

6G 联邦边缘学习新范式：基于任务导向的资源管理策略

王志勤¹, 江甲沫¹, 刘沛西², 曹晓雯³, 李阳¹, 韩凯峰¹, 杜滢¹, 朱光旭⁴

(1. 中国信息通信研究院移动通信创新中心, 北京 100191; 2. 北京大学电子学院, 北京 100871;
3. 广东工业大学信息工程学院, 广东 广州 510006; 4. 深圳市大数据研究院, 广东 深圳 518172)

摘要: 综述了面向 6G 的联邦边缘学习技术, 能够充分利用分布在网络边缘的丰富数据使之服务于人工智能模型训练, 以联邦边缘学习为代表的边缘智能技术应运而生, 其中无线资源管理策略将以最优化任务学习性能为导向, 例如优化模型训练时间、学习收敛性等, 从而实现从通信导向到任务导向的设计范式变革。首先, 概述了联邦边缘学习基本概念、典型应用场景及其在无线资源管理中的关键问题。然后, 以联邦边缘学习中带宽资源分配和用户调度策略为典型的资源管理案例, 深入阐述了基于任务导向的设计范式思想。最后, 对联邦边缘学习的未来潜在研究方向进行了展望, 包括与无线空中计算、通信感知一体化等全新技术的融合赋能。

关键词: 6G 智能网络; 任务导向的联邦边缘学习; 资源管理策略; 用户调度策略

中图分类号: TN929.5

文献标志码: A

DOI:10.11959/j.issn.1000-436x.2022128

New design paradigm for federated edge learning towards 6G: task-oriented resource management strategies

WANG Zhiqin¹, JIANG Jiamo¹, LIU Peixi², CAO Xiaowen³,
LI Yang¹, HAN Kaifeng¹, DU Ying¹, ZHU Guangxu⁴

1. Mobile Communication Innovation Center, China Academy of Information and Communications Technology, Beijing 100191, China
2. School of Electronics, Peking University, Beijing 100871, China
3. School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China
4. Shenzhen Research Institute of Big Data, Shenzhen 518172, China

Abstract: The 6G-oriented federated edge learning technology was reviewed, which could make full use of the rich data distributed at the edge of the network for model training, edge intelligence technologies represented by federated edge learning (FEEL) had emerged, in which wireless resource management strategies would be oriented by tasks, such as optimizing learning performance in terms of model training time, learning convergence rate, etc., leading to a design paradigm shift. First, the basic concepts, typical application scenarios and the key issues in wireless resource management of FEEL were outlined. Then, two typical resource management cases of bandwidth resource allocation and user scheduling strategy in FEEL were used to elaborate the idea of task-oriented design paradigm. Finally, the potential future research directions of FEEL were prospected, including the integration and empowerment with new technologies, such as over-the-air computation and integrated sensing and communication.

Keywords: intelligent network towards 6G, task-oriented federated edge learning, resource management strategy, user scheduling strategy

收稿日期: 2022-02-07; 修回日期: 2022-04-27

通信作者: 江甲沫, iangjiamo@caict.ac.cn

基金项目: 国家重点研发计划基金资助项目 (No.2020YFB1807100); 国家自然科学基金资助项目 (No.62001310); 广东省基础与应用基础研究基金资助项目 (No.2022A1515010109)

Foundation Items: The National Key Research and Development Program of China (No.2020YFB1807100), The National Natural Science Foundation of China (No.62001310), Guangdong Basic and Applied Basic Research Foundation (No.2022A1515010109)

0 引言

随着 5G 网络的大规模商用，全球已开启对下一代移动通信技术——6G 的研究探索。面向 2030 年及未来，人类社会将进入智能化时代，6G 将构建一张泛在互联的智慧网络，实现从服务于人、人与物，到支撑智能体高效连接的跃迁，通过人机物智能互联、协同共生，满足经济社会高质量发展需求，服务智慧化生产与生活，推动构建普惠智能的人类社会，从而实现“万物智联、数字孪生”的 6G 总体愿景^[1-3]。

为满足未来 6G 更加丰富的业务应用以及极致的性能需求，需要传统空口技术的持续演进以及对新型网络架构的深入探索。作为具有广泛共识的技术趋势之一，无线通信与人工智能深度融合，赋予无线空口和网络架构等内生智能特性^[4]。为高效收集和学习来自网络边缘侧的大规模数据，并为移动终端提供超快速、智能化服务以及环境感知等功能，边缘智能技术应运而生，其通过将机器学习算法部署在网络边缘（如基站和智能终端），以快速高效地利用分布式移动数据来持续训练和调整边缘云（或基站）中的人工智能模型^[5-6]。在众多边缘智能技术中，联邦边缘学习（FEEL, federated edge learning）以其优越的数据隐私保护性以及高效的终端计算资源利用率，逐渐成为目前最流行的边缘学习范式之一^[7-10]。在联邦边缘学习中，分布式无线设备可以协作执行一个共享机器学习任务，只需将局部学习模型上传到边缘服务器，并不需共享所有训练数据样本。由于样本数据被保留在每个设备上，只需上传局部机器学习模型参数至边缘服务器，因

此可以保护设备的数据隐私。同时，在设备本地完成局部模型更新参数，能高效利用本地的计算资源。

1) 联邦边缘学习技术及典型应用场景

在联邦边缘学习过程中，分布式无线设备协作执行机器学习任务，并不需共享所有训练数据样本，只需将局部学习模型上传到边缘服务器。这样，数据样本将被保留在每个设备上，不需要打破“数据孤岛”和共享数据资源，能更好地保护设备的数据隐私。联邦边缘学习的基本框架及流程如图 1 所示。联邦边缘学习的训练过程可以基于分布式梯度下降法迭代进行，即在每一次迭代中，不同终端设备根据各自的本地数据更新本地模型参数，并通过无线信道将各自的本地模型参数上传至边缘服务器进行模型汇总，以更新全局模型参数；上述步骤迭代进行，直至全局模型参数收敛。

联邦边缘学习技术应用前景广阔，可有效赋能智慧医疗、车联网、物联网通信等业务场景，并且由于其不需要共享数据，能够充分保证数据隐私和安全性。例如，在医疗领域，为了避免对医疗原始数据中隐私信息的直接访问，基于联邦边缘学习的智慧医疗可在保护患者病情隐私的前提下，依靠前期检验结果和患者历史就诊信息，建立学习模型，帮助医生提高诊断患者罹患相应疾病的准确率^[11]。在车联网领域，通过引入联邦边缘学习技术，可将道路中不同车辆的传感器数据以及道路基础设施所获取的交通数据进行联合训练，用以提升道路场景地图重建效率、准确性和稳健性^[12]。在物联网领域，运用联邦边缘学习可高效处理物联网设备所产生的海量实时数据，在有效支撑物联网应用业务的同时，实现对物联网系统状态的智能监测与反馈，赋能网络自动化运维^[13]。

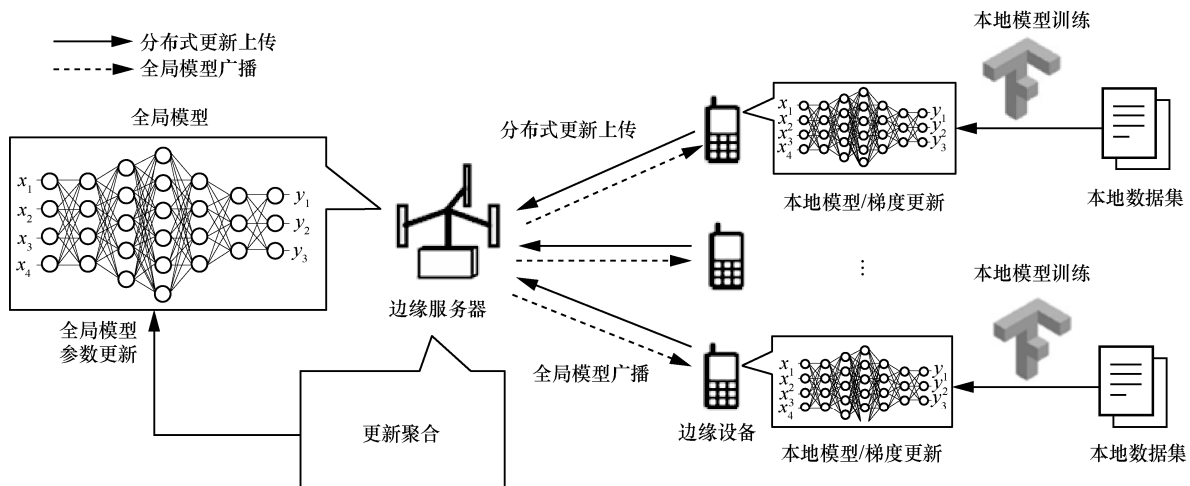


图 1 联邦边缘学习的基本框架及流程

同时,在无线网络中实现上述联邦学习应用仍面临非常严峻的挑战。一方面,联邦边缘学习网络的主要衡量指标一般为机器学习模型的训练可靠性、收敛速度等,而传统无线网络主要以通信性能为主要衡量指标,如丢包率、传输速率等。由于学习与通信两者间性能指标的差异,现有以通信性能最大化为目标的无线资源管理策略并不能直接应用于联邦边缘学习网络。另一方面,联邦边缘学习网络是以分布式方式在不同的设备间训练共享的人工智能模型,且设备需要通过无线链路频繁地与边缘服务器传输训练更新参数。然而,由于无线资源(如带宽等)有限且无线链路不具有可靠性,更新参数传输过程会不可避免地引入一些训练误差,影响边缘设备和服务器之间模型更新的质量和准确度,进而影响联邦边缘学习算法的性能。但是,无线资源与联邦学习性能之间目前还没有清晰的定量分析框架,无法准确衡量无线资源管理对联邦学习性能的影响。

2) 联邦边缘学习中的无线通信及资源管理问题

在香农信息理论的指导下,现有无线通信系统的核心设计目标是有效提升通信性能,如提升峰值速率、吞吐量、频谱效率、能量效率等,称为通信导向的最优设计。联邦学习中频繁的模型参数传输汇总过程导致了技术上的挑战:持续的模型/梯度参数传输和更新使终端设备和边缘服务器之间的无线通信交互十分频繁,增加无线通信链路负担,并逐渐成为制约联邦边缘学习性能提升的瓶颈。但是,现有以通信性能最大化为目标的无线资源管理策略并不能直接应用于联邦边缘学习网络,更无法突破该通信瓶颈。此外,不同于现有的通信网络只关注数据的语法信息传输(即通信符号的准确传输),边缘智能应用主要依靠数据的语义特征信息,而现有网络中数据内容的高级含义或相关性传输策略之间存在松耦合。为了实现特定的目标(如使用最少的频谱资源实现最大速率的数据比特传送,同时误码率最低),无线传输与数据的意义和有效性的分离会不可避免地导致冗余,例如传输的信息缺乏相关性或新鲜度,同时,现有的信息过滤、传输和处理技术难以跟上数据指数级增长的速度,极大制约信息传输的有效性。因此,为有效支持智能服务的高效通信需求,联邦边缘学习系统设计逐步向以任务导向为核心的设计范式转变^[14]。为提

高通信系统性能,常见的设计手段包括资源分配、用户调度等^[15]。相应地,在面向任务导向的联邦边缘学习中,无线资源分配和用户调度的设计目标也需要全新升级^[16],以进一步优化网络资源使用效率。

① 联邦边缘学习中的资源分配研究现状

优化设计包括带宽在内的无线资源分配策略已成为突破联邦边缘学习性能瓶颈的重要手段。创新无线资源分配策略、突破通信性能瓶颈,是目前联邦边缘学习网络设计的重要挑战,包括以下两方面:建立无线资源管理与联邦边缘学习性能的定量分析框架,探索资源分配策略对训练性能的准确度以及收敛速度等的影响;改变现有通信导向的无线资源管理方案,使其适用于任务导向的联邦边缘学习网络,以进一步优化网络资源使用效率。以最小化训练时间为全新的任务导向优化目标,下面介绍相关代表性工作。

由于联邦边缘学习训练过程由多个终端设备和边缘服务器之间的模型迭代更新组成,因此联邦边缘学习总训练时间由总通信轮次和每轮次的本地模型更新和聚合时延决定。为加快联邦边缘学习算法收敛,文献[17]通过联合优化传输功率和带宽,在给定的单轮时间约束下最小化每轮次全局损失函数。文献[18]考虑了存在中断概率时的最优带宽资源分配策略。上述工作主要关注如何加快联邦边缘学习算法的收敛速度,即减少通信轮次,但并未考虑如何缩短总训练时间。文献[19]提出一种基于多址接入的宽带模拟聚合方案,分析和比较了不同多址方案的通信时延性能,并通过仿真证明了该方案相比传统的正交频分多址接入方案可以显著降低联邦边缘学习的单次模型聚合时延。在此基础上,文献[20]考虑了用户移动性的场景,提出了基于联邦深度 Q 网络学习算法的最优路径选择及功率分配的联合优化方案,该方案使网络吞吐量最大化的同时确保了功率约束及移动性约束等条件,仿真结果证明了方案的有效性。但上述工作仅仅考虑单轮通信中的资源分配,而忽略联邦边缘学习的总通信轮次。目前已有部分工作直接关注联邦边缘学习的总训练时延。例如,文献[21]提出通信和计算等多维资源联合配置策略。文献[22]则结合学习、无线资源联合分配以及设备选择方案,最小化固定通信轮次下的总训练时间。文献[23]在进一步考虑计算

和通信资源受限场景下, 有效设计出能够权衡通信开销和学习性能的联合优化方案, 经仿真验证, 该方案的性能优于对比方案。

上述研究工作分别从不同角度探索无线资源分配策略, 以最小化联邦边缘学习训练时延。然而, 上述工作均未考虑通信轮次和每轮时延之间的重要折中关系, 本文将于第1节进行研究。

② 联邦边缘学习中的用户调度研究现状

为实现高效联邦边缘学习, 用户调度是一个备受关注的重要研究方向, 即在带宽有限的情况下, 每次模型更新过程中仅选择一部分用户上传模型数据, 通过减少设备接入以缓解通信瓶颈制约。

文献[24]考虑了联邦学习中的用户调度问题, 利用随机策略均匀选择设备上传模型数据, 从而有效降低通信时延。在文献[24]的基础上, 文献[25]比较了随机调度算法、轮询算法和比例公平算法等启发式调度算法, 并进一步分析了这3种调度算法的理论收敛性能。此外, 为了探索用户数据对调度的影响, 文献[26]提出了基于数据多样性的设备调度策略。文献[27]提出了一种在给定训练时间下最大化模型准确度的联合设备调度和资源分配算法。进一步, 为最小化通信轮次, 文献[28]提出了一种基于重要性的调度策略, 其中重要性度量指标为局部更新的范数, 即当某个设备具有更大的局部更新的范数时, 会被分配一个更高的调度概率。考虑单轮通信时延最小化, 文献[19, 29]提出了基于信道质量的调度策略, 其中有强信道的设备比具有弱信道的设备有更高的调度概率。

上述研究工作从不同方面针对联邦边缘学习的用户调度算法展开了研究。但是, 目前针对最小化训练时间的用户调度算法仍缺少最优设计, 有较大研究空间。为此, 本文第2节将从最小化通信时间的角度出发, 设计最优的无线资源分配和用户调度策略。

1 基于联合量化和带宽优化的资源分配策略

基于笔者团队最新研究成果, 本节将详细介绍具有不同计算能力的边缘设备在联邦边缘学习框架中设计任务导向的最优资源分配策略。考虑到面向复杂任务的模型通常具有大规模参数的特点, 在终端设备和边缘服务器之间的模型迭代更

新过程将导致巨额的通信开销。为了解决这一问题, 文献[30]提出了量化的联邦边缘学习方案, 旨在通过应用量化技术实现对模型的高效压缩以减少交互的数据总量, 从而大幅降低无线资源的占用率。目前已有研究开始关注通过压缩和量化来减少通信开销。例如, 文献[31]研究了量化方案对模型最终收敛效果的影响, 得出了在高压缩率的条件下量化模型性能接近理想模型性能的结论。文献[32]研究了在给定训练时间内通过联合优化数据压缩程度和本地更新步数来最小化训练损失, 但没有涉及通信资源分配。文献[33]提出了一种自适应的模型压缩机制, 通过舍弃参数更新缓慢的模型部分节点, 能够有效减少冗余通信。文献[34]针对能耗和量化误差受限场景, 设计了减少模型收敛时间的优化方案, 揭示了学习准确度和更新时延之间的折中关系。更进一步, 文献[35]探讨了模型低压缩率的影响, 提出了将本地更新的梯度进行1 bit 量化并融合多数表决的聚合方案, 在给定总训练时间的情况下, 揭示了功率和算力受限场景下通信轮次与通信中断概率的折中关系。然而, 上述研究并未揭示通信轮次和每轮时延之间的固有折中关系。

本节将分析以最小化总训练时间为目标的通信轮次和每轮时延之间的折中关系, 其中边缘设备需要量化上传梯度以减小通信开销, 但减少最小通信轮次和抑制每轮时延之间存在着基本的折中关系, 即通过增加量化级数 q 可以减少最小通信轮次, 但以延长单轮训练时间为代价。由于设备的计算能力有差异, 导致它们的计算时间也不同。为了满足每轮训练的时间约束, 应该给计算能力低的设备分配更多的频率带宽, 通过减小通信时间补偿计算时间, 反之亦然。因此, 设备间的带宽分配应该同时考虑信道条件和计算资源, 这与传统只考虑信道条件的带宽分配工作截然不同。为此, 需要建模总训练时间最小化问题, 优化量化级数和带宽分配, 设计交替优化算法解决该问题。

1.1 系统模型

1.1.1 联邦边缘学习框架

基于量化的联邦边缘学习系统模型如图2所示。考虑一个由 K 个边缘设备和一个边缘服务器组成的联邦边缘学习系统。在边缘服务器的协调下, 多个边缘设备协作训练一个全局模型。该模型用参数向量 $\mathbf{w} \in \mathbb{R}^d$ 表示, 其中 d 表示模型大小。

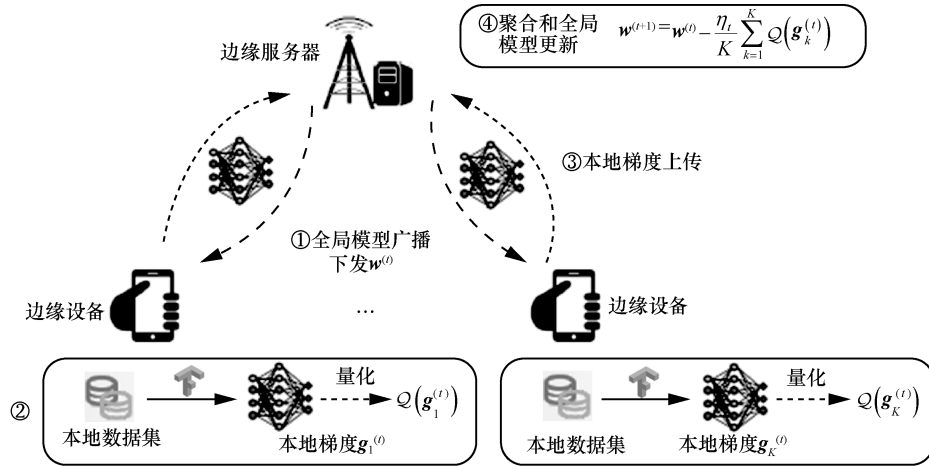


图 2 基于量化的联邦边缘学习系统模型

训练过程等价于最小化经验损失函数，即

$$F(\mathbf{w}) = \frac{1}{K} \sum_{k=1}^K F_k(\mathbf{w}) \quad (1)$$

其中， $F_k(\mathbf{w})$ 是边缘设备 k ($k \in [K]$) 处的本地损失函数。假设边缘设备 k 持有本地数据集 \mathcal{D}_k ，大小为 D ，即 $|\mathcal{D}_k| = D$ 。本地损失函数 $F_k(\mathbf{w})$ 表示为

$$F_k(\mathbf{w}) = \frac{1}{D} \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}_k} f(\mathbf{w}; \mathbf{x}_i, y_i) + \lambda R(\mathbf{w}) \quad (2)$$

其中， $f(\mathbf{w}; \mathbf{x}_i, y_i)$ 表示特定学习任务下量化模型 \mathbf{w} 在训练数据 \mathbf{x}_i 及真实标签 y_i 上的单样本损失函数； $R(\mathbf{w})$ 表示某些强凸正则化函数，其强度由一个超参数 $\lambda \geq 0$ 控制。

在联邦边缘学习中，训练过程是以分布式的方式同时使用联邦随机梯度下降 (FedSGD, federated stochastic gradient decent) 的算法来实现的。考虑某个特定的通信轮次或者迭代 n ，所有边缘设备首先从边缘服务器下载当前全局模型 $\mathbf{w}^{(t)}$ 。然后，每个边缘设备利用从本地数据集 \mathcal{D}_k 中随机采样得到的小批量样本进行本地随机梯度下降，得到梯度 $\mathbf{g}_k^{(t)}$ 。将边缘设备 k 在第 t 轮迭代中采样的小批量样本记为 $\bar{\mathcal{D}}_k^{(t)}$ ，其大小为 m_b 。因此，梯度 $\mathbf{g}_k^{(t)}$ 表示为

$$\mathbf{g}_k^{(t)} = \frac{1}{m_b} \sum_{(\mathbf{x}_i, y_i) \in \bar{\mathcal{D}}_k^{(t)}} \nabla f(\mathbf{w}^{(t)}; \mathbf{x}_i, y_i) + \lambda \nabla R(\mathbf{w}^{(t)}) \quad (3)$$

每个边缘设备将量化后的梯度 $Q(\mathbf{g}_k^{(t)})$ 上传到边缘服务器。量化方案 $Q(\cdot)$ 将在 1.1.2 节进行详细阐述。收到所有设备上传的梯度后，边缘服务器将梯度进行聚合并以此更新全局模型，即

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} - \frac{\eta_t}{K} \sum_{k=1}^K Q(\mathbf{g}_k^{(t)}) \quad (4)$$

其中， η_t 表示第 t 轮迭代中的学习率。随后，边缘服务器将更新全局模型，并将其广播给所有的边缘设备，以初始化下一轮训练。上述过程一直持续到满足收敛条件或达到最大通信轮次为止。

1.1.2 对梯度的随机量化方案

考虑一种被广泛使用的随机量化方案^[36]对本地的梯度进行量化。对于任意向量 $\mathbf{g} \in \mathbb{R}^d$ ，随机量化器 $Q(\mathbf{g}) : \mathbb{R}^d \rightarrow \mathbb{R}^d$ 依元素定义为

$$Q(\mathbf{g}_i) = \|\mathbf{g}\| \text{sgn}(g_i) \xi_i(\mathbf{g}, q), \forall i \in [d] \quad (5)$$

其中，量化器的输出 $Q(\mathbf{g})$ 由三部分组成，即向量的 ℓ_2 范数 $\|\mathbf{g}\|$ 、向量元素符号 $\text{sgn}(g_i)$ (g_i 表示向量 \mathbf{g} 的第 i 个元素)，以及每个向量元素的量化值 $\xi_i(\mathbf{g}, q)$ 。 $\{\xi_i(\mathbf{g}, q)\}$ 是按式(6)定义的随机变量。

$$\xi_i(\mathbf{g}, q) = \begin{cases} \frac{l+1}{q}, & \text{以概率 } \frac{|g_i|}{\|\mathbf{g}\|} q - l \\ \frac{l}{q}, & \text{其他} \end{cases} \quad (6)$$

其中， l 表示一个整数并且满足 $0 \leq l < q$ 和 $\frac{|g_i|}{\|\mathbf{g}\|} \in$

$$\left[\frac{l}{q}, \frac{l+1}{q} \right)。$$

1.2 通信时间最小化问题建模

在量化联邦边缘学习中，一个通信轮次中的计算时间和通信时间如图 3 所示，每个设备的单轮训练时间由计算时间 T_k^{comp} 和通信时间 T_k^{comm} 两部分组成。由于边缘服务器使用整个频段向所有设备广播相同的全局模型，与从多个边缘设备上传到边缘服务器的更新导致的上行时延相比，全局模型广播导致的下行时延是可以忽略不计的。

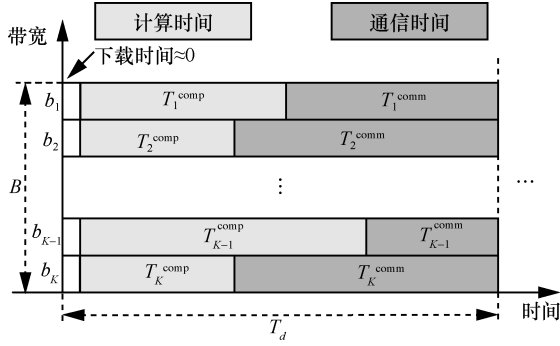


图 3 一个通信轮次中的计算时间和通信时间

假设单轮训练时间的上限为 T_d ，即 $T_k^{\text{comp}} + T_k^{\text{comm}} \leq T_d$ 。定义 N_ϵ 为达到损失函数 ϵ -最优值间隔时的最小通信轮次，即 $F(\mathbf{w}^{(N_\epsilon)}) - F(\mathbf{w}_*) \leq \epsilon$ ，其中 $\mathbf{w}_* = \arg \min_{\mathbf{w}} F(\mathbf{w})$ 表示最优的模型参数。当达到损失函数 ϵ -最优值间隔时训练过程即停止。那么，整个训练过程持续的时间可以表示为

$$T = N_\epsilon T_d \quad (7)$$

基于文献[37]的分析推导，可将总训练时间最小化问题建模为

$$\begin{aligned} \text{P1} \quad & \min_{q \in \mathbb{Z}^+, \{b_k\}, T_d} T_d N_\epsilon \\ \text{s.t.} \quad & \text{C1: } T_k^{\text{comp}} + T_k^{\text{comm}} \leq T_d, \forall k \in [K] \\ & \text{C2: } \sum_{k=1}^K b_k = B \\ & \text{C3: } q \geq 2 \end{aligned}$$

其中， b_k 为分配给边缘设备 k 的带宽， B 为系统总带宽，优化目标为达到损失函数 ϵ -最优值间隔的总训练时间， $N_\epsilon = \left\lceil \left(\frac{\sqrt{d}}{qK} + 1 \right) \left(\frac{A}{\epsilon} - B \right) + 1 \right\rceil$ ，C1 为每轮通信中每个设备的训练时间约束，C2 为总带宽约束，C3 为量化水平约束。

1.3 最优算法设计

由于变量 T_d 和 q 的互相耦合且 q 为正整数，P1 为非凸整数规划问题，难以求取全局最优解。为了得到 P1 的解决方案，首先将其拆分为 2 个子问题：一是在固定量化级数 q 的情况下，求解最优带宽分配 b_k 和 T_d ；二是在固定带宽分配 b_k 和 T_d 的情况下，求解最优量化级数 q 。可以发现，第一个子问题可以高效地求解出唯一解，第二个子问题可以转化为非凸问题，再通过连续凸近似（SCA, successive

convex approximation）^[38]的方法进行求解。然后，通过交替求解每个子问题，可以得到量化级数和带宽分配优化的次优解^[31]。

1.4 仿真实验

1.4.1 仿真设置

考虑一个边缘服务器覆盖外圈半径为 500 m、内圈半径为 100 m 的环形区域的联邦边缘学习系统。在该区域内，边缘设备被随机放置并均匀分布在圆形区域内，且 $K = 6$ 。考虑使用 CIFAR-10 数据集进行图像分类的学习任务，该数据集由 50 000 张训练图像和 10 000 张验证图像组成，涉及 10 类彩色目标，如飞机、汽车等。选择带有批量归一化的 ResNet-20（共 269 722 个参数）网络作为本实验的学习模型。目前，关于最优衰减学习率的方案并没有通用的结论和理论分析。一般来说，针对不同的神经网络模型和任务，其最优衰减学习率可能不同。通过大量实验发现，分数学习能够达到最佳的学习性能，因此选择分数衰减学习率 $\eta_n = \frac{100}{n + 1000}$ 作为学习率方案。

1.4.2 仿真结果

带宽分配最优时，通过仿真得到的训练时间与量化级数 q 的关系如图 4 所示。其中，在每个量化级数上运行相同的训练过程至少 5 次，实线表示多次仿真结果的平均值，阴影表示多次仿真结果的范围。从图 4 可以看出，存在使训练时间最小化的最优量化级数。如 1.2 节所述，训练时间 $T = N_\epsilon T_d$ ，其中 N_ϵ 是 q 的递减函数， T_d 是 q 的递增函数。换言之，图 4 展示了联邦边缘学习系统中总通信轮次 N_ϵ 和每轮时延 T_d 之间的折中关系。此外，从图 4 中可以看出，通过理论优化中得到的最优量化级数与仿真结果一致，同时验证了所提算法的有效性。




图 4 训练时间与 q 的关系

损失函数最优值间隔与训练时间的关系如图 5 所示, 其中 q^* 表示最优的量化级数。首先, 通过求解训练时间最小化问题得到了最优量化级数和最优带宽分配策略。因此, 最优量化级数和最优带宽分配下的训练损失在更短的时间内达到了预定的阈值, 并且能取得最高的测试准确率。其次, 非最优量化级数和最优带宽分配下的训练性能会优于最优量化级数和平均带宽分配的性能, 这同时验证了资源分配的必要性。




图 5 损失函数最优值间隔与训练时间的关系

2 基于重要性感知的最小通信时延用户调度方案

本节描述了一种基于通信时延最小化的高效用户调度方案, 称为 TLM (training latency minimization) 方案。在现有研究中, 文献[39]强调了同时考虑信道质量和数据重要性的必要性, 提出一种调度策略, 即首先选择具有最好信道状态的设备子集, 然后在这些设备中, 基于数据重要性选择一个更小的设备子集上传模型数据。文献[40]提出一种间接方法, 通过设定一个权重系数建立一个基于梯度范数和单轮通信时间的加权和目标函数。该方法能在某些联邦边缘学习场景中取得较好的增益, 但需要理想的权重超参数的设定。文献[41]为了强调数据重要性, 引入了更新年龄 (AoU, age of update) 的概念, 提出了一种联合 AoU 和信道质量的用户调度方案, 高信道质量和 AoU 较大的用户获得较高的优先调度级。文献[42]提出了一种基于时分多址接入的用户选择算法, 采用贪心策略选择时延最小用户, 并最小化单轮训练所需的传输时延, 但该算法没有考虑不同用户计算任务对模型更新影响的重

要度不同。文献[43]引入深度强化学习 (DRL, deep reinforcement learning) 的方法来实现用户调度, 将用户选择问题建模为马尔可夫决策过程 (MDP, Markov decision process), 设计动作空间、状态空间以及奖励函数, 并采用分布式近端策略优化 (DPPO, distributed proximal policy optimization) 算法进行求解。

然而, 上述研究仅考虑了数据重要性和信道质量, 并未揭示数据重要性和通信轮次的联系及信道质量和单轮通信时延的联系。本节通过将数据重要性和通信轮次相联系、信道质量和单轮通信时延相联系, 利用理论模型将两者统一, 建模通信时间最小化优化问题。通过求解该优化问题发现, 最优的调度策略在前期会更多地注重数据重要性, 而在后期更注重信道质量。此外, 本文还将所提的单设备调度算法扩展至多设备调度场景当中。

2.1 系统模型

2.1.1 联邦边缘学习模型

训练过程等价于式(1)中的最小化经验损失函数。不同的是, 这里考虑基于随机调度的概率调度框架。联邦边缘学习用户概率调度框架如图 6 所示, 在整个学习过程中, 学习系统不断重复下述步骤直至全局模型收敛。

全局模型广播。边缘服务器广播当前的全局模型 $w^{(t)}$ 至各个边缘设备。

局部模型训练。每个设备根据其局部数据集和 $w^{(t)}$ 估计局部梯度 $g_k^{(t)}$ 。

随机设备调度。每个设备都被分配了一个特定的被选择概率 $p_k^{(t)}$, 调度器依据概率分布选择出本轮需要上传数据的设备。

局部梯度上传。每个设备将缩放后的局部梯度估计 $\hat{g}_k^{(t)} = \frac{n_k}{np_k^{(t)}} g_k^{(t)}$ 上传至边缘服务器, 其中缩放因子 $\frac{n_k}{np_k^{(t)}}$ 用来保证上传的局部更新是全局梯度的一个无偏估计。

全局模型更新。边缘服务器聚合局部更新 $\hat{g}^{(t)} = \frac{1}{K} \sum_{k=1}^K \hat{g}_k^{(t)}$, 并更新全局模型 $w^{(t+1)} = w^{(t)} - \eta^{(t)} \hat{g}^{(t)}$ 。

2.1.2 多址接入通信模型

采用正交频分多址接入来进行局部更新的上传。假设每个被选择的设备分配一个固定的带宽 B

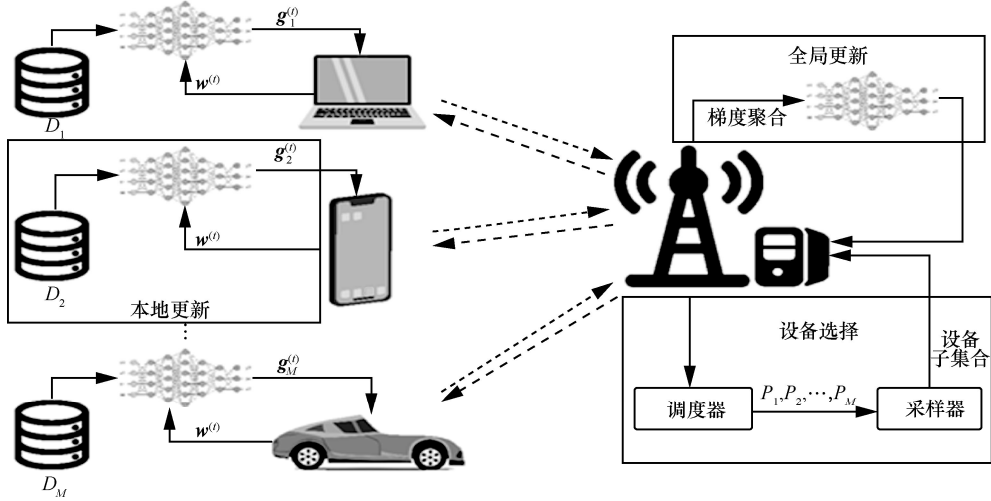


图6 联邦边缘学习用户概率调度框架

来进行数据上传。对于设备 k 而言, 上传时间 $T_{U,k}^{(t)}$ 可表示为

$$T_{U,k}^{(t)} = \frac{\tilde{q}d}{B\text{lb}(1 + \gamma_k^{(t)})} \quad (8)$$

其中, \tilde{q} 为每个模型参数的量化比特数; d 为模型参数数量; $\gamma_k^{(t)} = \frac{p_k^{(t)} |h_k^{(t)}|^2}{N_0}$ 为传输信噪比, $p_k^{(t)}$ 为传输功率, $|h_k^{(t)}|$ 为信道增益。假定信道系数 $\{h_k^{(t)}\}$ 在时间上为独立同分布且服从瑞利分布, 即 $h_k^{(t)} \sim \text{CN}(0, \sigma_k^2)$, 其中 σ_k^2 代表路径损失, 随着设备所处位置的不同而不同。

2.2 用户调度问题建模

概率调度的目的是在每轮的更新过程中最小化仍需的通信时间, 即

$$T^{(t)} = \sum_{i=t}^{N_t} T_C^{(i)} \quad (9)$$

其中, $T^{(t)}$ 和 N_t 分别代表更新 t 轮后仍需的通信时间和通信轮次, $T_C^{(i)} = T_B^{(i)} + T_U^{(i)}$ 代表第 i 轮的通信时间, $T_B^{(i)}$ 和 $T_U^{(i)}$ 分别代表第 i 轮的全局模型广播时间和局部更新上传时间。 $T_B^{(i)}$ 和调度策略无关, 并且与 $T_U^{(i)}$ 相比可以忽略。

由于 N_t 和 $\{T_U^{(i)}\}_{i=t+1}^{N_t}$ 为非因果变量, 直接最小化 $T^{(t)}$ 极具挑战性, 因此利用随机优化当中常用的前瞻模型将最小化 $T^{(t)}$ 的问题转化为

$$\begin{aligned} \text{P2} \quad & \min_{p_1^{(t)}, \dots, p_K^{(t)}} T_U^{(t)} + N_{t+1}^{\mathbb{E}} T_U^{\mathbb{E}} \\ \text{s.t.} \quad & \text{C1: } \sum_{k=1}^K p_k^{(t)} = 1 \end{aligned}$$

其中, $N_{t+1}^{\mathbb{E}}$ 代表经过第 t 轮更新后的期望仍需的通信轮次, $T_U^{\mathbb{E}}$ 代表未来轮次的单轮通信时间。

2.3 最优调度算法设计及分析

以上问题建模和分析不只适用于在单用户调度场景下求解 P2, 也支持将单用户调度结论扩展至多用户调度场景。

通过将 P2 转化为凸优化问题, 可以通过 KKT (Karush-Kuhn-Tucker) 条件求解, 得到原问题的最优解为

$$p_k^{(t)*} = \frac{\alpha_t \frac{n_k}{n} \|\mathbf{g}_k^{(t)}\|}{\sqrt{\frac{\tilde{q}d}{BR_k^{(t)}} + \lambda^*}} \quad (10)$$

其中, α_t 为一个标量因子; λ^* 为满足 $\sum_{k=1}^M p_k^{(t)*} = 1$ 的拉格朗日常数, 可以通过二分搜索法得到。

观察发现, $p_k^{(t)*}$ 由 3 个参数决定, 包括梯度重要性 $\frac{n_k}{n} \|\mathbf{g}_k^{(t)}\|$ 、传输速率 $\frac{1}{\sqrt{\frac{\tilde{q}d}{BR_k^{(t)}} + \lambda^*}}$ 和标量因子 α_t ,

α_t 用于调节前两者之间的比例关系。同时说明, 基于通信时间最小化的调度策略尝试平衡仍需的通信轮次 (梯度重要性相关) 和单轮通信时延 (传输速率相关)。 α_t 随着 t 的增大而不断减小, 由此看出, 所提调度策略在前期更注重梯度重要性, 而随着训练的进行, 即通信轮次 t 的不断增大, 调度概率的分布会更注重设备传输速率。此外, 单设备调度可扩展到多设备调度^[44]。


2.4 仿真实验

2.4.1 仿真设置

本节仿真中采用 CARLA (car learning to act) 仿真平台^[45]生成训练数据集和测试数据集。CARLA 是一个被广泛接受的模拟驾驶的基准系统，它提供了复杂的城市驾驶场景和高质量的三维渲染。利用 CARLA 在虚拟地图“Town02”中布置 32 辆汽车，其中 4 辆汽车为无人驾驶汽车，以每秒 20 帧的速度生成点云数据。虚拟环境鸟瞰图与点云图像如图 7 所示，图 7(a)展示了虚拟环境的鸟瞰图，并标注了 4 辆汽车的位置；图 7(b)展示了生成的点云图像。



(a) 鸟瞰图



(b) 点云图像

图 7 虚拟环境鸟瞰图与点云图像

每辆车生成 700 帧的数据，其中 200 帧用于训练，其余 500 帧用于测试和推断。本文采用稀疏嵌入卷积检测 (SECOND, sparsely embedded convolutional detection) 神经网络^[46]用于三维物体检测。从 CARLA 生成的原始数据按照文献^[47]中的流程

被处理成 KITTI 格式。每轮局部训练随机选择 16 帧，并采用分数衰减学习率。

2.4.2 仿真结果

仿真中将所提 TLM 方案与其他 3 种常见的调度方案进行比较：1) 基于重要性的方案 (IA, importance aware)^[22]，边缘设备的采样概率仅与其梯度重要性有关；2) 基于信道的方案 (CA, channel aware)，边缘设备的采样概率仅与其信道条件成正相关；3) 基于重要性和信道的方案 (ICA, importance and channel aware)^[40]。

图 8(a)和图 8(b)分别显示了通信时间为 6 000 s 和 14 000 s 时的平均精度，其中平均精度通过测量预测值与真实值的联合交叉 (IoU, intersection of union) 得到。从图 8 可以看出，CA 方案在信道衰减最大的 1 号车产生了最差的精度，而 IA 方案在数据不太重要的 4 号车展现了最差的精度。ICA 方案的目的是在 CA 和 IA 之间找到一个平衡点，但由于其启发式的性质，性能低于 TLM 方案。




图 8 不同训练时期的测试准确率

3 未来研究方向展望

本文通过对联邦边缘学习中资源分配和用户

调度 2 个资源管理策略方向的研究，深刻剖析了以任务导向的联邦边缘学习设计新范式。接下来，将介绍 2 个具备发展前景的潜在研究方向。

3.1 无线空中计算赋能联邦边缘学习

在联邦边缘学习场景下，若终端设备数目很大并且训练迭代次数很多时，“先通信再计算”的设计策略将会受限于网络中的无线资源，难以突破通信瓶颈。而利用无线空中计算技术^[48-49]进行高效的模型参数传输聚合，即空中联邦边缘学习(Air-FEEL, over-the-air federated edge learning)，成为解决上述联邦学习通信瓶颈的一个研究热门。无线空中计算赋能边缘联邦学习的场景如图 9 所示。

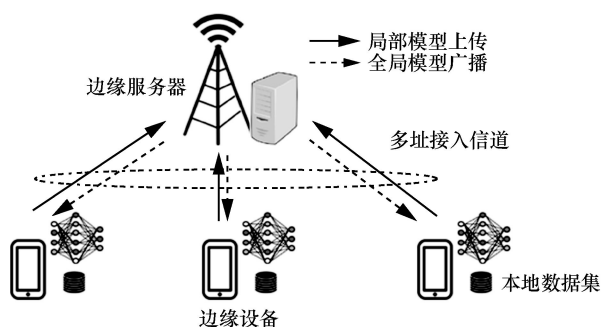


图 9 无线空中计算赋能边缘联邦学习的场景

与传统多址接入方式对多用户数据单独解码、通信计算分离设计不同，空中联邦边缘学习可以利用无线通道的波形叠加特性，一次性对训练梯度/模型在空中进行聚合运算，从而保证极低的聚合时延以及实现隐私保护，且与网络规模无关。这种设计可以有效降低分布式训练过程中的通信开销和时延，提高联邦边缘学习训练效率。例如，文献[50]结合用户筛选和接收端波束成形设计，在满足计算均方误差要求的情况下，最大化参与联邦学习的终端设备数目，以提高模型训练的性能。文献[19]针对一个宽带正交频分多址接入系统提出一种截断功率控制方法，排除深度衰落信道的终端设备，在学习性能和聚合误差之间取得良好的折中。

3.2 通信感知一体化赋能联邦边缘学习

通信感知一体化 (ISAC, integrated sensing and communication) 被业界普遍认为是未来 6G 网络中的关键接口技术和重点业务场景之一^[4]。ISAC 是指基于软硬件资源共享或信息共享，同时实现感知与通信功能协同的新型信息处理技术，有效提升系统频谱效率、硬件效率和信息处理效率^[51]。通过与 ISAC 的结合来释放联邦边缘学习的全部潜力具有

十分重大的应用前景。通信感知一体化赋能联邦边缘学习的场景如图 10 所示。

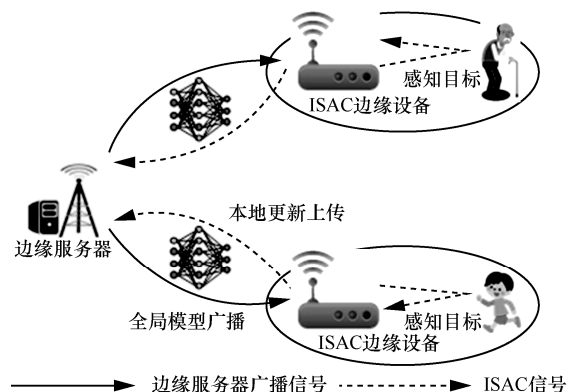


图 10 通信感知一体化赋能联邦边缘学习的场景

分布式无线 ISAC 边缘设备可以产生大量感知数据，这些数据需要通过人工智能算法进行快速准确的处理（也可能与来自其他传感器，如相机和激光雷达的传感数据共同处理），以支持具有超低时延“传感-通信-计算-控制”要求的业务。因此，联邦边缘学习可以成为一个非常有效的解决方案，其中分布式 ISAC 边缘设备可以用无线传输的方式交换它们在本地图训的人工智能模型，分布式更新所需的全局人工智能模型，同时保护每个设备的数据隐私。联邦边缘学习与 ISAC 的结合将带来大量潜在机遇。

4 结束语

本文概述了联邦边缘学习基本概念、典型应用场景及其在无线资源管理中的关键问题。然后，结合前期研究积累，以联邦边缘学习中带宽资源分配和用户调度策略为典型的资源管理案例，深入阐述基于任务导向的设计范式思想。最后，对联邦边缘学习的未来潜在研究方向进行了展望。

参考文献：

- [1] IMT-2030(6G)推进组. 6G 总体愿景与潜在关键技术白皮书[R]. 2021. IMT-2030 (6G) Promotion Group. White paper on 6G overall vision and potential key technology[R]. 2021.
- [2] 张平, 牛凯, 田辉, 等. 6G 移动通信技术展望[J]. 通信学报, 2019, 40(1): 141-148. ZHANG P, NIU K, TIAN H, et al. Technology prospect of 6G mobile communications[J]. Journal on Communications, 2019, 40(1): 141-148.
- [3] LETAIEF K B, CHEN W, SHI Y, et al. The roadmap to 6G: AI empowered wireless networks[J]. IEEE Communication Magazine, 2019, 57(8): 84-90.
- [4] WANG Z Q, DU Y, WEI K J, et al. Vision, application scenarios, and key technology trends for 6G mobile communications[J]. Science China Information Sciences, 2022, 65(5): 1-27.

- [5] ZHU G X, LIU D Z, DU Y Q, et al. Toward an intelligent edge: wireless communication meets machine learning[J]. *IEEE Communications Magazine*, 2020, 58(1): 19-25.
- [6] LI E, ZENG L, ZHOU Z, et al. Edge AI: On-demand accelerating deep neural network inference via edge computing[J]. *IEEE Transaction on Wireless Communication*, 2020, 19(1): 447-457.
- [7] ZHU G X, XU J, HUANG K B, et al. Over-the-air computing for wireless data aggregation in massive IoT[J]. *IEEE Wireless Communications*, 2021, 28(4): 57-65.
- [8] KONECNY J, MCMAHAN H B, YU F X, et al. Federated learning: strategies for improving communication efficiency[J]. *arXiv Preprint*, arXiv: 1610.05492, 2016.
- [9] YANG Q, LIU Y, CHEN T, et al. Federated machine learning: concept and applications[J]. *ACM Transaction on Intelligent Systems*, 2019, 10(2): 1-19.
- [10] CHEN M, YANG Z, SAAD W, et al. A joint learning and communications framework for federated learning over wireless networks[J]. *IEEE Transactions on Wireless Communications*, 2020, 20(1): 269-283.
- [11] DAYAN I, ROTH H R, ZHONG A X, et al. Federated learning for predicting clinical outcomes in patients with COVID-19[J]. *Nature Medicine*, 2021, 27(10): 1735-1743.
- [12] SAVAZZI S, NICOLI M, BENNIS M, et al. Opportunities of federated learning in connected, cooperative, and automated industrial systems[J]. *IEEE Communications Magazine*, 2021, 59(2): 16-21.
- [13] MILLS J, HU J, MIN G Y. Communication-efficient federated learning for wireless edge intelligence in IoT[J]. *IEEE Internet of Things Journal*, 2020, 7(7): 5986-5994.
- [14] LAN Q, WEN D Z, ZHANG Z Z, et al. What is semantic communication? A view on conveying meaning in the era of machine intelligence[J]. *arXiv Preprint*, arXiv: 2110.00196, 2021.
- [15] TSE D, VISWANATH P. *Fundamentals of wireless communication*[M]. Cambridge: Cambridge University Press, 2005.
- [16] SHEN C, XU J, ZHENG S H, et al. Resource rationing for wireless federated learning: concept, benefits, and challenges[J]. *IEEE Communications Magazine*, 2021, 59(5): 82-87.
- [17] CHEN M Z, YANG Z H, SAAD W, et al. A joint learning and communications framework for federated learning over wireless networks[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(1): 269-283.
- [18] WANG Y M, XU Y Q, SHI Q J, et al. Quantized federated learning under transmission delay and outage constraints[J]. *IEEE Journal on Selected Areas in Communications*, 2022, 40(1): 323-341.
- [19] ZHU G X, WANG Y, HUANG K B. Broadband analog aggregation for low-latency federated edge learning[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(1): 491-506.
- [20] LUO R Y, TIAN H, NI W L. Communication-aware path design for indoor robots exploiting federated deep reinforcement learning[C]//*Proceedings of 2021 IEEE 32nd Annual International Symposium on Personal, Indoor and Mobile Radio Communications*. Piscataway: IEEE Press, 2021: 1197-1202.
- [21] WAN S, LU J X, FAN P Y, et al. Convergence analysis and system design for federated learning over wireless networks[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(12): 3622-3639.
- [22] CHEN M Z, POOR H V, SAAD W, et al. Convergence time optimization for federated learning over wireless networks[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(4): 2457-2471.
- [23] REN J Y, SUN J S, TIAN H, et al. Joint resource allocation for efficient federated learning in Internet of Things supported by edge computing[C]//*Proceedings of 2021 IEEE International Conference on Communications Workshops*. Piscataway: IEEE Press, 2021: 1-6.
- [24] MCMAHAN B, MOORE E, RAMAGE D, et al. *Communication-efficient learning of deep networks from decentralized data*[C]//*Artificial Intelligence and Statistics*. New York: PMLR, 2017: 1273-1282.
- [25] YANG H H, LIU Z Z, QUEK T Q S, et al. Scheduling policies for federated learning in wireless networks[J]. *IEEE Transactions on Communications*, 2020, 68(1): 317-333.
- [26] TAIK A, MLIKA Z, CHERKAoui S. Data-aware device scheduling for federated edge learning[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2022, 8(1): 408-421.
- [27] WANG S Q, TUOR T, SALONIDIS T, et al. Adaptive federated learning in resource constrained edge computing systems[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(6): 1205-1221.
- [28] RIZK E, VLASKI S, SAYED A H. Optimal importance sampling for federated learning[C]//*Proceedings of 2021 IEEE International Conference on Acoustics, Speech and Signal Processing*. Piscataway: IEEE Press, 2021: 3095-3099.
- [29] AMIRI M M, GÜNDÜZ D. Federated learning over wireless fading channels[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(5): 3546-3557.
- [30] KONECNY J, MCMAHAN H B, YU F X, et al. Federated learning: strategies for improving communication and efficiency[J]. *arXiv Preprint*, arXiv: 1610.05492, 2016.
- [31] AMIRI M M, GUNDUZ D, KULKARNI S R, et al. Federated learning with quantized global model updates[J]. *arXiv Preprint*, arXiv: 2006.10672, 2020.
- [32] NORI M K, YUN S, KIM I M. Fast federated learning by balancing communication trade-offs[J]. *IEEE Transactions on Communications*, 2021, 69(8): 5168-5182.
- [33] 唐伦, 汪智平, 蒲昊, 等. 基于自适应梯度压缩的高效联邦学习通信机制研究[J]. *电子与信息学报*, 2022: doi.org/10.11999/JEIT211262.
- TANG L, WANG Z P, PU H, et al. Research on efficient federated learning communication mechanism based on adaptive gradient compression[J]. *Journal of Electronics & Information Technology*, 2022: doi.org/10.11999/JEIT211262.
- [34] BOUZINIS P S, DIAMANTOULAKIS P D, KARAGIANNIDIS G K. Wireless quantized federated learning: a joint computation and communication design[J]. *arXiv Preprint*, arXiv: 2203.05878, 2022.
- [35] ZHU G X, DU Y Q, GÜNDÜZ D, et al. One-bit over-the-air aggregation for communication-efficient federated edge learning: design and convergence analysis[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(3): 2120-2135.
- [36] ALISTARH D, GRUBIC D, LI J, et al. QSGD: communication-efficient SGD via gradient quantization and encoding[C]//*Advances in Neural Information Process. Systems*. Massachusetts: MIT Press, 2017: 1707-1718.
- [37] LIU P X, JIANG J M, ZHU G X, et al. Training time minimization for federated edge learning with optimized gradient quantization and bandwidth allocation[J]. *arXiv Preprint*, arXiv: 2112.14387, 2021.
- [38] RAZAVIYAYN M. *Successive convex approximation: analysis and applications*[D]. TwenCities: University of Minnesota, 2014.
- [39] AMIRI M M, GÜNDÜZ D, KULKARNI S R, et al. Convergence of update aware device scheduling for federated learning at the wireless edge[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(6): 3643-3658.
- [40] REN J K, HE Y H, WEN D Z, et al. Scheduling for cellular federated edge learning with importance and channel awareness[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(11): 7690-7703.

- [41] YANG H H, ARAFA A, QUEK T Q S, et al. Age-based scheduling policy for federated learning in mobile edge networks[C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2020: 8743-8747.
- [42] NISHIO T, YONETANI R. Client selection for federated learning with heterogeneous resources in mobile edge[C]//Proceedings of 2019 IEEE International Conference on Communications. Piscataway: IEEE Press, 2019: 1-7.
- [43] 贺文晨, 郭少勇, 邱雪松, 等. 基于 DRL 的联邦学习节点选择方法[J]. 通信学报, 2021, 42(6): 62-71.
HE W, GUO S, QIU X, et al. Node selection method in federated learning based on deep reinforcement learning[J]. Journal on Communications, 2021, 42(6): 62-71.
- [44] ZHANG M J, ZHU G X, WANG S, et al. Accelerating federated edge learning via optimized probabilistic device scheduling[C]//Proceedings of 2021 IEEE 22nd International Workshop on Signal Processing Advances in Wireless Communications. Piscataway: IEEE Press, 2021: 606-610.
- [45] DOSOVITSKIY A, ROS G, CODEVILLA F, et al. CARLA: an open urban driving simulator[J]. arXiv Preprint, arXiv: 1711.03938, 2017.
- [46] YAN Y, MAO Y X, LI B. SECOND: sparsely embedded convolutional detection[J]. Sensors, 2018, 18(10): 3337.
- [47] ZHANG Z J, WANG S, HONG Y C, et al. Distributed dynamic map fusion via federated learning for intelligent networked vehicles[C]//Proceedings of 2021 IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2021: 953-959.
- [48] ABARI O, RAHUL H, KATABI D. Over-the-air function computation in sensor networks[J]. arXiv Preprint, arXiv:1612. 02307, 2016.
- [49] JEON S, WANG C, GASTPAR M. Computation over Gaussian networks with orthogonal components [J]. IEEE Transaction on Information Theory, 2014, 60(12):7841-7861.
- [50] YANG K, JIANG T, SHI Y M, et al. Federated learning via over-the-air computation[J]. IEEE Transactions on Wireless Communications, 2020, 19(3): 2022-2035.
- [51] IMT-2030 (6G) 推进组. 通信感知一体化技术研究报告[R]. 2021. IMT-2030 (6G) Promotion Group. Research report on integrated sensing and communications technology [R]. 2021.

[作者简介]



王志勤 (1970-)，女，北京人，博士，中国信息通信研究院教授级高级工程师，主要研究方向为无线移动通信技术和标准。



江甲沫 (1985-)，男，吉林长春人，博士，中国信息通信研究院高级工程师，主要研究方向为面向 6G 的无线人工智能、通信感知一体化技术。



刘沛西 (1991-)，男，湖北仙桃人，北京大学博士生，主要研究方向为面向 6G 的无线人工智能技术。



曹晓雯 (1995-)，女，广东河源人，广东工业大学博士生，主要研究方向为面向 6G 的无线人工智能、无线空中计算技术。




李阳 (1993-)，男，河南濮阳人，中国信息通信研究院助理工程师，主要研究方向为新一代移动通信与人工智能结合技术。



韩凯峰 (1993-)，男，北京人，博士，中国信息通信研究院高级工程师，主要研究方向为面向 6G 的无线人工智能、通信感知一体化技术。



杜滢 (1978-)，女，山东菏泽人，中国信息通信研究院教授级高级工程师，主要研究方向为无线移动通信技术和标准。



朱光旭 (1989-)，男，广东广州人，博士，深圳市大数据研究院研究员，主要研究方向为面向 6G 的无线人工智能技术。