

基于多维个体属性的分层联邦持续学习公平激励机制

赵泽暄¹⁾ 钱 迎¹⁾ 马连博¹⁾ 黄 敏²⁾ 王兴伟³⁾

¹⁾(东北大学软件学院 沈阳 110819)

²⁾(东北大学信息科学与工程学院 沈阳 110819)

³⁾(东北大学计算机科学与工程学院 沈阳 110819)

摘 要 随着边缘计算(Edge Computing, EC)与人工智能(Artificial Intelligence, AI)的融合,先进的AI模型得以部署在靠近用户的网络边缘,从而推动了分布式设备之间的协同训练。在边缘AI中,联邦持续学习(Federated Continual Learning, FCL)框架能够在确保数据隐私的前提下,利用多个客户端的持续数据流进行学习,并共同优化全局模型。然而,现有激励机制多聚焦于解决数据异质性(如数据量和质量)等单一维度的问题,未能充分考虑客户端的多维个体属性。与此同时,在分层FCL环境中,客户端的动态参与和数据的非独立同分布(Non-Independent and Identically Distributed, Non-IID)特性使得边缘服务器的贡献评估变得更加复杂,进而引发了收益分配不均的问题。为此,本文提出了一种基于多维个体属性与公平贡献评估的分层FCL激励机制。在下层边-端架构中,本文提出的机制采用基于深度学习的多维个体属性反向拍卖机制,依据客户端的数据时效性、任务匹配度、计算能力、存储能力以及训练成本等多维因素,动态选择最合适的客户端参与训练,并合理分配奖励。在上层云-边架构中,针对Non-IID数据环境,机制进一步引入余弦类别沙普利值方法,在无需辅助验证数据集的前提下,能够以低计算成本利用余弦相似度刻画边缘服务器的类别特定贡献,从而提升机制的公平性和有效性。该机制在兼顾激励相容性、个体理性和保留价格约束的基础上,优化了客户端选择策略,并实现了公平的贡献评估与收益分配。通过严格的理论分析和广泛的实验验证,充分证明了该机制在促进客户端积极参与和实现公平贡献评估方面的有效性。

关键词 边缘计算;分层联邦持续学习;多维个体属性;合作博弈;激励机制

中图法分类号 TP18 **DOI号** 10.11897/SP.J.1016.2026.01825

Fair Incentive Mechanism for Hierarchical Federated Continual Learning Based on Multi-Dimensional Individual Attributes

ZHAO Ze-Xuan¹⁾ QIAN Ying¹⁾ MA Lian-Bo¹⁾ HUANG Min²⁾ WANG Xing-Wei³⁾

¹⁾(School of Software, Northeastern University, Shenyang 110819)

²⁾(School of Information Science and Engineering, Northeastern University, Shenyang 110819)

³⁾(School of Computer Science and Engineering, Northeastern University, Shenyang 110819)

Abstract With the convergence of Edge Computing (EC) and Artificial Intelligence (AI), advanced AI models are increasingly deployed at the network edge, in close proximity to end users. This strategic deployment not only facilitates real-time data processing but also fosters collaborative training among distributed devices, thereby improving the efficiency, scalability,

收稿日期:2025-10-28;在线发布日期:2026-04-16。本课题得到国家自然科学基金(62472079)、国家重点研发计划项目(2022YFB4500800)资助。赵泽暄,硕士研究生,主要研究领域为联邦学习、边缘计算。E-mail: 2471412@stu.neu.edu.cn。钱迎(通信作者),博士研究生,主要研究领域为联邦学习、边缘计算。E-mail: 2110494@stu.neu.edu.cn。马连博(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)杰出会员,主要研究领域为计算智能、边缘计算与联邦学习。E-mail: malb@swc.neu.edu.cn。黄敏,博士,教授,博士生导师,主要研究领域为工业互联网、供应链与智能优化。王兴伟,博士,教授,博士生导师,国家杰出青年科学基金获得者,中国计算机学会会士,主要研究领域为计算机网络、云计算与人工智能。

and responsiveness of AI systems. In the context of edge AI, the Federated Continual Learning (FCL) framework emerges as a promising paradigm that supports continuous learning from streaming client data while preserving privacy. By aggregating local updates instead of transmitting raw data, FCL jointly optimizes a global model, ensuring confidentiality, reducing communication overhead, and enabling sustainable model evolution over time. However, existing incentive mechanisms in federated settings primarily focus on unidimensional factors, such as data heterogeneity in terms of volume and quality. They often overlook the inherently multidimensional nature of client attributes, which include not only data timeliness and task relevance but also computational capacity, storage capability, training costs, and communication bandwidth. Neglecting these aspects reduces the effectiveness of client selection and undermines fairness in reward allocation. Meanwhile, in a hierarchical FCL environment, evaluating edge-server contributions at the upper cloud-edge level becomes considerably more complex, as dynamic participation causes resource availability to fluctuate across rounds and Non-Independent and Identically Distributed (Non-IID) data further complicates contribution evaluation, often resulting in inequitable reward allocation. Consequently, existing methods often struggle to simultaneously capture complex time-varying characteristics and category-specific effects. To address these issues, this paper proposes a hierarchical FCL incentive mechanism that explicitly integrates multidimensional individual attributes and ensures equitable contribution evaluation. At the lower edge-client level, the mechanism adopts a deep learning-based reverse-auction framework that accounts for multidimensional individual attributes. Within this framework, the allocation network determines the probability of selecting each client, while the reward network computes the corresponding payment. Both outputs derive from the joint consideration of multidimensional attributes, including data timeliness, task relevance, computational power, storage resources, and training costs. This design enables adaptive participant selection under dynamic conditions and ensures that rewards align with actual contribution potential. At the upper cloud-edge level, the mechanism introduces the Cosine-Class Shapley Value (CCSV) to evaluate edge-server contributions under Non-IID data conditions. Without relying on auxiliary validation datasets, CCSV constructs a category-level characteristic function by computing the cosine similarity between the last-layer gradient aggregated by a sub-coalition of edge servers and the globally aggregated gradient of the grand coalition, and then derives each edge server's expected marginal contribution across all coalitions. To reduce computational complexity, the cosine similarity between gradients is used as a good approximation to the Shapley value, thereby reducing computational overhead while maintaining fairness. Overall, the proposed mechanism approximately satisfies incentive compatibility, individual rationality, and reserve-price constraints, while simultaneously optimizing client selection and enabling fair reward distribution at both levels of the hierarchy. Rigorous theoretical analysis and extensive experimental validation confirm its effectiveness in promoting sustained client participation, maintaining fairness across heterogeneous participants, and improving the robustness of federated continual learning, while also offering valuable insights for the future design of efficient and fairness-aware FCL systems in real-world deployments.

Keywords edge computing; hierarchical federated continual learning; multi-dimensional individual attributes; cooperative game; incentive mechanism

1 引言

联邦学习(Federated Learning, FL)^[1]作为一种分布式机器学习框架,通过在客户端本地训练模型并共享模型参数,而非原始数据,有效保障了数据隐私^[2-4]。随着物联网、智能设备和移动设备的广泛应用,各类智能终端不断产生海量数据^[5],推动了FL在多设备协同训练机器学习模型中的广泛应用。然而,随着数据流的持续变化,传统FL难以适应动态任务需求并保持对旧任务的有效性。因此,联邦持续学习(Federated Continual Learning, FCL)应运而生^[6-7],解决了FL无法处理持续变化数据和任务的挑战。FCL在传统FL的基础上引入了持续学习的理念^[8-9],能够高效处理不断变化的数据流和任务需求。与FL不同,FCL不仅支持客户端之间的协同训练,还能够在持续学习新任务的同时保留旧任务的知识。FCL特别适用于边缘AI应用,在这些场景中,数据和任务的动态性要求模型必须实时更新并适应新的环境。

移动边缘计算(Mobile Edge Computing, MEC)通过将计算和存储资源部署在数据源附近^[10-12],极大地降低了通信延迟和带宽消耗,使得边缘设备能够在本地高效处理数据并及时更新模型。将FCL应用在MEC,不仅能够提升系统的响应速度和实时性,还确保了数据隐私保护和模型的长期适应性。因此,FCL在边缘计算环境中的应用,尤其是在实时推理和持续学习方面,展现出了巨大的潜力。

在实际应用中,尤其是自动驾驶、智能交通和数字孪生等时间敏感的AI应用中,数据持续变化且任务需求频繁调整^[13]。FCL框架需要在边缘计算环境中快速响应这些变化,及时对新生成的数据进行训练,以确保模型能够适应新环境并进行准确推断,同时保持与当前任务的高度匹配。例如,在智能医疗系统中,依赖传感器和健康监测设备收集的数据来实时跟踪病人的生理状态。在这种场景下,模型不仅需要及时更新以适应病人健康状况的变化,还需与医疗任务需求紧密对接,确保任务相关性。如果模型未能快速适应这些变化,它可能无法准确预测病人的健康趋势或进行及时干预,从而影响医疗决策的准确性和效率。

其次,训练效率长期受到通信条件、计算能力和数据异质性等多重因素的制约。单一因素的优化不足以确保系统的整体效率和稳定性,现有机制主要

集中于解决数据异质性问题,但在实际应用中,常常忽视了数据与资源异构性之间的平衡。在FCL框架下,客户端的参与不仅受到数据质量的影响,还与计算能力、存储能力以及任务的训练成本等多个因素密切相关。然而,传统方法往往忽视了客户端的多维个体属性,导致在客户端选择和奖励分配过程中无法实现公平的资源配置,进而影响系统的效率和稳定性。

此外,分层FCL框架的动态参与问题和数据的非独立同分布(Non-Independent and Identically Distributed, Non-IID)特性^[14-15],进一步加大了云服务器在评估边缘服务器贡献时的复杂性。客户端的参与情况、计算资源和数据质量随时可能发生变化,这使得边缘服务器的贡献评估变得困难,进而影响到奖励的公平分配。

因此,如何在保证激励相容性、个体理性和保留价格约束的前提下,优化客户端选择和贡献评估策略,并使FCL能够有效应对时间敏感的AI应用中的动态任务和数据流变化,仍是当前FCL系统面临的主要问题。

为了解决FCL框架中存在的动态响应时效性、客户端多维属性和贡献评估不公平等问题,本文提出了一种分层多维公平激励机制(Hierarchical Multidimensional Fair Incentive Mechanism, HMFIM)。该机制在下层边-端架构中综合考虑客户端的多维属性,如数据的时效性、任务匹配度、计算能力、存储能力以及训练成本等因素,通过神经网络建模拍卖规则,并结合机器学习自动化设计最佳拍卖策略,从而实现了客户端的动态选择和合理奖励分配。在上层云-边协作环境中,考虑到每次迭代对系统整体性能的重要性相同,本框架采用多次单阶段合作博弈方法来确保各次迭代之间的公平性,同时引入余弦类别沙普利值方法优化边缘服务器的奖励分配策略,从而提升系统的公平性并增强其稳定性。

本文的主要贡献如下:

(1)提出分层联邦持续学习下的激励机制,能够实时响应数据流的变化,确保模型能够快速更新并进行精准推断。该机制充分综合数据时效性和任务匹配度,利用激励机制促进客户端参与和协同训练,从而有效解决了动态任务适应和数据流变化的挑战。

(2)设计了基于多维个体属性的反向拍卖机制,将拍卖过程建模为一个深度学习问题。与传统

拍卖不同,这种基于深度学习的反向拍卖通过神经网络综合考虑客户端的多维属性,能够在最大化社会福利的同时,有效满足激励相容性、个体理性及保留价格约束,从而保证客户端的诚信参与。

(3)引入了余弦类别沙普利值方法实现公平贡献评估,通过基于梯度的余弦相似度构造类别级特征函数,在无需额外验证数据集的前提下,计算边缘服务器的期望边际贡献,从而刻画其整体贡献与类别特定影响。

(4)证明了基于梯度的余弦相似度可作为沙普利值的有效近似,并给出了该近似误差的理论界限,避免了传统沙普利值方法中由于参与者数量庞大而带来的高计算成本。

2 相关工作

许多研究在选择高质量客户端时,通常假设客户端会无条件提供数据和计算资源^[16-18]。然而,实际上,客户端在参与训练时需要消耗大量的计算和通信资源。训练过程中的计算负荷和数据上传开销可能显著影响设备的正常使用。如果缺乏合理的激励,或者奖励不足以弥补这些资源消耗,客户端将面临不公平的负担,进而缺乏参与的动力,甚至可能选择放弃参与训练^[19-20]。为了解决这一问题,许多研究提出了不同的激励机制,旨在激发客户端的参与积极性,确保其在训练任务中获得合理的回报,并增强参与的主动性。

现有的联邦学习激励机制研究主要采用合同理论、博弈理论和拍卖机制等方法来进行设计。合同理论^[21-23]的激励机制通常用于最大化客户端的关键性能指标,并在完全信息不对称的情境下应用,能够通过有效分配资源来优化激励奖励。然而,合同理论的局限性在于其依赖于传统的优化方法,可能导致无法高效应对动态变化的参与者需求和计算负载。

博弈理论^[24-26]方法着重于寻找参与者之间的博弈均衡,特别适用于参与者之间存在复杂互动的场景。通过考虑多方决策过程中的博弈策略,博弈理论能够实现效用的最大化分配。然而,博弈理论的缺点在于其计算复杂度较高,尤其是在参与者数量较多时,可能导致训练时间的延长,从而影响整体训练效率。

拍卖机制^[27-29]主要应用于高竞争的场景,旨在最大化社会福利。其优势在于公平性和效率,能够

确保资源在多个竞争参与者之间得到高效分配。然而,拍卖机制也存在一定的局限性,尤其是在客户端信息不完全的情况下,可能会导致不诚实行为的出现。

尽管前述研究在FL框架中取得了一定进展,但针对分层联邦学习(Hierarchical Federated Learning, HFL)中特有的激励机制设计问题,关注仍较为有限。随着HFL^[30-32]框架的提出,终端设备不再直接与云服务器(即模型拥有者)通信,而是将参数的中间聚合过程移至边缘层,如通过集群头、基站或其他设备,只有在需要进行全局聚合时,才与云服务器进行通信^[33]。该架构充分利用边缘节点的计算与带宽资源进行局部聚合,在保留联邦学习隐私保护特性的基础上,有效降低了频繁通信带来的开销。此外,这种分层的学习范式显著降低了对中心云服务器的直接依赖。近年来,部分研究开始关注HFL框架中的激励机制设计。例如,Lim等人^[34]提出了一个动态资源分配框架,旨在解决分层联邦学习中的资源分配和激励机制问题。Wang等人^[35]提出了一种结合分层合同理论和区块链技术的激励机制,旨在解决分层联邦学习中多维激励问题,并通过增强信任和透明度来优化资源分配和客户端激励。

为了更直观地定位本文工作的创新性与差异化优势,本文将具有代表性的现有激励机制进行了系统性分类与对比,如表1所示。上述激励机制通常基于静态数据集的假设,主要侧重于优化计算与通信资源,难以适应FCL中持续数据流导致的数据价值衰减特性。此外,现有机制缺乏一个全面的激励框架,难以在数据时效性、任务匹配度与客户端计算、存储能力等复杂多维属性之间建立有效的权衡机制,也未解决引入边缘服务器后的贡献评估与分配难题。因此,本文针对这一问题,提出了基于多维个体属性与公平贡献评估的H-MFIM。该机制综合数据的时效性和任务匹配度,在激励相容性、个体理性和保留价格约束下选择高质量客户端,并通过公平贡献评估确保边缘服务器贡献的公正分配。

3 系统模型

3.1 系统概述

云-边-端协同系统被设计为分层联邦持续学习网络,整体架构如图1所示。该系统由1个云服务器、S个边缘服务器和M个客户端构成,其中边缘服务器集合记为 $S=\{1, \dots, s, \dots, S\}$,客户端集合记为

表1 现有激励机制与H-MFIM的对比				
类别	文献	关注点	适用架构	数据环境
合同理论	[21]	系统可靠性	单层FL	静态数据集
	[22]	服务器效用	单层FL	静态数据集
	[23]	数据质量	单层FL	静态数据集
博弈理论	[24]	训练延迟	单层FL	静态数据集
	[25]	隐私成本	单层FL	静态数据集
	[26]	长期效用	单层FL	静态数据集
	[27]	系统能耗	单层FL	静态数据集
拍卖机制	[28]	社会福利	单层FL	静态数据集
	[29]	机会公平	单层FL	静态数据集
现有HFL	[34]	资源分配	分层FL	静态数据集
	[35]	信任机制	分层FL	静态数据集
H-MFIM	本文	多维属性与贡献公平	分层FCL	持续数据流

$\mathcal{M}=\{1,\cdots,m,\cdots,M\}$ 。在此框架下,客户端数据以持续数据流的形式存在,并随时间推移形成多个数据集,数据集的数量与规模受限本地设备的存储容量。其中,每个边缘服务器均与云服务器相连,对任意一个边缘服务器 $s\in\mathcal{S}$,其连接的客户端子集记为 $C_s=\{1,\cdots,l,\cdots,L\}\subseteq\mathcal{M}$,并满足 $\bigcup_{s\in\mathcal{S}}C_s=\mathcal{M}$ 。为简化系统建模,假设每个客户端仅连接一个边缘服务器,且该连接关系在每轮训练过程中保持不变,主要符号见表2。

(1)云服务器(Cloud Server):云服务器作为系统的全局协调者,主要负责初始化全局模型参数 w_g ,并向边缘服务器下发分层联邦持续学习任务。在训练过程中,云端接收各边缘服务器上传的边缘模型参数 w_s ,用于进行全局聚合并更新全局模型

表2 主要符号说明	
符号	定义
$\mathcal{S},\mathcal{M}$	边缘服务器和客户端集合
C_s	边缘服务器 s 连接的客户端子集
C'_s	边缘服务器 s 选中的客户端子集
w_g,w_s,w_l	全局模型、边缘模型和客户端模型的参数
$f(\bullet)$	以 $\bullet$ 为参数化的模型
ρ^s,ρ^M	边缘服务器和客户端的奖励
$\mathcal{X}_m$	客户端 m 的本地数据集
p_m	客户端 m 的多维个体属性配置文件
v_m,b_m,t_m,h_m	客户端 m 报价、保留价格、时效性与匹配度
L_l	客户端 l 存储的数据集总数
$x_l^{(i)}$	客户端 l 存储的第 i 个数据集的大小
$\tau_l^{(i)},m_l^{(i)}$	客户端 l 存储第 i 个数据集的时效性和匹配度
$T_{\max}$	最大时效性期限
$\alpha_l,\beta_l,\gamma_l$	客户端 l 每单位数据收集、存储和通信成本
δ_l	客户端 l 计算芯片的有效电容系数
c_l,f_l	客户端 l 的CPU周期数和CPU主频
s_l,B_l	客户端 l 的参数大小、传输速率

$f(w_g)$ 。为提高客户端的参与质量与系统整体效益,云服务器设计上层的奖励分配机制,依据各边缘服务器上传模型的质量评估其实际贡献并分配相应奖励 ρ^s ,同时激励边缘服务器优先选择高价值客户端参与训练,实现云-边-端架构下的分层协同与模型性能的持续优化。

(2)边缘服务器(Edge Servers,ESs):边缘服务器作为客户端与云平台之间的中间层,主要负责客户端的调度管理与本地模型参数的聚合。为了提高客户端的参与积极性,边缘服务器通过基于深度学




图1 基于多维个体属性公平激励机制的框架图(右侧展示了云-边-端三层协同训练与聚合的完整流程;左上侧为上层合作博弈,展示了云端对边缘服务器的贡献评估与奖励分配;左下侧为下层基于深度学习的反向拍卖,描述了客户端存储的多个数据集随时间动态变化的过程)

习的反向拍卖机制,在满足客户端保留价格约束的前提下,优先选择具备高时效性、高匹配度与低训练成本等多维个体属性优势的客户端参与训练,并对选中的客户端分配奖励 ρ^M 。客户端完成本地更新后,边缘服务器聚合其上传的模型参数 w_l ,生成边缘聚合模型 $f(w_s)$,并上传至云端参与全局模型 $f(w_g)$ 优化。

(3)客户端(Clients):客户端作为数据拥有者,利用本地数据参与全局模型的训练。每个客户端 $m \in \mathcal{M}$ 与其连接的边缘服务器进行通信,并在本地存储与维护自身的数据集 $\mathcal{X}_m$ 。被选中的客户端 $C'_s \in C_s$ 接收到边缘服务器下发的模型训练任务后,基于本地数据对模型进行更新,并将更新后的本地模型参数 w_l 上传至边缘服务器。为了全面评估客户端的训练潜力和实际价值,系统为每个客户端定义了一个多维个体属性配置文件 $p_m = (v_m, b_m, t_m, h_m)$,其中 v_m 表示客户端基于训练成本所提出的报价, b_m 表示客户端的保留价格, t_m 表示客户端本地数据的时效性, h_m 表示客户端本地数据与当前训练任务之间的匹配度。在实际训练中,边缘服务器依据多维属性信息结合激励机制优先调度高价值客户端参与训练。

(4)云一边一端训练过程:首先,云服务器作为全局协调者发布训练任务并初始化全局模型参数 w_g ,随后将其下发至所有参与的ESs。每个ESs $\in \mathcal{S}$ 接收到模型后,将任务信息广播至其连接的客户端 C_s ,并启动反向拍卖机制以选择客户端参与训练。客户端 $m \in C_s$ 根据自身数据分布与资源状态,提交多维个体属性配置文件 p_m 参与竞价。ESs在收集所有投标信息后,选出最合适的客户端集合 $C'_s \subseteq C_s$ 。中选客户端基于本地持续数据流进行模型训练,生成更新后的本地模型参数 w_l 并上传至对应ESs。ESs对收集到的本地模型参数进行聚合,并进入下一轮竞价与训练。完成预设的 T 轮迭代后,各ES将最终聚合结果 w_s 上传至云端。最终,云服务器聚合各边缘模型 $f(w_s)$ 以更新全局模型 $f(w_g)$,同时利用余弦类别沙普利值对ESs进行公平的贡献评估并分配奖励 $\rho^S = \{\rho_s^S, \dots, \rho_s^S, \dots, \rho_s^S\}$ 。各ES在获取云端奖励后,再依据下层激励规则对选中的客户端分配激励报酬 $\rho^M = \{\rho_l^M, \dots, \rho_l^M, \dots, \rho_l^M\}$,以实现公平有效的激励机制。

(5)激励机制:在分层联邦持续学习系统中,本文设计了一种融合反向拍卖与贡献感知的激励机

制,构建了涵盖云端、ESs与客户端的多层协同激励框架。在该机制中,下层为ES与客户端之间的竞价交互,上层为云与ESs之间的合作博弈。下层客户端的多维属性通过模型参数转化为上层的贡献评价,而上层的公平收益又反向作用于下层的客户端激励。这种双向互馈机制有效地激发了ES侧在模型训练过程中的积极性,在提升训练效率的同时增强了参与动力,从而实现了系统整体逻辑的闭环运作。

①下层基于深度学习的反向拍卖:在客户端选择与激励分配过程中,本文设计了一种基于深度学习的反向拍卖机制,该机制模拟了在保留价格约束条件下,边缘服务器与客户端之间的博弈关系。具体而言,ES作为拍卖发起方和买方,竞购高质量的数据和计算资源;客户端则作为卖方,提供本地资源和数据,以换取参与训练任务的机会与潜在奖励。ES根据客户端提交的信息,利用神经网络模型进行选择与定价。该机制不仅能够适应客户端在数据、资源和任务相关性方面的异构性,还能通过端到端学习实现激励相容,从而提升系统整体的社会福利和模型性能。

②上层合作博弈:为确保在非独立同分布情况下对边缘服务器贡献评估的公平性,本文在云端与边缘服务器之间引入合作博弈框架。由于数据分布的异质性和客户端参与的动态性,传统的贡献评估方法难以准确量化每个边缘服务器的实际价值。因此,该机制采用基于余弦相似度的贡献感知方法,建模云端对各边缘服务器的激励分配策略,以提升协同训练的公平性与鲁棒性,进一步驱动边缘节点更积极参与全局优化过程。

3.2 客户端建模

(1)客户端数据质量:当前许多机制在处理客户端数据时仅关注单一维度的异质性。然而,客户端数据质量不仅受到数据本身特性的影响,还需考虑数据的时间因素和与当前任务的相关程度。在分层联邦持续学习中,客户端 l 存储 L_l 个数据集,记作 $\{\mathcal{X}_l^{(i)}\}_{i=1}^{L_l}$,每个数据集的大小记为 $x_l^{(i)}$ 。

客户端 l 存储的数据集具有不同的时效性,随着时间推移,数据的时效性逐渐降低。客户端 l 存储的第 i 个数据集的时效性 $\tau_l^{(i)}$ 由该数据集的生成时间戳 $T_l^{(i)}$ 和客户端当前的时间戳 $T_l^{(c)}$ 之间的差异来计算,具体公式为

$$\tau_l^{(i)} = 1 - \frac{T_l^{(c)} - T_l^{(i)}}{T_{\max}} \quad (1)$$

其中, $T_{\max}$ 为最大时效性期限。客户端 l 的时效性 t_l 为所存储数据集时效性的加权平均, 公式为

$$t_l = \frac{\sum_{i=1}^{L_l} x_l^{(i)} \cdot \tau_l^{(i)}}{\sum_{i=1}^{L_l} x_l^{(i)}} \quad (2)$$

其中, L_l 是客户端 l 存储的数据集总数, $x_l^{(i)}$ 表示客户端 l 存储的第 i 个数据集的大小。

客户端存储的数据集与当前任务存在不同程度的匹配度。为了衡量客户端数据集与当前任务的匹配度, 本文采用 Hellinger 距离来量化概率分布的相似性。客户端 l 的第 i 个数据集 $\mathcal{X}_l^{(i)}$ 的匹配度 $m_l^{(i)}$ 定义如下:

$$m_l^{(i)} = 1 - \frac{1}{\sqrt{2}} \left\| \sqrt{F_{l,i}} - \sqrt{F_a} \right\|_2 \quad (3)$$

其中, $F_{l,i}$ 表示客户端 l 第 i 个数据集 $\mathcal{X}_l^{(i)}$ 的概率分布, F_a 是当前任务的概率分布。客户端 l 的总体匹配度 h_l 则通过对所有数据集的匹配度进行加权平均来计算:

$$h_l = \frac{\sum_{i=1}^{L_l} x_l^{(i)} \cdot m_l^{(i)}}{\sum_{i=1}^{L_l} x_l^{(i)}} \quad (4)$$

值得注意的是, 客户端 l 的数据时效性 t_l 和任务匹配度 h_l 是随时间变化的动态指标。它们会随着客户端本地新数据的到达而实时变化。

(2) 客户端成本: 客户端的训练成本包括数据收集成本、数据存储成本、通信成本和计算成本。假设每单位数据的收集成本为 α_l , 则客户端数据收集成本可表示为

$$C_{\text{data}}^{(l)} = \alpha_l \sum_{i=1}^{L_l} x_l^{(i)} \quad (5)$$

数据存储成本根据存储的数据集总量来计算。假设每单位数据存储的成本为 β_l , 则客户端的存储成本为

$$C_{\text{storage}}^{(l)} = \beta_l \sum_{i=1}^{L_l} x_l^{(i)} \quad (6)$$

客户端 l 与边缘服务器之间的通信成本可表示为

$$C_{\text{comm}}^{(l)} = \gamma_l \frac{s_l}{B_l} \quad (7)$$

其中, γ_l 是每单位传输成本, B_l 是客户端 l 的传输速率, s_l 是客户端 l 的本地模型参数大小。

假设每个数据集都参与计算任务, 参考论文[35], 则客户端 l 的计算成本可以表示为

$$C_{\text{comp}}^{(l)} = \zeta \delta_l c_l \left(\sum_{i=1}^{L_l} x_l^{(i)} \right) f_l^2 \quad (8)$$

其中, ζ 是每单位能耗成本, δ_l 是客户端 l 计算芯片的有效电容系数, c_l 是训练单位数据所需的 CPU 周期数, f_l 是 CPU 主频。因此, 客户端 l 的总成本可表示为

$$Cost_l = C_{\text{data}}^{(l)} + C_{\text{storage}}^{(l)} + C_{\text{comm}}^{(l)} + C_{\text{comp}}^{(l)} \quad (9)$$

(3) 客户端收益: 客户端 l 的收益由其提供的总数据量 x_l 和神经网络计算出的奖励因子 r_l 决定, 同时也与边缘服务器 s 所连接的其他客户端 $C_s \setminus \{l\}$ 的报酬有关。具体而言, 客户端 l 的收益可以通过以下公式计算:

$$\rho_l^M = \frac{x_l \cdot r_l}{\sum_{i \in C_s} x_i \cdot r_i} \times R^M \quad (10)$$

其中, R^M 为边缘服务器分配给客户端的总奖励; x_l 表示客户端 l 的总数据量, 若客户端 l 不参与训练, 则其 x_l 取值为 0。

(4) 客户端效用: 客户端 l 的效用函数取决于其类型配置文件 p' 。具体而言, 保留价格 b_l 代表客户端参与联邦训练任务所能接受的最低价格, 反映了其对自身数据价值与算力资源的期望定价。该价格决定了客户端的参与意愿, 基于此, 客户端 l 的效用函数定义为如下分段形式:

$$u_l(p_l, p') = \begin{cases} r_l(p') - v_l \cdot a_l(p'), & \text{if } r_l(p') \geq b_l, \\ -\infty, & \text{if } r_l(p') < b_l \end{cases} \quad (11)$$

其中, r_l 和 a_l 分别为神经网络输出的奖励因子和分配概率。 v_l 为客户端 l 的真实估值报价。当客户端收到的奖励低于保留价格 b_l 时, 表明未达到客户端的预期底线, 客户端将拒绝参与任务, 此时效用被设定为负无穷; 仅当奖励不低于保留价格时, 客户端才会参与协作。

3.3 边缘服务器建模

(1) 边缘服务器成本: 边缘服务器的成本由通信成本和协调成本组成。设 μ_s 为单位协调成本, 边缘服务器的总成本可表示为

$$Cost_s = \gamma_s \times \frac{s_s}{B_s} + \gamma_l \times \frac{s_l}{B_l} + \mu_s |C_s| \quad (12)$$

其中, γ_s 和 γ_l 分别为边缘服务器与云端、客户端之间的单位通信成本; s_s 和 s_l 分别为边缘服务器与云端、客户端之间的传输参数大小; B_s 和 B_l 分别为边缘服务器与云端、客户端之间传输速率。

(2) 边缘服务器收益: 边缘服务器的收益按一定比例 ϖ_s , 从云端支付给边缘服务器的总收益 R^s 中进行分配:

$$\varpi_s = \hat{\phi}_s \cdot \sum_{n \in C_s} x_n / \left(\sum_{j \in S} \hat{\phi}_j \cdot \sum_{n \in C_j} x_n \right) \quad (13)$$

其中, $\hat{\phi}_s$ 为边缘服务器 s 的余弦类别沙普利值, $\sum_{n \in C_s} x_n$ 为边缘服务器 s 所连接客户端的数据量。边缘服务器收益还需要考虑参与任务的风险。基于文献[35]中的风险建模思路, 本文采用风险厌恶模型来量化这一影响, 则边缘服务器 s 收益为:

$$\rho_s^s = \ln(\theta_s + \varpi_s R^s) \quad (14)$$

其中, θ_s 为风险厌恶系数, θ_s 越大, 表示感知风险越高, 参与意愿越低。

(3) 边缘服务器效用: 边缘服务器的效用为其收益与成本之间的差值, 表示为:

$$u_s = \rho_s^s - \text{Cost}_s \quad (15)$$

3.4 云端建模

(1) 云端成本: 云端的成本即为分配给边缘服务器的总奖励。该奖励依据各个边缘服务器所连接的所有客户端的数据质量总和进行计算, 云端总成本可表示为:

$$\text{Cost}_c = R^s = \sum_{m \in \mathcal{M}} \left(-\frac{\eta}{\log(\epsilon_m)} \right) \cdot x_m \pi \quad (16)$$

其中, η 为数据质量系数; ϵ_m 表示客户端 m 的本地准确度; 根据文献[36], 项 $-\frac{\eta}{\log(\epsilon_m)}$ 用于衡量客户端 m 的数据质量; π 为云端设定的单位服务价格。

(2) 云端收益: 云端的收益取决于全局模型的性能。参考文献[26], 模型准确率通常被建模为关于训练数据量的凹函数。因此, 云端收益定义为:

$$\rho^{c_s} = \omega \cdot g \left(\sum_{m \in \mathcal{M}} \left(-\frac{\eta}{\log(\epsilon_m)} \right) \cdot x_m \right) \quad (17)$$

其中, $\omega > 0$ 为系统参数, $g(x)$ 采用对数形式定义: $g(x) = \ln(1 + \nu x)$, 其中 ν 为饱和系数, 用于控制模型性能的收敛速率。

(3) 云端效用: 云端效用为其收益与成本之间的差值, 公式如下:

$$u_c = \rho^{c_s} - \text{Cost}_c \quad (18)$$

4 下层反向拍卖的客户端选择

4.1 形式化为学习问题

在多维个体属性反向拍卖中, 每个边缘服务器与其连接的客户端之间进行并行的客户端选择与奖励分配。假设边缘服务器 s 连接着 L 个客户端 $C_s = \{1, 2, \dots, L\} \subseteq M$, 其中每个客户端 $l \in C_s$ 都有一个

根据训练成本对边缘服务器 s 的估值报价 v_l , 有一个保留价格 b_l , 表示客户端 l 接受的最低支付以及客户端数据集的时效性 t_l 和任务匹配度 h_l 。令 $p_l = (v_l, b_l, t_l, h_l)$ 来表示客户端 l 的类型, 使用 $p = (p_1, p_2, \dots, p_L)$ 来表示边缘服务器 s 连接客户端的多维个体属性类型配置文件。令 $\mathcal{P}_l$ 表示客户端 l 的所有可能类型空间, $\mathcal{P}$ 表示所有客户端类型配置空间。假设客户端 l 的类型从已知分布 F_l 中独立地抽取且边缘服务器知道所有客户端的类型分布, 但不知道其实际类型。为了便于描述, 定义 $F = \prod_{l=1}^L F_l$ 和 $F_{-l} = \prod_{k \neq l} F_k$ 。进一步地, 令 $v_{-l} = (v_1, \dots, v_{l-1}, v_{l+1}, \dots, v_L)$ 表示不包含客户端 l 的估值报价配置文件, $b_{-l} = (b_1, \dots, b_{l-1}, b_{l+1}, \dots, b_L)$ 表示不包含客户端 l 的保留价格配置文件, 同样, t_{-l} 和 h_{-l} 也是类似的定义, 且 $p_{-l} = (v_{-l}, b_{-l}, t_{-l}, h_{-l})$ 。每个客户端报告(可能不真实)其多维个体属性配置文件。

定义 1. 多维个体属性反向拍卖. 多维个体属性反向拍卖机制 (a, r) 由一个随机分配规则 $a: \mathcal{P} \rightarrow [0, 1]^L$ 和一个奖励规则 $r: \mathcal{P} \rightarrow \mathbb{R}_{\geq 0}^L$ 组成, 给定一个类型配置文件 $p' \in \mathcal{P}$, $a_l(p') \in [0, 1]$ 表示客户端 l 被分配给边缘服务器的概率, 而 $r_l(p') \in \mathbb{R}_{\geq 0}$ 表示客户端 l 的预期奖励因子。

在每一轮的反向拍卖中, 分配网络 a 依据客户端的多维属性(包括报价、保留价格、时效性和匹配度)进行选择, 并根据奖励网络 r 来计算每个客户端的支付奖励。

定义 2. 社会福利. 社会福利定义为边缘服务器选择客户端带来的效用减去支付给客户端的奖励:

$$S(p) = u_s(a(p)) - \sum_{l=1}^L r_l(p) \quad (19)$$

定义 3. 占优策略激励相容 DSIC. 若没有客户端能够通过虚报其类型配置中的估值(即虚假报价)来获得更高的效用, 则该拍卖机制是占优策略激励相容的。设其真实类型为 $p_l = (v_l, b_l, t_l, h_l)$, 虚假类型配置为 $p'_l = (v'_l, b_l, t_l, h_l)$, 其中 v_l 为真实估值报价, v'_l 为偏离真实值的虚假报价。即对于每个客户端 $l \in C_s$, 若 $p \in \mathcal{P}$ 和 $p'_l \in \mathcal{P}_l$, 则

$$u_l(p_l, (p_l, p_{-l})) \geq u_l(p'_l, (p'_l, p_{-l})) \quad (20)$$

定义 4. 个体理性 IR. 若每个客户端参与训练都能获得非负效用, 则该拍卖是个体理性的。形式上, 对于每个客户端 $l \in C_s$, 若 $p \in \mathcal{P}$, 则有

$$u_l(p_l, (p_l, p_{-l})) \geq 0 \quad (21)$$

定义 5. 保留价格约束 RPC. 本文考虑满足保留价格约束的拍卖, 即对于每个客户端 l 和类型

配置文件 p , 都有

$$r_l(p) \geq b_l \quad \forall l \in C_s, p \in \mathcal{P} \quad (22)$$

如 Dütting 等人^[37]所提出, 多维个体属性反向拍卖问题被形式化为一个学习问题。目标是设计拍卖规则以最大化社会福利, 并同时满足激励相容性、个体理性和保留价格约束。由于反向拍卖模型中的优化问题是非凸的, 无法严格满足以上约束, 因此, 本文使用以下度量标准来评估拍卖机制违反 DSIC、IR 和 RPC 的程度。

在机制 (a, r) 下, 客户端 l 的期望事后后悔是指在固定其他客户端类型情况下, 客户端 l 通过提交不真实类型所获得的最大效用增益, 即

$$rgt_l(a, r) = \mathbb{E}_{p \sim F} \left[\max_{p'_l \in \mathcal{P}_l} \chi_{(r_l(p'_l, p_{-l}) \geq b_l)} \left(u_l(p_l, (p'_l, p_{-l})) - u_l(p_l, (p_l, p_{-l})) \right) \right] \quad (23)$$

假设 F 在类型空间 $\mathcal{P}$ 上具有完整支持, 因此可推断出后悔是非负的, 且拍卖机制满足 DSIC, 当且仅当 $rgt_l(a, r) = 0$ 对所有 $l \in C_s$ 成立, 除零测度事件外。因此, 事后后悔与 DSIC 约束在数学上是等价的, 我们采用该指标来量化拍卖机制违反激励相容性的程度。

在机制 (a, r) 下, 客户端 l 违反 IR 的惩罚定义为

$$ir_l(a, r) = \mathbb{E}_{p \sim F} [\max \{0, -u_l(p_l, (p_l, p_{-l}))\}] \quad (24)$$

在机制 (a, r) 下, 客户端 l 违反保留价格约束的惩罚由以下公式给出:

$$rpc_l(a, r) = \mathbb{E}_{p \sim F} [\max \{0, b_l - r_l(p_l, (p_l, p_{-l}))\}] \quad (25)$$

接下来, 损失函数定义为负的社会福利:

$$L(a, r) = -\mathbb{E}_{p \sim F} \left[u_s(a(p)) - \sum_{l=1}^L r_l(p) \right] \quad (26)$$

将拍卖机制参数化为 (a^w, r^w) , 其中参数 $w \in \mathbb{R}^d$, 则学习问题表述为在期望事后后悔、IR 惩罚和 RPC 惩罚为零的情况下, 最小化期望负社会福利:

$$\begin{aligned} \min_{w \in \mathbb{R}^d} \quad & L(a^w, r^w) \\ \text{s.t.} \quad & rgt_l(a^w, r^w) = 0, \forall l \in C_s \\ & ir_l(a^w, r^w) = 0, \forall l \in C_s \\ & rpc_l(a^w, r^w) = 0, \forall l \in C_s \end{aligned} \quad (27)$$

从 F 中抽取 $\mathcal{L}$ 个多维个体属性类型配置文件样本 $\mathcal{T} = \{p^{(1)}, p^{(2)}, \dots, p^{(\mathcal{L})}\}$, 则拍卖机制 (a^w, r^w) 的损失为

$$\hat{L}(a, r) = -\frac{1}{\mathcal{L}} \sum_{\ell=1}^{\mathcal{L}} (u_s(a(p)) - \sum_{l=1}^L r_l(p^{(\ell)})) \quad (28)$$

客户端 l 的经验事后后悔为

$$\widehat{rgt}_l(a, r) = \frac{1}{\mathcal{L}} \sum_{\ell=1}^{\mathcal{L}} \max_{p'_l \in \mathcal{P}_l} \left\{ \chi_{(r_l(p'_l, p_{-l}^{(\ell)}) \geq b_l^{(\ell)})} \cdot (u_l(p_l^{(\ell)}, (p'_l, p_{-l}^{(\ell)})) - u_l(p_l^{(\ell)}, (p_l^{(\ell)}, p_{-l}^{(\ell)}))) \right\} \quad (29)$$

同理可得:

$$\widehat{ir}_l(a, r) = \frac{1}{\mathcal{L}} \sum_{\ell=1}^{\mathcal{L}} \max \{0, -u_l(p_l^{(\ell)}, (p_l^{(\ell)}, p_{-l}^{(\ell)}))\} \quad (30)$$

$$\widehat{rpc}_l(a, r) = \frac{1}{\mathcal{L}} \sum_{\ell=1}^{\mathcal{L}} \max \{0, b_l^{(\ell)} - r_l(p_l^{(\ell)}, p_{-l}^{(\ell)})\} \quad (31)$$

最终基于样本的学习公式如下:

$$\begin{aligned} \min_{w \in \mathbb{R}^d} \quad & \hat{L}(a^w, r^w) \\ \text{s.t.} \quad & \widehat{rgt}_l(a^w, r^w) = 0, \forall l \in C_s \\ & \widehat{ir}_l(a^w, r^w) = 0, \forall l \in C_s \\ & \widehat{rpc}_l(a^w, r^w) = 0, \forall l \in C_s \end{aligned} \quad (32)$$

4.2 神经网络架构

在多维个体属性反向拍卖机制中, 本文提出了一种新的神经网络架构, 称为多维个体属性网络 (Multi-dimensional Individual Attribute Network, MIANet), 用于建模分配规则和奖励规则, 如图 2 所示。为了有效应对客户端的动态参与, MIANet 将客户端的多维属性作为实时输入, 利用深度神经网络的自适应映射能力, 根据当前轮次状态动态计算分配概率和奖励因子, 从而实现对环境变化的实时响应。具体而言, 该架构由两个主要模块组成: 分配网络和奖励网络。两个网络通过联合训练进行优化。

分配网络 a^w : 客户端的多维属性配置文件 p 作为输入。具体而言, 输入特征由客户端的报价 v 、保留价格 b 、时效性 t 和匹配度 h 组成。网络使用 tanh 激活函数, 通过前馈全连接网络进行训练, 输出每个客户端被分配到边缘服务器进行训练的概率 $a_l \in [0, 1]$ 。在分配网络的输出层, 首先计算每个客户端对边缘服务器的得分 s_l , 然后通过 softmax 函数计算得到最终的分配概率: $a_l(p) = e^{s_l} / \sum_{k=1}^{L+1} e^{s_k}$, 其中 s_{L+1} 为虚拟得分, 表示未被分配的概率。

奖励网络 r^w : 奖励网络由 T 个全连接隐藏层和一个全连接输出层组成。以客户端的多维属性配置文件 p 为输入, 输出层计算得到每个客户端的得分 z_l 。为了确保输出的奖励为非负数, 将得分 z_l 经过 ReLU 激活函数处理, 得到最终的非负奖励因子 $r_l(p) = \max \{0, z_l\}$ 。




图2 基于深度学习的多维个体属性网络架构((a)为分配网络,输入客户端的多维属性,输出客户端的分配概率。(b)为奖励网络,输入客户端的多维属性,输出客户端的奖励因子)

在此架构中,多维属性作为网络的核心输入特征发挥关键作用。报价与保留价格反映了参与训练成本与最低接受价格,而数据时效性与任务匹配度则量化了数据质量。这种多维输入设计使得分配网络不再单纯追求最低报价,而是能够学习到在近似满足激励相容、个体理性及保留价格约束的前提下,权衡客户端的训练成本与数据价值,优先筛选出兼具高时效性与高匹配度的优质客户端,从而有效适应联邦持续学习中的动态特性。

4.3 训练过程

为了在最大化社会福利的同时满足复杂的约束条件,本文通过最小化负社会福利与违反约束的惩罚项来联合训练神经网络参数。与传统依赖人工设计固定启发式规则的方法不同,这种基于深度学习的机制能够自动学习最优的反向拍卖规则。

具体而言,MIANet采用增广拉格朗日法来解决网络参数空间中的约束优化问题。该方法通过引入拉格朗日乘子以及二次惩罚项来惩罚违反约束的情况,从而在优化过程中极小化约束违背,使得约束条件能够被近似满足。具有二次惩罚项的拉格朗日函数形式如下所示:

$$\begin{aligned} \mathcal{G}_\rho(w; \lambda_{rgt}, \lambda_{ir}, \lambda_{rpc}) = & \hat{L}(a^w, r^w) + \\ & \sum_{l \in C_s} \lambda_{rgt,l} \widehat{rgt}_l(a^w, r^w) + \frac{\rho}{2} \sum_{l \in C_s} \widehat{rgt}_l^2(a^w, r^w) + \\ & \sum_{l \in C_s} \lambda_{ir,l} \widehat{ir}_l(a^w, r^w) + \frac{\rho}{2} \sum_{l \in C_s} \widehat{ir}_l^2(a^w, r^w) + \\ & \sum_{l \in C_s} \lambda_{rpc,l} \widehat{rpc}_l(a^w, r^w) + \frac{\rho}{2} \sum_{l \in C_s} \widehat{rpc}_l^2(a^w, r^w) \end{aligned} \quad (33)$$

其中, $\lambda \in \mathbb{R}^n$ 为拉格朗日乘子向量, $\rho > 0$ 为调节二次惩罚项权重的参数。

拉格朗日求解器通过以下公式更新模型参数和拉格朗日乘子:

$$w^{t+1} \in \arg \min_w \mathcal{G}_\rho(w; \lambda_{rgt}^t, \lambda_{ir}^t, \lambda_{rpc}^t) \quad (34)$$

$$\lambda_{rgt,l}^{t+1} = \lambda_{rgt,l}^t + \rho \widehat{rgt}_l(a^{w^{t+1}}, r^{w^{t+1}}), \forall l \in C_s \quad (35)$$

$$\lambda_{ir,l}^{t+1} = \lambda_{ir,l}^t + \rho \widehat{ir}_l(a^{w^{t+1}}, r^{w^{t+1}}), \forall l \in C_s \quad (36)$$

$$\lambda_{rpc,l}^{t+1} = \lambda_{rpc,l}^t + \rho \widehat{rpc}_l(a^{w^{t+1}}, r^{w^{t+1}}), \forall l \in C_s \quad (37)$$

其中,公式(34)中的内部优化通过Adam优化器的多次迭代近似求解^[38]。

算法1. MIANet训练算法

输入: 大小为 B 的小批量 $\mathcal{B}_1, \dots, \mathcal{B}_T$

输出: 分配网络参数 w^a 和奖励网络参数 w^r

1. 参数: $\forall t, \rho_t > 0, \gamma > 0, \eta > 0, T \in \mathbb{N}, R \in \mathbb{N}, Q \in \mathbb{N}$

2. 初始化: $w^0 \in \mathbb{R}^d, \lambda_{rgt}^0 \in \mathbb{R}^L, \lambda_{ir}^0 \in \mathbb{R}^L, \lambda_{rpc}^0 \in \mathbb{R}^L$

3. FOR $t=0$ 到 T

4. 接收小批量 $\mathcal{B}_t = \{p^{(1)}, \dots, p^{(B)}\}$

5. 初始化虚假报价 $v_l^{(k)}, \forall k \in [B], l \in C_s$

6. FOR $r=0$ 到 R (寻找最优虚假报价)

7. $\forall k \in [B], l \in C_s$

8. $v_l^{(k)} \leftarrow v_l^{(k)} + \gamma \nabla_{v_l} u_l^w(p_l^{(k)}; (p_l^{(k)}, p_{-l}^{(k)}))$

9. ENDFOR

10. 计算拉格朗日梯度并更新 w^t

11. $w^{t+1} \leftarrow w^t - \eta \nabla_w \mathcal{G}_\rho(w^t; \lambda_{rgt}^t, \lambda_{ir}^t, \lambda_{rpc}^t)$

12. 每 Q 次迭代更新一次拉格朗日乘子

13. IF t 是 Q 的倍数

14. $\lambda_{rgt,l}^{t+1} \leftarrow \lambda_{rgt,l}^t + \rho_t \widehat{rgt}_l(w^{t+1}), \forall l \in C_s$

15. $\lambda_{ir,l}^{t+1} \leftarrow \lambda_{ir,l}^t + \rho_t \widehat{ir}_l(w^{t+1}), \forall l \in C_s$

16. $\lambda_{rpc,l}^{t+1} \leftarrow \lambda_{rpc,l}^t + \rho_l \widehat{rpc}_l(w^{t+1}), \forall l \in C_s$
17. ELSE
18. $\lambda_{rgt}^{t+1} \leftarrow \lambda_{rgt}^t$
19. $\lambda_{ir}^{t+1} \leftarrow \lambda_{ir}^t$
20. $\lambda_{rpc}^{t+1} \leftarrow \lambda_{rpc}^t$
21. ENDFOR

算法1描述了MIANet的训练流程。将训练样本划分为大小为 B 的小批量,并将第 t 次迭代时接收到的的小批量表示为 $\mathcal{B}_t$ 。在训练过程中,求解器首先通过梯度上升算法执行内层最大化计算,以求解每个客户端的最优虚假报价;随后,基于该结果利用增广拉格朗日方法交替更新模型参数与拉格朗日乘子。

5 上层基于合作博弈的贡献评估

5.1 云-边架构的多次单阶段合作博弈框架

假设 $M_w: \mathcal{X} \rightarrow \mathcal{Y}$ 是一个通过参数 w 定义监督分类器,其中, $\mathcal{X} \subset \mathbb{R}^d$ 表示输入空间, $\mathcal{Y} = \{1, 2, \dots, N\}$ 表示标签空间。这里, d 是输入数据的维度, N 是类别的数量。分类器包含两个主要部分:特征提取器和线性分类层。特征提取器将输入映射到 Q -维的嵌入空间,形式上表示为 $\mathcal{X} \rightarrow \mathbb{R}^Q$,而线性分类层则将这些特征嵌入映射到一个 N -维的对数几率空间(Logits Space),表示为 $\mathbb{R}^Q \rightarrow \mathbb{R}^N$ 。如图3所示,将线性分类层的权重矩阵 $\tilde{w}$ 分解为 N 个列向量,每个向量对应一个输出类别。




图3 最后一层权重矩阵在网络架构中的示意图

在云端与边缘服务器的协作中,本文构建了多次单阶段合作博弈 $\langle \mathcal{S}, \mathcal{V} \rangle$ 框架,以有效应对参与者的动态性。该框架将每一轮训练视为独立的博弈阶段,确保云端基于当前轮次的实际贡献进行评估。设集合 $\mathcal{S} = \{1, \dots, s, \dots, S\}$ 代表所有参与博弈的边缘服务器,云端作为协调者,负责全局模型的更新与

公平评估边缘服务器的贡献。特征函数 $\mathcal{V}: 2^{\mathcal{S}} \rightarrow \mathbb{R}$ 用于将参与者的子集映射到实数。对于任意边缘服务器子联盟 $T \subseteq \mathcal{S}$, $\mathcal{V}(T)$ 表示集合 T 中所有参与者共同合作所创造的价值。

在第 t 轮通信中,边缘服务器 s 通过聚合来自客户端的参数更新或梯度 $w_s^{(t)}$ 更新其边缘模型,随后上传边缘梯度 $w_s^{(t)}$ 至云端。云端将接收到的边缘更新加权平均得到全局更新 $w_g^{(t)}$:

$$w_g^{(t)} = \frac{1}{S} \sum_{s=1}^S w_s^{(t)} \quad (38)$$

云端使用全局梯度来更新全局模型 $M^{(t+1)}$:

$$M^{(t+1)} = M^{(t)} + w_g^{(t)} \quad (39)$$

5.2 基于公平性的余弦类别沙普利值

在传统的合作博弈模型中,参与者集合通常是固定的,且数据分布假定为独立同分布。然而,在边缘计算环境中,参与者通常是动态变化的,且每个参与者的数据往往呈现非独立同分布特性。因此,传统的沙普利值(Shapley Value, SV)^[39-40]方法难以适应这种动态参与和数据异质性的环境,尤其在Non-IID数据的情况下,传统方法难以捕捉到参与者的动态变化以及类别特定的影响,进而导致贡献评估结果的不公平。

此外,现有基于沙普利值的方法通常要求所有参与者提供辅助验证数据集,这不仅增加了计算负担,还可能引发隐私泄露的风险。为了解决这些问题,本文引入了余弦类别沙普利值(Cosine-Class Shapley Value, CCSV)方法^[41]。鉴于全模型参数计算易受底层特征提取器噪声的干扰,而最后一层线性分类层具有与输出类别对应的特性,故该方法聚焦于最后一层梯度。具体而言,CCSV通过计算每个边缘服务器上传的最后一层梯度与对应的全局聚合梯度之间的余弦相似度,量化其对整体联盟的贡献,从而在确保边缘服务器的贡献能够得到公平评估的同时,显著降低计算和通信开销。最终,云端根据每个边缘服务器的贡献大小进行奖励分配,确保合作博弈过程中的公平性和稳定性。

CCSV方法的核心思想是通过计算参数更新或梯度的方向对齐来评估对每个类别的贡献。设 $\tilde{w}_T$ 为边缘服务器子联盟 T 最后一层的聚合参数更新, $\tilde{w}_S$ 是大联盟 $\mathcal{S}$ 最后一层的聚合参数更新。进一步地,设 $\tilde{w}_T^j$ 为 $\tilde{w}_T$ 的第 j 列向量, $\tilde{w}_S^j$ 为 $\tilde{w}_S$ 的第 j 列向量,其中 $j \in \mathcal{Y}$ 。接下来,利用余弦相似度来量化边缘服务器组对每个类别的贡献,定义子联盟 T 对类别 j 的特征函数 $\mathcal{V}_j(T)$:

$$\mathcal{V}_j(\mathcal{T}) = \cos(\tilde{\mathbf{w}}_T^j, \tilde{\mathbf{w}}_S^j) = \frac{\langle \tilde{\mathbf{w}}_T^j, \tilde{\mathbf{w}}_S^j \rangle}{\|\tilde{\mathbf{w}}_T^j\| \|\tilde{\mathbf{w}}_S^j\|} \quad (40)$$

则边缘服务器 s 对类别 j 的余弦类别沙普利值定义为

$$\phi_s^j(\mathcal{V}) = \sum_{\mathcal{T} \subseteq \mathcal{S} \setminus \{s\}} \frac{|\mathcal{T}|!(S-|\mathcal{T}|-1)!}{S!} (\mathcal{V}_j(\mathcal{T} \cup \{s\}) - \mathcal{V}_j(\mathcal{T})) \quad (41)$$

其中, $\mathcal{S}$ 是所有边缘服务器的集合, $\mathcal{T}$ 是不包含 s 的边缘服务器子集, 贡献评估 $\phi_s^j(\mathcal{V})$ 表示了第 s 个边缘服务器在所有可能的联盟中对第 j 个类别的平均边际贡献。因此, 边缘服务器 s 的 CCSV 是一个 N 维向量, 其中每一维表示该边缘服务器对不同类别的贡献, 具体定义如下:

$$\phi_s(\mathcal{V}) = [\phi_s^1(\mathcal{V}), \dots, \phi_s^j(\mathcal{V}), \dots, \phi_s^N(\mathcal{V})] \quad (42)$$

5.3 余弦类别沙普利值高效近似

在公式(41)中, CCSV 需要枚举所有可能的边缘服务器组合, 并对每种组合进行模型评估^[42]。这导致了指数级的计算开销, 即计算复杂度为 $T(\mathcal{S}) = \mathcal{O}(2^S)$, 当参与者数量较多时, 时间开销变得极为庞大, 无法在实际应用中接受。因此, 优化 CCSV 的计算过程变得尤为重要。

为了解决这一问题, 本文参考了 Xu 等人^[43]提出的高效近似方法。设 $\tilde{\mathbf{w}}_s \subset \mathbf{w}_s$ 为边缘服务器 s 最后一层线性层对应的更新子向量。进一步地, 设 $\tilde{\mathbf{w}}_s^j$ 为 $\tilde{\mathbf{w}}_s$ 的第 j 列向量, 其中 $j \in \mathcal{Y}$ 。该方法通过直接计算边缘服务器更新参数 $\tilde{\mathbf{w}}_s$ 与大联盟 $\mathcal{S}$ 聚合更新参数 $\tilde{\mathbf{w}}_S$ 之间对不同类别的余弦相似度来有效近似沙普利值。

定理 1. 设 $A \in \mathbb{R}^+$, 且 $\phi_s^j = \cos(\tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_S^j)$ 。假设对于所有边缘服务器 $s \in \mathcal{S}$, 有 $\|\tilde{\mathbf{w}}_s^j\| = r$ 且 $|\langle \tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_S^j \rangle| \geq 1/A$ 。那么, $\phi_s^j - \mathcal{L}_s^j \phi_s^j \leq Ar^2$, 其中乘性因子 $\mathcal{L}_s^j$ 可以进行归一化处理, 详细证明见附录。

定理 1 表明, 梯度余弦相似度是沙普利值的良好近似, 且该近似误差在理论上有界的。但该近似在两种极端情形下存在局限性: (1) 当多个边缘服务器的梯度完全相同时, 该方法缺乏冗余去重机制; (2) 当边缘服务器的更新参数和大联盟的聚合更新参数正交时, 会导致计算失效。然而, 在分层联邦持续学习的 Non-IID 数据环境与高维参数空间中, 上述情况发生的概率极低。因此, 尽管这种近似设计存在一定的局限性, 但其在保证误差有界的前提下将计算复杂度从指数级降低至线性级, 更适用于资源受限的边缘计算环境。

通过每个边缘服务器上传的最后一层更新参数来近似计算其类别特定的沙普利值。具体来说, 边缘服务器 s 对类别 j 的贡献近似由余弦相似度定义为

$$\phi_s^j \approx \phi_s^j = \cos(\tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_S^j) \quad (43)$$

因此, 边缘服务器 s 对所有类别的近似 CCSV 定义为

$$\phi_s = [\cos(\tilde{\mathbf{w}}_s^1, \tilde{\mathbf{w}}_S^1), \dots, \cos(\tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_S^j), \dots, \cos(\tilde{\mathbf{w}}_s^N, \tilde{\mathbf{w}}_S^N)] \quad (44)$$

其中, 第 j 个元素表示边缘服务器 s 对类别 j 的学习贡献。如果 $\tilde{\mathbf{w}}_s^j$ 和 $\tilde{\mathbf{w}}_S^j$ 方向一致性较高, 意味着该边缘服务器对该类别的贡献更为显著。通过对每个类别的贡献进行加权平均, 最终得到边缘服务器 s 对整个任务的贡献评估。边缘服务器 s 的贡献计算公式为:

$$\varphi_s = \frac{1}{N} \sum_{j=1}^N \left(\frac{1 + \phi_s^j(\mathcal{V})}{2} \right) \quad (45)$$

接下来, 对 CCSV 进行归一化处理, 得到归一化后的贡献值:

$$\hat{\phi}_s = \frac{\varphi_s}{\sum_{k=1}^S \varphi_k} \quad (46)$$

这种归一化方法确保了不同边缘服务器的贡献能够得到公平评估, 从而有效地进行奖励分配。与传统的精确沙普利值计算方法相比, 后者通常需要 $\mathcal{O}(2^S - 1)$ 次调用, 而本文引入的 CCSV 方法只需进行 $\mathcal{O}(S + 1)$ 次推理。这一计算复杂度相较于传统方法显著降低, 特别是在边缘服务器的总数量 S 较大时, CCSV 方法的优势更为明显。同时, CCSV 方法能够更精确地反映每个类别特征的影响, 提供了更加细致的贡献评估, 而不需要额外的辅助验证数据集, 从而避免了传统方法所依赖的高昂计算成本。

6 实验结果与分析

6.1 实验设置

6.1.1 多维个体属性反向拍卖设置

实验基于 TensorFlow 深度学习框架实现多维个体属性反向拍卖机制。为了求解优化问题, 采用增广拉格朗日法进行模型参数更新。实验在配备 NVIDIA 3090 GPU 核心的 Linux 计算集群上进行, 以确保满足训练过程中所需的计算能力。

在训练过程中, 最大训练轮次设定为 80 次, 增广拉格朗日法的参数 ρ 初始值设为 1.0, 且设定每经

过2个轮次后递增一次。采用Adam优化器对模型参数进行更新,同时,为了求解内部最大化问题,我们利用梯度上升法执行40次虚假报价更新,并采用上一轮优化的虚假报价初始化当前轮次以加速收敛。为了确保拉格朗日乘子向量 λ 的逐步优化,将其更新频率设置为每100个小批量更新一次。此外,为了消除不同量纲对神经网络训练的影响并加速收敛,所有输入的属性数据均被归一化至 $[0,1]$ 区间。实验中的关键配置参数见表3。

表3 多维个体属性反向拍卖实验设置	
参数	值
学习率	0.001
小批量大小	128
训练数据样本数	640000
测试数据样本数	10000
虚假报价更新的学习率	0.1
网络初始化方法	Glorot
激活函数	Tanh
分配网络隐藏层数	3
奖励网络隐藏层数	3
分配网络隐藏层神经元数	100
奖励网络隐藏层神经元数	100

6.1.2 分层联邦持续学习设置

实验构建了一个由云端、边缘服务器和客户端组成的系统,采用了不同配置的边缘服务器,分别为5个、8个和10个。每个边缘服务器连接5到10个客户端,最多支持100个客户端参与训练。在每一轮训练中,通过多维个体属性反向拍卖机制选择客户端并完成边缘聚合,随后云端接收边缘模型更新,并采用FedAvg算法^[44]进行聚合。整个训练过程持续100轮,使用Adam优化器,学习率设定为0.01。

为了模拟边缘计算场景中数据分布异构与持续数据流的特性,本文选取MNIST和CIFAR-10数据集构建联邦持续学习实验环境。其中,MNIST采用轻量级卷积神经网络进行分类,CIFAR-10则采用ResNet-18网络结构以适配自然图像特征。具体而言,实验首先在空间维度将训练数据按预设数据划分策略划分并分配至各客户端,以构造客户端间的Non-IID数据分布;随后,在时间维度将每个客户端的本地数据划分为多个阶段,并按阶段逐步引入以形成持续数据流。在该类增量联邦持续学习设定下,前若干阶段中,客户端逐步接收包含新类别的数据,直至其持有的所有类别均已出现,在此之后的阶段中,数据流仅包含已有类别的增量样本。

基于上述机制,实验设计了四种数据划分方案,以在不同异质性强度下评估机制性能:

(1) 随机分片策略:首先将训练数据按标签排序,并划分为多个数据分片,随后随机分配给各客户端,从而模拟Non-IID数据分布情况。

(2) 标签选择划分策略:在该策略下,第一个类别的数据仅由第一个边缘服务器连接的客户端拥有,其余9个类别的数据均匀分配给所有边缘服务器连接的客户端,从而构造出极端的标签不平衡场景。

(3) 非均匀划分策略:将10个类别分为奇数类和偶数类,在边缘服务器各自连接的客户端上,奇数类按0%、10%、20%、30%、40%依次分配,偶数类按40%、30%、20%、10%、0%依次分配。

(4) Dirichlet划分策略:采用Dirichlet分布来生成各客户端的类别比例向量并据此分配样本。参数 α 用于控制异质性强度, α 值越小表示数据分布的异质性越强,从而更贴近真实场景中高度偏斜的数据分布。

6.2 下层反向拍卖的多维属性验证

为了评估基于多维个体属性反向拍卖机制的性能,开展了多次仿真实验。如图4所示,在训练初期,由于客户端虚假报价的存在,多维个体属性网络表现出较高的事后后悔,并伴随虚高的社会福利。随着训练的深入,该机制逐渐习得激励相容策略,有效抑制了虚假报价行为。这使得社会福利回落至真实水平并趋于稳定,同时事后后悔也显著降低。

具体来看,在图4(a)的设置下,多维个体属性网络的社会福利明显优于仅考虑出价的单维个体属性网络,且事后后悔值较低。随着系统规模的扩大,在图4(b)的设置中,多维个体属性网络依然保持较高的社会福利,并且事后后悔值持续较低,充分展示了多维属性拍卖机制的优势。在图4(c)的配置下,多维个体属性网络继续表现出最优的社会福利,且事后后悔几乎为零,证明该方法在大规模客户端参与的场景下依然能够保持高效和稳定的性能。

表4的结果表明,MIANet在社会福利指标上显著优于基于出价、时效性及匹配度的三种单维策略。与此同时,该机制的事后后悔、个体理性违背及保留价格违背均保持在较低水平。上述结果说明,MIANet能够通过多维属性的联合权衡,有效兼顾训练成本与数据价值,从而在近似满足激励相容性、个体理性及保留价格约束的前提下提升反向拍卖的整体性能。




图4 多维个体属性网络与单维个体属性网络的对比

表4 单维与多维个体属性反向拍卖的测试指标对比

实验设置 ESs*Clients	单维个体属性网络			多维个体属性网络			
	基于出价网络 的社会福利	基于时效性网 络的社会福利	基于匹配度网 络的社会福利	社会福利	事后后悔	个体理性 惩罚	保留价格 惩罚
5×25	6.156	8.223	5.844	9.068	0.002	0.029	0.003
8×64	9.752	11.978	11.456	14.485	0.001	0.017	0.031
10×100	12.344	11.713	13.025	17.689	0.001	0.025	0.013

图5展示了时效性与匹配度对支付奖励的影响。随着时效性和匹配度的增加,支付奖励呈现出明显的上升趋势。在高时效性和高匹配度的区域,支付奖励显著增高。相反,在低时效性和低匹配度的区域,支付奖励普遍较低,表明这两个因素对支付

奖励具有显著的正向影响。值得注意的是,图中的分布并未完全集中在某一特定区域,而是呈现一定的分散性,表明支付奖励不仅受到时效性和匹配度的影响,还会受到其他因素(如客户端的出价)共同作用的影响。




图5 时效性与匹配度对支付奖励的影响

6.3 上层合作沙普利值的公平性

本节实验聚焦于云-边架构下基于余弦类别沙普利值的公平贡献评估,特别是在Non-IID数据环境中的表现。图6展示了标签选择划分下类别沙普利值热力图。在极端类别不均衡场景下,类别0仅由ES1所连接的客户端持有,其余九个类别均匀分配。结果显示,ES1在类别0上的贡献显著高于其他边缘服务器,这与数据分配相符,表明CCSV能在异质场景下有效识别关键贡献。




图6 MNIST数据集下基于标签选择划分策略的类别沙普利值热力图

图7对比了真实估计沙普利值(True-Estimation Shapley Value, TESV,其特征函数为辅助验证集准确率)、余弦梯度沙普利值(Cosine Gradient Shapley Value, CGSV)^[43]与CCSV在非均匀划分策略下的边缘服务器贡献。实验结果表明,CCSV与TESV的贡献相对顺序一致,ES3最高,ES2和ES4居中,ES1和ES5最低,符合奇偶类别配额不均的设定。而CGSV对ES2至ES4的贡献评估偏高,区分度不足,与TESV存在明显偏差。综上,CCSV在Non-IID场景下能准确捕捉类别影响并有效支持公平贡献评估与奖励分配。




图7 MNIST数据集下基于非均匀划分策略的三种沙普利值方法对比

为了验证CCSV在复杂图像任务与高度异构环境下的有效性,本文在CIFAR-10数据集上采用Dirichlet划分策略模拟真实的Non-IID场景。图8展示了不同异质性参数下边缘服务器贡献值的热力图分布。实验结果表明,在强异质性场景下,边缘服务器间的贡献差异显著,CCSV能够识别关键贡献者及潜在表现为负贡献的边缘服务器;随着异质性减弱,数据分布趋于均衡,各边缘服务器的贡献值差异逐渐缩小。这说明CCSV能在复杂Non-IID场景下有效刻画贡献差异,从而为公平激励提供了可靠依据。




图8 CIFAR-10数据集下基于Dirichlet划分策略的边缘服务器贡献热力图

6.4 对比实验

图9和图10分别展示了H-MFIM方法在MNIST和CIFAR-10数据集上与五种基线方法的效用对比。这些基线方法包括贪心选择客户端^[45]、随机选择客户端^[46]、固定选择客户端、InFedge^[35]以及FedCG^[47]。实验结果表明,尽管H-MFIM在客户端效用方面略低于部分基线方法,但其在云端效用与边缘服务器效用两项指标上均取得最优表现。

进一步分析可知,客户端效用的相对降低与本文激励机制在最大化社会福利的同时引入了个体理性与保留价格约束有关。具体而言,在保证客户端效用非负的基础上,机制要求支付不低于其最低接受价格,个体理性与保留价格约束在机制学习过程




图9 MNIST数据集下不同基线方法的云端、边缘服务器与客户端效用对比




图10 CIFAR-10数据集下不同基线方法的云端、边缘服务器与客户端效用对比

中得到近似满足,从而对客户端效用的提升空间形成一定限制。相比之下,H-MFIM通过对多维个体属性的综合考量,实现了更精确的客户端选择与更合理的奖励分配,在满足可行性约束的前提下显著提升了云端与边缘服务器效用,体现了激励设计的有效性。

此外,相较于MNIST,CIFAR-10任务在图像特征复杂度与类别区分难度方面更具挑战性,模型训练难度显著增加,因此,在CIFAR-10数据集下云端效用的整体水平相对较低。尽管如此,H-MFIM在CIFAR-10场景下仍能够在云端和边缘服务器效用方面稳定优于各类基线方法,表明所提机制在复杂任务与异构环境下的有效性与鲁棒性。

7 结 论

本文围绕分层联邦持续学习环境下的激励机制设计问题展开研究,针对现有方法忽视客户端多维个体属性及边缘服务器贡献评估不公平等问题,提出了一种基于多维个体属性与公平贡献评估的分层激励机制。在下层边-端架构中,构建了一个深度学习驱动的反向拍卖模型,综合考虑客户端的报价、保留价格、数据时效性、任务匹配度、计算与存储能力

及训练成本等多维因素,实现了动态客户端选择与合理奖励分配,该机制在训练数据上近似满足激励相容性、个体理性和保留价格约束,并通过事后后悔和违背惩罚项的数值接近零来验证其有效性。在上层云-边架构中,引入余弦类别沙普利值解决了Non-IID条件下边缘服务器贡献评估的公平性问题,并证明了基于梯度的余弦相似度可作为沙普利值的良好近似,给出了其近似误差上界。由此,算法的时间复杂度由指数级显著降低至线性级,极大地提升了计算效率。实验结果进一步验证了本文方法相较于传统基线机制的显著优势。

我们进一步讨论了H-MFIM方法的局限性及未来研究方向。将H-MFIM方法应用于异构任务并发处理的复杂场景,特别是在存在非理性攻击的开放网络环境中,面临额外的挑战。为了提高H-MFIM方法的鲁棒性并拓展其适用边界,未来工作将致力于突破单一静态连接的限制,重点探究高移动性场景下的跨域协同激励机制。此外,我们将继续优化模型在复杂和动态环境中的适应能力,探索多任务并行训练、跨域知识迁移及区块链等可信技术的融合,旨在提升分层FCL激励机制在更复杂和开放应用环境中的安全性、效率和公平性。

参 考 文 献

- [1] Khan L U, Pandey S R, Tran N H, et al. Federated learning for edge networks: Resource optimization and incentive mechanism. *IEEE Communications Magazine*, 2020, 58(10): 88-93
- [2] Ma L, Qian Y, Yu G, et al. TBCIM: two-level blockchain-aided edge resource allocation mechanism for federated learning service market. *IEEE Transactions on Networking*, 2025, 33(6): 3408-3423
- [3] Dong J, Wang L, Fang Z, et al. Federated class-incremental learning//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA, 2022: 10164-10173
- [4] Tastan N, Nandakumar K. Capride learning: Confidential and private decentralized learning based on encryption-friendly distillation loss//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada, 2023: 8084-8092
- [5] Qian Y, Ma L. Parameter-efficient federated learning for edge computing with end devices resource limitation//*Proceedings of the 2022 4th International Conference on Industrial Artificial Intelligence*. Shenyang, China, 2022: 1-5
- [6] Wuerkaixi A, Cui S, Zhang J, et al. Accurate forgetting for heterogeneous federated continual learning. *arXiv preprint arXiv: 2502.14205*, 2025
- [7] Qi D, Zhao H, Li S. Better generative replay for continual federated learning. *arXiv preprint arXiv:2302.13001*, 2023
- [8] Shenaj D, Toldo M, Rigon A, et al. Asynchronous federated continual learning//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada, 2023: 5055-5063
- [9] Xu Y, Wang J, Ma L, et al. Two-Stage learning brain storm optimizer//*Proceedings of the International Conference on Intelligent Computing*. Bari, Italy, 2020: 28-40
- [10] Kang H, Li M, Lin L, et al. Bridging incentives and dependencies: an iterative combinatorial auction approach to dependency-aware offloading in mobile edge computing. *IEEE Transactions on Mobile Computing*, 2024, 23(12): 12113-12130
- [11] Zhou Y, Kang H D, Zhang T, et al. Multiple residual quantization of pruning//*Proceedings of the International Conference on Data Mining and Big Data*. Beijing, China, 2022: 209-219
- [12] Ma L, Wang X, Wang X, et al. TCDA: Truthful combinatorial double auctions for mobile edge computing in industrial Internet of Things. *IEEE Transactions on Mobile Computing*, 2021, 21(11): 4125-4138
- [13] Casado F E, Lema D, Iglesias R, et al. Ensemble and continual federated learning for classification tasks. *Machine Learning*, 2023, 112(9): 3413-3453
- [14] Liu Y, Chang S, Liu Y, et al. FairFed: Improving fairness and efficiency of contribution evaluation in federated learning via cooperative Shapley value//*Proceedings of the IEEE INFOCOM 2024-IEEE Conference on Computer Communications*. Vancouver, Canada, 2024: 621-630
- [15] Zhao Y, Li M, Lai L, et al. Federated learning with non-iid data. *arXiv preprint arXiv:1806.00582*, 2018
- [16] Lim W Y B, Ng J S, Xiong Z, et al. Incentive mechanism design for resource sharing in collaborative edge learning. *arXiv preprint arXiv:2006.00511*, 2020
- [17] Kapoor A, Kumar D. Federated learning for urban sensing systems: A comprehensive survey on attacks, defences, incentive mechanisms, and applications. *IEEE Communications Surveys & Tutorials*, 2025, 27(2): 1293-1325
- [18] Ren C, Yu H, Peng H, et al. Advances and open challenges in federated foundation models. *IEEE Communications Surveys & Tutorials*, 2025, 28: 2087-2126
- [19] Sim R H L, Zhang Y, Chan M C, et al. Collaborative machine learning with incentive-aware model rewards//*Proceedings of the 37th International Conference on Machine Learning*. 2020: 8927-8936
- [20] Han J, Khan A F, Zawad S, et al. TIFF: Tokenized incentive for federated learning//*Proceedings of the 2022 IEEE 15th International Conference on Cloud Computing*. Barcelona, Spain, 2022: 407-416
- [21] Kang J, Xiong Z, Niyato D, et al. Incentive mechanism for reliable federated learning: A joint optimization approach to combining reputation and contract theory. *IEEE Internet of Things Journal*, 2019, 6(6): 10700-10714
- [22] Ding N, Fang Z, Huang J. Incentive mechanism design for federated learning with multi-dimensional private information//*Proceedings of the 18th International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks*. Volos, Greece, 2020: 1-8
- [23] Li L, Yu X, Cai X, et al. Contract-theory-based incentive mechanism for federated learning in health crowdsensing. *IEEE Internet of Things Journal*, 2022, 10(5): 4475-4489
- [24] Sarikaya Y, Ercetin O. Motivating workers in federated learning: A stackelberg game perspective. *IEEE Networking Letters*, 2019, 2(1): 23-27
- [25] Hu R, Gong Y. Trading data for learning: Incentive mechanism for on-device federated learning//*Proceedings of the 2020 IEEE Global Communications Conference*. Taipei, China, 2020: 1-6
- [26] Zhan Y, Li P, Qu Z, et al. A learning-based incentive mechanism for federated learning. *IEEE Internet of Things Journal*, 2020, 7(7): 6360-6368
- [27] Le T H T, Tran N H, Tun Y K, et al. An incentive mechanism for federated learning in wireless cellular networks: An auction approach. *IEEE Transactions on Wireless Communications*, 2021, 20(8): 4874-4887
- [28] Jiao Y, Wang P, Niyato D, et al. Toward an automated auction framework for wireless federated learning services market. *IEEE Transactions on Mobile Computing*, 2020, 20(10): 3034-3048
- [29] Tang X, Yu H. Fairness-aware reverse auction-based federated learning. *IEEE Internet of Things Journal*, 2025, 12(7): 8862-

- 8872
- [30] Lim W Y B, Xiong Z, Miao C, et al. Hierarchical incentive mechanism design for federated machine learning in mobile networks. *IEEE Internet of Things Journal*, 2020, 7(10): 9575-9588
- [31] Wu J, Liu Q, Huang Z, et al. Hierarchical personalized federated learning for user modeling//*Proceedings of the Web Conference 2021*. Ljubljana, Slovenia, 2021: 957-968
- [32] Abad M S H, Ozfatura E, Gunduz D, et al. Hierarchical federated learning across heterogeneous cellular networks//*Proceedings of the 2020 IEEE International Conference on Acoustics, Speech and Signal Processing*. Barcelona, Spain, 2020: 8866-8870
- [33] Lim W Y B, Ng J S, Xiong Z, et al. Dynamic edge association and resource allocation in self-organizing hierarchical federated learning networks. *IEEE Journal on Selected Areas in Communications*, 2021, 39(12): 3640-3653
- [34] Lim W Y B, Ng J S, Xiong Z, et al. Decentralized edge intelligence: A dynamic resource allocation framework for hierarchical federated learning. *IEEE Transactions on Parallel and Distributed Systems*, 2021, 33(3): 536-550
- [35] Wang X, Zhao Y, Qiu C, et al. InFEDGE: A blockchain-based incentive mechanism in hierarchical federated learning for end-edge-cloud communications. *IEEE Journal on Selected Areas in Communications*, 2022, 40(12): 3325-3342
- [36] Zhang Y, Liu L, Gu Y, et al. Offloading in software defined network at edge with information asymmetry: A contract theoretical approach. *Journal of Signal Processing Systems*, 2016, 83(2): 241-253
- [37] Dütting P, Feng Z, Narasimhan H, et al. Optimal auctions through deep learning//*Proceedings of the 36th International Conference on Machine Learning*. Long Beach, USA, 2019: 1706-1715
- [38] Kingma D P, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [39] Shapley L S. A value for n-person games//Kuhn H W, Tucker A W, eds. *Contributions to the Theory of Games*. Princeton, USA: Princeton University Press, 1953: 307-317
- [40] Jia R, Dao D, Wang B, et al. Towards efficient data valuation based on the shapley value//*Proceedings of the 22nd International Conference on Artificial Intelligence and Statistics*. Naha, Japan, 2019: 1167-1176
- [41] Tastan N, Fares S, Aremu T, et al. Redefining contributions: Shapley-driven federated learning. *arXiv preprint arXiv:2406.00569*, 2024
- [42] Liu Z, Chen Y, Yu H, et al. Gtg-shapley: Efficient and accurate participant contribution evaluation in federated learning. *ACM Transactions on Intelligent Systems and Technology*, 2022, 13(4): 1-21
- [43] Xu X, Lyu L, Ma X, et al. Gradient driven rewards to guarantee fairness in collaborative machine learning. *Advances in Neural Information Processing Systems*, 2021, 34: 16104-16117
- [44] McMahan B, Moore E, Ramage D, et al. Communication-efficient learning of deep networks from decentralized data//*Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*. Fort Lauderdale, USA, 2017: 1273-1282
- [45] Zhou R, Pang J, Wang Z, et al. A truthful procurement auction for incentivizing heterogeneous clients in federated learning//*Proceedings of the 2021 IEEE 41st International Conference on Distributed Computing Systems*. Washington, USA, 2021: 183-193
- [46] Luo B, Feng Y, Wang S, et al. Incentive mechanism design for unbiased federated learning with randomized client participation//*Proceedings of the 2023 IEEE 43rd International Conference on Distributed Computing Systems*. Hong Kong, China, 2023: 545-555
- [47] Xu Y, Jiang Z, Xu H, et al. Federated learning with client selection and gradient compression in heterogeneous edge systems. *IEEE Transactions on Mobile Computing*, 2023, 23(5): 5446-5461

附录.

定理1证明. 为便于误差上界的推导, 首先将 ϕ_s^j 作等价重写, 把近似量 ϕ_s^j 对应的系数合并为乘性因子 $\mathcal{L}_s^j$, 其余项合为加性误差.

$$\begin{aligned} \phi_s^j &= \sum_{T \subseteq \mathcal{S} \setminus \{s\}} \frac{|\mathcal{T}|!(S-|\mathcal{T}|-1)!}{S!} (\mathcal{V}_j(\mathcal{T} \cup \{s\}) - \mathcal{V}_j(\mathcal{T})) = \\ &= \sum_{T \subseteq \mathcal{S} \setminus \{s\}} \frac{|\mathcal{T}|!(S-|\mathcal{T}|-1)!}{S!} (\cos(\tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j, \tilde{\mathbf{w}}_s^j) - \cos(\tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j)) \end{aligned} \quad (47)$$

为了简化表示, 令 $\Delta_s = \cos(\tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j, \tilde{\mathbf{w}}_s^j) - \cos(\tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j)$, 并记 $r_1 = \|\tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j\|$, $r_2 = \|\tilde{\mathbf{w}}_{\mathcal{T}}^j\|$, $r_3 = \|\tilde{\mathbf{w}}_s^j\|$, 则可得:

$$\begin{aligned} \Delta_s &= \frac{\langle \tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j, \tilde{\mathbf{w}}_s^j \rangle}{\|\tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j\| \times \|\tilde{\mathbf{w}}_s^j\|} - \frac{\langle \tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j \rangle}{\|\tilde{\mathbf{w}}_{\mathcal{T}}^j\| \times \|\tilde{\mathbf{w}}_s^j\|} = \\ &= \frac{\langle \tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j, \tilde{\mathbf{w}}_s^j \rangle}{r_1 r_3} - \frac{\langle \tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j \rangle}{r_2 r_3} = \\ &= \frac{1}{r_1 r_2 r_3} \langle r_2 \tilde{\mathbf{w}}_{\mathcal{T} \cup \{s\}}^j - r_1 \tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j \rangle = \frac{(r_2 - r_1) \langle \tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j \rangle}{r_1 r_2 r_3} + \\ &+ \frac{r_s^j r_2 \langle \tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j \rangle}{r_1 r_2 r_3} = \frac{r_2 - r_1}{r_1} \mathcal{V}_j(\mathcal{T}) + \frac{r_s^j r}{r_1} \cos(\tilde{\mathbf{w}}_{\mathcal{T}}^j, \tilde{\mathbf{w}}_s^j) \quad (48) \end{aligned}$$

结合公式(47), 并令 $\alpha_s = \frac{|\mathcal{T}|!(S-|\mathcal{T}|-1)!}{S!} \frac{r_2 - r_1}{r_1}$, $\beta_s = \frac{|\mathcal{T}|!(S-|\mathcal{T}|-1)!}{S!} \frac{r_s^j r}{r_1}$, 则 ϕ_s^j 可表示为

$$\phi_s^j = \underbrace{\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \alpha_s \mathcal{V}_j(T)}_{\text{加性误差}} + \underbrace{\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \beta_s \psi_s^j}_{\text{乘性因子 } \mathcal{L}_s^j} \quad (49)$$

由三角不等式和柯西-施瓦茨不等式,可推得误差与近似值比值的上界:

$$\begin{aligned} & \left| \frac{r_2 - r_1}{r_1} \mathcal{V}_j(T) \right| = \frac{|(r_2 - r_1) \cos(\tilde{\mathbf{w}}_T^j, \tilde{\mathbf{w}}_s^j)|}{\left| \frac{r_s^j T}{r_1} \cos(\tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_s^j) \right|} = \\ & |r_2 - r_1| \frac{|\langle \tilde{\mathbf{w}}_T^j, \tilde{\mathbf{w}}_s^j \rangle|}{|r_s^j T|} \frac{1}{|\langle \tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_s^j \rangle|} \leq \\ & r \sqrt{\frac{\|\tilde{\mathbf{w}}_T^j\|^2}{r_2^2} \frac{\|\tilde{\mathbf{w}}_s^j\|^2}{r_s^j T}} \frac{1}{|\langle \tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_s^j \rangle|} \leq \\ & r r_3 \frac{1}{r_s^j |\langle \tilde{\mathbf{w}}_s^j, \tilde{\mathbf{w}}_s^j \rangle|} \leq A r^2 \end{aligned} \quad (50)$$

由上述推导可知,误差与近似值的比值在求和中每个联盟 T 上被上界于 $A r^2$,因此,可以得到如下结论:

$$\left| \frac{\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \alpha_s \mathcal{V}_j(T)}{\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \beta_s \psi_s^j} \right| \leq A r^2 \quad (51)$$

接下来,为证明 $\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \beta_s \psi_s^j \leq 1$,引入假设 $r_s^j T / r_1 \leq 1$,并由于 $|\psi_s^j| \leq 1$,可得 $|r_s^j T \psi_s^j / r_1| \leq 1$. 因此,对所有联盟 T 求和时,有 $\sum_{T \subseteq \mathcal{S} \setminus \{s\}} r_s^j T \psi_s^j / r_1 \leq \sum_{T \subseteq \mathcal{S} \setminus \{s\}} 1$,因为枚举 T 并不完全,所以系数小于 1,将沙普利系数带入可得 $\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \beta_s \psi_s^j \leq$

$\sum_{T \subseteq \mathcal{S} \setminus \{s\}} \frac{|T|!(S-|T|-1)!}{S!} \leq 1$,结合公式(49)与公式(51),可得 $\phi_s^j - \mathcal{L}_s^j \psi_s^j \leq A r^2$.

虽然证明了 ϕ_s^j 与 ψ_s^j 之间的误差是有界的,但为了直接使用 ψ_s^j 作为公平性度量,还需确保乘性因子 $\mathcal{L}_s^j$ 对所有参与者是近似相等的。

引理 1. 假设 $\exists M > 0$,使得对于 $\forall T \subseteq \mathcal{S} \setminus \{s, s'\}$, $\min(\|\tilde{\mathbf{w}}_{T \cup \{s\}}^j\|, \|\tilde{\mathbf{w}}_{T \cup \{s'\}}^j\|) \geq M r$,则有

$$\max_{s, s' \in \mathcal{S}} \mathcal{L}_s^j - \mathcal{L}_{s'}^j \leq \sum_{T \subseteq \mathcal{S} \setminus \{s, s'\}} 1 / \binom{S-1}{|T|} \cdot \frac{2}{M^2 r} \quad (52)$$

引理 1 证明. 由于对称性,若 $\tilde{\mathbf{w}}_s^j = \tilde{\mathbf{w}}_{s'}^j$,则 $\mathcal{L}_s^j = \mathcal{L}_{s'}^j$. 因此,只需要考虑 $\tilde{\mathbf{w}}_s^j \neq \tilde{\mathbf{w}}_{s'}^j$,将 T 分为三种情况来考虑求和项. 1) $s \in T \wedge s' \in T$; 2) $s \in T \oplus s' \in T$; 3) $s \notin T \wedge s' \notin T$.

首先,由于 $\mathcal{L}_s^j$ 的求和域限制,同时包含 s 和 s' 的情况 1 直接排除. 对于情况 2,设 $T \subseteq \mathcal{S} \setminus \{s, s'\}$,并定义 $\mathcal{T}_s = T \cup \{s\}$ 和 $\mathcal{T}_{s'} = T \cup \{s'\}$. 此时, $\mathcal{L}_s^j$ 的求和对应项可表示为 $1 / \binom{S-1}{|T|} \times 1 / \|\tilde{\mathbf{w}}_{\mathcal{T}_s \cup \{s\}}^j\|$,由于梯度聚合满足 $\tilde{\mathbf{w}}_{\mathcal{T}_s \cup \{s\}}^j = \tilde{\mathbf{w}}_{T \cup \{s, s'\}}^j = \tilde{\mathbf{w}}_{\mathcal{T}_{s'} \cup \{s\}}^j$,且 $|\mathcal{T}_s| = |T| + 1 = |\mathcal{T}_{s'}|$,故对称项在差值计算 $\mathcal{L}_s^j - \mathcal{L}_{s'}^j$ 中被抵消,即情况 2 的贡献为 0. 对于情况 3,可得到下式:

$$\begin{aligned} \mathcal{L}_s^j - \mathcal{L}_{s'}^j &= \sum_{T \subseteq \mathcal{S} \setminus \{s, s'\}} 1 / \binom{S-1}{|T|} \left[\frac{1}{\|\tilde{\mathbf{w}}_{T \cup \{s\}}^j\|} - \frac{1}{\|\tilde{\mathbf{w}}_{T \cup \{s'\}}^j\|} \right] = \\ & \sum_{T \subseteq \mathcal{S} \setminus \{s, s'\}} 1 / \binom{S-1}{|T|} \frac{\|\tilde{\mathbf{w}}_{T \cup \{s'\}}^j\| - \|\tilde{\mathbf{w}}_{T \cup \{s\}}^j\|}{\|\tilde{\mathbf{w}}_{T \cup \{s\}}^j\| \times \|\tilde{\mathbf{w}}_{T \cup \{s'\}}^j\|} \leq \\ & \sum_{T \subseteq \mathcal{S} \setminus \{s, s'\}} 1 / \binom{S-1}{|T|} \frac{2r}{M^2 r^2} \leq \sum_{T \subseteq \mathcal{S} \setminus \{s, s'\}} 1 / \binom{S-1}{|T|} \frac{2}{M^2 r} \end{aligned} \quad (53)$$

由上述分析可知,不同参与者的乘性因子近似相等. 因此,在计算相对贡献时可将其视为公共常数,这为定理 1 中消除影响的归一化处理提供了严格的理论依据.

证毕.



ZHAO Ze-Xuan, M. S. candidate. Her main research interests include federated learning and edge computing.

QIAN Ying, Ph. D. candidate. Her main research interests include federated learning and edge computing.

MA Lian-Bo, Ph. D., professor, Ph. D. supervisor. His research interests include computational intelligence, edge computing and federated learning.

HUANG Min, Ph. D., professor, Ph. D. supervisor. Her research interests include industrial internet, supply chain and intelligent optimization.

WANG Xing-Wei, Ph. D., professor, Ph. D. supervisor. His research interests include computer networks, cloud computing and artificial intelligence.

Background

Federated Continual Learning enables clients to collaboratively train models in a dynamic data distribution environment, where each client continuously receives local data in a data stream form, and the central server coordinates the

federated learning process in this dynamic environment. Most existing studies assume that clients are always willing to participate in training. However, participation inevitably incurs computational and communication costs. Unless adequately

compensated, self-interested clients generally lack the motivation to contribute data. Therefore, this paper focuses on the critical issue of incentive mechanisms in federated continual learning. In the cloud-edge-client architecture, client selection and contribution evaluation remain challenging research topics.

Most current research on incentive mechanisms in federated learning is confined to static data scenarios and single-dimensional optimization, lacking a comprehensive consideration of multi-dimensional attributes. Facing multiple challenges in federated continual learning environments, such as dynamic client participation, non-independent and identically distributed data, and resource heterogeneity, traditional incentive mechanisms perform poorly in contribution evaluation, making fair reward allocation difficult. Moreover, due to their static design assumptions, these mechanisms cannot adapt to continuously changing data streams and task demands, leading to significant shortcomings in client selection and fair contribution evaluation.

To address the limitations of existing research, this paper proposes a fair incentive mechanism for federated continual learning in a hierarchical framework. In the lower layer, a multi-dimensional reverse auction mechanism based on deep learning is constructed, which dynamically selects clients and allocates reasonable rewards based on neural networks that analyze multi-dimensional client attributes, subject to client reserve-price

constraints. In the upper layer, this paper introduces the Cosine-Class Shapley Value method, which measures the contribution of edge servers in a Non-IID data environment through gradient-based cosine similarity, ensuring the fairness and accuracy of the evaluation. Furthermore, we theoretically show that gradient cosine similarity provides an effective approximation to the Shapley value and derive an explicit bound on the approximation error. Extensive simulations demonstrate that, under dynamic and Non-IID conditions, the proposed mechanism achieves higher social welfare with lower ex post regret, satisfies individual rationality and reserve-price constraints, and simultaneously improves the utilities of the cloud and edge, thereby ensuring overall fairness.

This work was supported by the National Natural Science Foundation of China (62472079) and the National Key Research and Development Program of China (2022YFB4500800). The latter focuses on cloud supervision and governance in JointCloud computing and aims to advance its practical application. Our research team has made significant contributions in areas such as federated learning incentives and cross-domain resource scheduling, publishing five papers in top-tier international journals, including IEEE TON, IEEE TMC, and IEEE TSC (CCF A-class), two of which have been selected as ESI highly cited papers.