

面向工业物联网的意图驱动联邦学习：基于合同理论的边缘数据增强机制

覃少雯¹, 李晓欢¹, 曾健峰¹, 吴远², 康嘉文³

(1. 桂林电子科技大学信息与通信学院, 广西 桂林 541004; 2. 澳门大学智慧城市技术研究院, 澳门 999078; 3. 广东工业大学自动化学院, 广东 广州 510006)

摘要: 针对工业物联网中联邦学习终端样本不足、边缘生成能力异构以及云一边信息不对称等问题, 提出了一种面向工业物联网的意图驱动联邦学习边缘数据增强机制。该机制利用大语言模型解析用户意图, 将非结构化需求转化为可优化的结构化参数, 并结合终端数据分布偏离度进行边缘生成数据分配; 同时, 基于合同理论设计边缘增强服务激励机制, 引导异构边缘节点提供有效数据增强服务。仿真实验结果表明, 所提方法能够提升非独立同分布场景下的模型训练性能, 并在不同用户意图约束下自适应调整边缘增强服务水平, 使模型训练结果更符合用户对精度、时延和成本的差异化需求。

关键词: 工业物联网; 意图驱动; 联邦学习; 数据增强; 合同理论; 边缘计算

中图分类号: TP181

文献标志码: A

Intent-Driven Federated Learning for Industrial Internet of Things: A Contract Theory-Based Edge Data Augmentation Mechanism

Qin Shaowen¹, Li Xiaohuan¹, Zeng Jianfeng¹, Wu Yuan², Kang Jiawen³

1. School of information and communication, Guilin University of Electronic Technology, Guilin 541004, China

2. Faculty of Science and Technology, University of Macau, Macau 999078, China

3. School of Automation, Guangdong University of Technology, Guangzhou 510006, China

Abstract: To address the key challenges including insufficient terminal samples, heterogeneous edge generation capabilities, and cloud-edge information asymmetry in federated learning for the Industrial Internet of Things, this paper proposes an intent driven edge data augmentation mechanism for federated learning in industrial IoT. The proposed mechanism employs a large language model to interpret user intents and transform unstructured requirements into optimizable structured parameters. Edge-generated data are then allocated according to the distribution deviation of terminal data. In addition, a contract theory-based incentive mechanism is developed for edge augmentation services, which encourages heterogeneous edge nodes to provide effective data augmentation. Simulation results show that the proposed method can improve model training performance in non-independent and identically distributed (Non-IID) scenarios and adaptively adjust the edge augmentation service level under different user intent constraints, making the training outcomes better aligned with users' heterogeneous requirements for accuracy, latency, and cost.

Key words: Industrial Internet of Things, intent-driven networking, federated learning, data augmentation, contract theory, edge computing

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 李晓欢, lxhguet@guet.edu.cn

基金项目: 国家自然科学基金资助项目 (No. U22A2054); 广西研究生教育创新计划项目 (No. YCBZ2026184)

Foundation Items: The National Natural Science Foundation of China (No. U22A2054), The Innovation Project of Guangxi Graduate Education (No. YCBZ2026184)

0 引言

随着工业物联网 (Industrial Internet of Things, IIoT) 的快速发展, 大量终端设备被部署于复杂多变的生产环境中, 用于采集设备状态及运行数据^[1-2], 并支撑设备故障诊断、仓储物流调度 and 产品质量检测等智能任务。在这些任务中, 工业智能模型的训练与部署需求并不完全相同, 例如, 在智能制造车间, 设备故障预测任务要求模型具备极高的实时响应能力; 在智能仓库中, 自动分拣和装卸任务需要快速响应订单变化以确保物资准时配送; 而在工业质检场景中, 产品缺陷识别任务则更强调高识别精度。因此 IIoT 中的智能训练过程需要能够根据不同任务需求灵活调整模型性能、训练时延和资源成本。然而, 这些包含任务需求的用户意图通常以自然语言或作业指令形式表达, 虽内容具体但却难以直接量化。意图驱动网络 (Intent-Based Networking, IBN)^[3-4] 通过利用大语言模型 (Large Language Model, LLM)^[5] 解析自然语言任务描述, 可以将用户意图映射为可执行策略^[6-7]。但由于 IIoT 节点通常分布在不同区域, 设备类型和计算能力各异, 且数据存在隐私敏感性, 使得难以将数据上传到某个节点进行集中式训练^[8]。联邦学习 (Federated Learning, FL)^[9-10] 作为一种隐私保护的分布式学习范式, 可以使终端设备在本地数据不出域的前提下协同训练全局模型, 从而在保护原始数据隐私的同时充分利用分散在不同终端上的工业数据。

然而, 在 IIoT 中, 部分终端设备受限于样本稀缺或运行状态单一, 无法积累充足的高质量训练数据^[11], 因此仅依靠有限本地真实数据难以支撑有效的模型训练^[12]。此外, 由于终端设备在工作环境、采样频率及运行状态等方面存在显著差异, 其本地数据通常呈现出明显的非独立同分布 (Non-independent and identically distributed, Non-IID) 特性, 这会导致模型收敛速度下降并影响泛化性能, 从而影响 FL 的整体训练效果^[13]。为了缓解分布式环境下数据稀缺与分布偏移问题, 数据增强技术被引入 FL, 以增加训练数据的多样性和覆盖度^[14-15]。现有方法通常在终端设备或云服务器生成补充样本, 以改善模型训练性能。但由于终端设备生成能力受到算力和能耗限制, 而云服务器集中生成则会引入额外的通信开销与时延, 二者均难以满足 IIoT

场景下的高效训练需求。相比之下, 边缘服务器计算能力强且更靠近终端设备, 在执行数据增强时能够兼顾性能、时延和适应性优势^[16], 因此边缘辅助的数据增强机制被认为是提升 FL 性能的一种有效手段。

尽管边缘辅助数据增强能够缓解终端样本不足和数据分布异质性问题, 但在意图驱动的 FL 场景中, 数据增强决策并非独立的资源配置问题, 而是受到用户任务需求、终端数据状态和边缘服务能力的共同影响。首先, 不同用户意图对模型精度、训练时延和系统成本具有不同偏好, 这些高层需求需要进一步映射为可执行的数据增强服务需求, 而现有意图驱动方法主要面向网络控制与策略生成, 尚缺乏面向 FL 训练过程的跨层映射机制。其次, 边缘增强服务水平不仅决定生成样本规模, 还会通过终端数据分配进一步影响有效训练数据规模、Non-IID 程度、模型误差和训练时延^[17], 这使得边缘增强服务的确定需要同时考虑其对联邦学习训练性能和训练效率的影响^[18-19]。最后, 不同边缘节点的生成能力、数据有效性和资源成本通常属于私有信息^[20], 云服务器难以直接依据用户意图确定合理的增强任务与奖励水平。因此, 如何在信息不对称条件下, 统一考虑用户意图、终端数据需求、边缘增强服务和联邦训练性能, 并合理确定增强服务水平、数据分配与激励支付, 是本文关注的核心问题。

针对上述问题, 本文提出一种面向 IIoT 的意图驱动边缘增强 FL 机制。该机制利用 LLM 将用户非结构化意图解析为可优化的结构化参数, 并据此刻画不同任务对模型性能、训练效率、系统成本和数据增强的差异化需求。在此基础上, 结合终端数据分布特征和边缘节点异构能力确定增强服务与数据分配策略, 并基于合同理论设计信息不对称条件下的边缘增强服务激励机制, 从而根据用户意图自适应确定边缘增强服务水平与数据分配, 并引导异构边缘节点提供相应的增强服务。本文的主要贡献如下:

(1) 提出一种面向 IIoT 的意图驱动边缘增强 FL 框架, 将用户高层意图解析为模型误差、训练时延、系统成本和增强偏离等结构化参数, 并建立意图参数与边缘增强服务、数据分配及联邦训练过程之间的关联, 使不同任务需求能够进一步作用于

边缘增强与联邦训练策略。

(2) 构建面向联邦训练的边缘数据增强模型, 根据终端数据分布偏离度进行生成数据分配, 并引入有效生成数据量刻画生成样本对模型训练的实际贡献。在此基础上, 建立增强服务水平与模型误差、训练时延及增强偏离之间的关系, 使边缘增强服务能够根据用户意图和终端数据状态进行自适应调整。

(3) 针对边缘节点生成能力和资源成本私有导致的云一边信息不对称问题, 设计意图驱动的边缘增强服务合同机制, 以增强服务水平和奖励支付为合同变量, 在满足个体理性和激励相容约束的条件下优化边缘增强服务配置, 并推导可行合同的单调性条件与最优奖励表达式, 引导不同类型边缘节点选择与自身能力相匹配的增强服务。

1 相关工作

1.1 意图驱动网络

IBN将用户需求抽象为高级意图, 并通过意图解析、策略生成、策略执行和意图保障等过程, 将非结构化或半结构化需求自动映射为可执行的网络控制策略, 为复杂网络环境下的自动化管理与智能控制提供了一种有效思路。Njah等^[21]提出一种AI驱动的IBN架构, 将意图驱动网络划分为意图细化、意图激活和意图保障等关键环节, 并结合LLM、深度强化学习和多智能体强化学习实现从高层意图到网络策略执行的自动化过程。随着大语言模型的发展, LLM辅助的意图理解与策略生成^[22-23]逐渐成为IBN的重要研究方向。Wei等^[24]通过链式推理机制增强模型的推理能力, 为意图解析与策略生成提供技术基础。Manias等^[25]面向5G核心网络管理提出一种基于LLM的意图提取方法, 能够从用户自然语言请求中识别部署、修改、性能保障、可行性检查和状态通知等多类网络意图。针对单纯依赖提示词的LLM方法可能存在输入长度受限、相似意图区分困难和幻觉输出等问题, Manias等^[26]进一步引入语义路由机制, 通过确定性路由提升LLM辅助意图识别的准确性和可靠性。此外, 除了意图提取与解析, 意图保障也是IBN中的重要问题。Dzeparoska等^[27]提出一种由LLM引导的意图保障框架, 通过提取关键性能指标并度量目标状态与运行状态之间的意图偏移, 实现对意图偏

离的检测和纠正。Romero等^[28]将智能体AI与意图驱动范式引入工业自动化系统, 利用LLM代理将高层业务或运维意图分解为期望、条件、目标、上下文和信息等可执行组成部分, 并在预测性维护场景中验证了该方法的可行性。

然而, 现有研究主要面向意图驱动的网络自治控制, 侧重于将用户意图转化为网络配置或控制策略, 尚未充分考虑工业物联网中FL训练过程的差异化需求。对于模型性能、训练时延和系统成本等高层任务偏好, 仍缺乏将其进一步转化为数据增强服务需求并作用于联邦训练过程的有效机制。

1.2 联邦学习中的数据增强

在IIoT场景中, 终端设备长期运行于复杂工况下, 采集的数据样本规模有限且类别分布不均, 一些极端工况的故障样本较为稀缺。这样的问题导致IIoT中的FL模型更新方向偏离全局优化目标, 进而影响模型收敛速度和泛化性能。为缓解数据异质性带来的性能下降, 数据增强逐渐成为FL中的重要研究方向。Duan等^[17]提出了Fed-TDA方法, 通过低维统计信息合成表格数据, 在保护隐私和降低通信开销的同时缓解Non-IID数据对模型训练的影响。Li等^[29]提出基于硬特征匹配的数据合成方法, 通过学习真实样本的类别相关特征生成辅助数据, 以降低客户端之间的数据分布差异。Morafah等^[30]利用预训练Stable Diffusion模型在客户端侧生成缺失类别样本, 使增强后的本地数据分布更加接近全局分布。Li等^[31]提出FIMI框架, 根据终端缺失数据情况生成补充样本, 并联合考虑数据增强策略与资源利用策略, 从而提升FL训练效率。虽然生成数据可以用于缓解FL中的数据异质性, 但也引入了资源消耗与参与激励问题。Tay等^[32]提出一种基于合成数据奖励的协作机器学习机制, 根据参与方的数据贡献分配合成数据, 从而激励自利参与方进行数据协作。Huang等^[33]针对AIGC赋能的FL场景, 考虑客户端在本地训练和数据合成过程中产生的成本, 设计了数据质量感知的激励机制, 以鼓励客户端参与模型训练并合理采用生成数据。Zhang等^[34]进一步研究生成式AI提供方与异构边缘设备共同参与的FL场景, 通过反向拍卖机制实现生成数据服务交易, 并根据生成数据质量优化参与方选择与支付策略。

上述研究表明, 数据增强能够有效缓解FL中




图1 意图驱动边缘增强联邦学习框架

的数据稀缺和分布异质性问题。然而，现有方法大多围绕客户端本地生成、生成模型调用或生成数据交易展开，尚未充分考虑工业物联网中云一边一端协同架构下的边缘增强服务建模问题。特别是在边缘节点生成能力和资源成本难以被云服务器准确获知的情况下，现有方法难以根据用户意图和终端数据需求确定差异化的增强服务水平与数据分配策略，同时通过激励机制引导异构边缘节点提供相应的增强服务。

2 系统模型

2.1 系统框架

本文考虑一个面向工业物联网场景的意图驱动边缘增强FL系统，采用云一边一端三层协同架构，如图1所示。云服务器位于系统顶层，负责接收用户以自然语言任务描述或作业指令形式输入的任务意图，并利用大语言模型进行语义解析，进而将用户意图转化为结构化意图元组。在此基础上，云服务器结合用户意图与系统状态设计面向边缘节点的合同选项，引导边缘节点参与数据增强与训练协同。同时，云服务器还负责接收各边缘节点上传的边缘聚合模型，并执行全局模型聚合。边缘节点位于系统中间层，既是增强服务提供者，也是区域模型聚合者。每个边缘节点根据自身资源状态、生成能力、意图要求以及所辖终端设备的原始数据分布，选择合适的合同，并按照合同要求生成数据、分配给所属终端设备。在终端完成本地训练后，边缘节点进一步收集其所辖终端上传的本地模型更

新，并执行边缘聚合，形成边缘模型后上传至云服务器。终端设备位于系统底层，负责采集真实工业数据，并基于本地真实数据与边缘生成数据共同执行本地模型训练。由此，所提出框架形成了“终端本地训练—边缘区域聚合—云侧全局聚合”的两级FL流程，其中边缘生成数据通过影响终端有效训练数据规模，进一步作用于本地训练效果、边缘聚合质量以及全局模型性能。

本文将 $E = \{1, \dots, e, \dots, E\}$ 设为边缘服务器的集合，每个边缘服务器 e 管理一组终端设备，记为 $U = \{1_e, \dots, u_e, \dots, U_e\}$ 。对于每个边缘服务器 e ，其所服务的终端设备集合记为 $u_e \subseteq U$ 。在系统运行过程中，每个终端设备 u 拥有一个本地真实数据集 D_u ，其大小为 $d_u = |D_u|$ 。设数据类别个数为 $K = \{1, \dots, k, \dots, K\}$ ，终端 u 在第 k 类上的真实样本数记为 $d_{u,k}$ ，满足 $\sum_{k=1}^K d_{u,k} = d_u$ 。终端 u 的本地类别分布为 $p_{u,k} = \frac{d_{u,k}}{d_u}$ 。在边缘增强机制下，边缘服务器 e 可为其管辖终端 u 生成补充数据集 $\tilde{D}_u$ ，其样本规模记为 $\tilde{d}_u = |\tilde{D}_u|$ 。生成样本并不直接等价于真实样本，它们对模型训练的贡献通常受到生成质量、场景匹配程度以及样本可利用性的影响。

2.2 意图解析与结构化表示

在工业物联网场景中，用户通常以自然语言、任务描述或作业指令的形式表达系统需求，例如“在给定资源预算内提升故障识别精度”，“优先保证生成数据与目标工况一致性”，“在边缘设备可部

署条件下完成模型训练”等。这样的原始意图往往是非结构化的,难以直接用于后续的数据增强、资源分配和联邦训练优化。因此,在系统优化开始之前,需要首先对用户意图进行解析,并将其转换为可参与后续优化建模的结构化表示。

本文在云侧引入LLM对其进行语义解析与任务编译,并将其表示为结构化意图元组:

$$I = \{ \lambda_a, \lambda_d, \lambda_c, \lambda_s, \rho \} \# (1)$$

其中, λ_a 、 λ_d 、 λ_c 和 λ_s 分别表示用户对模型误差、训练时延、系统成本和增强服务偏离的关注程度(即权重因子),并作为相应目标项的权重参与云服务器效用计算,满足 $\lambda_a, \lambda_d, \lambda_c, \lambda_s, \rho \in [0, 1]$, 且 $\lambda_a + \lambda_d + \lambda_c + \lambda_s = 1$ 。 ρ 表示用户对数据增强依赖程度,用于控制生成样本在终端训练数据中的最大允许比例,并进一步影响意图驱动的目标增强服务水平。为保证结构化意图能够直接用于后续优化,LLM按照预定义的输出约束生成意图元组,并对各参数的取值范围及权重和进行限制。由此,不同用户意图通过改变上述权重和增强依赖参数,影响云服务器对增强服务水平的优化,并进一步确定与不同增强服务水平对应的合同奖励。

2.3 数据增强与偏离惩罚模型

在边缘数据增强过程中,边缘节点需要根据所辖终端设备的数据分布情况,将生成样本合理分配给不同终端。本文将边缘节点分配给每个终端的增强样本数定义为:

$$\tilde{d}_u = \frac{\frac{H_u}{d_u}}{\sum_{u \in U} \frac{H_u}{d_u}} Y_e \# (2)$$

其中, Y_e 为边缘节点 e 所提供的增强服务水平,即该边缘节点实际生成可分配给所属终端设备的生成样本总量; H_u 为设备 u 的分布偏离度,定义为其局部标签分布与参考分布之间的 Jensen - Shannon 散度^[35],表示为:

$$H_u = \frac{1}{2} \sum_{k=1}^K p_{u,k} \log \frac{2p_{u,k}}{p_{u,k} + p_{\text{ref},k}} + \frac{1}{2} \sum_{k=1}^K p_{\text{ref},k} \log \frac{2p_{\text{ref},k}}{p_{u,k} + p_{\text{ref},k}} \# (3)$$

其中 $p_{u,k}$ 表示终端设备 u 的本地数据集中,第 k 类样本所占的比例; $p_{\text{ref},k}$ 表示终端设备 u 所属边缘节点所辖终端数据聚合形成的参考分布中第 k 类样本所

占比例。因此, H_u 用于衡量终端设备 u 的本地数据分布相对于其所属边缘区域数据分布的偏离程度。

虽然边缘侧生成数据可以缓解终端设备样本不足和数据分布不均衡的问题,但生成数据并不能无限制地替代真实数据。一方面,过高比例的生成样本可能引入额外噪声,削弱模型对真实分布的拟合能力;另一方面,生成过程本身会消耗边缘计算资源。为了应对这个问题,本文对客户接收的生成数据比例进行了约束。对每个端 u ,生成数据占比

为 $\frac{\tilde{d}_u}{d_u + \tilde{d}_u}$, 满足:

$$\frac{\tilde{d}_u}{d_u + \tilde{d}_u} \leq \rho_u \# (4)$$

其中 ρ_u 为生成样本比例上限, 定义为:

$$\rho_u = \rho_{\min} + (\rho_{\max} - \rho_{\min}) \rho \frac{H_u}{H_u + \kappa} \# (5)$$

其中, $\rho_{\min}$ 为最低生成样本比例上限, $\rho_{\max}$ 为最大上限, $\kappa > 0$ 为控制增长速度的平滑常数。由上述可得,生成数据量 $\tilde{d}_u$ 应满足 $0 \leq \tilde{d}_u \leq \frac{\rho_u}{1 - \rho_u} d_u$, 其

最大生成数据量上限为 $\tilde{d}_u^{\max} = \frac{\rho_u}{1 - \rho_u} d_u$ 。

由于存在最大生成数据量,可能会出现某些终端所分配的生成数据达到上限,边缘节点通过迭代或缩放方式将生成数据分配给各终端,同时不超过每个终端的最大比例限制。此外,由于生成样本的质量可能存在差异,因此并非所有生成样本都能够等效地提升模型训练效果。为此,引入有效生成数据量的概念,将生成质量纳入数据规模的度量。对于终端设备 u ,其有效数据规模为:

$$d_u^e = d_u + \xi_e \tilde{d}_u \# (6)$$

其中 $\xi_e \in (0, 1]$ 表示生成数据的有效利用率,通过对历史生成样本进行任务一致性和质量验证,并统计通过验证的有效样本数与候选生成样本总数的比例进行估计。进一步地,考虑生成数据的有效利用率,将边缘节点 e 的有效增强服务水平定义为其对所属终端提供的有效生成数据总量,表示为:

$$Y_e^{\text{eff}} = \sum_{u \in U} \xi_e \tilde{d}_u \# (7)$$

其中, Y_e^{eff} 表示边缘节点 e 的有效增强服务水平,用于刻画其生成数据经有效利用率折算后对终端训练的实际贡献。在给定用户意图元组 I 的条件下,

云服务器对不同边缘节点的增强服务存在期望目标。该目标不仅取决于用户对增强的整体依赖程度,还受到系统数据分布异质性程度的影响。边缘节点 e 的平均分布偏离度 $\bar{H}_e$ 定义为:

$$\bar{H}_e = \sum_{u \in \mathcal{U}_e} \omega_u H_u \# (8)$$

其中, $\omega_u = \frac{d_u}{\sum_{u \in U} d_u}$ 。基于此可得到意图驱动的目标增强水平 $\bar{Y}_e$, 定义为:

$$\bar{Y}_e = \eta \rho \bar{H}_e \sum_{u \in \mathcal{U}_e} d_u \# (9)$$

其中 $\eta > 0$ 为归一化系数。然后, 增强偏离惩罚可定义为:

$$\Psi = \sum_{e \in \mathcal{E}} \omega_e (Y_e - \bar{Y}_e)^2 \# (10)$$

其中, $\omega_e = \frac{\sum_{u \in U} d_u}{\sum_{e \in E} \sum_{u \in U} d_u}$ 。增强偏离惩罚用于衡量边缘节点实际提供的增强服务水平与意图驱动目标增强水平之间的偏差, 避免增强服务过低导致训练性能不足, 从而影响训练效率和资源利用。

2.4 训练误差与时间模型

在FL中, 终端设备的训练性能与其可用数据规模相关。通常情况下, 当设备拥有更多训练样本时, 其本地模型能够获得更稳定的梯度更新, 从而降低整体训练误差。然而, 在实际IIoT环境中, 由于设备采集数据能力有限, 不同终端设备之间往往存在显著的数据规模差异。这种数据不均衡问题会导致FL模型收敛速度下降, 并影响最终模型精度, 而终端设备的本地学习误差可以近似为有效数据集大小的幂律函数^[31]。对于终端设备 u , 本地学习误差建模为:

$$\delta_u = a_u d_u^{e-b_u} + c_u \# (11)$$

其中 a_u 、 b_u 、 c_u 是通过离线拟合得到的经验参数。由此可得, 本地学习误差取决于有效生成数据量。为了描述边缘节点与所辖终端设备之间的局部学习性能, 可以将边缘节点的局部误差定义为所辖终端设备本地误差的加权平均^[31], 表示为:

$$\delta_e = \sum_{u \in U} \tilde{\omega}_u \delta_u \# (12)$$

其中 $\tilde{\omega}_u = \frac{d_u^e}{\sum_{u \in U} d_u^e}$ 表示局部聚合权重。接着本文将云端聚合所有边缘节点所上传的局部模型的全局

误差表示为:

$$\delta_c = \sum_{e \in E} \tilde{\omega}_e \delta_e \# (13)$$

其中 $\tilde{\omega}_e = \frac{\sum_{u \in U} d_u^e}{\sum_{e \in E} \sum_{u \in U} d_u^e}$ 表示全局聚合权重。

在FL中, 模型训练误差通常呈指数收敛趋势。当误差降低至 δ_c 时, 可以得到云端与边缘节点之间的FL收敛轮次为:

$$N = \frac{\zeta \ln \frac{1}{\delta_c}}{1 - \bar{\delta}_e} \# (14)$$

其中, ζ 为常数参数; $\bar{\delta}_e$ 为平均局部学习误差。对终端设备 u , 其处理单条训练样本所需的平均计算时间定义为 t_u^s , 因此其本地训练时延可表示为:

$$T_u = t_u^s (d_u + \tilde{d}_u) \# (15)$$

考虑终端本地训练完成后需将模型上传至所属边缘节点, 设 $T_{u,e}^{up}$ 为终端设备 u 向边缘节点 e 上传本地模型的通信时延, T_e^{agg} 为边缘节点执行区域模型聚合的计算时延。由于同一边缘节点下的终端设备并行训练, 边缘节点的单轮完成时延由最慢终端决定, 可表示为:

$$T_e^r = \max_{u \in \mathcal{U}_e} (T_u + T_{u,e}^{up}) + T_e^{agg} \# (16)$$

进一步地, 设 $T_{e,c}^{up}$ 为边缘节点 e 向云服务器上传区域模型的通信时延, T_c^{agg} 为云服务器执行全局模型聚合的计算时延, 则全局单轮时延定义为:

$$T^r = \max_{e \in \mathcal{E}} (T_e^r + T_{e,c}^{up}) + T_c^{agg} \# (17)$$

此外, 边缘节点在联邦训练开始前需要完成生成模型推理以及生成数据向终端设备的下发。将该一次性增强阶段时延记为 T^{aug} , 其中包括边缘生成模型推理时延和生成数据下发时延。由于增强数据在联邦训练开始前生成并分配完成, 因此该部分时延仅计算一次。由此, 总训练时延表示为:

$$T^{tot} = T^{aug} + NT^r \# (18)$$

2.5 效用模型

由于不同边缘节点在计算资源、生成能力以及生成数据有效性等方面存在差异, 因此本文将边缘节点的数据增强能力建模为私有类型 θ_e 。边缘节点在执行数据增强任务时, 其成本函数定义为:

$$C_e = \frac{\beta}{\theta_e} Y_e^2 (1 + \kappa \zeta_e) \# (19)$$

其中, β 表示单位数据增强服务的基础资源消耗系数, 即模型推理、计算资源占用以及能耗等带来的系统级基础开销; κ 表示生成数据有效性所引入的额外资源开销敏感系数, 即生成数据在生成过程中带来的附加计算与推理成本。

边缘节点通过分配生成数据以平衡节点能力、生成规模、质量要求与生成成本, 本文将其效用函数定义为:

$$U_e = R_e - C_e \# (20)$$

其中, R_e 表示云服务器向边缘节点提供的数据增强服务支付的奖励, 其大小与边缘节点提供的增强服务水平相关。

由于云服务器需要联合考虑全局 FL 误差、训练时延、增强偏离以及系统成本, 以满足不同意图的需求, 因此本文将其效用函数定义为:

$$U_c = -(\lambda_a \frac{\delta_c}{\delta_0} + \lambda_d \frac{T^{\text{tot}}}{T_0} + \lambda_s \frac{\Psi}{\Psi_0} + \lambda_c \frac{\sum_{e=1}^E R_e}{C_0}) \# (21)$$

其中 δ_0 、 T_0 、 Ψ_0 、 C_0 分别为模型误差、训练时延、增强偏离和奖励成本的归一化尺度, 用于消除不同效用项之间的量纲和数值尺度差异。奖励成本通过效用函数中的加权项进行软约束, 其重要程度由意图参数 λ 调节。该效用函数反映了云服务器在模型性能、训练效率、语义一致性以及系统资源消耗之间的联合权衡。

3 最优合同设计

3.1 合同制定

在所考虑的意图驱动 FL 系统中, 不同边缘服务器在执行数据增强任务时, 其计算能力、能耗开销以及单位生成数据的有效性存在显著差异。这些能力与成本信息通常由边缘节点自身掌握, 云服务器无法事先准确获取, 因此云一边交互过程具有典型的信息不对称特征。在此情况下, 云服务器使用合同理论来找出最佳边缘节点。在这里, 云服务器是设计合同的领导者, 每个边缘节点根据其类型选择最佳合同项。

由于云服务器不知道每个边缘节点的生成成本, 因此它可以根据历史数据中边缘节点类型的统计分布将边缘节点分为离散类型。本文将边缘节点分为不同的 M 个类型, 并将第 m 种类型的边缘节点表示为 θ_m 。边缘节点可分为 m 种类型的集合 $\Delta =$

$\{\theta_m; 1 \leq m \leq M\}$ 。边缘节点的类型按非递减顺序排列为 $\theta_1 \leq \theta_2 \leq \dots \leq \theta_M$ 。边缘节点属于某个类型 m 的概率是 Q_m , 有 $\sum_{m \in M} Q_m = 1$ 。因此, m 型边缘节点的效用可以重写为:

$$U_m = R_m - C_m \# (22)$$

云端根据意图元组 I 和系统状态, 设计面向边缘节点的合同菜单, 表示为 $\phi = \{(R_m, Y_m), m \in M\}$, 其中 (R_m, Y_m) 用于 m 型边缘节点。该合同含义为若边缘节点选择合同 (R_m, Y_m) , 则其需提供不低于 Y_m 的生成数据服务水平, 并获得奖励 R_m 。为了确保每个边缘节点自动选择为其特定类型设计的合同项目, 可行的合同必须满足以下约束:

(1) 个体理性约束 (Individual Rationality, IR), 边缘节点仅在参与后获得非负效用时才愿意接受合同, 因此满足:

$$R_m - \frac{\beta}{\theta_m} Y_m^2 (1 + \kappa \xi_m) \geq 0, \forall m \in M \# (23)$$

(2) 激励相容约束 (Incentive Compatibility, IC), 为确保类型为 θ_m 的边缘节点选择其对应合同, 而不是伪装成其他类型, 需满足:

$$R_m - \frac{\beta}{\theta_m} Y_m^2 (1 + \kappa \xi_m) \geq R_i - \frac{\beta}{\theta_m} Y_i^2 (1 + \kappa \xi_m), \forall m, i \in M \# (24)$$

在 IR 和 IC 约束下, 将云服务器的预期效用最大化问题表述为:

$$\begin{aligned} P1: \max_{R_m, Y_m} U_c \\ \text{s.t. IR 约束 (23), (25)} \\ \text{IC 约束 (24) \#} \end{aligned}$$

3.2 最优合同方案

由于奖励分配与增强服务水平之间存在强耦合关系, 同时需要满足信息不对称条件下的 IR 与 IC 约束, 因此原始合同优化问题难以直接求解。为降低问题复杂度, 本文利用契约理论中的单调性与局部激励相容性质对约束条件进行等价化简, 并进一步推导给定增强服务水平条件下的最优奖励表达式, 从而将原问题转化为仅关于增强服务水平的优化问题。

为简化后续推导, 定义:

$$\alpha_m = \frac{\beta}{\theta_m} (1 + \kappa \xi_m) \# (26)$$

则第 m 类边缘节点的效用函数可进一步写为:

$$U_m = R_m - \alpha_m Y_m^2 \quad (27)$$

由于边缘节点类型满足 $\theta_1 \leq \theta_2 \leq \dots \leq \theta_M$, 因此有 $\alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_M$ 。这表明, 高类型边缘节点具有更低的数据增强单位成本, 因此其能够以更低代价提供更高水平的数据增强服务。

引理 1 在信息不对称条件下, 一个可行合同需满足以下条件:

$$R_1 - \alpha_1 Y_1^2 \geq 0 \quad (28-1)$$

$$Y_1 \leq Y_2 \leq \dots \leq Y_M, R_1 \leq R_2 \leq \dots \leq R_M \quad (28-2)$$

$$R_m - \alpha_m Y_m^2 \geq R_{m-1} - \alpha_m Y_{m-1}^2, \forall m \in \{2, \dots, M\} \quad (28-3)$$

$$R_m - \alpha_m Y_m^2 \geq R_{m+1} - \alpha_m Y_{m+1}^2, \forall m \in \{1, \dots, M-1\} \quad (28-4)$$

证明 依据文献^[36], 该结论可由契约理论中的单调性与局部激励相容性质推导得到。结合 IR 与 IC 约束, 可进一步得到可行合同需要满足的条件, 因此引理成立。

此外, 约束(28-1)对应 IR 约束, 用于保证边缘节点参与系统后能够获得非负收益。约束(28-2)表示高类型边缘节点对应更高的数据增强服务水平。约束(28-3)与约束(28-4)分别对应局部向下与局部向上激励相容条件, 用于保证不同类型边缘节点均会选择与自身能力匹配的合同项, 而不会伪装成其他类型节点。基于引理 1, 可以进一步得到给定增强服务水平条件下的最优奖励。

引理 2 对于满足 $Y_1 \leq Y_2 \leq \dots \leq Y_M$ 的可行增强服务集合, 其最优奖励满足:

$$R^* = \begin{cases} \alpha_1 Y_1^2, m=1 \\ R_{m-1} + \alpha_m (Y_m^2 - Y_{m-1}^2), m=2, \dots, M \end{cases} \quad (29)$$

证明 依据文献^[36], 根据 IR 约束, 在最优情况下最低类型边缘节点满足 $R_1 - \alpha_1 Y_1^2 = 0$, 因此有 $R_1^* = \alpha_1 Y_1^2$, 进一步地, 根据局部 IC 约束可得 $R_m - R_{m-1} = \alpha_m (Y_m^2 - Y_{m-1}^2)$, 递推展开即可得到上述最优奖励表达式。

将最优奖励表达式代入云服务器效用函数后, 原始优化问题可进一步转化为仅关于增强服务水平 Y_m 的优化问题, 即:

$$P2: \max_{Y_m} U_c \quad (30)$$

$$s.t. Y_1 \leq Y_2 \leq \dots \leq Y_M$$

其中, 云服务器效用函数的系统成本项进一步写为

$$\lambda_c \frac{\sum_{m=1}^M Q_m R_m^*}{C_0}。由于全局 FL 误差 δ_c 、训练时延 $T^{tot}$$$

以及增强偏离惩罚 Ψ 均与增强服务水平 Y_m 密切相关, 因此增强服务水平不仅影响边缘节点奖励, 同时还会影响系统整体学习性能与训练效率。更高的数据增强服务水平虽然能够提升终端设备有效训练数据量, 从而降低全局 FL 误差, 但同时也会增加生成成本与训练时延。因此, 云服务器需要在模型性能、训练效率、增强服务匹配程度以及系统资源消耗之间进行联合权衡, 从而获得最优合同菜单。

3.3 最优合同求解算法

当前原始合同优化问题已被转化为仅关于增强服务水平 Y_m 的优化问题, 但由于云服务器效用函数中包含多种非线性耦合项, 因此问题 P2 仍然难以直接获得闭式最优解。为此, 本文提出一种意图驱动的合同理论优化算法, 通过迭代调整增强服务水平并搜索能够提升云服务器效用的可行合同, 在满足单调性、IR 和 IC 约束的条件下获得近似最优合同。算法的细节如算法 1 所示。

算法 1 意图驱动的合同理论优化算法

输入 边缘节点类型集合 Θ , 意图元组 I , 初始增强服务水平 $Y^{(0)}$, 初始搜索步长 ΔY , 最小搜索步长 $\Delta Y_{\min}$, 最大迭代次数 K

输出 最优合同 (Y^*, R^*)

1) 初始化满足单调性约束的 $Y^{(0)}$, 并计算 $\delta_c^{(0)}$ 、 $T^{\text{tot},(0)}$ 、 $\Psi^{(0)}$ 和 $U_c^{(0)}$

2) 根据引理 2 计算初始奖励 $R^{(0)}$

3) 设置迭代索引 $k = 0$

4) while $k < K$ 且 $\Delta Y \geq \Delta Y_{\min}$ do

5) 在当前增强服务水平 Y^k 的邻域内生成候选服务水平, 并实施单调性约束;

6) 根据引理 2 计算候选合同对应的奖励, 并保留满足 IR 和 IC 约束的可行合同;

7) 计算各可行候选对应的 δ_g 、 T_{tot} 、 Ψ 和云服务器效用 U_c ;

8) 选择云服务器效用最大的可行候选 $(\hat{Y}, \hat{R})$

9) if $U_c(\hat{Y}) > U_c^{(k)} + \varepsilon$ then

10) $Y^{(k+1)} = \hat{Y}$, $R^{(k+1)} = \hat{R}$, 更新 $U_c^{(k+1)}$

11) else

12) 减小搜索步长 ΔY , 当前合同不变

13) end if

14) $k = k + 1$

15)end while

16) 返回效用最大的可行合同(Y^*, R^*)

命题 1 算法 1 产生的已接受合同序列对应的云服务器效用单调不减, 并能够在有限迭代次数内终止。当算法由于搜索步长达到给定下限而终止时, 所得合同为当前搜索精度下的局部近似最优可行合同。

证明 设第 k 次已接受更新对应的增强服务水平和云服务器效用分别为 $Y^{(k)}$ 和 $U^{(k)}$ 。根据算法 1, 候选合同首先需要满足增强服务水平单调性以及 IR 和 IC 约束, 且仅当候选合同满足 $U_c(\hat{Y}) > U_c^{(k)} + \varepsilon$ 时才接受该更新。因此, 对于任意被接受的相邻两次更新均有 $U_c^{(k+1)} > U_c^{(k)}$, 即算法产生的已接受效用序列单调递增。另一方面, 各类型边缘节点的增强服务水平受到生成能力和终端生成样本比例约束, 因此存在有限的服务上界, 即 $0 < Y_m < Y_m^{\max}$, 在该有界可行域内, 模型误差、训练时延、增强服务偏离以及奖励成本均为有限值, 因此云服务器效用 U_c 存在有限上界。由此, 已接受的效用序列为单调递增且有上界的序列, 其效用值收敛。当当前搜索步长下不存在能够使云服务器效用提高超过 ε 的可行邻域解时, 算法减小搜索步长; 当搜索步长达到预设下限 $\Delta Y_{\min}$ 或迭代次数达到 K 时算法终止。因此, 算法能够在有限迭代次数内结束; 若由搜索步长条件触发终止, 则当前合同在给定搜索精度下不存在能够进一步显著提升云服务器效用的可行邻域解, 因此为局部近似最优可行合同。证毕。

设边缘节点类型数量为 M , 算法最大迭代次数为 K 。在每轮迭代中, 算法基于当前增强服务水平生成与 M 线性相关的邻域候选合同。对于每个候选合同, 根据引理 2 递推计算奖励的复杂度为 $O(M)$, 单调性检查的复杂度为 $O(M)$, 而对不同类型边缘节点进行 IR 和 IC 可行性检查在最坏情况下需要比较不同合同项, 其复杂度为 $O(M^2)$ 。由于每轮产生 $O(M)$ 个候选合同, 单轮迭代的最坏时间复杂度为 $O(M^3)$, 从而算法总时间复杂度为 $O(KM^3)$ 。实际 IIoT 场景中的边缘节点类型通常采用有限离散集合, 因此 M 相对较小, 且算法仅在云端执行合同求解, 不参与终端模型的逐轮训练过程, 因而具有可接受的计算开销。

4 实验结果

4.1 实验设置

为验证所提意图驱动边缘增强 FL 机制的有效性, 本文从训练性能、意图适应性、合同激励有效性和参数敏感性等方面开展仿真实验。为保证不同 LLM 意图解析结果的可比性, 实验对所有模型采用相同的提示模板和输出约束。提示词为: “请根据用户输入的任务需求, 将其转换为结构化意图参数 $I = \{\lambda_a, \lambda_d, \lambda_c, \lambda_s, \rho\}$, 其分别表示对模型误差、训练时延、系统成本和增强服务偏离的关注程度, 取值范围均为 $[0, 1]$, 且满足 $\lambda_a + \lambda_d + \lambda_c + \lambda_s = 1$; $\rho \in [0, 1]$ 表示对数据增强的依赖程度。仅输出上述 5 个参数, 不输出额外解释。” 为验证所提机制对不同用户意图的适应能力, 本文设置四类自然语言意图:

(1) “这批设备状态异常比较复杂, 希望模型尽可能学充分。” 此类意图关心模型效果, 即精度优先意图。

(2) “生产状态变化很快, 请尽快完成模型更新。” 此类意图关心训练或更新速度, 希望模型尽快完成更新, 即时延优先意图。

(3) “这次任务不是特别紧急, 也不是关键设备任务, 不需要太多花费。” 此类意图关心资源消耗和激励支出, 希望减少边缘生成服务带来的奖励成本、计算成本和通信开销, 即成本优先意图。

(4) “模型性能稳定提升即可。” 此类意图希望模型效果、训练时延、奖励成本和增强偏离之间保持折中, 即均衡意图。

本文对不同 LLM 采用相同的意图解析提示模板, 并显式规定各意图参数的语义、取值范围及输出约束, 并将不同语义改写 5 次进行重复解码。实验中固定各模型的调用配置和解码参数, 并要求模型仅返回满足式 (1) 约束的结构化参数。实验采用云一边一端三层协同架构, 系统中包含 1 个云服务器、6 个边缘节点和 18 个终端设备。每个边缘节点管理 3 个终端设备。边缘节点根据合同约定提供增强服务, 并按照终端数据分布偏离度将生成样本分配给所辖终端。终端设备基于本地真实数据和边缘生成数据执行本地训练, 随后将本地模型上传至边缘节点进行区域聚合, 最后由云服务器执行全局聚合。实验选取分类任务作为基础 FL 任务, 并采用 CIFAR-10^[37] 数据集和 Paderborn^[38] 数据集验证所

提方法的训练性能, 其中 CIFAR-10 为图像数据, Paderborn 为工业数据。对于 CIFAR-10, 采用类别条件生成对抗网络作为生成模型; 对于 Paderborn, 采用类别条件的一维 WGAN-GP 生成振动信号片段, 然后将原始振动信号划分为定长样本, 两者均使用卷积神经网络作为本地训练模型。为模拟工业物联网中终端数据分布差异, 本文采用 Dirichlet 分布构造 Non-IID 数据划分, 数值设置为 $\text{Dir} = \{0.1, 0.3, 0.5, 1.0\}$ 。本文将所提方法与以下基线方法进行比较, 各方法采用相同的数据划分、联邦训练配置、边缘异构场景和可用增强资源约束:

(1) 无增强方案。该方法不引入边缘数据增强机制, 终端设备仅利用本地真实数据进行模型训练, 边缘节点只负责区域模型聚合。

(2) 均匀分配方案。边缘节点提供生成数据, 但对所属终端设备采用均匀分配策略, 即在相同增强服务水平下, 将生成样本平均分配给各终端设备, 不考虑终端数据分布偏离度。

(3) 随机增强方案。边缘节点提供生成数据, 但随机选择生成数据的分配对象和分配比例, 不考虑终端设备的数据分布偏离度和类别缺失情况。该方法与本文方法保持相同的总增强规模约束。

(4) Contract-FL^[36]。该方法基于文献[36]的多维私有信息合同激励机制, 根据边缘节点的服务成本和时延构造类型偏好, 并据此选择边缘节点和确定增强服务水平。

此外, 我们还采用了两种经典的 FL 数据增强

表2 均衡意图下不同边缘类型选择不同合同的效用

边缘类型	合同项					
	C1	C2	C3	C4	C5	C6
0.5	0.01	-0.26	-6.38	-68.56	-239.31	-479.30
1	0.019	0.02	-1.49	-22.21	-86.23	-182.23
1.5	0.022	0.12	0.13	-6.76	-35.21	-83.20
2	0.023	0.17	0.80	0.96	-9.70	-33.69
2.5	0.023	0.20	1.43	4.59	5.60	-3.98
3.0	0.023	0.22	1.765	8.68	15.80	15.81

算法作为基线, 分别为:

(5) FedMix^[39]。该方法基于混合增强进行联邦数据增强, 通过对样本和特征进行加权混合构造生成数据, 以增加本地训练数据的多样性。

(6) FedGAN^[40]。该方法基于生成对抗网络进行联邦数据增强, 通过在联邦学习框架下训练生成模型, 生成辅助样本以改善客户端本地数据分布。

4.2 合同效果分析

表1展示了不同 LLM 对同一类用户意图的解析结果。在具体数值上, 不同 LLM 存在一定差异, 但整体趋势基本一致。在精度优先意图下, 各模型均赋予 λ_a 较高权重; 在时延优先意图下, λ_d 成为主要权重; 在成本优先意图下, λ_c 相对较高; 而在均衡意图下, 各性能指标对应权重分布更加平缓。不同 LLM 在具体参数取值上存在一定差异, 但其主导权重总体与用户所表达的任务优先级保持一致。为排除不同解析模型输出差异对后续机制比较的影

表1 不同 LLM 输出的意图元组

LLM	意图类型	λ_a	λ_d	λ_c	λ_s	ρ
GPT-5.5	精度优先	0.61±0.04	0.1±0	0.1±0	0.19±0.04	0.78±0.03
Qwen3.7		0.59±0.04	0.11±0.02	0.1±0	0.2±0.03	0.38±0.03
DeepSeek-V4		0.59±0.02	0.15±0	0.12±0.03	0.14±0.02	0.5±0
GPT-5.5	时延优先	0.20±0	0.59±0.02	0.1±0	0.11±0.02	0.31±0.02
Qwen3.7		0.16±0.02	0.59±0.02	0.15±0	0.1±0	0.05±0.04
DeepSeek-V4		0.3±0	0.45±0	0.15±0	0.1±0	0.5±0
GPT-5.5	成本优先	0.15±	0.1±0	0.64±0.02	0.11±0.02	0.17±0.05
Qwen3.7		0.12±0.3	0.14±0.02	0.63±0.3	0.11±0.02	0.39±0.12
DeepSeek-V4		0.3±0	0.15±0	0.45±0	0.1±0	0.28±0.05
GPT-5.5	均衡	0.28±0.04	0.26±0.02	0.26±0.02	0.21±0.03	0.51±0.02
Qwen3.7		0.31±0.02	0.29±0.02	0.29±0.02	0.11±0.02	0.4±0
DeepSeek-V4		0.31±0.02	0.25±0	0.24±0.02	0.2±0	0.5±0

响, 本文选取 GPT-5.5 作为代表性意图解析器, 并在后续实验中保持固定。




图2 不同意图下的期望奖励与偏离惩罚对比

表2以均衡意图为例, 给出了不同类型边缘节点选择不同合同项时获得的效用。对于每一种边缘类型, 其选择与自身类型相匹配的合同项时均能获得最大效用, 即效用矩阵的最大值均位于对角线位置。这说明不同类型边缘节点没有动机伪装成其他类型选择合同项, 所设计合同满足激励相容约束。同时, 各类型边缘节点选择自身合同项后的效用均大于0, 表明参与边缘增强服务能够为边缘节点带来非负收益, 合同满足个体理性约束。当低类型边缘节点选择高服务水平合同项时效用明显下降, 甚至出现负值, 这是因为其生成能力较弱, 承担高增强服务水平会带来较高成本; 而高类型边缘节点虽然选择低服务水平合同项也能获得正效用, 但由于奖励支付较低, 其效用仍低于选择自身合同项时的效用。因此, 所设计合同能够在信息不对称条件下实现边缘节点的自选择, 引导不同生成能力的边缘节点选择合适的增强服务水平。

表3 不同模块消融后的性能对比

方法	准确率 ↑	时延 ($\times 10^{-2}$)s ↓	生成样 本数↓	JS散度改 善↑
合同+数据分配	0.722	13.349	416	0.0542
意图+数据分配	0.898	13.652	722	0.1049
意图+合同	0.903	13.442	276	0.0255
本文方法	0.917	12.151	276	0.0874

图2给出了不同用户意图下期望奖励与增强偏离惩罚的变化对比。其中, 期望奖励反映云服务器为获得边缘增强服务所需支付的奖励水平, 增强偏




图3 不同边缘类型在不同意图下的增强服务水平对比

离惩罚用于衡量实际增强服务水平与意图驱动目标增强水平之间的偏差。在精度优先意图下系统为获得更高训练性能, 会提供较高的期望奖励, 同时增强偏离惩罚较低, 说明实际增强服务水平与目标需求较为接近。在时延优先和成本优先意图下, 系统更关注训练效率或奖励成本, 因此期望奖励相对降低, 增强偏离惩罚有所增加。在均衡意图下, 系统综合考虑模型误差、训练时延、奖励成本和增强偏离等因素, 期望奖励和偏离惩罚均处于多目标权衡后的结果。

图3给出了不同边缘类型在不同用户意图下的增强服务水平。随着边缘类型值增大, 边缘节点的增强服务水平整体呈上升趋势, 说明高类型边缘节点由于生成能力更强、单位生成成本更低, 能够承担更高的数据增强服务。另外, 不同意图下的增强服务水平也存在明显差异, 在精度优先意图下, 系统更加关注模型训练性能, 因此倾向于分配更高的增强服务水平。在时延优先和成本优先意图下, 系统需要控制额外训练时延和奖励成本, 因此增强服务水平相对降低。均衡意图下的增强服务水平介于多种目标之间, 体现了模型误差、训练时延、奖励成本和增强偏离之间的折中。

4.3 训练性能对比

表3给出了不同模块消融后的性能对比结果。去除意图驱动模块后, 固定的均衡参数无法反映不同任务对精度、时延和成本的差异化偏好, 导致增强策略的任务适应能力下降。去除合同机制后, 系统缺少对边缘增强服务水平的激励约束, 更容易通过增加生成数据获得模型性能收益, 但同时带来更高的增强与训练开销, 说明合同机制能够抑制过度增强并实现性能与成本之间的权衡。去除分布感知的数据分配后, 生成数据无法根据终端数据分布偏

离程度进行针对性配置,使有限增强资源对 Non-IID 问题的缓解作用减弱。因此,三个模块分别从任务需求适配、边缘服务约束和增强资源利用三个层面共同支撑了所提出机制的整体性能。

表4 不同生成数据有效利用率下的增强服务对比


生成数据有效利用率	有效增强量	归一化云侧误差	归一化期望奖励
0.6	304.2	0.972	0.147
0.8	418.4	0.942	0.176
1.0	540.0	0.881	0.208

表4给出了不同生成数据有效利用率下的增强服务对比结果。随着生成数据有效利用率的提高,有效增强量持续增加,云侧归一化误差明显下降,说明更高质量的生成数据能够形成更充分的有效训练贡献并改善模型训练效果。与此同时,归一化期望奖励随有效利用率提高而增加,表明在生成数据能够产生更高训练收益时,系统需要提供相应的服务激励。


图4以精度优先意图为例,给出了不同方案在不同数据集上的准确率随训练轮数变化情况。本文方案在两个数据集上均获得了较高的收敛性能和更高的最终准确率。与无增强方案相比,数据增强能够缓解终端样本不足和类别分布偏斜问题;与均匀增强和随机增强方案相比,本文方案根据终端数据分布偏离度分配生成数据,提高了生成样本的利用效率。**Contract-FL**通过合同激励选择具有较高服务偏好的边缘节点,能够在训练前期获得较快的性能提升,但由于未进一步结合任务意图和终端数据分布对增强服务进行联合优化,其后期性能提升逐渐受限。另外,相比于FedMix和FedGAN,本文方案不仅考虑生成样本对本地训练的补充作用,还进一步结合边缘节点生成能力异构、终端分布偏离程度和用户意图约束自适应确定增强服务水平,因此能够获得更稳定的训练性能。

图5给出了不同用户意图下本文方法在不同数据集上的准确率与训练时延对比结果。可以看出,用户意图会直接影响系统在模型性能和训练开销之间的取舍。在精度优先意图下,系统倾向于提供更高的增强服务水平,因此在两个数据集上均取得最高准确率,但对应训练时延也相对较高;在时延优先意图下,系统通过控制增强规模和训练开销降低

总时延,但准确率相比精度优先意图有所下降;在成本优先意图下,系统进一步压缩奖励支付和增强服务水平,因此训练时延最低,但模型准确率下降最为明显。均衡意图下,系统综合考虑模型误差、训练时延、奖励成本和增强偏离等因素,准确率和时延均处于折中水平。



(a) CIFAR-10




(b) Paderborn


图5 不同意图下准确率与时延对比

图6给出了本文方法在不同数据集的不同 Non-IID 设置下的收敛性能对比。在所有的 Non-IID 设置下,本文方法都能够保持较好的训练效果。这是因为所提边缘数据增强机制能够根据终端数据分布偏离度为数据不足或类别分布偏斜严重的终端补充生成样本,从而增加本地有效训练数据规模,改善终端本地数据分布,减小本地模型更新方向与全局目标之间的偏差。随着Dir增大,各终端数据分布逐渐接近全局分布,相比强Non-IID,弱Non-IID条件下终端本地数据本身就已经均衡,因此数据增强效果有限。

为分析边缘节点生成能力异构程度对系统性能的影响,本文设置3种边缘异构场景。其中,低异




(a) CIFAR-10




(b) Paderborn

图4 不同方案在不同数据集中的准确率对比



(a) CIFAR-10



(b) Paderborn

图6 不同数据集中不同Non-IID设置下的收敛对比

构场景的边缘类型集合为 $\{1.4, 1.5, 1.6\}$; 中异构场景的边缘类型集合为 $\{0.8, 1.5, 2.0\}$; 高异构场景的边缘类型集合为 $\{0.3, 1.2, 2.0\}$ 。图7给出了Paderborn数据集中不同边缘异构程度下各方法的训练性能和增强样本量对比结果。本文方案在三种异构程度下均取得最高准确率, 说明所提方法能够在边缘节点生成能力差异较大的情况下保持稳定的训练性能。相比之下, 均匀增强和随机增强策略采用固定增强规模, 未考虑边缘节点生成能力差异和终端数据分布偏离情况。Contract-FL能够根据边缘成本和时延调整合同服务水平, 但由于未进一步结合用户意图和终端数据分布进行增强服务优化, 其整体准确率仍低于本文方案。FedMix和FedGAN虽然能够通过数据增强提升模型性能, 但缺乏对边缘服务异构和意图约束的联合建模, 整体准确率仍低于本文方案。该结果说明, 本文方案并非采用固定增强规模, 而是根据边缘节点生成能力、合同激励结果和终端数据需求动态确定增强服务水平。上述结果表明, 所提方法能够在边缘异构场景下实现更有效的增强服务配置。

5 结束语




图7 不同边缘异构程度下的准确率对比

针对固定增强策略难以适应不同工业任务需求, 且边缘节点生成能力和服务成本的私有性使云服务器难以根据用户意图合理确定增强服务水平与奖励策略的问题, 本文提出一种面向工业物联网的意图驱动联邦学习边缘数据增强机制。该机制利用LLM将用户任务需求转化为结构化意图参数, 根据终端数据分布偏离度进行生成数据分配, 并基于合同理论设计边缘增强服务激励机制, 从而根据用

户意图自适应确定增强服务水平与奖励策略。实验结果表明,所提方法能够提升 Non-IID 场景下的联邦训练性能,并在不同用户意图下实现模型误差、训练时延、奖励成本和增强偏离之间的有效权衡。在未来的实际部署中,边缘资源、生成数据质量及终端状态可能随时间动态变化。后续将面向动态工业场景研究鲁棒意图解析、自适应合同优化和生成数据质量评估方法,进一步提升系统的可靠性与适应性。

参考文献:

- [1] Afrin S, Rafa S J, Kabir M, et al. Industrial Internet of Things: Implementations, challenges, and potential solutions across various industries [J]. *Computers in Industry*, 2025, 170: 104317.
- [2] Li Q, Li L, Liu Z, et al. Cloud - Edge Collaboration for Industrial Internet of Things: Scalable Neurocomputing and Rolling-Horizon Optimization [J]. *IEEE Internet of Things Journal*, 2025, 12(12): 19929-19943.
- [3] Sidhu S K S, Sharma A. Artificial Intelligence in Intent-Based Networking: A Comprehensive Survey on Enabling Autonomous Network Management [C]//2025 3rd International Conference on Advances in Computation, Communication and Information Technology (ICAICCIT): v. 1. 2025: 579-584.
- [4] Sidhu S K S, Sharma A. Intent-Based Networking for 5G, B5G, and 6G: An Overview of Autonomous and Intelligent Network Management [C]//2025 3rd International Conference on Advances in Computation, Communication and Information Technology (ICAICCIT): v. 1. 2025: 365-372.
- [5] Zhao W X, Zhou K, Li J, et al. A Survey of Large Language Models [J]. *Frontiers of Computer Science*, 2026, 20(12): 2012627.
- [6] Tageldien M, Selim B, Sboui L. Large Language Models in Intent-Based Networking: a Comprehensive Survey Across the Intent Lifecycle [C]//2025 International Telecommunications Conference (ITC-Egypt). 2025: 810-817.
- [7] Guo L, Wang J, Wu J, et al. Following the Compass: LLM-Empowered Intent Translation with Manual Guidance [C]//2024 IEEE 32nd International Conference on Network Protocols (ICNP). 2024: 1-12.
- [8] Mishra N, Hafizul Islam S, Zeadally S. A survey on security and cryptographic perspective of Industrial-Internet-of-Things [J]. *Internet of Things*, 2024, 25: 101037.
- [9] Pei J, Liu W, Li J, et al. A Review of Federated Learning Methods in Heterogeneous Scenarios [J]. *IEEE Transactions on Consumer Electronics*, 2024, 70(3): 5983-5999.
- [10] Guendouzi B S, Ouchani S, El Assaad H, et al. A systematic review of federated learning: Challenges, aggregation methods, and development tools [J]. *Journal of Network and Computer Applications*, 2023, 220: 103714.
- [11] Chen J, Tang J, Chen J. Federated Meta-Learning Framework for Few-shot Fault Diagnosis in Industrial IoT [C]//GLOBECOM 2022 - 2022 IEEE Global Communications Conference. 2022: 2993-2998.
- [12] Lu S, Gao Z, Xu Q, et al. Class-Imbalance Privacy-Preserving Federated Learning for Decentralized Fault Diagnosis With Biometric Authentication [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 9101-9111.
- [13] Xiao Y, Shao H, Lin J, et al. BCE-FL: A Secure and Privacy-Preserving Federated Learning System for Device Fault Diagnosis Under Non-IID Condition in IIoT [J]. *IEEE Internet of Things Journal*, 2024, 11(8): 14241-14252.
- [14] Lee Y, Gong J, Kang J. Generative AI-Powered Plugin for Robust Federated Learning in Heterogeneous IoT Networks [C]//2025 IEEE International Conference on Big Data (BigData). 2025: 7365-7369.
- [15] 汤凌韬, 王迪, 刘盛云. 面向非独立同分布数据的联邦学习数据增强方案 [J]. *通信学报*, 2023, 44(1): 164-176.
- [16] Zhang Z, Gao Z, Guo Y, et al. Scalable and Low-Latency Federated Learning With Cooperative Mobile Edge Networking [J]. *IEEE Transactions on Mobile Computing*, 2024, 23(1): 812-822.
- [17] Duan S, Liu C, Han P, et al. Fed-TDA: Federated Tabular Data Augmentation on Non-IID Data [PP/OL]. *arXiv* (2023-01-12) [2026-06-09]. <http://arxiv.org/abs/2211.13116>.
- [18] Zhan Y, Zhang J, Hong Z, et al. A Survey of Incentive Mechanism Design for Federated Learning [J]. *IEEE Transactions on Emerging Topics in Computing*, 2022, 10(2): 1035-1044.
- [19] 田有亮, 吴柿红, 李沓, 等. 基于激励机制的联邦学习优化算法 [J]. *通信学报*, 2023, 44(5): 169-180.
- [20] Shumailov I, Shumaylov Z, Zhao Y, et al. AI models collapse when trained on recursively generated data [J]. *Nature*, 2024, 631(8022): 755-759.
- [21] Njah Y, Leivadeas A, Falkner M. An AI-Driven Intent-Based Network Architecture [J]. *IEEE Communications Magazine*, 2025, 63(4): 146-153.
- [22] OpenAI, Achiam J, Adler S, et al. GPT-4 Technical Report [PP/OL]. *arXiv* (2024-03-04) [2026-06-09]. <http://arxiv.org/abs/2303.08774>.
- [23] 霍如, 沙宗轩, 吕科呈, 等. GAI 使能网络智能化: 基于 LLM 的网络操作系统 [J]. *通信学报*, 2025, 46(6): 32-44.
- [24] Wei J, Wang X, Schuurmans D, et al. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models [C]//36th Conference on Neural Information Processing Systems (NeurIPS 2022): v. 35. 2022: 24824-24837.
- [25] Manias D M, Chouman A, Shami A. Towards Intent-Based Network Management: Large Language Models for Intent Extraction in 5G Core Networks [C]//2024 20th International Conference on the Design of Reliable Communication Networks (DRCN). 2024: 1-6.
- [26] Manias D M, Chouman A, Shami A. Semantic Routing for Enhanced Performance of LLM-Assisted Intent-Based 5G Core Network Management and Orchestration [C]//GLOBECOM 2024 - 2024 IEEE Global Communications Conference. 2024: 2924-2929.
- [27] Dzevaroska K, Tizghadam A, Leon-Garcia A. Intent Assurance using LLMs guided by Intent Drift [C]//NOMS 2024-2024 IEEE Network Operations and Management Symposium. 2024: 1-7.
- [28] Romero M L, Suyama R. Agentic AI for Intent-Based Industrial Automation [C]//2025 16th IEEE International Conference on Industry Applications (INDUSCON). São Sebastião, Brazil: IEEE, 2025: 437-444.
- [29] Li Z, Sun Y, Shao J, et al. Feature Matching Data Synthesis for Non-IID Federated Learning [J]. *IEEE Transactions on Mobile Computing*, 2024, 23(10): 9352-9367.
- [30] Morafah M, Reisser M, Lin B, et al. Stable Diffusion-based Data Augmentation for Federated Learning with Non-IID Data [PP/OL]. *arXiv*

(2024-05-13)[2026-06-09]. <http://arxiv.org/abs/2405.07925>.

- [31] Li P, Zhang H, Wu Y, et al. Filling the Missing: Exploring Generative AI for Enhanced Federated Learning Over Heterogeneous Mobile Edge Devices[J]. IEEE Transactions on Mobile Computing, 2024, 23(10):10001-10015.
- [32] Tay S S, Xu X, Foo C S, et al. Incentivizing Collaboration in Machine Learning via Synthetic Data Rewards[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(9):9448-9456.
- [33] Huang G, Wu Q, Li J, et al. IMFL-AIGC: Incentive Mechanism Design for Federated Learning Empowered by Artificial Intelligence Generated Content[J]. IEEE Transactions on Mobile Computing, 2024, 23(12):12603-12620.
- [34] Zhang H, Li P, Dai M, et al. Efficient Federated Learning With Quality-Aware Generated Models: An Incentive Mechanism[J]. IEEE Internet of Things Journal, 2025, 12(2):1628-1642.
- [35] Lin J. Divergence measures based on the Shannon entropy[J]. IEEE Transactions on Information Theory, 1991, 37(1):145-151.
- [36] Ding N, Fang Z, Huang J. Optimal Contract Design for Efficient Federated Learning With Multi-Dimensional Private Information[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1):186-200.
- [37] Krizhevsky A. Learning Multiple Layers of Features from Tiny Images[J].
- [38] Lessmeier C, Kimotho J K, Zimmer D, et al. Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification[J]. PHM Society European Conference, 2016, 3(1).
- [39] Yoon T, Shin S, Hwang S J, et al. FedMix: Approximation of Mixup Under Mean Augmented Federated Learning[C]//9th International Conference on Learning Representations, ICLR 2021, 2021.
- [40] Nguyen D C, Ding M, Pathirana P N, et al. Federated Learning for COVID-19 Detection With Generative Adversarial Networks in Edge Cloud Computing[J]. IEEE Internet of Things Journal, 2022, 9(12):10257-10271.



覃少雯(1996-),女,广西南宁人,桂林电子科技大学博士生,主要研究方向为联邦学习、工业物联网及边缘智能等。



李晓欢(1982-),男,重庆人,博士,桂林电子科技大学教授,主要研究方向为智能计算、无人机网络和生成式人工智能等。



曾健峰(1999-),男,广西桂林人,桂林电子科技大学硕士研究生,主要研究方向为联邦学习及工业物联网等。



吴远(1981-),男,浙江杭州人,博士,澳门大学教授,主要研究方向为边缘/云计算、边缘智能、智能通信系统及深度学习等。



康嘉文(1992-),男,广东茂名,博士,广东工业大学教授,主要研究方向为人工智能、信息安全及边缘智能等。