

去中心化联邦学习的分层策略与动态资源联合优化^①



张 昕¹, 陈雨彤¹, 金子龙²

¹(南京信息工程大学 软件学院, 南京 210044)

²(浙江理工大学 信息科学与工程学院, 杭州 310018)

通信作者: 金子龙, E-mail: zljn@outlook.com

摘 要: 针对去中心化联邦学习中因节点动态异构性及通信资源分配不合理导致的模型收敛效率低、通信开销大等问题, 本文提出一种基于深度强化学习的分层设备通信优化方案. 首先, 构建分层拓扑驱动的联邦学习框架, 底层设备通过 Gossip 协议实现局部模型聚合, 高层代表节点执行跨区域全局协同, 降低通信频率并缓解动态网络下的参数不一致问题. 其次, 设计基于深度确定性策略梯度 (deep deterministic policy gradient, DDPG) 的动态资源联合优化算法, 通过联合调整节点协作策略与频谱资源分配, 自适应平衡通信成本与模型精度, 抑制设备间传输差异引起的全局模型偏移. 实验结果表明, 在 MNIST 和 CIFAR-10 数据集上, 所提方案相较于传统去中心化联邦学习方法, 模型预测精度平均提升 2.61%, 通信能耗降低 64.1%.

关键词: 去中心化; 联邦学习; 分层拓扑; 深度强化学习; 资源联合优化

引用格式: 张昕, 陈雨彤, 金子龙. 去中心化联邦学习的分层策略与动态资源联合优化. 计算机系统应用, 2025, 34(11): 30-41. <http://www.c-s-a.org.cn/1003-3254/9986.html>

Hierarchical Strategy and Dynamic Resource Joint Optimization for Decentralized Federated Learning

ZHANG Xin¹, CHEN Yu-Tong¹, JIN Zi-Long²

¹(School of Software, Nanjing University of Information Science & Technology, Nanjing 210044, China)

²(School of Information Science and Engineering, Zhejiang Sci-tech University, Hangzhou 310018, China)

Abstract: In view of the low convergence efficiency and high communication overhead caused by dynamic heterogeneity among nodes and unreasonable communication resources in decentralized federated learning (DFL), this study proposes a hierarchical device-to-device (D2D) communication optimization scheme based on deep reinforcement learning. First, a hierarchical topology-driven federated learning framework is constructed. Specifically, the bottom-layer devices achieve local model aggregation via the Gossip protocol, while the top-layer representative nodes perform cross-region global collaboration, thus reducing communication frequency and mitigating the parameter inconsistency under dynamic networks. Second, a dynamic resource joint optimization algorithm based on deep deterministic policy gradient (DDPG) is designed to jointly optimize node collaboration strategies and spectrum resource allocation, adaptively balancing communication costs and model accuracy while suppressing the global model displacement caused by transmission disparities among devices. Experimental results on the MNIST and CIFAR-10 datasets demonstrate that the proposed scheme improves average model prediction accuracy by 2.61% and reduces communication energy consumption by 64.1%, compared to traditional decentralized federated learning methods.

① 基金项目: 国家自然科学基金 (62271264)

收稿时间: 2025-03-31; 修改时间: 2025-05-07; 采用时间: 2025-05-15; csa 在线出版时间: 2025-09-18

CNKI 网络首发时间: 2025-09-19

Key words: decentralized; federated learning; hierarchical topology; deep reinforcement learning; resource joint optimization

随着 5G 网络的广泛部署和边缘计算技术的快速发展,移动终端设备产生的数据呈现指数级别增长,智能手机、物联网传感器等边缘节点正成为数据生态系统的核心载体.以智能交通系统为例,车载传感器需要实时处理道路环境数据以实现碰撞预警,但受《通用数据保护条例》(GDPR)等法规限制,车辆原始数据难以上传至中心服务器.在此背景下,联邦学习凭借其数据隐私保护机制,成为实现分布式智能协同的关键技术^[1].然而,传统联邦学习依赖中心服务器架构,逐渐暴露出单点故障风险与可扩展性瓶颈.例如在工业物联网场景,中心服务器宕机将中断全局模型更新,影响设备故障预测的可靠性^[2].为此,去中心化联邦学习(DFL)^[3]应运而生,DFL通过节点间点对点通信构建分布式协作网络,节点不仅在本地训练模型,还能直接交换模型参数与共享信息,有效降低对中心服务器的依赖,在增强系统鲁棒性的同时,进一步契合了边缘计算场景的发展需求.尽管DFL缓解了中心化架构的部分问题,但在海量异构边缘设备之间进行频繁模型交换,通信开销急剧攀升,成为制约实用化的核心障碍.尤其在动态边缘环境中,设备性能异构、网络条件差异与拓扑结构不稳定^[4],导致了以下关键挑战.

(1) 节点异构性强^[5]:设备计算能力与网络状态差异显著,导致本地训练时延波动大;边缘数据呈现非独立同分布,易引发模型聚合偏差.

(2) 通信资源分配低效:传统静态拓扑结构^[6,7]难适应节点动态变化,资源争抢导致关键梯度延迟传输,异步通信引发模型偏移,影响收敛效率.

(3) 效率与精度难以兼顾:压缩通信虽节省资源,但可能损失模型关键信息,难以实现协同优化.

上述挑战相互耦合,导致传统DFL模型在收敛效率和稳定性方面的不足.节点的异构性与资源分配问题共同作用,导致了局部聚合效率低下以及全局模型的偏移,此外效率与精度之间的失衡也影响了模型的鲁棒性.因此,本文聚焦的问题是如何在异构、动态边缘环境中构建自适应动态网络特性的联合优化框架,通过协调节点协作策略、动态资源分配与多目标平衡机制,实现边缘场景下高效且鲁棒的联邦学习部署.

针对上述问题,本文提出了一种基于双层拓扑的去中心化联邦学习聚合框架,并进一步考虑通信成本和通信时延限制,利用强化学习策略实现模型训练效果优化.该框架通过引入Gossip协议^[8]实现D2D有效聚合,设计了双层节点拓扑结构动态稀疏化,基于强化学习针对去中心化联邦学习模型进行动态优化,旨在保障通信开销和时延的基础上,提高模型的训练精度和收敛速度.具体的研究目标和贡献如下.

(1) 提出基于分层拓扑的去中心化联邦学习方案,低层节点采用Gossip协议聚合,高层代表节点全局聚合,以减少通信开销,加速模型收敛,适应网络异构性和节点动态变化.

(2) 设计基于DDPG强化学习的去中心化联邦学习联合优化方案,考虑到双层拓扑架构下的通信开销与整体时延,利用分布式部署强化学习代理结合全局协同策略实现模型精度与通信优化.

(3) 通过与基线模型的对比,本文提出的模型在MNIST数据集和CIFAR-10数据集上,模型精度和通信消耗上均达到更好的表现.

1 相关工作

去中心化联邦学习的模型优化研究主要围绕通信效率提升、收敛性能保障、模型稳定性增强以及训练效果等关键问题展开.DFL摒弃了中心化服务器^[9],以分布式对等(peer-to-peer, P2P)方式进行模型更新,使其在面对设备离线、节点动态变化等场景下更具鲁棒性和扩展性.但缺乏中心协调也意味着通信成本上升,如何在有限通信资源下实现高效协作成为研究重点.

研究者们提出了多种方法以缓解通信负担并提升系统性能.一些工作尝试从物理层与模型压缩角度降低通信负担,例如Yang等人^[10]结合空中计算提出二阶优化算法加快模型收敛,Chen等人^[11]则通过非均匀化与自适应策略减少模型参数传输.

由于去中心化联邦学习通常采用拓扑结构进行信息传递,拓扑设计对通信效率有重要影响.Li等人^[12]提出了一种异步去中心化FL方法,基于Push-Sum协议减少网络负载,提高模型收敛速度.Zhai等人^[13]提出了

一种多输入多输出 (MIMO) 技术优化的空中 DFL (OA-DFL) 框架, 结合混合矩阵优化模型聚合, 有效提升通信效率和收敛性能. 乔少杰等人^[14]提出了一种基于贡献度证明的去中心化联邦学习框架, 设计了新的共识机制减少存储开销, 提升学习效率. Masmoudi 等人^[15]提出了 OCD-FL 框架, 该框架基于对等方选择机制, 实现通信开销控制和效率提升.

在实际应用中, 通信链路的不可靠性会影响 DFL 的稳定性, 研究通过引入动态拓扑, 增强模型可靠性. Li 等人^[16]研究了不可靠通信信道对 DFL 的影响, 提出动态调整本地聚合轮次以降低通信错误对模型收敛的影响. Xiong 等人^[17]提出了一种 RIS 辅助拓扑控制方法, 利用可重构智能表面 (RIS) 动态调整网络拓扑, 提高通信链路的可靠性和整体系统性能.

尽管上述研究在单一目标优化上取得了一定进展, 但在多目标协同优化方面仍面临挑战. 部分工作虽尝试在通信效率与模型精度间寻求平衡, 例如 Tang 等人^[18]提出 GossipFL 框架, 稀疏化和 Gossip 算法用来减少通信开销, 但关键梯度丢失可能影响模型精度; Elgabli 等人^[19]通过层级联邦优化减少通信频率, 取得较好平衡, 但静态通信策略难以适应动态网络结构的变化.

此外, 如何在通信开销和计算资源之间取得平衡也成为研究热点. Huang 等人^[20]从理论角度分析了非凸去中心化优化的理论极限, 提出在保持收敛速度的同时最小化通信复杂度; Tan 等人^[21]针对异构通信网络中的 DFL 优化问题, 提出了 FedStar 框架, 利用异步通信与权重聚合提升高延迟网络中的模型训练效率; Liu 等人^[22]在 D2D 网络中研究了自适应簇头选择与资源调度机制, 提升了协作效率与系统稳定性. 上述方案仍旧停留在静态框架, 未考虑动态环境.

近年来, 强化学习也逐渐被引入 DFL, 以实现多目标联合优化, 例如 Nguyen 等人^[23]设计了 FedDRL 框架, 利用深度强化学习方法动态分配客户端聚合权重, 以缓解性能偏差问题. 此外, Sun 等人^[24]构建了 PG-FFL, 通过奖励函数设计以提升异构客户端间的性能一致性. 这些研究表明, 强化学习策略在 DFL 环境下存在提升系统适应性和多目标性能的潜力.

尽管已有研究尝试将强化学习用于联邦学习系统参数优化^[23,24], 但在 DFL 场景下, 强化学习用于通信优化问题仍需进一步探索. Yin 等人^[25]提出的 FWDDPG 方法是面向 DFL 的强化学习方案尝试, 通过深度强化

学习策略对 5G 小基站间的双工切换进行优化控制, 降低通信负担并提升收敛效率, 为 DFL 中动态调度问题提供了有效路径.

然而, 现有 DFL 优化方法大多依赖固定设计或静态策略, 难以应对动态网络环境中通信效率与模型性能的双重要求. 为此, 本文提出一种联合优化框架, 设计支持异构节点的分层拓扑机制, 并引入基于深度强化学习的自适应调度策略, 以实现通信与计算资源的协同优化, 全面提升 DFL 的实用性与动态适应性.

2 系统建模

2.1 网络拓扑定义

对于一个有 N 个移动设备 (智能移动电话或智能车辆) 组成的设备-设备 (device to device, D2D) 网络而言, 其中每个设备都携带一定量的数据, 并具有一定的计算能力, 在网络中作为客户端节点来参与训练任务, 设备与设备间可以两两建立链接, 所有设备共同组成的无向图则代表了当下该网络的拓扑关系, 如图 1 所示. 该网络区别于传统以参数服务器为核心的 FL, 设备与设备之间建立链接进行模型参数交换.

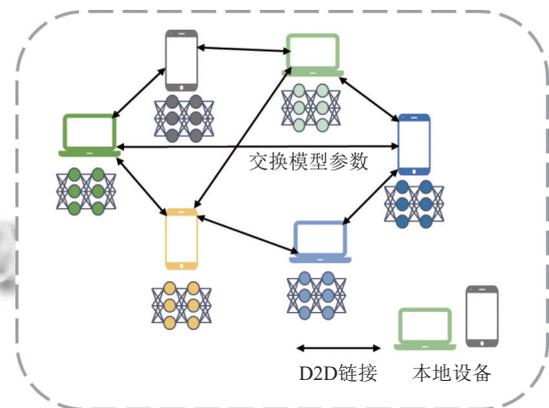


图1 D2D联邦学习架构

该网络下的设备节点集合则可以表示为 $N = \{1, 2, \dots, N\}$, $N = |N|$ 表示节点的总数. 若两个节点 $(i, j) \in N^2$ 处于彼此的通信范围内, 则它们之间存在连接关系, 对于节点 i 而言, 它的邻域可以表示为 $K_i = \{j \in N | (i, j) \in N^2\}$, 代表所有与节点 i 相连接的邻居节点. 考虑现实动态环境, 网络拓扑可能会发生变化, 即节点邻域 K_i 可能会随时间发生变化.

2.2 联邦学习框架

对于去中心化联邦学习的客户端节点而言, 每个

客户端都在执行本地训练任务, 节点 i 的本地训练损失可以表示为:

$$L_i(\theta_i) = \frac{1}{M_i} \sum_{j=1}^{m_i} L(x_j; \theta_i) \quad (1)$$

其中, M_i 是节点 i 本地训练样本量. $L(x_j; \theta_i)$ 是节点 i 对于第 j 个样本 x_j 和模型参数 θ_i 的损失函数.

在去中心化联邦学习中, 每个节点在完成本地训练后, 会将更新的模型参数 θ_i 发送给其邻接节点, 以便全局模型能够进行更新. 全局模型的更新过程由网络中各节点的本地更新结果聚合来实现. 全局模型的更新过程可以表示为:

$$\theta = \frac{1}{|N|} \sum_{i \in N} \theta_i \quad (2)$$

其中, $|N|$ 为网络中节点总数, 即网络中节点数量. θ_i 为节点 i 的模型参数. 全局损失函数可以表示为:

$$L(\theta) = \frac{1}{|N|} \sum_{i \in N} \left(\frac{1}{m_i} \sum_{j=1}^{m_i} L(x_j; \theta_i) \right) \quad (3)$$

2.3 通信成本与传输时延模型

本文采用正交频分多址 (OFDMA)^[26] 作为本地参数上传的数据访问方式. OFDMA 技术通过将可用带宽划分为多个独立的子载波, 使多个节点能够同时进行数据传输, 从而提高通信效率并降低信道干扰. 为了更清晰地描述数据传输的过程, 基于香农公式计算每个节点的传输速率, 并进一步分析路径损耗、时延和能耗等关键通信参数.

2.3.1 数据传输速率

在 OFDMA 系统中, 整个可用带宽 B_{total} 被划分为 S 个子载波, 每个子载波带宽为:

$$\Delta B = \frac{B_{\text{total}}}{S} \quad (4)$$

对于节点 i 通过子载波 c 传输数据到节点 j , 其传输速率可由香农容量公式计算得到:

$$R_{ij}^{(c)} = \Delta B \cdot \log_2(1 + \text{SNR}_{ij}^{(c)}) = \Delta B \cdot \log_2 \left(1 + \frac{P_{\text{tx},i}^{(c)} |h_{ij}^{(c)}|^2}{N_0 \Delta B} \right) \quad (5)$$

其中, $\text{SNR}_{ij}^{(c)}$ 是信噪比, $P_{\text{tx},i}^{(c)}$ 是节点 i 在子载波 c 上的发送功率 (W), $h_{ij}^{(c)}$ 是包含路径损耗和信道衰落的信道增益, N_0 则是噪声功率谱密度 (W/Hz).

由于数据传输往往涉及多个子载波, 因此节点 i 到 j 的总传输速率为所有子载波速率之和:

$$R_{ij} = \sum_{c=1}^S R_{ij}^{(c)} \quad (6)$$

多子载波传输能够在 D2D 环境下有效提升数据吞吐量, 在复杂网络环境能够保持较好的通信性能.

2.3.2 路径损耗模型

在无线通信中, 信道增益 $h_{ij}^{(n)}$ 受到多种因素的影响, 其中最主要的是路径损耗. 节点 i 到 j 的信道增益幅度平方, 可以表示为:

$$|h_{ij}^{(c)}|^2 = \frac{G_i G_j (\lambda^{(c)})^2}{(4\pi d_{ij})^2 L} \quad (7)$$

其中, d_{ij} 代表节点 i 与 j 的物理距离 (m), $\lambda^{(c)}$ 表示信号波长 (m), $\lambda = c/f_c^{(c)}$, c 为光速, $f_c^{(c)}$ 为子载波的中心频率, $G_i G_j$ 指的是发射与接收天线增益, L 则是其他损耗因子, 例如障碍物穿透损耗、衰落等. 随着节点间距离 d_{ij} 的增加, 信道增益将显著下降, 导致数据传输速率降低.

2.3.3 传输时延

在 FL 通信过程中, 传输时延是影响整体训练时间的关键因素. 数据从节点 i 传输到节点 j 时间表示为:

$$t_{ij} = \frac{S_{\text{eff}}}{R_{ij}} = \frac{\rho \cdot S_{\text{full}}}{\sum_{c=1}^S R_{ij}^{(c)}} \quad (8)$$

其中, S_{eff} 指有效传输数据量 (bit), 该数值与稀疏化率 ρ 相关, 而 S_{full} 是完整数据大小 (bit).

2.3.4 链路能耗

在设备到设备 (D2D) 通信中, 链路的能耗直接影响设备的续航能力, 因此研究链路能耗的计算方法至关重要. 链路 $i \rightarrow j$ 在子载波 c 上单次传输的能耗为发送功率与时间的乘积:

$$E_{ij}^{(c)} = P_{\text{tx},i}^{(c)} \cdot t_{ij} \quad (9)$$

链路 $i \rightarrow j$ 的总能耗为所有子载波能耗之和:

$$E_{ij} = \sum_{c=1}^S E_{ij}^{(c)} \quad (10)$$

其中, S 指子载波总数. 由式 (10) 可知, 发送功率越大、传输时间越长, 能耗也就越高. 因此, 在通信优化中, 需

要合理规划节点间的传输路径和传输功率,以降低能量消耗,提高网络的可持续运行能力。

3 融合 Gossip 机制的分层 DFL 训练框架

为了减少 D2D 联邦学习中客户端间传递模型参数带来的通信成本,本文设计了基于数据相似性的集群划分策略,并在集群内部基于多维度评分函数推选代表节点,以实现训练模型的分层聚合策略。分层拓扑聚合策略分为两步:第 1 步是基于 Gossip 协议的点对点聚合策略,在集群内部通过局部模型交换快速消减数据异构性,减少全局通信频率。第 2 步是高层全局聚合策略,通过代表节点跨集群聚合全局模型,平衡数据分布差异,提升收敛效率,如图 2 所示。

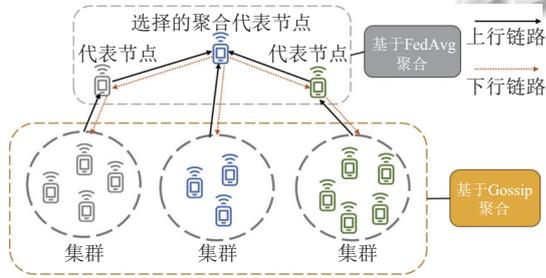


图2 分层拓扑聚合协议

3.1 基于数据相似性的集群划分策略

为了实现基于数据相似性的集群划分,需要有效提取节点间的数据相似性,本文采用余弦相似度对特征分布相似性进行提取。

对每个节点的本地数据集 D_i , 提取其类别分布向量 $V_i \in R_C$, C 为总类别数。

$$V_i = [v_{i,1}, v_{i,2}, \dots, v_{i,C}] \quad (11)$$

其中, $v_{i,j}$ 表示类别 j 在节点 i 数据集 D_i 中所占比例。

结合数据分布相似性与物理拓扑距离,对低层节点混合度量进行动态集群划分,数据相似性度量为:

$$\text{Sim}(D_i, D_j) = \frac{V_i \cdot V_j}{\|V_i\| \|V_j\|}, V_i = \left[\frac{m_{i,1}}{M_i}, \dots, \frac{m_{i,C}}{M_i} \right] \quad (12)$$

其中, V_i 为节点 i 的类别分布向量, $m_{i,C}$ 为类别 C 的样本数, M_i 为总样本数。

节点间的拓扑距离除了应该考虑节点间物理距离,传输时延对于 D2D 网络同样重要,将传输时延纳入指标后,拓扑距离度量表示如下:

$$d_{\text{topo}}(i, j) = \frac{d_{\text{phy}}(i, j)}{d_{\text{max}}} + \frac{t_{ij}}{t_{\text{max}}} \quad (13)$$

其中, d_{phy} 为物理距离, t_{ij} 为传输延迟。

则集群综合评分函数可以表示为数据相似性与物理拓扑距离的加权函数:

$$\text{Score}(i, j) = \alpha \cdot \text{Sim}(D_i, D_j) + \beta \cdot e^{-d_{\text{topo}}(i, j)} \quad (14)$$

其中, α 、 β 为调节权重的超参数, $\alpha + \beta = 1$ 。

通过综合评分函数的建立,节点会优先连接数据相似且拓扑邻近的邻居节点,与邻居节点形成集群 C_r , 其中 $r = 1, 2, \dots, K$, K 为集群数量。

3.2 分层拓扑聚合策略

分层拓扑聚合策略具体而言分为两步:第 1 步在基于数据相似性生成的集群内部,节点基于 Gossip 协议进行聚合,交换稀疏化模型参数;第 2 步在选拔出的集群代表节点间,进行全局聚合,获得全局聚合参数并下发至集群内节点。

由于代表节点承担了全局模型聚合以及参数下发任务,集群内的代表节点选择时,应综合考虑节点计算能力和通信能力,代表节点 i 的多维度评分函数为:

$$X_i = \alpha \cdot \frac{c^{\text{CPU}}}{C_{\text{max}}} + \beta \cdot \frac{b^{\text{PW}}}{B_{\text{max}}} + \delta \cdot \text{Stab}_i \quad (15)$$

其中, c^{CPU} 指节点的计算能力, C_{max} 是节点计算能力最大值, b^{PW} 是节点的带宽, B_{max} 是带宽上限,代表节点应优先选择资源充足的节点, Stab_i 是结合节点历史参与率与故障率,节点稳定性的衡量标准。

3.2.1 集群内基于 Gossip 协议聚合

为满足集群内部节点间点对点聚合,本文引入 Gossip 协议作为聚合协议,该协议通过随机选择邻居节点进行参数交换,使得信息在集群内部逐步扩散,从而在多轮迭代后实现全局一致性。相比传统的中心化聚合方式, Gossip 协议能够在去中心化环境下有效降低通信开销,同时提高模型鲁棒性和收敛速度。

在每个集群内部,节点通过 Gossip 协议交换稀疏化的模型参数,并进行动态加权平均,集群内节点 i 的第 $k+1$ 轮模型参数为:

$$\theta_i^{(k+1)} = \sum_{j \in K_i^{(k)}} \alpha_{ij} \cdot S(\theta_j^{(k)}) + \left(1 - \sum_{j \in K_i^{(k)}} \alpha_{ij} \right) \cdot \theta_i^{(k)} \quad (16)$$

其中, $K_i^{(k)}$ 是节点 i 在第 k 轮 Gossip 中选择的邻居集合, $S(\theta)$ 为参数稀疏化函数, α_{ij} 是节点 i 对邻居 j 的信任权重,基于以下因素计算:

$$\alpha_{ij} = \frac{C(i, j) \cdot D_i}{\sum_{m \in N_c^{(k)}} C(i, m) \cdot D_m} \quad (17)$$

其中, D_i 是节点 i 的本地数据量. $C(i, j)$ 是通信质量指标, 加权多个代表通信质量的参数可形成归一化评分:

$$C(i, j) = \alpha \frac{B_{ij}}{B_{\max}} + \beta \frac{L_{\min}}{L_{ij}} + \gamma(1 - P_{ij}) \quad (18)$$

其中, B_{ij} 是节点间实际带宽, B_{\max} 是系统最大带宽. L_{ij} 是节点间延迟, L_{\min} 是系统最小延迟. P_{ij} 代表丢包率. 权重系数为 $\alpha + \beta + \gamma = 1$, 可以根据场景进行调整, 当处于大模型传输的带宽敏感场景时, 则可以增加 α 权重. 当处于需要实现实时控制的延迟敏感场景, 则可以加大 β 的权重.

模型参数 θ 的稀疏化函数 $S(\theta)$ 可表示为:

$$S(\theta) = \theta \odot M_1, M_1 = \begin{cases} 1, & \theta_i \in \text{Top-Z} \\ 0, & \text{否则} \end{cases} \quad (19)$$

其中, $Z = \rho \cdot |\theta|$, ρ 是稀疏化参数.

3.2.2 高层节点全局聚合

在全局聚合阶段, 各集群的代表节点随机推举出一个节点 R_r , 向该节点传输当前各集合的稀疏化模型参数, 并基于 FedAvg 聚合策略, 依据全局权重, 进行聚合:

$$\theta_{\text{global}}^{(t+1)} = \sum_{r=1}^K Y_C \cdot S(\theta_{R_r}^{(t)}) \quad (20)$$

其中, K 是集群数量, Y_C 是集群数据在全局数据占比:

$$Y_C = \frac{\sum_{i \in C} D_{c,i}}{\sum_{i=1}^C \sum_{j \in C_i} D_{c,j}} \quad (21)$$

代表节点在聚合后会统一进行模型下发, 将聚合后的全局模型下发至集群内本地节点, 本地节点接收全局模型后继续训练, 持续迭代直至模型收敛.

算法 1 展示了融合 Gossip 机制的分层 DFL 训练框架的伪代码.

算法 1. 融合 Gossip 机制的分层 DFL 训练框架

输入: 设备节点数量 N , 阈值 α 和 β , 本地训练轮次 E , 全局通信轮次 T .
输出: 训练完成的全局模型参数 θ .

1. 初始化: 节点 i 提取本地数据集 D_i 并计算类别分布向量 V_i
2. 计算数据相似性度量 $\text{Sim}(D_i, D_j)$ 和拓扑距离度量 $d_{\text{topo}}(i, j)$

3. 依据综合评分函数 $\text{Score}(i, j)$ 进行集群划分, 形成多个局部集群 $C_r, r \in K$
4. 计算集群 C_r 候选节点的评分函数 X_i , 选择评分最高的节点作为代表节点 R_r

5. **For** $t=0, 1, 2, \dots, T-1$ 轮全局通信 **do**

6. 每个集群并行执行集群内 Gossip 聚合:

7. **For** $r=0, \dots, E-1$ 轮本地训练 **do**

8. 内部节点 $i \in C_r$ 更新本地模型:

$$\theta_i^{(r+1)} = \sum_{j \in K_i^{(r)}} \alpha_{ij} \cdot S(\theta_j^{(r)}) + \left(1 - \sum_{j \in K_i^{(r)}} \alpha_{ij}\right) \theta_i^{(r)}$$

9. **End For**

10. Gossip 轮次完成, 返回本地更新后的模型 $\theta_i^{(t)}$

11. 集群中代表节点 R_r 执行全局聚合:

$$\theta_{\text{global}}^{(t+1)} = \sum_{r=1}^K Y_C \cdot S(\theta_{R_r}^{(t)})$$

12. 更新全局模型参数 $\theta_{\text{global}}^{(t+1)}$

13. 全局模型更新后, 各代表节点 R_r 向集群 C_r 内部广播最新参数

$\theta_{\text{global}}^{(t+1)}$

14. **Until** 收敛或达到最大轮次 T

15. 返回最终训练完成的全局模型参数 θ

16. **End**

4 基于强化学习策略的资源联合优化

针对分层拓扑下通信资源动态分配与多目标协同优化的核心挑战, 本节提出基于 DDPG 的联合优化框架. 在分层联邦聚合架构中, 底层设备通过 Gossip 协议实现局部模型快速聚合, 高层代表节点执行跨区域全局协同, 以减少通信频率并缓解动态网络下的参数偏移问题. 基于此架构, 设计了一种分布式强化学习机制, 通过 DDPG 智能体动态调整节点资源分配与模型稀疏化率, 联合优化通信成本、模型精度与时延.

4.1 分层拓扑下的通信成本模型

在分层拓扑结构中, 通信成本主要包括集群内聚合阶段通信成本、全局聚合上传与模型下发通信成本. 接下来对 3 部分通信成本模型分别进行建模和分析.

4.1.1 集群内聚合阶段通信成本

每个集群 C 内的节点共享 S_C 个子载波, 按集群本地数据量动态分配, 得到集群内计算速率:

$$\Delta B_C = \frac{B_{\text{total}}}{S_C}, R_{i,j}^{\text{local}} = \sum_{c=1}^{S_C} \Delta B_C^{(c)} \cdot \log_2 \left(1 + \frac{P_{\text{tx},i}^{(c)} |h_{ij}^{(c)}|^2}{N_0 \Delta B_C^{(c)}} \right) \quad (22)$$

集群内节点通信时延可表示为:

$$t_{\text{local}} = \frac{S_{\text{eff}}}{R_{i,j}^{\text{local}}} = \frac{\rho \cdot S_{\text{full}}}{\sum_{c=1}^{S_C} \Delta B_C^{(c)} \cdot \log_2 \left(1 + \frac{P_{\text{tx},i}^{(c)} |h_{ij}^{(c)}|^2}{N_0 \Delta B_C^{(c)}} \right)} \quad (23)$$

集群内总能耗可以表示为:

$$E_{\text{local}} = \sum_{i \in C_k} \sum_{j \in K_i} \sum_{c=1}^{S_C} P_{\text{tx},i}^{(c)} \cdot t_{\text{local}} \quad (24)$$

其中, K_i 为设备 i 连接邻居节点集合, C_k 指当前集群.

4.1.2 全局聚合阶段通信成本

在全局聚合阶段, 代表节点通过随机选择设备进行全局参数上传, 完成全局模型的聚合. 该阶段通信成本包括上传时延、能耗, 以及下发的时延与能耗.

聚合阶段上传时延: 代表节点间通过随机推举聚合节点, 将参数传输至该节点完成全局聚合, 时延为:

$$t_{\text{global}} = \frac{\rho_G S_{\text{full}}}{\sum_{c=1}^{S_G} \Delta B_G \log_2 \left(1 + \frac{P_{\text{tx},i}^{(c)} |h_{i,r}^{(c)}|^2}{N_0 \Delta B_C} \right)} \quad (25)$$

其中, ρ_G 为全局稀疏化率, 控制压缩比例, S_G 为全局子载波数, 表示参与全局聚合子载波数目, $\Delta B_G = \frac{B_{\text{total}}}{S_G}$; $h_{i,r}^{(n)}$ 为节点 i 聚合选择节点 r 信道增益.

每个集群的代表节点仅需向选择的聚合节点上传模型, 全局聚合能耗为代表节点的上传能耗, 表示为:

$$E_{\text{global}} = \sum_{c=1}^C P_{\text{tx},r}^{(c)} \cdot t_{\text{global}} \quad (26)$$

下发阶段时延: 在全局模型聚合完成后, 需要将模型参数下发至每个集群内的节点. 该过程采用 OFDMA 并行传输机制, 每个节点下发时延计算如下:

$$t_{\text{down},i} = \frac{S_{\text{eff}}}{B_i \log_2 \left(1 + \frac{P_{\text{tx},i} |h_i|^2}{N_0 B_i} \right)} \quad (27)$$

其中, B_i 是动态分配给节点 i 的带宽, $P_{\text{tx},i}$ 是节点 i 在模型下发阶段的发射功率.

下发阶段能耗: 代表节点 i 下发至每个链路的传输能耗, 可以表示为:

$$E_{\text{down},i} = P_{\text{tx},i} \cdot t_{\text{down},i} \quad (28)$$

整个集群的总下发能耗为节点 i 至集群内每个节点的传输能耗之和:

$$E_{\text{down}} = \sum_{i \in S_C} E_{\text{down},i} \quad (29)$$

4.1.3 总能耗及总时延

综合各个阶段的能耗, 得到集群总通信能耗为:

$$E_{\text{total}} = E_{\text{local}} + E_{\text{global}} + E_{\text{down}} \quad (30)$$

总时延包括集群内通信、全局聚合和下发时延:

$$t_{\text{total}} = \max_{c,n} (t_{\text{global}}) + \max_{i \in N_S} (t_{\text{down},i}) + \max_{c,n} (t_{\text{global}}) \quad (31)$$

由于链路传输是并行的, 总时延取决于最慢链路.

经过上述计算, 获得了各个阶段的总能耗与总时延, 为后续优化提供了基础模型.

4.2 基于 DDPG 的资源联合优化问题

本文提出一种融合通信资源分配与模型训练状态的分布式 DDPG 策略优化框架. 该方法引入多目标奖励函数, 将模型精度、通信开销与时延统一纳入优化目标, 适用于 D2DDFL 中高动态、强异构的复杂环境.

考虑到 D2D 场景中缺乏中心服务器, 集群代表节点间的通信资源有限, 传统集中式调度难以实施. 为此, 本文在每个代表节点部署局部 DDPG 代理模型, 基于本地观测动态调整集群内的拓扑结构与资源分配. 各代理之间通过并行协作、全局协调机制与策略独立性, 联合实现全局优化目标. 该分布式强化学习方案具备适应性与可扩展性, 能够在保障通信效率的同时提升整体模型收敛性能, 其系统结构如图 3 所示.

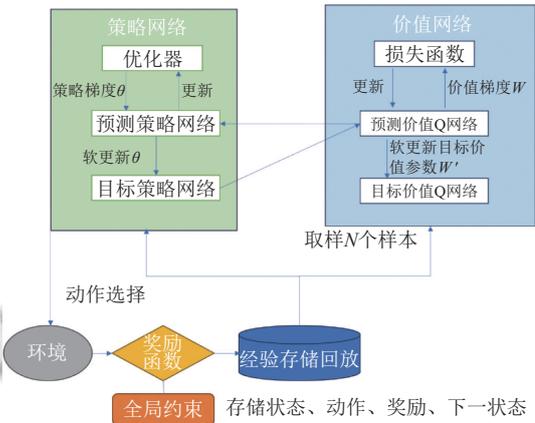


图3 代表节点部署的局部 DDPG 方案

4.2.1 全局优化目标

为实现模型训练损失、通信成本以及训练时延的多目标联合优化, 本文构建如式 (32) 所示的全局优化目标函数, 其中 θ 是全局模型参数矩阵, ρ 是稀疏化率, 控制传输数据量, P_{tx} 是发射功率矩阵负责各子载波功率分配, B 是带宽分配矩阵, 负责子载波分配, f 是本地计算频率向量, 代表集群内节点 CPU 频率. 权重系数 $\omega_1, \omega_2, \omega_3$ 用于平衡模型损失、能耗和时延的优先级. C1 限制通信成本, C2 限制整体时延, C3 限制带宽分配, C4 对发射功率进行限制, C5 限制计算频率, C6 是对模型收敛的约束条件, ϵ 是约束模型参数的阈值.

$$\begin{cases}
 \text{P1: } \min_{\theta, \rho, P_{\text{tx}}, B, f} (\omega_1 \cdot L(\theta) + \omega_2 \cdot E_{\text{total}} + \omega_3 \cdot t_{\text{total}}) \\
 \text{s.t. } \begin{cases}
 \text{C1: } E_{\text{total}} \leq E_{\text{max}} \\
 \text{C2: } t_{\text{total}} \leq T_{\text{max}} \\
 \text{C3: } \sum_{c=1}^C N_c + N_g \leq N_{\text{total}} \\
 \text{C4: } \sum_{n=1}^{N_c} P_{\text{tx},i}^{(n)} \leq P_{\text{max}}, \forall i \in C_c \\
 \text{C5: } 0 \leq f_k \leq f_k^{\text{max}}, \forall k \in C_c \\
 \text{C6: } \text{Var}(\nabla\theta) \leq \epsilon
 \end{cases}
 \end{cases} \quad (32)$$

接下来拆分全局优化目标, 获得局部优化目标。

4.2.2 局部优化目标

每个代理 k 的目标是优化其所在集群 C_k 的模型性能、通信成本与时延。具体其目标函数可以表达为:

$$\min_{\pi_k} E[\omega_1 \cdot L_k(\theta_k) + \omega_2 \cdot E_k + \omega_3 \cdot t_k] \quad (33)$$

其中, $L_k(\theta_k)$ 表示集群 C_k 的本地模型损失, E_k 代表集群内的通信能耗, 包括局部聚合、代表节点的交互。 t_k 是通信时延, 包含局部聚合和全局通信时间。

4.2.3 局部状态空间

每个代理 k 观测的局部状态包括多个关键要素, 以确保在优化过程中能够做出有效的资源分配和拓扑调整决策。代理所需状态信息包含模型参数 W_k 、梯度 ∇W_k 和梯度方差 $\text{Var}(W_k)$ 。还需要评估集群内链路质量, 包括信噪比 SNR_{ij} 和带宽 B_{ij} , 其中 i, j 属于集群 C_k 中的节点。监控节点资源状态, 如剩余能量 E_i^{re} 、CPU频率 f_i^{CPU} 和任务负载 l_i 。代理最后需要计算集群内节点数据的相似性, 表示为 $\text{Sim}(D_i, D_j)$, 其中 i, j 属于集群 C_k 。局部状态空间函数 S_k 表示为:

$$S_k = \{W_k, \nabla W_k, \text{Var}(W_k), \{\text{SNR}_{ij}, B_{ij}\}_{i,j \in C_k}, \{E_i^{\text{re}}, f_i^{\text{CPU}}, l_i\}_{i \in C_k}, \{\text{Sim}(D_i, D_j)\}_{i,j \in C_k}\} \quad (34)$$

其中, S_k 包含了代理 k 所需的所有本地观测信息, 确保代理能够在资源受限的环境中进行高效优化。

4.2.4 局部动作空间

每个代理 k 可执行的动作作为其集群内的资源分配与拓扑调整。具体动作包括对资源的分配, 包括节点 i 发射功率 $P_{\text{tx},i}$ 和带宽分配 ΔB_i , 其中 $P_{\text{tx},i}$ 的取值范围为 $[0, P_{\text{max}}]$, 而 ΔB_i 的取值范围为 $[0, B_{\text{max}}/C]$ 。对模型稀疏化的调整则是自适应调节本地模型稀疏化率 ρ_k , 其取值范围为 $[0.1, 0.9]$ 。

4.2.5 局部奖励函数

代理 k 的奖励函数需要平衡本地目标与全局约束, 具体形式为:

$$r_k = -\eta_1 \cdot L_k(W_k) - \eta_2 \cdot E_k - \eta_3 \cdot t_k + \eta_4 \cdot \Delta \text{ACC}_k - \eta_5 \cdot \text{Violation} \quad (35)$$

其中, 奖励函数的各项分别反映了不同的优化目标和约束条件。模型收敛 $\eta_1 \cdot L_k(W_k)$ 表示集群 C_k 的本地模型损失, 损失越小, 模型收敛越好。能耗项 $\eta_2 \cdot E_k$ 表示集群 C_k 的通信能耗, 能耗越低, 系统的能源使用效率越高。时延项 $\eta_3 \cdot t_k$ 表示集群 C_k 的训练时延, 包括局部聚合和全局通信, 时延越低, 系统的响应速度越快。精度提升项 $\eta_4 \cdot \Delta \text{ACC}_k$ 表示集群 C_k 的模型精度提升, 精度提升越大, 模型的性能越好。约束惩罚项 $\eta_5 \cdot \text{Violation}$ 表示集群 C_k 违反全局约束的程度, 如果集群违反了全局约束, 如总时延或能耗超过限制, 则会产生惩罚, 为了保证全局优化目标, η_5 取值较大。

4.2.6 全局协调机制

环境反馈将全局约束分解至局部奖励函数。对于时延, 如果集群 C_k 的时延超过总时延限制, 施加惩罚:

$$r_k = r_k - \eta \cdot \frac{t_k - t_{\text{max}}}{C} \quad (36)$$

对于能耗约束, 如果集群 C_k 的能耗超过设置的能耗限制, 施加如下惩罚:

$$r_k = r_k - \eta \cdot \max(E_k - E_{\text{max}}, 0) \quad (37)$$

对于子载波冲突惩罚, 如果多个代理分配相同子载波, 所有涉事代理的奖励被惩罚:

$$r_k = r_k - \text{Overlap}(\Delta B_k, \Delta B_l) \quad (38)$$

在上述步骤中, 通过集群内 Gossip 聚合降低全局通信频次, 结合 DDPG 代理动态调整每轮稀疏率、发射功率和带宽分配, 实现按需通信与协同调度, 从而在资源受限环境下, 保持模型稳定收敛与能耗可控。

5 实验结果与性能分析

5.1 实验设置

本实验环境由 Windows 11 操作系统、NVIDIA GeForce GTX 3070Ti GPU、Intel Core i7 2.5 GHz CPU 和 32 GB RAM 组成。实验开发基于 Python 3.9, 并使用 PyCharm 进行实现和管理。

采用分布式联邦学习架构进行性能验证, 系统内

共部署 20 个参与节点, 并通过极坐标随机生成算法在 2000 m 半径内均匀布设. 节点间通过 D2D 通信链路交换梯度参数, 物理层传输配置如下: 终端最大功率为 17 dBm, 信道模型大尺度路径损耗采用自由空间模型 (路径损耗指数 $\alpha=2$), 小尺度衰落采用 Jakes 瑞利模型. 链路带宽资源分配为 20 MHz, 噪声功率谱密度设定为 -174 dBm/Hz, 本地计算能力设置为 2.5 GHz, 局部计算有效开关电容设定为 10^{-29} .

5.2 数据集和基线设置

为了评估本文提出方法在异构数据场景下的鲁棒性, 选择 IID 和 Non-IID 数据划分模式分别进行验证, 采用 CIFAR-10-ResNet18 与 MNIST-CNN 基准数据集进行模型训练及验证.

MNIST 数据集×CNN 模型: MNIST 数据集中包括了 10 个手写数字类别, 提供了 60 000 个训练样本和 10 000 个测试样本. 使用包含两个 5×5 的卷积层 CNN 模型. 该模型的第 1 层设有 4 个输出通道, 第 2 层设有 8 个输出通道, 每层后面添加一个 2×2 的最大池化层.

CIFAR-10 数据集×ResNet-18 模型: CIFAR-10 数据集由 10 个类别彩色图像构成, 每个含有 6 000 张图, 总计提供 50 000 个训练样本和 10 000 个测试样本. 采用 ResNet-18 模型. 模型首层为 3×3 卷积层, 叠加 4 组残差块组, 包含 2 个残差块, 内部通过双 3×3 卷积层提取特征, 最终通过池化层映射至 10 类结果.

在对比实验中, 本文选择了多种主流典型的 D2D 联邦学习或分布式聚合策略作为对比基线. 去中心化 Gossip 联邦学习^[18]: GossipFL 通过随机节点配对实现模型交换, 以缓解数据偏差; 基于随机生成邻居 D2D 联邦学习^[27]: D2DFL 采用随机拓扑图进行聚合; 分布式 SGD^[28]方法: DSGD 依赖全链接同步保证模型一致. 这些基线模型用于对比评估模型精度与损失, 并进一步比较模型所消耗能耗, 从而全面评估所提出方案在降低通信成本和提升模型精度的优势.

5.3 性能分析

图 4 展示了在 MNIST 数据集下, 随着训练轮次增加, 部署在集群代表节点上的 DDPG 模型奖励情况.

奖励反映了每轮智能体所获得的奖励. 模型训练初期, 200 轮之前奖励低且波动剧烈, 策略未找到有效动作, 行为接近盲目猜测. 进入 200–600 轮震荡阶段, 奖励开始提升但波动显著, 尝试调整连续动作以达到

更好奖励, 此时模型还未到最优解. 600 轮之后, 震荡幅度衰减奖励较为稳定, 智能体基本确定了最优策略.

本节绘制了 IID 下在 MNIST 和 CIFAR-10 数据集上损失和精度情况, 分别在图 5–图 8 中显示.

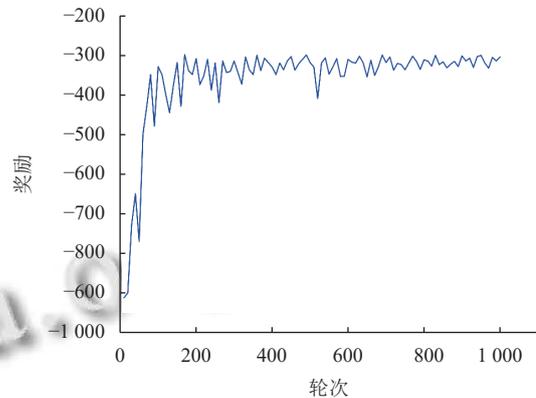


图 4 DDPG 的奖励值

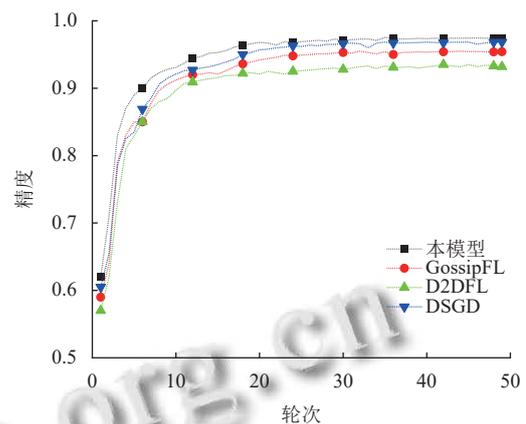


图 5 MNIST 下模型精度对比

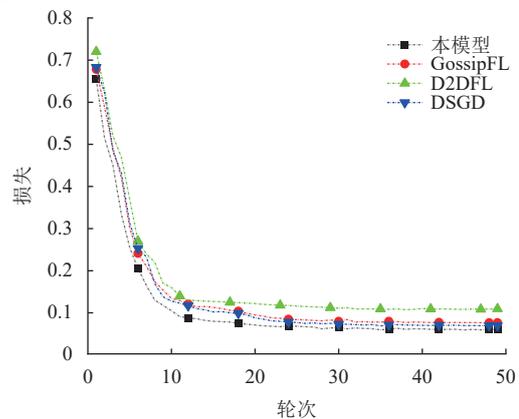


图 6 MNIST 下模型损失对比

从图 5 及图 6 中可以观察到, 随着训练轮数的增加, 所有方案最终都会趋向于一个相对稳定的收敛阈

值. 在 IID 数据分布下 MNIST 数据集上, 各模型经过大约 25 轮训练后, 算法接近收敛. 本文提出的方法在收敛速度上优于基线. 相比 DSGD, 精度提高了 0.67%, 同时损失减少了 0.004 83. 与 GossipFL 相比, 精度提升了 2.15%, 损失也减少了 0.009 1. 与 D2DFL 相比, 精度提高了 4.39%, 而损失减少了 0.016.

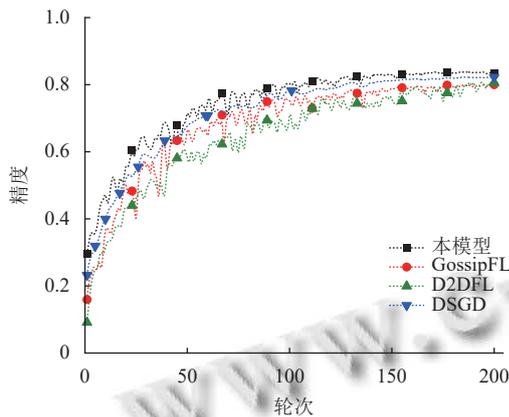


图7 CIFAR-10 下的模型精度对比

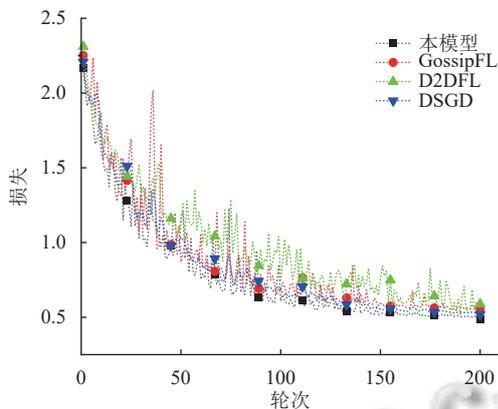


图8 CIFAR-10 下的模型损失对比

在 CIFAR-10 数据集上进行模型训练时, IID 数据下, 经过大约 125 轮后, 算法基本达到收敛状态. 与 3 种基线方法进行比较, 本文提出的方法在表现上均优于基线. 其中 DSGD 因其节点间存在全链接, 模型训练震动较小, 收敛速度较快, 精度表现较好. 本模型与 DSGD 相比, 精度提高了 1.51%, 损失减少了 0.027 6. GossipFL 因采用随机节点配对, 震动幅度较大, 收敛速度一般. 与 GossipFL 相比, 本模型精度提升了 2.95%, 损失也减少了 0.043 4. D2DFL 在精度与收敛上表现较为不佳, 主要由于其基于随机拓扑图的全局信息传递较慢, 节点训练易偏移. 与 D2DFL 相比, 本模型精度提

高了 3.96%, 而损失减少了 0.088 5.

进一步在 Non-IID 数据分布下验证本模型的有效性, 图 9 和图 10 展示了本模型和基线方法在 MNIST 数据集中采用 Non-IID 数据分布下的精度和损失情况.

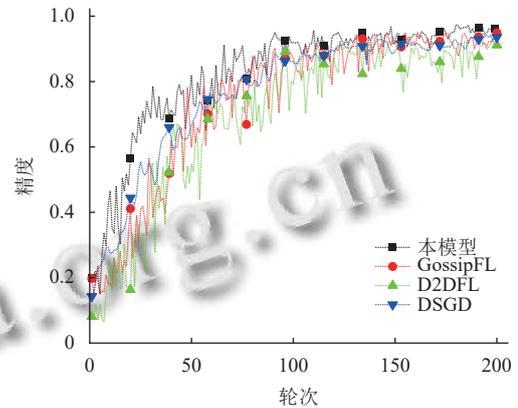


图9 MNIST 下 Non-IID 精度表现

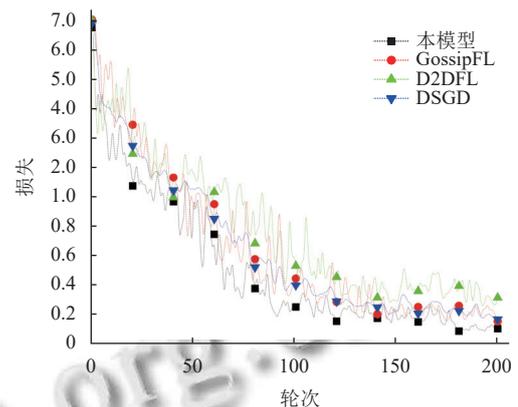


图10 MNIST 下 Non-IID 损失表现

在 Non-IID 数据分布下, 本模型相较基线模型仍保持最好表现, 模型收敛轮次与基线相比较少. 与此同时, 模型精度与损失的波动幅度相较 GossipFL 与 D2DFL 波动较小, DSGD 由于其全链接的拓扑关系, 表现最为稳定, 但同时要负担最高的通信消耗.

图 11 展示了本方案与 3 个基线在数据集 MNIST 和 CIFAR-10 上达到同样精度所需的通信能量消耗对比. 本方案在 MNIST 数据集和 CIFAR-10 均保持最小能耗成本. 在 MNIST 数据集上, 本方案相比 DSGD 模型节省了 77.4% 的能耗, 是由于能耗主要来自链路传输, DSGD 算法采用全链接, 模型传输能耗最大. 基于随机拓扑图的 D2D 联邦学习, 相较 DSGD 算法减少了链接, 节省了部分能耗, 但由于数据交换局限性, 需要

消耗资源换取精度, 能耗保持较高水平. 基于 Gossip 协议去中心化方案在实验中能耗相对较低, 但其限制于局部关系, 在全局模型上需要花费更多资源以换取精度. 本模型由于兼顾全局和局部聚合, 充分考虑通信成本优化问题, 表现优于基线.

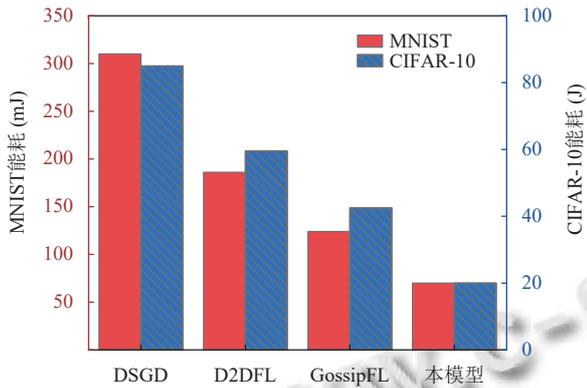


图 11 能耗对比

6 结论与展望

本文针对 DFL 边缘动态环境中通信效率低、资源分配不合理、模型收敛性差等问题, 提出了一种结合分层拓扑结构与强化学习的多目标联合优化方法. 相较于现有工作大多集中在通信压缩、固定拓扑优化或静态策略方案, 本文的核心贡献体现在以下 3 个方面.

(1) 提出了结合数据分布相似与拓扑特性进行节点集群划分, 基于 Gossip 协议与代表节点设计双层聚合机制, 能够同时提升模型训练速度与系统鲁棒性, 突破传统固定或全连接拓扑为主的 DFL 方法局限性.

(2) 设计了基于 DDPG 的多目标资源调度方案, 将模型精度、通信开销与传输时延共同纳入强化学习奖励函数, 具备动态环境下的自适应资源调控能力, 克服静态或启发式调度策略对网络变化响应不足的问题.

(3) 在 MNIST 与 CIFAR-10 两种数据集上与基线方法进行了对比, 实验结果表明本文方法在模型精度、能耗控制、收敛速度等方面均优于主流基线方案, 展示了良好通用性与实际部署潜力.

综上, 本文不仅构建了适应节点异构和网络动态性的拓扑结构, 同时融合强化学习策略实现了通信效率、模型精度与系统时延的多目标协同优化, 为实现高效、智能、可部署的 DFL 提供了新方案. 现阶段针对动态网络环境, 仅使用了局部智能体全局协同策略,

下一步希望能够在有限通信资源下, 重点研究多智能体强化学习驱动的资源分配算法, 实现频谱效率、能耗与时延的联合优化. 进一步可以引入联邦博弈论的动态激励策略与分布式共识协议, 以构建具备自我演进能力的去中心化通信框架, 为车联网、工业物联网等低时延高可靠场景提供理论支撑.

参考文献

- 傅刚. 非独立同分布数据下联邦学习算法中优化器的对比分析. 计算机系统应用, 2024, 33(5): 228–238. [doi: 10.15888/j.cnki.csa.009511]
- Putra MAP, Zainudin A, Sampedro GA, et al. Collaborative decentralized learning for detecting bearing faults in industrial Internet of Things. Proceedings of the 29th IEEE Asia Pacific Conference on Communications. Bali: IEEE, 2024. 385–389.
- 谭荣杰, 洪智勇, 余文华, 等. 非独立同分布数据下的去中心化联邦学习策略. 计算机工程与应用, 2023, 59(1): 269–277. [doi: 10.3778/j.issn.1002-8331.2204-0165]
- 陈关荣. 复杂动态网络环境下控制理论遇到的问题与挑战. 自动化学报, 2013, 39(4): 312–321.
- 罗军舟, 金嘉晖, 宋爱波, 等. 云计算: 体系架构与关键技术. 通信学报, 2011, 32(7): 3–21.
- 周传鑫, 孙奕, 汪德刚, 等. 联邦学习研究综述. 网络与信息安全学报, 2021, 7(5): 77–92.
- 王恩东, 闫瑞栋, 郭振华, 等. 分布式训练系统及其优化算法综述. 计算机学报, 2024, 47(1): 1–28.
- Hegedűs I, Danner G, Jelasity M. Decentralized learning works: An empirical comparison of Gossip learning and federated learning. Journal of Parallel and Distributed Computing, 2021, 148: 109–124. [doi: 10.1016/j.jpdc.2020.10.006]
- Beltrán ETM, Pérez MQ, Sánchez PMS, et al. Decentralized federated learning: Fundamentals, state of the art, frameworks, trends, and challenges. IEEE Communications Surveys & Tutorials, 2023, 25(4): 2983–3013.
- Yang P, Jiang YN, Wen DZ, et al. Decentralized over-the-air federated learning by second-order optimization method. IEEE Transactions on Wireless Communications, 2024, 23(6): 5632–5647. [doi: 10.1109/TWC.2023.3327610]
- Chen L, Liu W, Chen YF, et al. Communication-efficient design for quantized decentralized federated learning. IEEE Transactions on Signal Processing, 2024, 72: 1175–1188. [doi: 10.1109/TSP.2024.3363887]
- Li QL, Zhang M, Yin N, et al. Asymmetrically decentralized

- federated learning. *IEEE Transactions on Computers*, 2025, 74(8): 2745–2756. [doi: [10.1109/TC.2025.3569185](https://doi.org/10.1109/TC.2025.3569185)]
- 13 Zhai ZY, Yuan XJ, Wang X. Decentralized federated learning via MIMO over-the-air computation: Consensus analysis and performance optimization. *IEEE Transactions on Wireless Communications*, 2024, 23(9): 11847–11862. [doi: [10.1109/TWC.2024.3385443](https://doi.org/10.1109/TWC.2024.3385443)]
- 14 乔少杰, 林羽丰, 韩楠, 等. 基于贡献度证明共识机制的去中心化联邦学习框架. *软件学报*, 2023, 34(3): 1148–1167. [doi: [10.13328/j.cnki.jos.006784](https://doi.org/10.13328/j.cnki.jos.006784)]
- 15 Masmoudi N, Jaafar W. OCD-FL: A novel communication-efficient peer selection-based decentralized federated learning. *IEEE Transactions on Vehicular Technology*, 2025, 74(4): 6856–6861.
- 16 Li WC, Lv TJ, Ni W, *et al.* Decentralized federated learning over imperfect communication channels. *IEEE Transactions on Communications*, 2024, 72(11): 6973–6991. [doi: [10.1109/TCOMM.2024.3407208](https://doi.org/10.1109/TCOMM.2024.3407208)]
- 17 Xiong K, Wang R, Leng SP, *et al.* RIS-empowered topology control for decentralized federated learning in urban air mobility. *IEEE Internet of Things Journal*, 2024, 11(24): 40757–40770. [doi: [10.1109/JIOT.2024.3453964](https://doi.org/10.1109/JIOT.2024.3453964)]
- 18 Tang ZH, Shi SH, Li B, *et al.* GossipFL: A decentralized federated learning framework with sparsified and adaptive communication. *IEEE Transactions on Parallel and Distributed Systems*, 2023, 34(3): 909–922. [doi: [10.1109/TPDS.2022.3230938](https://doi.org/10.1109/TPDS.2022.3230938)]
- 19 Elgabli A, Park J, Ahmed S, *et al.* L-FGADMM: Layer-wise federated group ADMM for communication efficient decentralized deep learning. *Proceedings of the 2020 IEEE Wireless Communications and Networking Conference*. Seoul: IEEE, 2020. 1–6.
- 20 Huang XM, Yuan K. Optimal complexity in non-convex decentralized learning over time-varying networks. *arXiv: 2211.00533*, 2022.
- 21 Tan Y, Liu YX, Long GD, *et al.* Federated learning on non-IID graphs via structural knowledge sharing. *Proceedings of the 37th AAAI Conference on Artificial Intelligence*. Washington: AAAI Press, 2023. 9953–9961.
- 22 Liu SL, Liu CH, Wen DZ, *et al.* Efficient collaborative learning over unreliable D2D network: Adaptive cluster head selection and resource allocation. *IEEE Transactions on Communications*, 2025, 73(1): 425–438. [doi: [10.1109/TCOMM.2024.3435072](https://doi.org/10.1109/TCOMM.2024.3435072)]
- 23 Nguyen NH, Nguyen PL, Nguyen TD, *et al.* FedDRL: Deep reinforcement learning-based adaptive aggregation for non-IID data in federated learning. *Proceedings of the 51st International Conference on Parallel Processing*. Bordeaux: ACM, 2022. 73.
- 24 Sun YQ, Si SJ, Wang JZ, *et al.* A fair federated learning framework with reinforcement learning. *Proceedings of the 2022 International Joint Conference on Neural Networks (IJCNN)*. Padua: IEEE, 2022. 1–8.
- 25 Yin ZY, Wang Z, Li J, *et al.* Decentralized federated reinforcement learning for user-centric dynamic TFDD control. *IEEE Journal of Selected Topics in Signal Processing*, 2023, 17(1): 40–53. [doi: [10.1109/JSTSP.2022.3221671](https://doi.org/10.1109/JSTSP.2022.3221671)]
- 26 张天魁, 曾志民, 张颖莹. 基于博弈论的 OFDMA 系统多小区功率协调分配算法. *通信学报*, 2008, 39(1): 22–29. [doi: [10.3321/j.issn:1000-436X.2008.01.004](https://doi.org/10.3321/j.issn:1000-436X.2008.01.004)]
- 27 Martínez Beltrán ET, Perales Gómez AL, Feng C, *et al.* Fedstellar: A platform for decentralized federated learning. *Expert Systems with Applications*, 2024, 242: 122861. [doi: [10.1016/j.eswa.2023.122861](https://doi.org/10.1016/j.eswa.2023.122861)]
- 28 Zhu TT, He FX, Zhang L, *et al.* Topology-aware generalization of decentralized SGD. *Proceedings of the 39th International Conference on Machine Learning*. Baltimore: PMLR, 2022. 27479–27503.

(校对责编: 张重毅)