

面向工业物联网的时延感知半同步联邦学习客户端资源联合调度方案

王晔¹, 施颖², 夏天乐², 刘淼², 杨洁², 赵海涛³

(1. 江苏移动信息系统集成有限公司, 江苏 南京 210003; 2. 南京邮电大学通信与信息工程学院, 江苏 南京 210003;
3. 南京邮电大学物联网学院, 江苏 南京 210003)

摘要: 联邦学习作为一种灵活且可扩展的分布式机器学习方法, 在工业物联网 (IIoT, industrial Internet of things) 中得到了广泛应用, 在保护数据隐私的同时, 实现低时延、低通信开销和高精度的模型训练。然而, 由于工业物联网中边缘设备的计算能力和通信能力的异构性, 传统同步联邦学习面临“落后者效应”, 即服务器需要等待所有客户端完成本地模型参数上传, 显著降低训练效率, 难以满足工业物联网对低时延服务的需求。为了解决这一问题并降低设备异构性带来的训练时延, 提出了一种基于半同步机制的异构工业联邦学习框架, 并在此基础上设计了一种基于训练时延效益评分的客户端选择方案, 以提升训练效率。此外, 为了提高网络频谱资源的利用率, 基于全局训练时延均衡的数学关系, 提出了一种自适应设备数量的带宽分配机制, 优化被选客户端的模型上传策略。大量仿真结果表明, 与基于加权平均的联邦学习 (FedAvg, federated averaging) 和结合客户端选择的联邦学习 (FedCS, federated learning with client selection) 等基准方案相比, 所提方法在模型准确度、系统时延及频谱利用率等方面均具有显著优势。

关键词: 工业物联网; 联邦学习; 落后者效应; 客户端调度; 资源分配

中图分类号: TN915.08

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2025.00496

Latency-aware semi-synchronous federated learning client resource co-scheduling scheme for IIoT

WANG Ye¹, SHI Ying², XIA Tianle², LIU Miao², YANG Jie², ZHAO Haitao³

1. Jiangsu Mobile Information System Integration Co., Ltd., Nanjing 210003, China

2. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

3. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: Federated learning (FL), as a flexible and scalable distributed machine learning approach, has been widely applied in the industrial Internet of things (IIoT) to achieve low-latency, low communication overhead, and high-accuracy model training while preserving data privacy. However, due to the heterogeneity in computing and communication capabilities among edge devices in IIoT, traditional synchronous FL suffers from the “straggler effect”, where the server must wait for all clients to upload their local model parameters, significantly reducing training efficiency and making it difficult to meet the low-latency service requirements of IIoT. To address this issue and mitigate the training delay caused by device heterogeneity, a semi-synchronous heterogeneous industrial FL framework was proposed. Based on this framework, a client selection scheme was designed, leveraging training latency efficiency scores to enhance training efficiency. Furthermore, to improve network spectrum utilization, an adaptive bandwidth allocation mechanism based on a mathematical relationship was proposed that ensured equal global training latency per round, optimizing the model upload strategy of

收稿日期: 2025-03-28; 修回日期: 2025-06-10

通信作者: 赵海涛, zhaoh@njupt.edu.cn

基金项目: 江苏省前沿引领技术基础研究专项前沿项目 (No. BK20202001)

Foundation Item: Natural Science Foundation on Frontier Leading Technology Basic Research Project of Jiangsu province (No. BK20202001)

selected clients. Extensive simulation results demonstrate that, compared with benchmark schemes such as FedAvg and FedCS, the proposed approach achieves significant advantages in model accuracy, system latency, and spectrum efficiency.

Key words: industrial Internet of things, federated learning, straggler effect, client scheduling, resource allocation

0 引言

工业物联网 (IIoT, industrial Internet of things) 通过互联网连接各种智能设备, 为商业、政府及公共行业的相关问题提供了创新的全球解决方案^[1]。随着深度学习 (DL, deep learning) 的迅猛发展, 智能物联网 (AIoT, artificial intelligent Internet of things) 技术通过训练专门针对智能化业务的神经网络, 为工业物联网提供了更精准、灵活的智能决策方案, 以及更高效、可靠的传输优化能力^[2]。然而, 面向未来第六代移动通信系统 (6G, the 6th generation of mobile communication system) 的工业物联网将产生海量数据, 这些数据通常分布在机器人、机械臂、无人车、传感器等大规模异构工业设备终端上。传统基于数据驱动的分布式深度学习方法依赖于将各终端数据上传至云服务器进行神经网络的集中式训练, 这不仅会占用大量宝贵的频谱资源, 还可能在云端与终端的交互过程中无线传输方式导致隐私信息泄露^[3], 因此, 这种方法不适用于海量数据生成、设备部署密集、频谱资源有限且隐私需求敏感的工业物联网场景。

联邦学习 (FL, federated learning) 作为一种具有前景的分布式机器学习计算范式, 终端设备无须上传本地原始数据即可通过与云中心的分布式协同交互, 使中心服务器能够完成全局神经网络模型的训练^[4]。这一机制不仅显著提升了分布式学习性能, 还有效保护了各客户端的本地数据隐私^[5]。因此, 联邦学习在车联网^[6]、工业物联网^[7]、低空物联网^[8]、空天地一体化网络^[9]等领域得到了广泛应用与推广。文献[10]为应对恶意攻击带来的潜在安全威胁, 充分利用联邦学习中客户端的分布式结构特性, 提出了一种新的异常检测方法, 从而强化数据的隐私保护。文献[11]引入了三层协作的联邦学习框架, 并以最小化评估损失为目标, 提出了基于深度多智能体的“联邦强化”解决方案。

针对工业物联网场景, 考虑不同边缘智能设备采用不同感知接入技术等因素, 设备之间在通信资

源和本地计算能力等方面存在差异^[12]。如果采用传统基于同步机制的联邦学习, 在全局聚合阶段, 云服务器需要接收所有智能设备上传的模型参数, 即必须等待所有设备完成。然而, 实际问题在于有限的无线频谱资源与数量急剧增长各类工业设备之间的矛盾^[13], 这将大幅增加在工业物联网中部署同步联邦学习系统的开销^[14]。与此同时, 传统联邦学习在异构工业物联网场景中的部署可能出现“落后者效应”^[15], 这会显著增加全局模型收敛所需的训练时间^[16]。这种情况无法满足工业物联网场景中对实时监控、自动化控制和预测分析等应用的低时延要求, 从而影响生产过程的高效运行和产品质量的稳定性。

目前, 针对“落后者效应”研究者提出的解决方案主要分为同步机制下的客户端调度策略和异步策略两大类。前者指的是服务器依据特定标准对智能设备进行选择, 只有被选中的设备才能参与全局模型训练。Abdulrahman等^[17]综合考虑客户端的资源可用性、通信开销及数据分布不均衡等因素, 提出了一种基于多标准的联邦学习客户端选择方法, 在每轮全局迭代中最大化被选中客户端的数量。文献[18]则提出了一种高效的联邦学习自动化感知客户端选择框架, 能够动态适应客户端数量变化, 并输出合理的客户端调度策略。然而, 该方法可能导致参与训练的设备集相对固定, 从而增加全局模型发生过拟合的风险^[19]。文献[20]通过0-1背包优化问题刻画不稳定网络中设备的异构计算资源, 并在考虑各节点通信条件的基础上, 提出了一种异步节点选择方案, 以提升异构设备的训练效率。然而, 异步机制也引入了新的挑战, 即客户端的本地更新可能基于不同程度的过时信息, 进而增加模型发散或不收敛的风险。

针对现有方案分别带来的训练过拟合问题和模型发散风险, 本文提出了一种半同步策略用于联邦学习训练, 并通过三步优化来应对“落后者效应”。在保证数据多样性的前提下, 动态分配工业物联网的网络资源, 以提升系统整体效率。首先, 针对异

构工业物联网场景下的落后者问题，本文依据每个智能设备的通信与计算总时延对其进行聚类，使不同设备集以不同频率参与联邦学习过程。其次，考虑工业物联网中智能设备数量庞大，可能导致计算能力瓶颈或通信阻塞，从而影响系统运行效率，本文进一步引入效益分数来综合评估边缘智能设备参与训练的价值。在每轮全局迭代中，通过客户端选择性调度来缓解网络负载压力^[21]。最后，为进一步提升异构工业物联网中有限频谱资源的利用率，本文利用半同步机制下分布式交互时延相等的数学关系，在每轮训练中对参与训练的智能设备进行精细化的带宽分配。此举不仅优化了边缘智能设备对带宽资源的利用率，还有效降低了系统的整体训练时延，从而确保工业物联网环境下联邦学习系统的高效稳定运行。具体而言，本文主要贡献总结如下。

1) 构建了一种面向工业物联网的半同步联邦学习框架，优化异构工业物联网场景中的神经网络模型训练。针对智能设备的异构性，在联邦学习训练前基于计算与通信总时延对设备进行分层聚类，使不同设备群组以不同频率参与全局模型训练。该方法确保所有设备在规定时间内完成模型参数上传，从而有效缓解“落后者效应”，提升联邦学习的训练效率与适应性。

2) 针对工业物联网中海量智能设备可能导致的计算能力瓶颈和通信阻塞，基于训练时延构建效益分数，用于评估客户端的训练价值。在每轮全局迭代中，根据效益分数按固定比例选择部分智能设备参与训练。该调度策略有效提升模型精度，降低系统整体时延，从而增强联邦学习的训练效率与通信性能。

3) 进一步优化工业物联网的带宽资源分配，利用智能设备在全局迭代时间阈值内的时延近似关系，对有限总带宽进行精细分配，使参与训练的设备更高效地利用带宽资源。该策略有效降低系统训练时延，提升联邦学习在异构工业物联网中的训练效率和通信性能。

4) 为了验证方案的有效性与优越性，在 CIFAR-10 数据集上进行了大量仿真实验，并选取 FedAvg 和 FedCS 作为对比方案。实验结果表明，本文方案在多个关键指标上均表现出显著优势，进一步证明其在异构工业物联网环境下的适用性与优越性。

1 场景描述与系统建模

1.1 异构工业物联网联邦学习场景描述

异构工业物联网中联邦学习场景描述如图 1 所示，展示了一个由部署云端服务器的基站、具备边缘计算能力的智能设备和生产设备组成的异构工业物联网，并根据功能将其划分为多个区域。




图 1 异构工业物联网中联邦学习场景描述

该网络异构性体现在智能设备在计算、感知和通信能力等方面的差异^[22]。每个区域由一个智能设备负责管理和监控生产设备，执行诸如远程管理、状态检测和智能监控等智能业务操作。这些智能设备能够在本地存储私有数据，同时利用联邦学习框架训练共享的全局模型。通过云服务器智能设备能够进行通信交互，从而实现全局模型的优化与更新。此种模型训练方式不仅保护了数据隐私，还提升了模型的泛化能力和准确性，更好地支持智能业务的执行。面对异构工业物联网中对大规模数据处理的需求以及有限的无线频谱资源，本文采用正交频分多址 (OFDMA, orthogonal frequency division multiple access) 技术，在避免同频干扰的同时实现多个智能设备的高效并行数据传输。

此外，本文聚焦于提升图像识别类任务模型训练的泛化能力。在工业物联网场景中，图像识别任务主要包括包裹标签识别、运输线故障监测以及仓库环境的智能监控等^[23]。这些任务的目标是使智能物流设备能够借助深度学习算法优化物流作业流程，减少人工干预，提高作业效率与安全性。

1.2 联邦学习框架

假设网络中包含 N 个智能设备。联邦学习旨在通过云服务器训练出一个共享全局模型，该目标可以表述为使得全局损失函数 $F(w)$ 最小化^[24]

$$\arg \min_w F(w) = \arg \min_w \sum_{i \in I} \frac{|D_i|}{|D|} f_i(w), D = \bigcup_{i \in I} D_i \quad (1)$$

其中, w 是全局模型参数, I_t 是第 $t \leq H$ 轮被选中智能设备的集合, $|D|$ 是所有智能设备的训练样本总数, $|D_i|$ 是智能设备 i 的训练样本数量, $f_i(w_i)$ 是智能设备 i 的本地损失函数, 可以表示为

$$f_i(w_i) = \frac{1}{|D_i|} \sum_{n \in D_i} f(w, x_{i,n}, y_{i,n}) \quad (2)$$

其中, $(x_{i,n}, y_{i,n})$ 是智能设备 i 本地数据集第 n 个样本的输入输出对, 而 f 表示在本地模型参数 w_i 下捕获的误差值。

在联邦学习的过程中, 第 t 轮迭代分为 3 个步骤。异构工业物联网中联邦学习如图 2 所示。

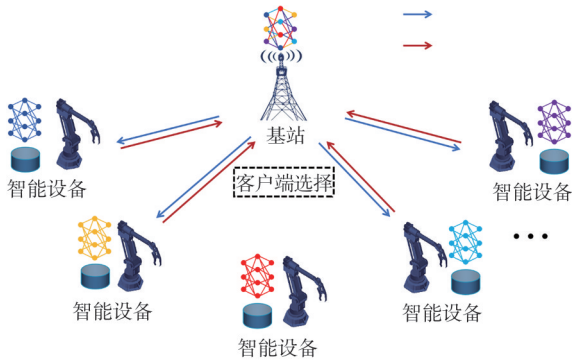


图2 异构工业物联网中联邦学习

1) 客户端调度并广播全局模型。云服务器根据制定的客户端调度策略确定被选择智能设备集, 并将最新全局模型 w^{t-1} 广播给被选择智能设备。

2) 本地训练并上传局部模型。被选择智能设备接收到最新全局模型, 并利用私有数据集在本地训练局部模型, 即 $w_i^t = w_i^{t-1} - \eta \nabla f_i(w_i^{t-1})$, 其中 η 表示本地学习率。在完成本地训练后, 智能设备将本地模型参数上传至云服务器。

3) 全局聚合并更新全局模型。云服务器在接收到本地模型参数后进行聚合更新全局模型, 即 $w^t = \sum_{i \in I_t} \frac{|D_i|}{|D|} w_i^t$, 其中 I_t 是第 t 轮被选中的设备集。

4) 重复上述步骤直至全局模型收敛。

1.3 联邦学习的通算时延开销模型

本文考虑智能设备异构性, 主要表现在每个智能设备的感知、计算和通信能力的差异性, 进而影响了本地训练的计算时延和模型上传的通信时延。全局模型广播和模型聚合的时延对所有智能设备是相同的, 与本地计算时延和模型上传的通信时延相比, 通常可以忽略不计。因此, 第 t 轮中智能设备 i

的时延定义为

$$\tau_{i,t} = \tau_{i,t}^{\text{comp}} + \tau_{i,t}^{\text{comm}} \quad (3)$$

其中, $\tau_{i,t}^{\text{comp}}$ 表示智能设备 i 的本地计算时延, $\tau_{i,t}^{\text{comm}}$ 表示智能设备 i 的通信时延。

第 t 轮中智能设备 i 的通信时延可以由式(4)得到

$$\tau_{i,t}^{\text{comm}} = \theta \text{lb} \left(\frac{1}{\varepsilon} \right) \frac{C_i |D_i|}{f_i} \quad (4)$$

其中, θ 是由期望模型结构决定的常数, $\theta \text{lb} \left(\frac{1}{\varepsilon} \right)$ 表示达到训练精度 ε 所需的局部迭代次数, C_i 是智能设备 i 训练一个数据样本所需的中央处理器 (CPU, central processing unit) 周期数, $|D_i|$ 表示智能设备 i 用于训练的样本总数, f_i 是智能设备 i 的 CPU 频率。

对于通信时延, 第 t 轮中智能设备 i 所能达到数据速率 $r_{i,t}$ 可由式(5)得到

$$r_{i,t} = b_{i,t} \text{lb} \left(1 + \frac{p g_i}{N_0} \right) \quad (5)$$

其中, $b_{i,t}$ 表示第 t 轮中智能设备 i 被分配到的带宽, p_i 是智能设备 i 的发射功率, g_i 是智能设备 i 的信道增益, N_0 是噪声功率密度。因此, 可以得到通信时延

$$\tau_{i,t}^{\text{comm}} = \frac{s}{r_{i,t}} \quad (6)$$

其中, s 是智能设备上传模型参数大小, 对于参与训练的联邦学习客户端, 需要上传的模型参数大小通常相等。

2 问题分析与建模

2.1 “落后者效应”带来的挑战

传统联邦学习采用同步机制来进行全局模型的训练, 即每轮全局迭代时延取决于最慢的被选择设备, 那么第 t 个全局轮次时延 τ_t 可以由式(7)所得

$$\tau_t = \max_{i \in I_t} \{ \tau_{i,t} \} \quad (7)$$

然而, 异构工业物联网场景中的智能设备类型和硬件配置各异, 设备本身感知能力、计算能力、通信能力、存储能力以及所处网络状态等因素各不相同。如果性能表现较差的设备参与全局轮次, 会对全局轮次时延 τ_t 造成较大的负面影响。在每轮全局迭代中, 一旦超过所设定的时间上限阈值 T , 服务器将不再接收本地模型参数, 并直接进行模型聚合。这可以在一定程度上缓解“落后者效应”, 此

时第 t 个全局轮次时延 τ_t 可以由式(8)所得

$$\tau_t = \min \left\{ \max_{i \in I_t} \{ \tau_{i,t} \}, T \right\} \quad (8)$$

需要注意的是,在实际部署中,不合理的时间阈值设置会导致部分落后设备难以有效参与到全局聚合,并造成数据多样性不足。

2.2 本文采用的半同步机制存在的缺陷

针对“落后者效应”产生的数据多样性缺失问题,本文决定采用一种半同步联邦学习框架。该框架整合了同步和异步的联邦学习机制,将所有智能设备根据时延进行分层聚类,将智能设备划分为不同设备集,使得其以不同频率参与到全局聚合过程中。本节主要阐述了该框架运用于工业物联网场景中存在的通信开销压力问题,分层聚类方法将在第3.1节中进行具体说明。

分层后的设备集索引表示为 k , 第1个设备集每1轮参与全局迭代,第2个设备集每2轮参与全局迭代,以此类推,第 ξ 个设备集每 ξ 轮参与全局迭代。全局模型的收敛需要经历上述的大量全局迭代轮次,而设备集数量是远远小于全局迭代轮次的,每 $1 \times 2 \times \dots \times \xi$ 个全局轮次所有设备集都会参与到全局聚合的过程中。由于工业物联网中的智能设备数量极其庞大以及有限的带宽资源,所有设备集参与训练的轮次会给网络带来极大的通信压力。

2.3 调度优化问题建模

本文目的是缓解“落后者效应”导致的系统时延过长问题,因此以最小化整体系统时延为目标,整体系统时延为每轮时延求和,优化问题(P1)如下所示

$$(P1) \quad \min \sum_t \tau_t$$

$$\text{s.t.} \quad \begin{cases} \tau_t = \min \left\{ \max_{i \in I_t} \{ \tau_{i,t} \}, T \right\} & (C1) \\ \sum b_{i,t} \leq B_{\text{tot}} & (C2) \end{cases} \quad (9)$$

其中, B_{tot} 表示可分配总带宽。约束(C1)表示每个全局迭代轮次时延,约束(C2)表示被选择智能设备的子带宽之和不能超过总带宽。可以看出,如果能够找到最小化 $\max_{i \in I_t} \{ \tau_{i,t} \}$ 的方案,就能够大大降低每轮时延,进而缩短整体系统时延。同时,考虑异构工业物联网中海量的智能设备以及有限的带宽资源,需要对带宽资源进行更加合理有效的分配,从而提高整体系统的训练效率。

2.4 问题转化

针对落后者问题,观察原始问题(P1)可以发现,缩短每轮全局迭代时延的关键在于如何缩短 $\max_{i \in I_t} \{ \tau_{i,t} \}$ 。最直观的,这取决于每轮参与全局聚合的设备集,但同时也要考虑总带宽约束,本文将缩短每轮全局时延问题转化为两个子问题。一是如何在固定带宽的情况下减少每轮全局迭代时延。本文提出一个基于时延的效益分数来评估智能设备的时延性能,通过选择时延较低的设备参与每轮全局训练,来有效解决该子问题。二是如何在固定设备集的情况下减少时延。这涉及如何合理分配总带宽,本文通过提出一种半同步联邦学习框架下的自适应带宽分配方案来提高频谱资源的利用率。因此,在本文提出的基于时延聚类半同步联邦学客户端资源联合调度的方案下,每轮全局迭代时服务器首先在前一轮带宽下根据效益分数进行客户端调度,然后确定被选择设备集后制定带宽分配方案。

3 方案设计

本节将讨论所提出的基于时延聚类的客户端调度和带宽分配的半同步框架各个步骤,基于时延聚类的客户端调度和带宽分配的半同步框架流程说明如图3所示。针对有限的带宽资源,在传统联邦学习过程之前,首先根据时延对智能设备进行分层,然后使用效用函数评估智能设备从而按照固定比例进行客户端选择,最后考虑总带宽有限的情况,对被选中的智能设备进行带宽的重新分配。下面详细讨论了该方案的3个重要步骤:时延聚类、客户端选择、自适应带宽分配。

3.1 时延聚类

该步骤即将所有智能设备根据时延进行分层聚类,其目的是增加数据多样性,使得智能设备能够以不同频率参与联邦学习,同时避免落后者问题^[25]。定义 level_i 为智能设备 i 的层级信息,其值不小于1,计算式如式(10)所示

$$\text{level}_i = \left\lfloor \frac{\tau_i}{T} \right\rfloor + 1 \geq 1 \quad (10)$$

其中, $\lfloor x \rfloor$ 表示对 x 进行向下取整操作。在联邦学习训练开始前,根据智能设备的时延信息对智能设备进行分层,具有相同 level_i 值的智能设备被分到同一个设备集 U_{level} ,用 k_i 来简单化表示 level_i ,一个设备集 U_{k_i} 包含一个层级的所有智能设备。定义每

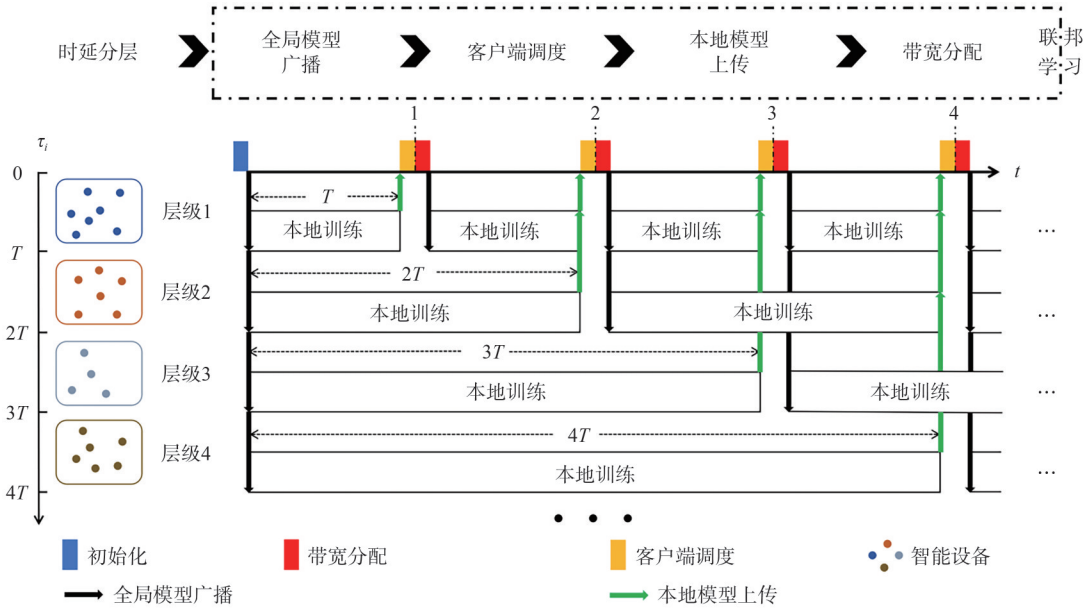


图3 基于时延聚类的客户端调度和带宽分配的半同步框架流程说明

个设备集都具有一个指示标志 flag_k ，值仅与迭代轮次有关，其计算式如式(11)所示

$$\text{flag}_{k,t} = \begin{cases} 1, & t \% k = 0 \\ 0, & t \% k \neq 0 \end{cases} \quad (11)$$

其中， t 表示全局迭代轮次， $\%$ 表示整除操作。若 $\text{flag}_{k,t} = 1$ ，则表示在第 t 次全局迭代中第 k 个设备集中的智能设备需要上传本地模型参数，反之则表示智能设备在本轮次不用上传。因此，为了细化到每个智能设备，定义 $\text{cc}_{i,t}$ 表示智能设备 i 在第 t 轮是否参与训练，其计算式如式(12)所示，若 $\text{cc}_{i,t} \neq 0$ ，则表示在当前轮次该智能设备参与训练，反之则不参加

$$\text{cc}_{i,t} = \text{flag}_{k,t} \cdot \text{level}_i \quad (12)$$

根据 $\text{cc}_{i,t}$ 的值，服务器可以在每个轮次预期哪些智能设备能够参与到全局迭代，然后根据式(13)聚合参数来训练全局模型

$$w^t = \sum_{i \in I_t} \frac{|D_i|}{\sum_{i \in I_t} |D_i| \text{cc}_{i,t}} w_i^t \text{cc}_{i,t} \quad (13)$$

在传统联邦学习过程中，智能设备本地训练的步长 η 是固定的，但位于不同层的智能设备需要采用不同步长，当 $\text{flag}_{k,t} = 1$ 时，设备集 k 中的智能设备根据式(14)更新本地模型

$$w_i^t = w_i^{t - \text{level}_i - 1} - \text{level}_i \cdot \eta \cdot \nabla f_i(w_i^{t - \text{level}_i - 1}) \quad (14)$$

在传统半同步机制中，所有设备都会参与到全局聚合过程中。然而，由于IIoT场景中有限的带宽

资源和海量的智能设备，如果所有设备都参与全局聚合，则需要更多训练轮次和更长等待时间。因此，需要在有限的带宽资源下，筛选高质量的客户端，以保证较低的训练时延以及模型收敛。此外，当智能设备采集的样本采用明显差异时，通常表现为训练数据的 non-iid 特性，数据质量较差的智能设备根据本文所提的客户端选择方案，则无法被选择。这表明该客户端的质量较低，反而会影响FL的性能。

3.2 客户端选择

智能设备以不同频率参与联邦学习过程，可以在一定程度上缓解带宽资源有限的问题，但仍然存在所有智能设备都参与训练的情况，这会给网络资源带来极大的压力。因此，本文使用基于时延的效益分数来评估智能设备的时延性能，按照一定比例进行智能设备选择。第 t 轮中智能设备 i 的效益分数 $u_{i,t}$ 计算式如式(15)所示

$$u_{i,t} = 1 - \frac{\tau_{i,t} - k_i T}{\tau_{\max}} \quad (15)$$

其中， $\tau_{\max} = \max_{I_t} (\tau_{i,t} - k_i T)$ 表示当前轮次最大时延。智能设备时延越大，其效益分数越小。考虑客户端的训练时间可能超出一个训练轮次的最大阈值，即为了聚焦客户端在当前轮次中所需要的时间，需要计算 $\tau_{i,t} - k_i T$ 。而 $\frac{\tau_{i,t} - k_i T}{\tau_{\max}}$ 则是对该时间进行归一化处理。 $u_{i,t}$ 则表示客户端在当前轮次所需要的训练时间越小，其效益分数越大。本文所设计的效益分

数思路是面向客户需求的,而现有客户端选择方案中关于时延的效益分数大多是根据所在场景中的客户需求设计的,因此不存在更高的效益分数。

第 t 轮中,服务器根据效益分数对智能设备进行排序,按照选择比例 c ,默认取值为 0.5,选择前 $\lfloor cK_t \rfloor$ 个智能设备参与本轮训练,其中 K_t 为本轮次 $\text{flag}_k = 1$ 的设备集的智能设备总数。

3.3 自适应带宽分配

在传统联邦学习的框架下,每轮智能设备被分配的带宽往往是静态且固定的,面对带宽资源有限的挑战,常见做法是通过减少参与训练的智能设备数量。然而这种做法可能导致带宽利用率低下的问题。由此,本文将带宽分配与智能设备调度相结合,以期提升带宽资源的利用效率。本节解决的问题是在固定设备集的情况下重新分配总带宽。

在有限的带宽资源环境下,如何高效且合理地分配带宽成了一项关键技术挑战。本文致力于探索一种策略,旨在将总带宽资源尽可能地集中分配给预先选定的固定客户端集合。这一目标的实现,关键在于确保所有分配给各个子客户端的带宽总和能够无限趋近于系统总带宽,从而最大化带宽利用率。与此同时,为了保障客户端能够顺畅且有效地参与到联邦学习过程中,本文特别对子带宽的取值范围进行了严格界定,即 $\frac{B_{\text{tot}}}{\lfloor pK_t \rfloor} \leq b_{i,t} \leq B_{\text{tot}}$ 。这样的设定,既保证了联邦学习任务的顺利进行,又防止了带宽分配不当而导致的资源浪费或性能瓶颈。本文所采用的半同步策略下,当前全局迭代轮次中智能设备之间的时延差异小于 T 。利用这一特性,可以对有限的带宽资源进行重新分配,使得智能设备时延尽可能一致,进而缩减每轮时延。因此,可以得到基于式(16)所示的带宽分配方式

$$\frac{\tau_{i_1,t}^{\text{comp}} + \frac{s}{b_{i_1,t} \ln\left(1 + \frac{p_i g_i}{N_0}\right)}}{\text{level}_{i_1}} = \frac{\tau_{i_2,t}^{\text{comp}} + \frac{s}{b_{i_2,t} \ln\left(1 + \frac{p_i g_i}{N_0}\right)}}{\text{level}_{i_2}} = \dots = \frac{\tau_{i_{k_t},t}^{\text{comp}} + \frac{s}{b_{i_{k_t},t} \ln\left(1 + \frac{p_i g_i}{N_0}\right)}}{\text{level}_{i_{k_t}}} \quad (16)$$

对于式(16)所示的求解方程,本文使用 Python 中 SciPy 库的 minimize 函数进行高效求解。根据该方案,服务器能够动态地调整各个智能设备的带宽分配方案。这不仅提升了联邦学习的整体效率,还在一定程度上缩短了本轮全局迭代的总时延,为联邦学习技术的广泛应用提供了有力支持。

基于时延聚类的客户端调度和带宽分配的半同步联邦学习框架如算法 1 所示。

算法 1 基于时延聚类的客户端调度和带宽分配的半同步联邦学习框架

初始化 全局模型 w^0 , 智能设备集 I 及其索引 i , 总带宽 B_{tot} , 全局迭代轮次 H

输出 全局模型 w^H

根据式(10)计算 level_i , 对智能设备进行分层聚类

#服务器:

每轮迭代 (总轮次为 H):

根据式(15)计算 $\text{flag}_k = 1$ 的设备集中智能设备的效益分数,并进行降序排序,选择前 $\lfloor cK_t \rfloor$ 个智能设备参与本轮训练

根据式(16)求解子带宽,进行带宽的重新分配

接收被选择智能设备的本地模型参数进行聚合

将最新的全局模型 w^t 广播给被选择的智能设备

#智能设备 i :

接收服务器广播的全局模型 w^t

根据式(14)更新本地模型,直至训练精度 ε

上传本地模型参数至服务器

4 仿真分析

本节对提出的方案进行性能比较,首先介绍了所用数据集和相关实验环境,接着选取了两种具有代表性的传统方案作为对比方案,验证了所提方案的优越性,最后改变了不同参数以探讨所提方案的性能变化。

4.1 数据集与实验环境

1) 数据集: 使用的 CIFAR-10 数据集是一个用于普适物体识别的计算机视觉数据集,包含了 60 000 张 32×32 的彩色图像,这些图像被分为 10 个

不同的类别，其中 50 000 张用于训练集，10 000 张用于测试集。由于该数据集图像数量适中、类别多样且图像尺寸一致，成了图像识别算法和深度学习模型的基准测试集，有助于评估和比较不同方案的性能。

2) 实验环境：假设存在 50 个智能设备，均匀分布在一个 $2 \text{ km} \times 2 \text{ km}$ 的正方形区域内，该区域由位于中心的基站服务器覆盖。路径损耗是基于 $128.1 + 37.6 \times d_i$ 计算得到，其中 d_i 是指服务器与智能设备 i 之间的距离，单位为千米，因此信道增益可以由 $g_i = 10^{-(128.1 + 37.6 \times d_i)/10}$ 建模并计算得出。智能设备的数据分布基于狄利克雷分布将数据集进行分割，由 β 来控制标签的不平衡程度，值越小分布越不平衡，在仿真实验中默认其值为 0.1。智能设备训练一个数据样本的 CPU 周期数服从均匀分布，即 $C_i \sim U(3, 5) \times 10^8$ 周期数每样本，CPU 频率也服从均匀分布，即 $f_i \sim U(0.8, 3) \times 10^9 \text{ Hz}$ 。具体仿真参数见表 1。

表 1 仿真参数

| 参数名 | 数值 |
|---|---|
| 智能设备总数 N | 50 |
| 总带宽 B_{tot} | 750 kHz |
| 标签不平衡程度 β | 0.1 |
| CPU 周期数 C_i | $U(3, 5) \times 10^8$ |
| CPU 频率数 f_i | $U(0.8, 3) \times 10^9 \text{ Hz}$ |
| 全局时间阈值 T | 20 s |
| 本地模型参数大小 s | 100 kbit ^[9] |
| 智能设备传输功率 p | 0.1 W |
| 平衡常数 α | 0.5 |
| 平衡常数 σ | 0.5 |
| 平衡常数 φ | 0.5 |
| 选择比例 c | 0.5 |
| 本地迭代轮次 $\theta \text{lb}(\frac{1}{\epsilon})$ | $1 \times \text{lb}(\frac{1}{5 \times 10^{-2}}) \approx 4.32$ |
| 噪声功率密度 N_0 | -94 dBm |
| 有效电容系数 λ | 200×10^{-12} |

4.2 不同方案下的性能对比

采用两种基准方案作为对比，一种是传统的联邦平均 (FedAvg, federated averaging) 方案^[26-27]，在这种方案下，所有智能设备全部能够参与联邦学习的全局聚合阶段。由于每轮全局迭代所有智能设备都参与，该方案的准确度是所提方案最理想的极限性能。另一种是具有智能设备选择的联邦学习 (FedCS, federated learning with client selection)^[28-29]方

案，这种情况下，服务器只接收时间阈值前完成本地训练的智能设备的模型参数来进行聚合。

本文主要研究非独立同分布的场景，选择 $\beta = 0.1$ 的情况来进行 3 种方案的对比，这种情况下智能设备数据的非独立同分布程度较高。

$\beta = 0.1$ 时 3 种方案准确度比较如图 4 所示，可以看到，作为基准的 FedAvg 方案准确度高达 72.72%，是 3 个方案中最高的，这是由于此方案下所有智能设备都参与了全局模型的训练。其中本文提出的方案准确度为 69.00%，仅次于 FedAvg 方案，这是因为利用智能设备分层的方法使得所有智能设备都有机会参与到全局迭代的过程中。FedCS 方案准确度最低，只有 55.76%，在该方案下服务器只接收时间阈值内完成上传的本地模型，智能设备的计算能力、通信资源相对固定，这就导致了参与全局训练的智能设备也是固定的，降低了数据多样性，进而降低了全局模型的测试准确度。

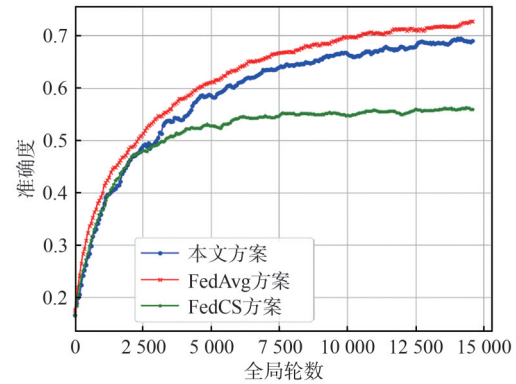


图 4 $\beta = 0.1$ 时 3 种方案准确度比较

$\beta = 0.1$ 时 3 种方案时延与准确度比较如图 5 所示，可以看出 FedAvg 的时延是最高的，高达 $1.27 \times 10^6 \text{ s}$ ，约是本文所提方案时延的 4.83 倍，这是由于服务器需要等待所有智能设备上传完本地模型参数才能进行聚合操作，这种方案下的高准确度是以高时延为代价的，在实际情况下不符合需求。FedCS 的整体系统时延为 $2.98 \times 10^5 \text{ s}$ ，这是因为每轮全局迭代都设置了时间阈值，服务器无须等待所有智能设备都上传完本地模型参数。此外，本文方案时延仅有 $2.63 \times 10^5 \text{ s}$ ，比 FedCS 时延少了 11.74%，是 3 种方案中时延最少的，这是由于在设置时间阈值的情况下为被选择的智能设备进行了带宽资源的重新分配，更有效地提高了带宽利用率。综合来看，所提方案具有低时延和较高准确度的优势，这是极具现实意义的。

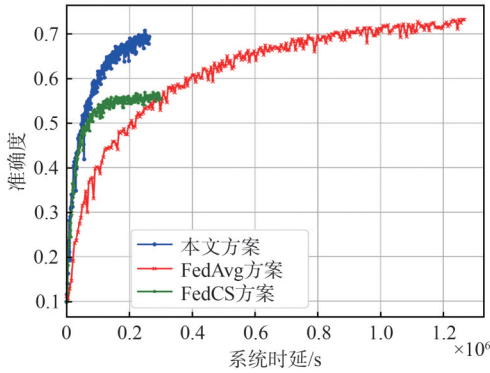


图5 $\beta = 0.1$ 时3种方案时延与准确度比较

为了更直观地观察到带宽资源优化分配下3种方案的性能比较, 本节进一步提出一个频谱利用指标FU来衡量频谱资源在联邦学习过程中的利用率, 定义其计算式如下

$$FU = \frac{B_{used} \times acc_t}{B_{tot} \times \tau_t} \quad (17)$$

其中, B_{used} 表示训练过程中实际使用的总带宽, acc_t 表示第 t 轮全局模型的准确度。 $\frac{B_{used}}{B_{tot}}$ 可以表示带宽利用率, 其值越大说明对带宽资源的使用程度越高, 同时, 准确度 acc_t 越高说明全局模型的性能越好, 每轮全局时延值 τ_t 越小说明训练效率越高。因此, FU 越高, 表明对频谱资源的利用效率越高。基于仿真实验的比较分析, 计算了3种方案训练过程中的FU, 3种方案频谱利用指标比较如图6所示。可以观察到, 本文所提方案的FU值最高, 这是因为所提方案在客户端调度后增加了带宽分配的步骤, 会在缩短每轮全局时延的同时提高带宽利用率。尽管 FedCS 时延较小, 但其FU是最低的, 这是因为该方案只接收时间阈值内的局部模型, 超过时间阈值的智能设备占用子信道但是并没有上传局部模型参数, 这会导致带宽利用率很低。

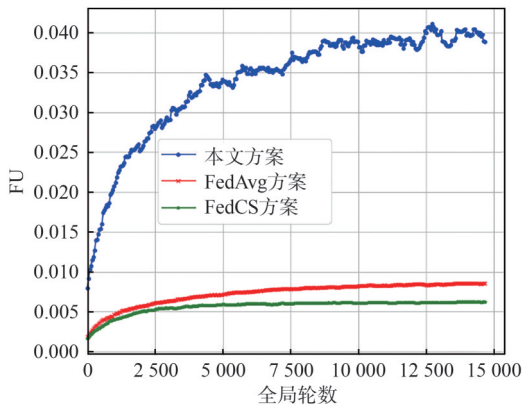


图6 3种方案频谱利用指标比较

4.3 不同参数下的性能对比

本节主要探讨不同参数对提出的方案时延、准确度的影响。首先, 令智能设备总数分别为10、25、50、75, 不同设备总数下时延与准确度比较如图7所示。当智能设备数量较少时, 数据多样性可能相对较低, 从而导致全局模型的泛化性能受限, 表现为准确度不高。然而, 当智能设备总数增加到75时, 可以观察到准确度相较于总数为50时有所下降。这主要是当设备数量过多时, 虽然数据多样性得到了进一步提升, 但同时也需要更多通信轮次来充分利用这些多样性高的数据, 需要更多时间来提高系统准确度。




图7 不同设备总数下时延与准确度比较

此外, 从时延角度来看, 随着智能设备总数的增加, 整体系统时延也在逐步上升。这是通信资源的有限性所导致的, 随着设备数量的增多, 通信负载加重, 时延自然也随之增加。因此结合时延和准确度, 在仿真实验中采取设备总数为50与传统方案进行性能对比。这一选择既保证了数据多样性以提升准确度, 又避免了因设备数量过多而导致的过高时延。

接下来, 将深入且全面地探讨每轮智能设备选择比例这一关键参数对系统时延以及准确度所产生的具体影响。为了精准地分析这种影响, 将智能设备的选择比例分别设定为0.2、0.5和0.7, 不同设备选择比例下时延与准确度比较如图8所示。通过观察实验结果可以发现, 智能设备选择比例的改变对训练时延的影响极为突出。深入探究其背后的原因, 不难发现, 随着选择比例的不断增大, 每轮参与到全局迭代过程中的智能设备数量呈现出逐步递增的趋势, 每个客户端被分配到的频谱资源会相应减少, 从而直接导致整体系统时延不断攀升。然而, 事情往往具有两面性。尽管选择比例的增加带来了系统时延的上升, 但当更多智能设备积极参与到每轮迭代中时, 也为系统

带来了数据多样性方面的显著提升。在模型训练的情境下，数据多样性意味着模型能够接触到更多类型、更具代表性的数据，这有助于模型更好地理解和处理各种复杂情况，进而提高模型的泛化能力。从实验结果中也可以看到，系统准确度随着选择比例的增加而逐渐升高，这一现象进一步有力地验证了数据多样性对于提高系统模型训练精度的重要性。




图8 不同设备选择比例下时延与准确度比较

5 结束语

联邦学习被运用于工业物联网中实现设备之间的智能协同和资源优化，推动实现数字化转型。但由于智能化工业设备在计算能力、通信资源等方面存在异构性，容易造成“落后者效应”，严重影响系统性能。本文针对此问题，以降低整体系统时延为目标，首先采用半同步的联邦学习策略，将智能设备根据计算和通信时延进行分层聚类，使得其能够以不同频率参与到全局迭代过程中以提高数据多样性。进一步针对工业物联网中智能设备数量庞大对联邦学习部署性能的限制，基于训练时延提出一种效益函数进行客户端调度。最后利用半同步策略下时延相等的数学关系，对带宽资源进行优化配置。与传统策略相比，仿真结果显示了所提方案在准确度、整体系统时延和频谱利用方面的性能优势。基于本文研究，未来将进一步结合非正交多址、空中计算、数字孪生、分割学习等先进的无线通信与人工智能技术，构建面向6G内生智能^[30]与边缘通感算融合^[31]的低时延、高鲁棒协同智算范式，突破工业联邦学习在复杂动态环境、多维资源耦合约束下的高效可靠部署瓶颈。

参考文献：

- [1] CHOUDHARY A. Internet of things: a comprehensive overview, architectures, applications, simulation tools, challenges and future directions[J]. Discover Internet of Things, 2024, 4(1): 31.
- [2] SAHA R, MISRA S, CHAKRABORTY A, et al. Data-centric client selection for federated learning over distributed edge networks[J]. IEEE Transactions on Parallel and Distributed Systems, 2023, 34(2): 675-686.
- [3] GE L N, LI H A, WANG X, et al. A review of secure federated learning: privacy leakage threats, protection technologies, challenges and future directions[J]. Neurocomputing, 2023, 561: 126897.
- [4] LO S K, LU Q H, WANG C, et al. A systematic literature review on federated machine learning: from a software engineering perspective[J]. ACM Computing Surveys, 2021, 54(5): 1-39.
- [5] 王晓明, 黄斌杓. 基于用户选择的鲁棒与隐私保护联邦学习方案[J]. 计算机应用研究, 2025, 42(6): 1859-1867.
WANG X M, HUANG B R. Robust and privacy-preserving federated learning scheme based on user selection[J]. Application Research of Computers, 2025, 42(6): 1859-1867.
- [6] 刘淼, 林婉茹, 王琴, 等. 车联网联邦学习的数据异质性问题及基于个性化的解决方法综述[J]. 通信学报, 2024, 45(10): 207-224.
LIU M, LIN W R, WANG Q, et al. Survey on data heterogeneity problems and personalization based solutions of federated learning in Internet of vehicles[J]. Journal on Communications, 2024, 45(10): 207-224.
- [7] XIA Y J, LIU X J, ZHAO Y X, et al. FCLA-DT: federated continual learning with authentication for distributed digital twin-based industrial IoT[J]. Journal of Communications and Information Networks, 2024, 9(4): 362-373.
- [8] 申凌峰, 王光辉, 白天水, 等. 基于选举策略的低空物联网稳定联邦学习方法[J]. 物联网学报, 2024, 8(3): 55-65.
SHEN L F, WANG G H, BAI T S, et al. Stable federated learning method for low-altitude IoT networks based on election strategy[J]. Chinese Journal on Internet of Things, 2024, 8(3): 55-65.
- [9] 范珂欣, 安丽荣, 张钦宇. 业务驱动的空天地海一体化网络技术研究[J]. 电信科学, 2024, 40(6): 25-37.
FAN K X, AN L R, ZHANG Q Y. Research on service-driven network technologies for space-air-ground-sea integration[J]. Telecommunications Science, 2024, 40(6): 25-37.
- [10] MOTHUKURI V, KHARE P, PARIZI R M, et al. Federated-learning-based anomaly detection for IoT security attacks[J]. IEEE Internet of Things Journal, 2022, 9(4): 2545-2554.
- [11] ZHANG W T, YANG D, WU W, et al. Optimizing federated learning in distributed industrial IoT: a multi-agent approach[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(12): 3688-3703.
- [12] 郭英芸, 高博, 张志飞, 等. 一种基于带宽分配的联邦学习激励机制[J]. 物联网学报, 2022(4): 82-92.
GUO Y Y, GAO B, ZHANG Z F, et al. An incentive mechanism with bandwidth allocation for federated learning[J]. Chinese Journal on Internet of Things, 2022(4): 82-92.
- [13] ZHU C, ZHU G L, YANG J, et al. Quick and good: a DRL based communication-caching-energy joint optimization scheme for pro-

- longing the lifetime of UAV assisted IoE[J]. *Journal of Communications and Information Networks*, 2024, 9(4): 1-14.
- [14] YANG K, SHI Y M, ZHOU Y, et al. Federated machine learning for intelligent IoT via reconfigurable intelligent surface[J]. *IEEE Network*, 2020, 34(5): 16-22.
- [15] NING B Y. Federated learning optimisation algorithm based on Non-IID data[C]//*Proceedings of the 2023 IEEE International Conference on Electrical, Automation and Computer Engineering (ICEACE)*. Piscataway: IEEE Press, 2024: 1663-1669.
- [16] SUN W, LEI S Y, WANG L, et al. Adaptive federated learning and digital twin for industrial Internet of things[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(8): 5605-5614.
- [17] ABDULRAHMAN S, TOUT H, MOURAD A, et al. FedMCCS: multicriteria client selection model for optimal IoT federated learning[J]. *IEEE Internet of Things Journal*, 2021, 8(6): 4723-4735.
- [18] DENG Y H, LYU F, REN J, et al. AUCTION: automated and quality-aware client selection framework for efficient federated learning[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2022, 33(8): 1996-2009.
- [19] SHEN S, SHEN G J, DAI Z H, et al. Asynchronous federated deep-reinforcement-learning-based dependency task offloading for UAV-assisted vehicular networks[J]. *IEEE Internet of Things Journal*, 2024, 11(19): 31561-31574.
- [20] CHEN Z Y, LIAO W X, HUA K, et al. Towards asynchronous federated learning for heterogeneous edge-powered Internet of things[J]. *Digital Communications and Networks*, 2021, 7(3): 317-326.
- [21] XU J, WANG H Q. Client selection and bandwidth allocation in wireless federated learning networks: a long-term perspective[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(2): 1188-1200.
- [22] 刘淼, 夏雨虹, 赵海涛, 等. 面向6G工业物联网的联邦学习: 从需求、愿景到挑战、机遇[J]. *电子与信息学报*, 2024, 46(12): 4335-4353. LIU M, XIA Y H, ZHAO H T, et al. Federated learning technologies for 6G industrial Internet of things: from requirements, vision to challenges, opportunities[J]. *Journal of Electronics & Information Technology*, 2024, 46(12): 4335-4353.
- [23] SONG Y X, YU F R, ZHOU L, et al. Applications of the Internet of Things (IoT) in smart logistics: a comprehensive survey[J]. *IEEE Internet of Things Journal*, 2021, 8(6): 4250-4274.
- [24] XU Y, XIAO M J, TAN H S, et al. Incentive mechanism for differentially private federated learning in industrial Internet of things[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 6927-6939.
- [25] YU L K, SUN X, ALBELAIHI R, et al. Latency-aware semi-synchronous client selection and model aggregation for wireless federated learning[J]. *Future Internet*, 2023, 15(11): 352.
- [26] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]//*Proceedings of the International Conference on Artificial Intelligence and Statistics*, 2016.
- [27] WU D X, SHEN G H, HUANG Z Q, et al. A trust-aware task offloading framework in mobile edge computing[J]. *IEEE Access*, 2019, 7: 150105-150119.
- [28] NISHIO T, YONETANI R. Client selection for federated learning with heterogeneous resources in mobile edge[C]//*Proceedings of the ICC 2019-2019 IEEE International Conference on Communications (ICC)*. Piscataway: IEEE Press, 2019: 1-7.
- [29] HUANG T S, LIN W W, WU W T, et al. An efficiency-boosting client selection scheme for federated learning with fairness guarantee[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2021, 32(7): 1552-1564.
- [30] 耿光磊, 高博, 熊轲, 等. 联邦学习赋能6G网络综述[J]. *物联网学报*, 2023(2): 50-66. GENG G L, GAO B, XIONG K, et al. A survey of federated learning for 6G networks[J]. *Chinese Journal on Internet of Things*, 2023(2): 50-66.
- [31] 齐俏, 陈晓明. 面向边缘智能网络的通-感-算融合: 架构、挑战和展望[J]. *移动通信*, 2024, 48(3): 40-46. QI Q, CHEN X M. Integrated sensing, communication, and computing for edge intelligent networks: architecture, challenges, and outlook[J]. *Mobile Communications*, 2024, 48(3): 40-46.

[作者简介]



王晔(1987-), 男, 博士, 江苏移动信息系统集成有限公司高级工程师, 主要研究方向为智能网联、移动通信技术。



施颖(2000-), 女, 南京邮电大学通信与信息工程学院硕士生, 主要研究方向为联邦学习、资源调度。



夏天乐(2002-), 男, 南京邮电大学通信与信息工程学院硕士生, 主要研究方向为群智协同、联邦学习。



刘淼(1988-), 男, 博士, 南京邮电大学通信与信息工程学院讲师、硕士生导师, 主要研究方向为泛在无线通信与物联网、电信技术。



杨洁(1980-), 女, 博士, 南京邮电大学通信与信息工程学院副教授, 主要研究方向为移动通信技术、电信技术。



赵海涛(1983-), 男, 博士, 南京邮电大学物联网学院教授、博士生导师, 主要研究方向为泛在无线通信与物联网、移动通信技术。