计算损失 $\mathcal{L}_{DFD}$和 $\mathcal{L}_{DFC}$。 λ_1 和 λ_2 是用于平衡这些损失项的超参数。

4.3. 域感知聚合

在全局聚合阶段，对于域偏斜联邦学习场景，直接进行平均聚合 [31]会产生偏差并忽视域多样性，从而限制模型性能。为缓解这一问题，我们考虑以域感知方式将每个客户端的域差异纳入全局模型的聚合过程。我们首先设定一个理想的参照：均匀全局域分布，因为它自然能促进同一类别在所有域之间的公平性。然后，我们衡量每个本地域分布与该均匀全局域分布之间的距离，并将其视为域差异。

具体而言，我们将这一统一的全局域分布定义为固定向量 $\mathcal{G} = [\frac{1}{Q}, \ldots, \frac{1}{Q}] \in \mathbb{R}^{\mathbb{C}}$，其中 Q 表示域的数量，且 $\mathcal{G}$ 中每个元素的值为 $1/Q$（例如，对于 PACS， [19]、 $Q = 4$）。对于客户端 k，本地域分布 $\mathcal{B}_k = [\frac{n_k^1}{n^1}, \ldots, \frac{n_k^{\mathbb{C}}}{n^{\mathbb{C}}}] \in \mathbb{R}^{\mathbb{C}}$ 也抽象为一个向量，其中 $n_k^c \approx n_k/\mathbb{C}$ 且 $n^c \approx N/\mathbb{C}$（在域偏斜情况下，标签分布保持一致）。因此，我们将客户端 k的本地域分布重新表示为 $\mathcal{B}_k = [\frac{n_k}{N}, \ldots, \frac{n_k}{N}] \in \mathbb{R}^{\mathbb{C}}$。随后，我们按如下方式计算客户端 k 的域差异 $\mathbf{d}_k$：

$$\mathbf{d}_k = \sqrt{\frac{1}{2}\sum_{c=1}^{\mathbb{C}}(\mathcal{B}_k^c - \mathcal{G}^c)^2}, \quad \mathcal{B}_k^c = \frac{n_k}{N}, \quad \mathcal{G}^c = \frac{1}{Q}, \tag{10}$$

其中 Q 表示域的数量， $N = \sum_{k=1}^{K} n_k$。根据式（10），我们得到每个客户端$\mathbf{d}_k$ 的域差异 k。随后，我们规定，数据集规模 k 较大 n_k 且域差异$\mathbf{d}_k$ 较小的客户端将获得更高的聚合权重$\mathbf{p}_k$：

$$\mathbf{p}_k = \frac{\epsilon(\alpha \cdot \frac{n_k}{N} - \beta \cdot \mathbf{d}_k)}{\sum_{j=1}^{K}\epsilon(\alpha \cdot \frac{n_j}{N} - \beta \cdot \mathbf{d}_j)}, \tag{11}$$

其中 ϵ 表示 Sigmoid 函数， α 而 β 用于平衡 n_k 和$\mathbf{d}_k$。根据式（11），即使客户端的数据集规模很大（例如，其所属领域占主导地位），我们也能为每个客户端确定更具区分性的权重，而非简单地取平均值。最后，我们以域感知方式获得全局模型$w^* = \sum_{k=1}^{K}\mathbf{p}_k \cdot w_k$。

随后，全局模型会广播给每个参与客户端，作为下一轮本地更新的初始化。请注意，每个客户端的解耦器 $\mathcal{A}_D$、校正器 $\mathcal{A}_C$ 和$\mathbf{m}$均保留在本地，不参与聚合。

4.4. 总结与讨论

在每个通信轮次中，通过优化 $\mathcal{L}$ 公式（9）来训练本地模型，使其适应私有数据集；随后，服务器以域感知聚合的方式收集这些本地权重，得到全局模型，并将其分发给每位参与者，作为下一通信轮次的初始化。F^2DC 的概览如图 3 所示，详细算法见算法 1。

此外，我们提出的 F^2DC 具有模块化特性，因此适用范围广泛。一方面，我们的解耦器 $\mathcal{A}_D$ 和校正器 $\mathcal{A}_C$ 可以轻松融入现有联邦学习方法，从而提升本地决策的鲁棒性。另一方面，在全局聚合中纳入领域差异，有助于增强域偏斜联邦学习场景中客户端之间的共识。从实验结果来看，仅通过我们的域特征解耦器和校正器增强 FedAvg [31]，便能在 PACS 上实现 8。94% 的性能提升 [19],详情请参阅表3。

5. 实验

5.1. 实验设置

数据集。我们在以下三个常用的多域数据集上进行实验：

算法 1： F^2DC 的伪代码流程

输入： 通信轮次 R，本地轮次 E，
客户端 K，第 k 个客户端的数据 $\mathcal{D}_k$ 和模型 w_k
输出： 最终的联邦学习全局模型 w_R^*
对于 每个通信轮次 $r = 1, 2, ..., R$ **do**
  $\mathcal{K}_r \Leftarrow \{1, ..., K\}$ // 随机选择客户端
  对每个客户端 $k \in \mathcal{K}_r$ **并行执行**
    $w_k \leftarrow$ **本地更新**(w_r^*)
  end
  /* 域感知聚合（第4.3节） */
  $\mathbf{d}_k \leftarrow (\mathcal{B}_k, \mathcal{G})$ 见式（10）// 差异
  $\mathbf{p}_k \leftarrow (\mathbf{d}_k, n_k)$ 见式（11）// 确定权重
  $w_{r+1}^* \leftarrow \sum_{k=1}^{|\mathcal{K}_r|} \mathbf{p}_k \cdot w_k$ // 全局模型
end
本地更新(w_r^*):
$w_k \leftarrow w_r^* + \{\mathcal{A}_D, \mathcal{A}_C, \mathbf{m}\}$ // 分发
对每个本地轮次 $e = 1, 2, ..., E$ **执行**
  对每个批次 $b \in$ 私有数据 $\mathcal{D}_k$ **执行**
    /* DFD模块（第4.1节） */
    $\mathcal{M}_i \leftarrow (\mathcal{A}_D, f_i)$ 见公式（3）// 掩码矩阵
    $f_i^+, f_i^- \leftarrow (\mathcal{M}_i, f_i)$ 见式（4）// 解耦
    $\mathcal{L}_{DFD}\ (f_i^+, f_i^-, y_i, \widehat{y_i}, \mathbf{m})_{i \in b} \leftarrow$ 式（5）
    /* DFC 模块（第4.2节） */
    $f_i^\star \leftarrow (\mathcal{A}_C, \mathcal{M}_i, f_i^-)$ 见式（6）// 校准
    $\mathcal{L}_{DFC}\ (f_i^\star, y_i, \mathbf{m})_{i \in b} \leftarrow$ 式（7）
    $\mathcal{L}_{CE}\ (\ell_i, y_i)_{i \in b} \leftarrow$ 式（8）
    $\mathcal{L} = \mathcal{L}_{CE} + \frac{1}{|L|} \sum_{j=1}^{|L|} (\lambda_1 \cdot \mathcal{L}_{DFD}^{L_j} + \lambda_2 \cdot \mathcal{L}_{DFC}^{L_j})$
    $w_k \leftarrow w_k - \eta \nabla \mathcal{L}(w_k; b)$ // 更新模型
  end
end
$w_k \leftarrow w_k - \{\mathcal{A}_D, \mathcal{A}_C, \mathbf{m}\}$ // 保留在本地
将 w_k 返回服务器

• Digits [33]包含四个域：MNIST (M)、USPS (U)、SVHN (SV) 和 SYN (SY)，共有10个类别。
• Office-Caltech [18] 由四个域组成：Caltech (C)、Amazon (A)、Webcam (W) 和 DSLR (D)，每个域均由 10 个重叠类别构成。

• PACS [19] 由四个域组成：Photo (P)、Art- Painting (AP)、Cartoon (Ct) 和 Sketch (Sk)。每个域包含 7 个类别。

域偏斜联邦学习场景。 根据 [5], ，我们分别为 Digits、Office-Caltech 和 PACS 初始化 20、10 和 10 个客户端。分配给这些客户端的域是随机生成后固定的：Digits（M：3，U：6，SV：6，SY：5）、Office-Caltech（C：3，A：2，W：2，D：3）、PACS（P：2，AP：3，Ct：2，Sk：3）。对于每个客户端，从分配到的域中随机选取本地数据，Digits、Office-Caltech 和 PACS 的选取比例分别为 1%、20% 和 30%。

模型架构。 为确保比较公平，我们使用 ResNet-10 [10] 开展实验，维度为 $d = 512$。所有对比方法均采用相同的模型。

对比方法。 我们将 F^2DC 与四类最先进（SOTA）基线方法进行比较：1）标准 FedAvg[31], FedProx [23]；2）基于对比的方法 MOON [20], FedRCL[36]；3）基于原型的方法 FPL [13], FedTGP [53], FedSA[57]；以及 4）基于共识的方法 FedHEAL [5], FDSE [48]。在这些方法中，FPL [13], FedHEAL [5], 和 FDSE[48]是为域偏斜联邦学习设计的。

实现细节。除非另有说明，我们运行$R = 100$ 全局通信轮次；Digits、Office-Caltech 和 PACS 数据集的客户端数量 K 分别设为 20、10 和 10。增加通信轮次后，所有方法的准确率几乎没有提升或完全没有提升 R。我们遵循 [20, 23]，使用 SGD 优化器更新模型，学习率 η 设为 0.01，动量设为 0.9，批量大小设为 64，权重衰减设为 10^{-5}，本地轮次设为 $E = 10$。嵌入的维度 d 为 512。我们通过实验将公式（3）中的 σ 设为 0.1，将公式（5）中的 τ 设为 0.06，$\lambda_1 = 0.8$ 和 $\lambda_2 = 1.0$ 设为公式（9）中的值，$\alpha = 1.0$ 和 $\beta = 0.4$ 设为公式（11）中的值。我们将第4.1节中的解耦器 $\mathcal{A}_D$ 和第4.2节中的校正器$\mathcal{A}_C$ 实现为带有批归一化和 ReLU 激活的两层卷积神经网络架构，其输入和输出均为 $\in \mathbb{R}^{C \times H \times W}$。公式（5）和公式（7）中的 m 是一个单层多层感知机架构，用于预测逻辑值 $\mathbb{R}^d \rightarrow \mathbb{R}^{\mathbb{C}}$。默认情况下，我们将 $\mathcal{A}_D$ 和 $\mathcal{A}_C$ 插入本地模型特征提取器的最后一个骨干层之后。

评估指标。 接下来 [23, 24], 我们使用每个领域的 top-1 准确率，以及跨域准确率的平均值（AVG）和标准差（STD）作为评估指标。所有报告的结果均为使用不同随机种子进行的三次独立运行的平均值。

5.2. 主要结果

与最先进方法的比较。 表 1 和表 2 展示了我们提出的 F^2DC 与九种竞争方法在 Digits、Office-Caltech 和 PACS 上的比较结果。这些结果从经验上表明，F^2DC 的表现始终优于其他方法，这证实了我们的方法在不同域之间具有良好的泛化能力，并提升了跨域公平性（即，标准差更小）。此外，我们观察到，基于对比的方法（例如，MOON、FedRCL）表现不佳，在 PACS 上甚至显著差于 FedAvg。这可能是因为，通过对比方案强制本地模型与折衷后的全局表征对齐会产生不利影响，并进一步加剧性能下降。这凸显了推动本地训练摆脱客户端特定领域偏差的重要性。与基于消除的领域偏斜联邦学习方法 FDSE 不同，F^2DC 通过校准域特定偏置特征，释放出更多类别相关线索，从而在不同域之间做出更准确的决策。

表1. **对　　比结果**在 Office-Caltech 和 PACS 上。最佳结果以**红色粗体**标出，次优结果以**蓝色粗　　ld**.

方法	Office-Caltech						PACS					
	Caltech											
FedAvg [AISTATS'17]	59.82	65.26	51.72	46.67	55.86	8.27	60.98	52.49	74.63	77.46	66.39	11.74
FedProx [MLSys'20]	60.18	66.11	54.96	47.30	57.13	7.98	61.88	57.40	76.34	80.14	68.94	11.00
MOON [CVPR'21]	57.14	63.16	44.48	40.87	51.41	10.49	59.72	50.29	70.35	70.22	62.64	9.63
FPL [CVPR'23]	60.05	65.53	52.90	64.45	60.73	5.75	66.67	58.38	79.75	77.59	70.59	9.95
FedTGP [AAAI'24]	61.28	63.84	53.37	63.68	60.54	4.92	60.68	56.06	75.27	78.03	67.51	10.78
FedRCL [CVPR'24]	60.27	65.89	48.72	50.14	56.24	8.64	61.37	55.17	70.78	76.57	65.97	9.54
FedHEAL [CVPR'24]	61.02	67.47	55.36	62.99	61.71	4.95	70.39	65.82	80.57	76.61	**73.34**	**6.54**
FedSA [AAAI'25]	63.52	66.21	56.90	58.93	61.39	**4.24**	68.55	60.42	78.32	75.50	70.69	7.98
FDSE [CVPR'25]	60.39	66.80	58.31	67.20	**63.18**	4.50	69.27	65.46	78.65	79.12	73.13	6.83
F^2领域偏斜（我们的方法）	62.95	68.42	64.79	71.12	**66.82**	**3.65**	75.15	68.71	79.91	82.11	**76.47**	**5.83**

表2. **比较结果** Digits 上的结果，续表 1。

方法	Digits					
	MNIST				平均值↑	
FedAvg	96.04	89.84	88.04	51.05	81.24	20.42
FedProx	96.13	89.04	87.56	51.00	80.93	20.30
MOON	94.70	89.64	87.68	34.40	76.60	28.29
FPL	96.12	89.94	89.15	49.15	81.09	21.52
FedTGP	95.38	87.49	87.37	49.40	79.91	20.68
FedRCL	93.08	89.73	84.98	51.20	79.75	19.32
FedHEAL	96.39	87.00	89.41	56.95	82.43	17.45
FedSA	94.85	90.74	88.48	57.41	82.87	17.18
FDSE	95.17	90.34	90.98	60.13	**84.15**	**16.19**
F^2DC（我们的方法）	97.75	92.94	90.53	67.69	**87.23**	**13.36**

表3. F^2DC 在 PACS 上的**模块化**，我们将提出的 DFD 和 DFC 插入四种强基线方法中。

方法	P	AP	Ct	Sk	平均值 ↑
FedAvg	74.86 ↑13.88	65.90 ↑13.41	79.70 ↑5.07	80.86 ↑3.40	75.33 ↑8.94
FPL	76.85 ↑10.18	64.46 ↑6.08	80.02 ↑0.27	80.75 ↑3.16	75.52 ↑4.93
FedHEAL	75.56 ↑5.17	65.95 ↑0.13	81.27 ↑0.70	77.48 ↑0.87	75.06 ↑1.72
FDSE	72.25 ↑2.98	65.99 ↑0.53	80.56 ↑1.91	80.36 ↑1.24	74.79 ↑1.66

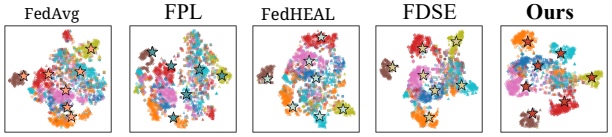


图4. **t-SNE可视化**（PACS）。每种颜色代表一个类别，每种形状代表一个领域，星形表示语义中心。

提升现有联邦学习方法的性能。 F^2DC 的一个关键优势是其模块化设计。如表
ble3，我们报告了基线方法与我们的 DFD 和 DFC 模块相结合后的结果，详细列出了最终准确率以及相较于原始方法的性能提升。结果表明，我们的两个模块能够在多个领域中持续提升性能。FedAvg 获益最大，相较于其原始版本，平均准确率提升了8.94%。

Table 4. **效率对比**（每轮 10 个客户端）　　在 PACS 上。

方法	上传$_{\times 10^7}$	通信	FLOPs$_{\times 10^{10}}$	时间$_{train}$
FedAvg	5.43	193.72MB	16.31	176.94秒
FPL	5.45	197.30MB	19.45	215.61秒
FedHEAL	5.43	193.72MB	16.70	186.92秒
F^2DC	5.43	193.72MB	16.46	180.67s

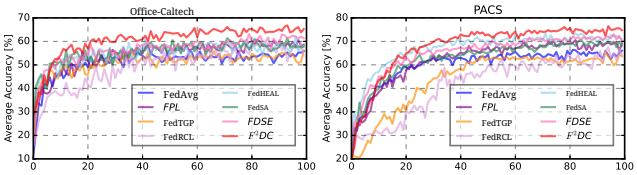


图5. **Office-Caltech上平均准确率的收敛情况对比**（**左图**）和 PACS（**右图**）。放大查看详情。

t-SNE可视化。图4 展示了 PACS 上不同联邦学习方法的表征空间 t-SNE [40] 可视化结果。与这四种强基线方法相比，1）F^2DC 提高了类间可分性，即与其他方法相比，不同颜色样本之间的距离更大；2） F^2DC 减小了同色样本的类内距离，从而使聚类更加紧密。这进一步表明 F^2DC 能够在不同领域中建立一致的语义表征和决策边界。

效率分析。表4 展示了PACS数据集上10 个客户端的通信和计算成本。与FedAvg相比， F^2DC不会产生额外的通信成本。 F^2DC以适中的计算成本取得了更优的性能，额外的训练成本主要来自解耦器和校正器。

收敛。 在图5中，我们绘制了各种联邦学习方法每轮的平均准确率。可以观察到，我们的F^2DC 收敛速度更快，并且随着训练的进行，最终取得了更好的性能。

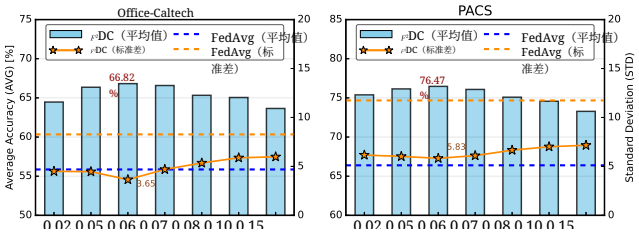


图6. **超参数研究** 使用不同的 τ 公式（5）。

表5. **超参数研究** 使用 σ 公式（3）在 PACS 上。

σ	0.01	0.05	0.1	0.3	0.5	1.0	5.0
平均值 ↑	74.81	75.19	**76.47**	75.34	74.40	74.15	73.86
标准差 ↓	6.48	6.32	**5.83**	6.35	6.71	7.05	7.23



图7. **超参数研究**，采用 α 和 β，针对公式（11）。

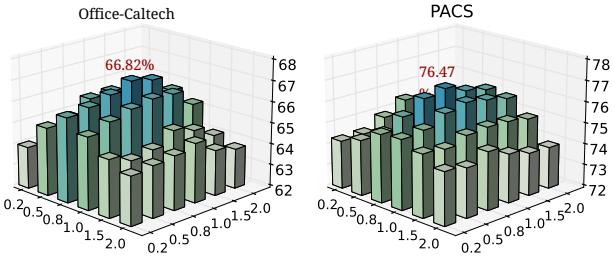


图8. **超参数研究**，采用 λ_1 和 λ_2，针对公式（9）。

5.3. 验证分析

超参数研究。 我们首先在图 τ （公式（5））中考察超参数6的影响，结果表明，较小的 τ 比更大的值更有利于特征分离。我们观察到 F^2DC 对 $\tau \in [0.05, 0.07]$ 并不敏感，并且当 $\tau = 0.06$时性能最佳。

随后，我们在表 σ （公式（3））中报告超参数对掩码矩阵离散程度的影响，其中超参数控制5。对于较低的 σ 值，公式（ $\mathcal{M}_i$ 3）中的掩码矩阵会变得更加离散；对于较高的值， $\mathcal{M}_i$ 则会变得更加均匀。过小的 σ 值（$\rightarrow$ 二元采样）或过大的值（$\rightarrow$ 均匀采样）都会妨碍训练。

我们研究了 α 和 β 式（11）在较大范围内的表现，并在图7中展示了准确率。我们观察到 F^2DC 通过纳入域差异提升了性能。总体而言， $\alpha \in [0.8, 1.2]$ 和 $\beta \in [0.3, 0.5]$是域感知聚合的合适选择，可使 F^2DC 获得稳定且有竞争力的性能。此外，我们还展示了不同 λ_1 和 λ_2 式（9）的准确率

表6. **消融研究**：我们 F^2DC 在 Office-Caltech（**上方**）和 PACS（**下方**）上的关键模块。详情请参见第5.3节。

$\mathcal{L}_{DFD}$	Di	C	A	W	D	平均值↑	
		59.82	65.26	51.72	46.67	55.86	8.27
	✓	60.25	65.79	54.39	50.33	57.69	6.76
✓	✓	66.68	67.53	56.56	60.02	62.70	5.30
✓	✓	63.71	68.21	59.07	67.62	64.65	4.22
✓	✓	60.84	67.79	62.10	70.45	65.29	4.57
✓	✓	✓	62.95				**3.65**

$\mathcal{L}_{DFD}$	Di	P	AP	Ct	Sk	平均值↑	
		60.98	52.49	74.63	77.46	66.39	11.74
	✓	61.28	57.64	75.71	79.09	68.43	10.15
✓	✓	72.95	61.52	79.06	80.13	73.41	8.35
✓	✓	72.55	65.44	77.61	78.95	73.64	6.12
✓	✓	74.86	65.90	79.70	80.86	75.33	6.80
✓	✓	✓	75.15			**76.47**	**5.83**

表7. **对 DC 各种特征的消融研究**，针对 PACS。

协议	P	AP	Ct	Sk	平均值 ↑	标准差 ↓
f^+	74.21	67.52	78.35	80.47	75.13	5.90
f^-	59.45	50.09	52.56	69.37	57.87	8.63
$f^\star$	74.83	64.05	75.80	79.29	73.49	6.71
$\widetilde{f}$	75.15	68.71	79.91	82.11	**76.47**	**5.83**

见图8。结果表明， F^2DC 在不同的 λ_1 和 λ_2 取值下均能保持稳定的性能，但过大的 λ_1 或 λ_2 会导致优化不稳定性。当 $\alpha = 1.0$， $\beta = 0.4$ 时，准确率提升幅度很小（见图7 和 $\lambda_1 = 0.8$， $\lambda_2 = 1.0$ 见图8。

消融研究。 我们在表 6（第一行对应 FedAvg [31]）。我们观察到，每个组件都对整体性能有积极贡献，而将它们组合起来则能获得最佳性能。这支持了我们的动机：通过 DFD 解耦局部特征，再通过 DFC 校准域偏置特征。

在表7中，我们随后报告了在 PACS 上使用 F^2 DC 获得的各种特征的结果。结果表明， f^+显著优于 f^-，这表明我们的解耦器能够有效地解耦局部特征。与 f^-相比， $f^\star$取得了持续的改进，这说明 $f^\star$ 捕获了额外的类别相关线索，可用于跨域决策。

6. 结论

本文提出了用于域偏斜联邦学习的联邦特征解耦与校准（F^2DC）。为此， F^2DC 将局部特征解耦，并校正存在领域偏差的特征，以提取更多有用线索；同时执行域感知聚合，促进客户端之间达成共识。大量实验结果证明了所提出的 F^2DC 的有效性和模块化特性。

致谢

本研究部分获得澳大利亚研究理事会联结项目 LP210300009 和 LP230100083、新加坡教育部（MOE）学术研究基金（AcRF）一级资助（24-SIS-SMU-008）、新加坡科技研究局的 MTC YIRG 资助（M24N8c0103）以及李光前奖学金（T050273）的支持。

参考文献

[1] Sikai Bai、张杰、郭松、李帅成、Jingcai Guo、侯军、韩涛和卢晓成。Diprompt：用于联邦学习中多种潜在域泛化的解耦提示调优。载于 CVPR，第 27284–27293 页，2024年。3[2] Cosmin I Bercea、Benedikt Wiestler、Daniel Rueckert 和 Shadi Albarqouni。用于无监督脑部异常检测的联邦解耦表示学习。《自然·机器智能》，4(8)：685–695，2022年。3[3] 蔡兆伟和 Nuno Vasconcelos。重新思考混合精度神经网络的可微搜索。载于 CVPR，第 2349–2358 页，2020年。4[4] 陈佳怡和张爱东。论模态与任务无关的联邦学习中非对称知识迁移的解耦。载于 AAAI，第 11311–11319 页，2024年。3[5] 陈宇航、Wenke Huang 和 Mang Ye。域偏斜条件下基于局部一致性与领域多样性的公平联邦学习。载于 CVPR，第 12077–12086 页，2024年。3, 6[6] 傅乐乐、黄胜、赖衍义、廖天池、张传福和陈川。超越联邦原型学习：面向域偏斜数据的可学习语义锚点与超球面对比。载于 AAAI，第 16648–16656 页，2025年。3 – .[7] 傅乐乐、黄胜、赖衍义、张传福、Hong-Ning Dai、郑子彬和陈川。通过对齐表示空间与参数空间实现特征偏移下的联邦领域无关原型学习。《IEEE 移动计算汇刊》，24(9)：9004–9019，2025年。2[8] Marco Fumero、Florian Wenzel、Luca Zancato、Alessandro Achille、Emanuele Rodol`a、Stefano Soatto、Bernhard Sch¨olkopf 和 Francesco Locatello。利用稀疏且共享的特征激活进行解耦表示学习。载于 NeurIPS，第 27682–27698 页，2023年。3[9] 高亮、Huazhu Fu、李莉、陈英雯、徐明和徐成忠。FedDC：通过局部漂移解耦与校正处理非独立同分布数据的联邦学习。载于 CVPR，第 10112–10121 页，2022年。3[10] 何恺明、张祥雨、任少卿和孙剑。用于图像识别的深度残差学习。载于 CVPR，第 770–778 页，2016年。3, 4, 6[11] 黄胜、傅乐乐、廖天池、邓博文、张传福和陈川。FedBG：利用背景数据主动缓解跨域图联邦学习中的偏差。载于国际人工智能联合会议，第 5408–5416 页，2025年。3[12] Wenke Huang、Mang Ye 和 Bo Du。在异构联邦学习中，向他人学习，做自己。载于 CVPR，第 10143–10153 页，2022年。3[13] Wenke Huang、Mang Ye、Zekun Shi、He Li 和 Bo Du。《重新思考领域偏移下的联邦学习：原型视角》。发表于 CVPR，第 16312–16322 页，2023年。3、6[14] Wenke Huang、Mang Ye、Zekun Shi、Guancheng Wan、He Li、Bo Du 和 Qiang Yang。《面向泛化、鲁棒性与公平性的联邦学习：综述与基准》。IEEE TPAMI，46(12)：9387–9406，2024年。3[15] Meirui Jiang、Zirui Wang 和 Qi Dou。《HarmoFL：异构医疗图像联邦学习中的本地与全局漂移协调》。发表于 AAAI，第 1087–1095 页，2022年。3[16]Peter Kairouz、H Brendan McMahan、Brendan Avent、Aur´elien Bellet 等。《联邦学习的进展与开放问题》。《机器学习基础与趋势》，14(1)：1–210，2021年。1[17] Sai Praneeth Karimireddy、Satyen Kale、Mehryar Mohri、Sashank Reddi、Sebastian Stich 和 Ananda Theertha Suresh。《SCAFFOLD：联邦学习的随机控制平均》。发表于 ICML，第 5132–5143 页，2020年。1[18] Boqing Kong、Yuan Shi、Fei Sha 和 Kristen Grauman。《用于无监督领域自适应的测地流核》。发表于 CVPR，第 2066–2073 页，2012年。6[19] Da Li、Yongxin Yang、Yi-Zhe Song 和 Timothy M Hospedales。《更深、更广、更具艺术性的领域泛化》。发表于 ICCV，第 5542–5550 页，2017年。1、3、5、6[20] Qinbin Li、Bingsheng He 和 Dawn Song。《模型对比联邦学习》。发表于 CVPR，第 10713–10722 页，2021年。6[21] Qinbin Li、Yiqun Diao、Quan Chen 和 Bingsheng He。《非独立同分布数据孤岛上的联邦学习：一项实验研究》。发表于 ICDE，第 965–978 页，2022年。1、3[22] Tian Li、Anit Kumar Sahu、Ameet Talwalkar 和 Virginia Smith。《联邦学习：挑战、方法与未来方向》。《IEEE信号处理杂志》，37(3)：50–60，2020年。1、3[23] Tian Li、Anit Kumar Sahu、Manzil Zaheer、Maziar Sanjabi、Ameet Talwalkar 和 Virginia Smith。《异质网络中的联邦优化》。发表于 MLSys，第 429–450 页，2020年。1、3、6[24] Tian Li、Maziar Sanjabi、Ahmad Beirami 和 Virginia Smith。《联邦学习中的公平资源分配》。发表于 ICLR，2020年。6[25] Xiang Li、Kaixuan Huang、Wenhao Yang、Shusen Wang 和 Zhihua Zhang。《关于非独立同分布数据上 FedAvg 的收敛性》。发表于 ICLR，2020年。1、3[26] Xiang Li、Yasushi Makihara、Chi Xu、Yasushi Yagi 和 Mingwu Ren。《通过半监督解耦表示学习身份与协变量特征的步态识别》。发表于 CVPR，第 13309–13319 页，2020年。3[27] Yichen Li、Wenchao Xu、Haozhao Wang、Yining Qi、Jingcai Guo 和 Ruixuan Li。《基于自适应知识匹配的个性化联邦领域增量学习》。发表于 ECCV，第 127–144 页，2024年。3[28] Zhiwei Li、Guodong Long、Tianyi Zhou、Jing Jiang 和 Chengqi Zhang。《个性化联邦协同过滤：一种变分自编码器方法》。发表于 AAAI，第 18602–18610 页，2025年。3

[29] Christos Louizos、Max Welling 和 Diederik P King ma。《通过 l_0 正则化学习稀疏神经网络》。发表于 ICLR，2018年。4[30] Jianxin Ma、Chang Zhou、Peng Cui、Hongxia Yang 和 Wenwu Zhu。《学习用于推荐的解耦表示》。发表于 NeurIPS，第 5711–5722 页，2019年。3[31] Brendan McMahan、Eider Moore、Daniel Ramage、Seth Hampson 和 Blaise Aguera y Arcas。《基于去中心化数据的深度网络通信高效学习》。发表于 AISTATS，第 1273–1282 页，2017年。1、2、3、5、6、8[32] Yujie Mo、Yajie Lei、Jialie Shen、Xiaoshuang Shi、Heng Tao Shen 和 Xiaofeng Zhu。《解耦多重图表示学习》。发表于 ICML，第 24983–25005 页，2023年。3[33] Xingchao Peng、Qinxun Bai、Xide Xia、Zijun Huang、Kate Saenko 和 Bo Wang。《多源领域自适应的矩匹配》。发表于 ICCV，第 1406–1415 页，2019年。6[34] De Boer Pieter-Tjerk、Dirk P Kroese、Shie Mannor 和 Reuven Rubinstein。《交叉熵方法教程》。《运筹学年鉴》，134(1)：19–67，2005年。5[35] Ramprasaath R Selvaraju、Michael Cogswell、Abhishek Das、Ramakrishna Vedantam、Devi Parikh 和 Dhruv Batra。《Grad-CAM：通过基于梯度的定位实现深度网络的视觉解释》。发表于 ICCV，第 618–626 页，2017年。2[36] Seonguk Seo、Jinkyu Kim、Geeho Kim 和 Bohyung Han。《面向联邦学习的松弛对比学习》。发表于 CVPR，第 12279–12288 页，2024年。6[37] Benyuan Sun、Hongxing Huo、Yi Yang 和 Bo Bai。《PartialFed：通过部分初始化实现跨域个性化联邦学习》。发表于 NeurIPS，第 23309–23320 页，2021年。3[38] Canh T Dinh、Nguyen Tran 和 Josh Nguyen。《基于 Moreau 包络的个性化联邦学习》。发表于 NeurIPS，第 21394–21405 页，2020年。3[39] Md Palash Uddin、Yong Xiang、Xuequan Lu、John Yearwood 和 Longxiang Gao。《通过解耦信息瓶颈实现联邦学习》。《IEEE服务计算汇刊》，16(3)：1874–1889，2022年。3[40] Laurens van der Maaten 和 Geoffrey Hinton。《使用 t-SNE 可视化数据》。《机器学习研究杂志》，9(86)：2579–2605，2008年。7[41] Feng Wang 和 Huaping Liu。《理解对比损失的行为》。发表于 CVPR，第 2495–2504 页，2021年。4[42] Haozhao Wang、Haoran Xu、Yichen Li、Yuan Xu 等。《FedCDA：采用跨轮次散度感知聚合的联邦学习》。发表于 ICLR，2024年。1、3[43] Huan Wang、Haoran Li、Huaming Chen、Jun Yan、Jiahua Shi 和 Jun Shen。《FedDifRC：释放文本到图像扩散模型在异构联邦学习中的潜力》。发表于 ICCV，第 3726–3736 页，2025年。1[44] Huan Wang、Haoran Li、Huaming Chen、Jun Yan、Jiahua Shi 和 Jun Shen。《FedSC：采用语义感知协作的联邦学习》。发表于 ACM SIGKDD，第 2938–2949 页，2025年。3[45] Huan Wang、Haoran Li、Huaming Chen、Jun Yan、Lijuan Wang、Jiahua Shi、Shiping Chen 和 Jun Shen。《FedSKC：基于结构化知识协作的非独立同分布数据联邦学习。在 IEEE国际Web服务会议 上，第 702–712 页，2025年。3[46] Xin Wang、Hong Chen、Si'ao Tang、Zihao Wu 和 Wenwu Zhu。解耦表示学习。IEEE TPAMI，46（12）：9677–9696，2024年。3[47] Yuan Wang、Huazhu Fu、Renuga Kanagavelu、Qingsong Wei 等。用于应对数据异质性的无聚合联邦学习。在 CVPR 上，第 26233–26242 页，2024年。1，3[48] Zheng Wang、Zihui Wang、Xiaoliang Fan 和 Cheng Wang。带有域偏移消除器的联邦学习。在 CVPR 上，第 4978–4987 页，2025年。2，3，6[49] Haoran Xu、Jiaze Li、Wanyi Wu 和 Hao Ren。缓解样本级客户端漂移的联邦学习。在 AAAI 上，第 21752–21760 页，2025年。3[50] Peng Yan 和 Guodong Long。联邦学习的个性化解耦。在 ICME 上，第 318–323 页，2023年。3[51] Rui Ye、Mingkai Xu、Jianyu Wang、Chenxin Xu、Siheng Chen 和 Yanfeng Wang。Feddisco：差异感知协作的联邦学习。在 ICML 上，第 39879–39902 页，2023年。1，3[52] Jianqing Zhang、Yang Hua、Hao Wang、Tao Song、Zhengui Xue、Ruhui Ma 和 Haibing Guan。Fedala：用于个性化联邦学习的自适应本地聚合。在 AAAI 上，第 11237–11244 页，2023年。3[53] Jianqing Zhang、Yang Liu、Yang Hua 和 Jian Cao。FedTGP：可训练全局原型与自适应间隔增强对比学习，用于联邦学习中的数据和模型异质性。在 AAAI 上，第 16768–16776 页，2024年。6[54] Jianqiao Zhang、Caifeng Shan 和 Jungong Han。Fedgmkd：一种通过知识蒸馏和差异感知聚合实现的高效原型联邦学习框架。在 NeurIPS 上，第 118326–118356 页，2024年。3[55] Kaike Zhang、Qi Cao、Gaolin Fang、Bingbing Xu、Hongjian Zou、Huawei Shen 和 Xueqi Cheng。Dyted：离散时间动态图的解耦表示学习。在 ACM SIGKDD 上，第 3309–3320 页，2023年。3[56] Ziyuan Zhang、Luan Tran、Xi Yin、Yousef Atoum、Xiaoming Liu、Jian Wan 和 Nanxin Wang。基于解耦表示学习的步态识别。在 CVPR 上，第 4710–4719 页，2019年。3[57] Yanbing Zhou、Xiangmou Qu、Chenlong You、Jiyang Zhou、Jingyue Tang、Xin Zheng、Chunmao Cai 和 Yingbo Wu。Fedsa：基于语义锚点的统一表示学习，用于基于原型的联邦学习。在 AAAI 上，第 23009–23017 页，2025年。3，6[58] Hangyu Zhu、Jinjin Xu、Shiqing Liu 和 Yaochu Jin。非独立同分布数据上的联邦学习：综述。Elsevier Neurocomputing，465：371–390，2021年。1，3