

面向协同感知的高效通信边缘学习网络架构设计



Communication-Efficient Edge Learning Architecture Designs for Cooperative Sensing

张泽中/ZHANG Zezhong¹, 刘沛西/LIU Peixi²,
朱光旭/ZHU Guangxu³

(1. 香港中文大学(深圳), 中国 深圳 518172;

2. 北京大学电子学院, 中国 北京 100871;

3. 深圳市大数据研究院, 中国 深圳 518172)

(1. The Chinese University of Hong Kong (Shenzhen), Shenzhen 518172, China;

2. School of Electronics, Peking University, Beijing 100871, China;

3. Shenzhen Institute of Big Data, Shenzhen 518172, China)

DOI: 10.12142/ZTETJ.202205007

网络出版地址: <https://kns.cnki.net/kcms/detail/34.1228.TN.20221025.1321.002.html>

网络出版日期: 2022-10-25

收稿日期: 2022-08-12

摘要: 针对多场景多设备与单场景多视角两类代表性的协作感知场景, 提出了针对性的基于联邦学习的协作感知学习框架, 并针对在无线通信场景下, 通信与感知资源有限以及信道随机性等挑战, 提出了相对应的资源分配方案与用户调度策略。保证了提出的学习算法能够在无线网络下实现高质量且稳定的协同感知, 并通过仿真验证并分析了算法的正确性与有效性。

关键词: 通信感知一体化; 联邦学习; 资源分配; 用户调度

Abstract: Two typical cooperative sensing scenarios, including multiple-scene-multiple-device and single-scene-multiple-view are considered, and specific federated learning architectures for the two cooperative sensing scenarios are proposed. Moreover, under the situation where the communication and sensing resources are limited and the channel conditions are stochastic, a resource allocation scheme and a user scheduling policy for the two learning architectures are respectively proposed. It shows that the proposed algorithms can guarantee high-quality and robust cooperative sensing, and verify the effectiveness of the algorithms through simulations.

Keywords: integrated sensing and communication; federated learning; resource allocation; user scheduling

近年来, 随着无线通信与互联网技术的蓬勃发展, 远程医疗、智能驾驶、智慧城市等新兴技术不断涌现并逐步融入日常生活^[1-2]。这些新兴技术都需要稳健且高精度的感知能力, 并依赖于快速且稳定的无线通信技术。因此, 研究以高效感知为目标的新型无线通信技术以及通信感知一体化技术, 对实现对6G网络下各类新兴应用的技术支撑具有重要的意义^[3]。

随着边缘计算与物联网技术的兴起, 各类新兴应用呈现出个人化、社区化的特征, 生成的数据也呈现出边缘化与分布式的特征, 这也使得数据的聚集与统一化处理变得难以实现。一方面, 单个设备或单个视角收集到的数据受到周围特定环境影响, 可靠性较低, 因此需要联合多个设备收集到的数据进行协作处理, 以实现高精度的可靠的智能感知; 另一

方面, 应用数量与使用频率的急剧增长, 使得分布在网络边缘的数据量大幅增加, 并且由于数据隐私受到越来越广泛的关注, 数据的收集与分享变得越发困难。考虑到上述挑战, 现阶段亟需开发在不影响数据隐私的前提下, 能够实现高效智能感知的分布式算法。作为边缘智能中的一类重要学习范式, 联邦学习旨在不涉及原始数据转移的情况下实现多设备间的协作训练^[4], 因此将联邦学习范式用于协作感知任务是当前热门的研究方向之一。由于不同场景下数据的分布情况不同, 因此我们需要设计针对性的联邦学习架构以匹配相应的数据分布情况。本工作中, 我们考虑的是多场景多设备与单场景多视角两类代表性的场景, 它们分别对应以下两种典型的数据分布情况^[5]。

(1) 数据横向分布: 不同设备中的数据处于相同特征空间, 但区别于样本空间;

(2) 数据纵向分布: 不同设备中的数据处于相同的样本

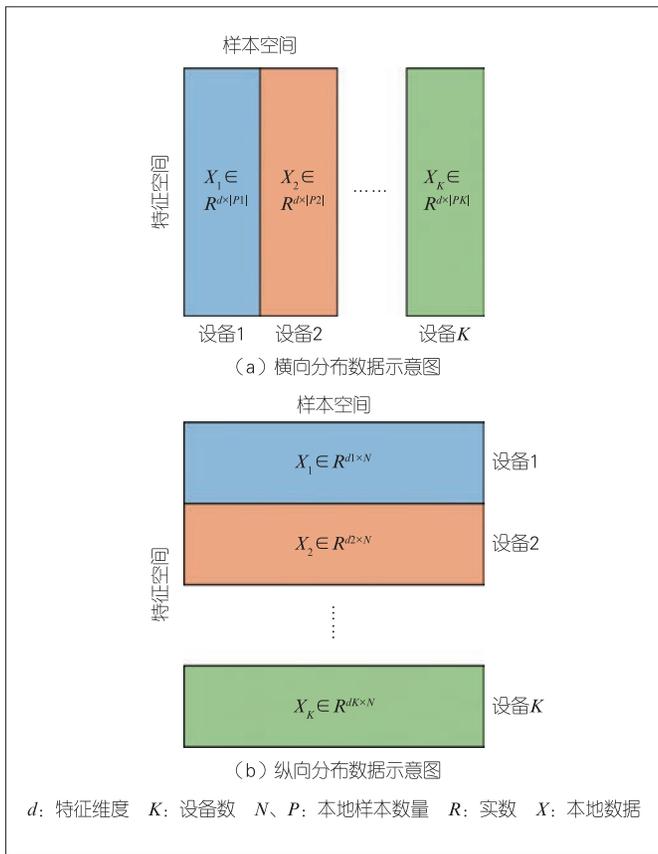
基金项目: 国家自然科学基金(62001310); 广东省基础与应用基础研究基金(2022A1515010109)

空间，但区别于特征空间。

针对以上两类场景，我们分别采用对应的横向联邦学习与纵向联邦学习架构，以联合边缘设备进行模型训练，从而实现基于学习模型的智能感知。考虑到无线网络下通信与感知往往都依赖于无线信号的收发，而时频资源有限，因此需要对系统中的通信、感知、计算资源进行联合优化，达成合理的资源分配，以实现高质量感知。同时，由于信道状态具有不确定性，少数信道衰落严重的链路会导致单个通信回合时延过大，因此需要结合适当的用户调度策略以降低模型训练的时延，实现快速准确的感知。在本工作中，针对上述挑战，我们分别设计了相应的资源分配方案与用户调度策略，并通过具体的分析与仿真验证了算法的正确性与有效性。

1 横向协作感知

针对多个设备分布于不同场景且采集的数据处于相同特征空间的情况，如图 1 (a) 所示，我们考虑基于无线反射信号的动作识别感知任务，采用横向联邦学习架构，并设计了相应的通感算资源分配策略。



▲图 1 两类典型的数据分布示意图

1.1 系统模型及性能指标

1.1.1 横向联邦学习架构

横向联邦学习架构利用横向分布数据联合训练一个设备间通用的模型 w ，其需要最小化的目标函数为：

$$F(w) = \frac{1}{K} \sum_{k \in \mathcal{K}} \mathbb{E}_{\xi \sim \xi_k} [f_k(w; \xi)] \tag{1}$$

其中， $f_k(w; \xi)$ 为设备 k 对应的本地损失函数； ξ 代表随机种子，体现为批量数据的随机选取。

联邦学习的循环训练过程包含多个通信回合，其中每个回合 r 由 5 个步骤构成，如图 2 所示。

(1) 模型转发：各设备从服务器端下载模型 $w^{(r)}$ 。

(2) 数据感知：各设备切换至感知模式，发送调频连续波信号，用于周围环境感知。收集到的数据表示为 $\{(x_i, y_i)\}_{i \in \mathcal{D}_k^{(r)}}$ ，包含 $b^{(r)} = |\mathcal{D}_k^{(r)}|$ 个样本。当前回合收集到的数据将用于步骤 (3)。

(3) 本地模型更新：各设备基于本地数据集，并采用随机梯度下降法来更新本地模型 $w^{(r)}$ ：

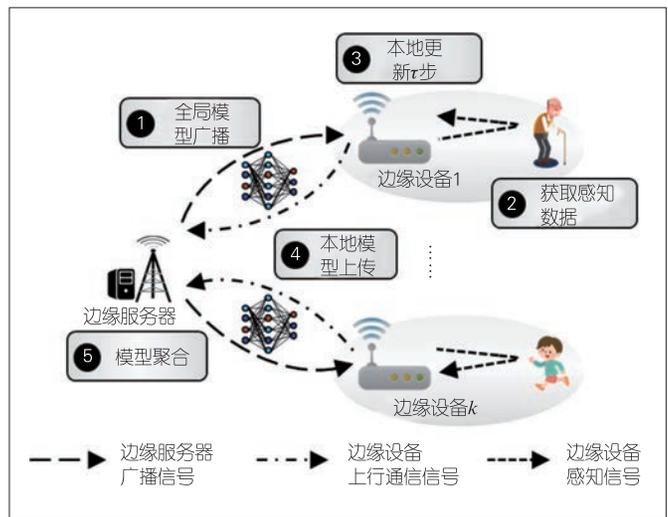
$$w_k^{(r,0)} = w^{(r)},$$

$$w_k^{(r,\ell+1)} = w_k^{(r,\ell)} - \eta g_k(w_k^{(r,\ell)}), \ell = 0, 1, \dots, r-1, \forall k, \tag{2}$$

其中， η 为学习率； $g_k(w_k^{(r,\ell)}) = \frac{1}{b^{(r)}} \sum_{i \in \mathcal{D}_k^{(r)}} \nabla f(w_k^{(r,\ell)}; x_i, y_i)$ 为随机梯度。

(4) 本地模型上传：各设备上模型 $w^{(r,\ell)}$ 至服务器。

(5) 模型聚合：服务器端接收到所有设备发送的模型信息后，将所有本地模型进行求平均处理得到更新后的全局模型：



▲图 2 基于调频连续波信号回波的动作感知任务示意图

$$\mathbf{w}^{(r+1)} = \frac{1}{K} \sum_{k \in \mathcal{K}} \mathbf{w}_k^{(r,\tau)} \quad (3)$$

1.1.2 无线通信模型

假设各设备采用不同频段的子载波进行通信，相互间不存在干扰，则设备 k 在时刻 t 发出的信号在服务器端的接收形式为：

$$y_{c,k}(t) = \sqrt{p_{c,k}(t)} h_k(t) c_k(t) + n_k(t), \quad (4)$$

其中， $h_k(t) \in \mathbb{C}$ 为设备 k 到服务器端的信道系数， $p_{c,k}(t)$ 是通信发射功率， $c_k(t)$ 为传输信号， $n_k(t)$ 为加性高斯噪声。由于传输模型到服务器端的时间往往比信道相干时间长得多，我们假设设备到服务器端的信道为快速瑞利衰落信道，且信道系数可表示为 $h_k = \sqrt{\phi_k} \bar{h}_k$ ，其中 ϕ_k 表示大尺度衰落系数， $\bar{h}_k \in \mathcal{CN}(0,1)$ 为小尺度衰落系数。基于以上事实，我们采用遍历信道容量来刻画设备 k 到服务器端的传输速率：

$$C_k(p_{c,k}) = \mathbb{E}_{h_k} \left[B_0 \log_2 \left(1 + \frac{p_{c,k} |h_k|^2}{B_0 N_0} \right) \right] \quad (5)$$

1.1.3 感知模型

本工作中，我们考虑基于调频连续波信号回波的动作感知任务，具体场景如图2所示。设备 k 的调频连续波信号为 $s_k(t)$ ，所占带宽为 B_s ，且每个调频脉冲时间长度为 T_p ，如图3所示。假设人体由 B 个可分辨的身体部位所组成。经由路径 p 的发射信号被 B 个身体分割部位反射后，到达设备接收端。该接收信号的表示如公式(6)：

$$y_{s,k,p}(t) = \sqrt{p_{s,k}(t)} \times \underbrace{\frac{A}{\sqrt{4\pi}} \sum_{b=1}^B \frac{\sqrt{G_{k,b,p}(t)}}{r_{k,b,p}^2(t)} \exp\left(-j \frac{4\pi f_c r_{k,b,p}(t)}{c}\right)}_{\triangleq \bar{y}_{s,k,p}(t)} s_k\left(t - \frac{2r_{k,b,p}(t)}{c}\right) \quad (6)$$

其中， $p_{s,k}(t)$ 为感知信号功率， A 为与天线增益相关的系数， $G_{k,b,p}(t)$ 是与雷达横截面正相关的复系数， $r_{k,b,p}(t)$ 是身体分割部位 b 由路径 p 到接收机的信号传播距离， $c = 3 \times 10^8 \text{ m/s}$ 为光速。设备 k 接收到的感知信号则可表示为：

$$y_{s,k}(t) = \sum_{p=1}^P \sqrt{p_{s,k}(t)} \bar{y}_{s,k,p}(t) + e_k(t) = \sqrt{p_{s,k}(t)} \bar{y}_{s,k,1}(t) + \sqrt{p_{s,k}(t)} \bar{y}_{s,k,-1}(t) + e_k(t), \quad (7)$$

其中， $\bar{y}_{s,k,1}(t)$ 是沿一阶反射路径的散射信号的归一化表示， $\bar{y}_{s,k,-1}(t) \triangleq \sum_{p=2}^P \bar{y}_{s,k,p}(t)$ 为沿更高阶反射路径的散射信号的归一化表示， $e(t)$ 为由于地面反射波和接收端噪声而产生的加性高斯项。

1.2 通信与感知性能分析

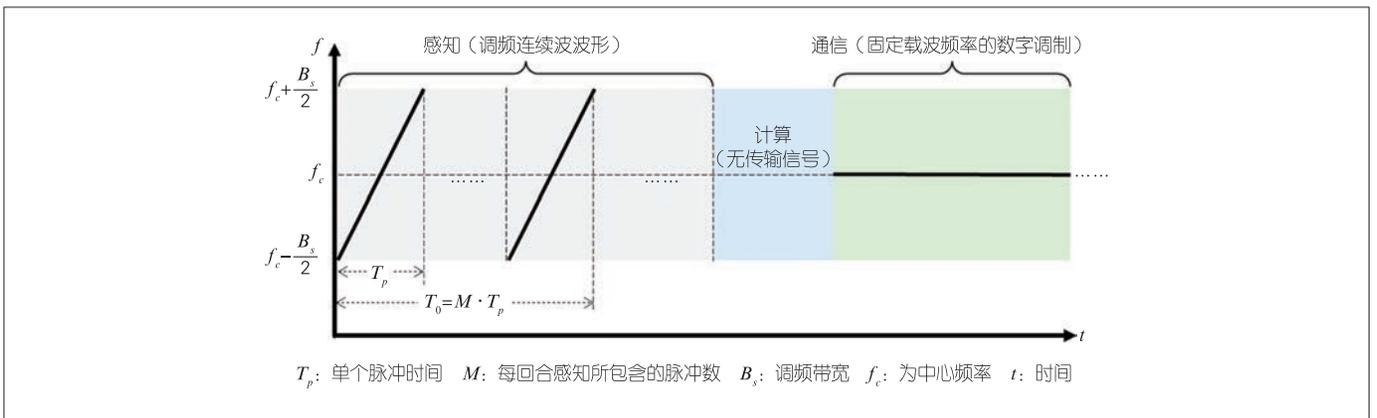
1.2.1 通信速率分析

根据文献[6]中的相关引理，公式(2)中的遍历信道容量可进一步表示为：

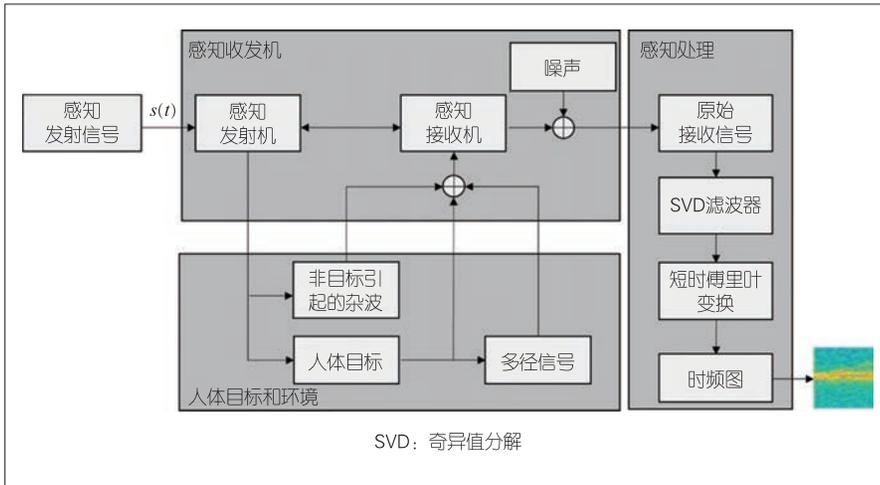
$$C_k(p_{c,k}) = -\frac{B_0}{\ln 2} e^{\frac{B_0 N_0}{p_{c,k} \phi_k}} \text{Ei} \left(-\frac{B_0 N_0}{p_{c,k} \phi_k} \right) \quad (8)$$

1.2.2 感知质量分析

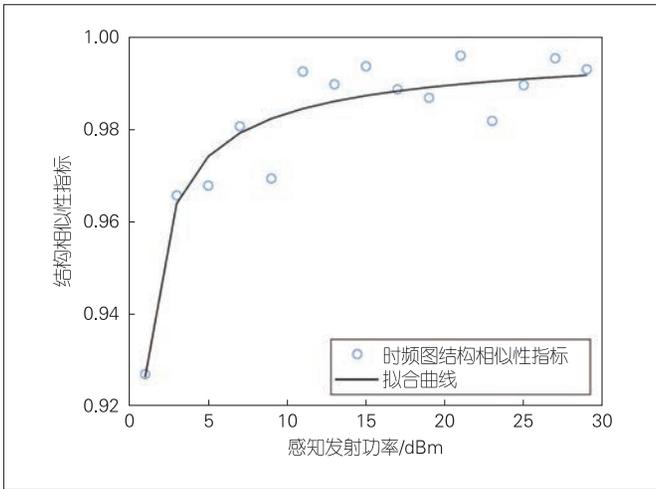
在基于调频连续波信号回波的动作感知任务中，动作特征可以由回波信号的微多普勒特性来刻画。为获取回波信号的微多普勒信息，我们对一段时间 T_0 内包含 M 个脉冲的回波信号进行数据处理以获得其时频谱，具体过程如图4所示。依据文献[7]中的分析，时频谱的质量随着感知信号的功率增加而提升。同时，当感知信号功率远高于地面反射波和噪声功率时，时频谱质量趋于饱和。该现象可以由图5中的



▲图3 通信感知一体化波形在单个通信回合内的时频特征示意图



▲图4 利用无线信号实现人体动作感知流程示意图



▲图5 时频谱质量与感知信号发射功率关系示意图

实验结果来验证。因此，我们可以为感知信号的发射功率设置一个阈值 $P_{s,k}^{\min}$ ，当 $p_{s,k} \geq P_{s,k}^{\min}$ 时，我们认为设备 k 可以获取高质量的感知数据。

1.3 问题建模

在本工作中，我们关注在时延、能耗与功率峰值约束的情况下，以加速感知模型训练过程为目标的系统整体资源配置优化问题。

1.3.1 时延约束

(1) 感知时间

假设每个通信回合需要生成 $b^{(r)}$ 个数据样本，则感知所需时间为：

$$T_{s,k}^{(r)} = T_0 \cdot b^{(r)} \quad (9)$$

(2) 本地计算时间

令 ν 表示在单个通信回合中处理一个数据样本时中央处理器（CPU）所需的循环次数，则设备 k 在通信回合 r 所需的本地计算时间为：

$$T_{cp,k}^{(r)} = \frac{b^{(r)} \nu \tau}{f_{cpu}} \quad (10)$$

其中， f_{cpu} 为每个设备的CPU频率。

(3) 本地模型上传时间

由于模型大小固定，各设备在每个回合须上传的比特数也是固定的，因此上传时间满足公式（11）约束即可保证模型成功上传：

$$(C1) T_{cm,k} C_k(p_{c,k}) \geq D_b, \forall k \in \mathcal{K} \quad (11)$$

其中， $C_k(p_{c,k})$ 是公式（5）中的遍历信道容量。

考虑各设备均同步上传梯度的情况，那么第 r 个通信回合的延迟为：

$$T^{(r)} = \max_{k \in \mathcal{K}} \{T_{s,k}^{(r)} + T_{cp,k}^{(r)} + T_{cm,k}^{(r)}\} \quad (12)$$

我们对整个训练过程的时延也设置了上限 T^{\max} 进行约束：

$$(C2) \sum_{r=1}^R T^{(r)} \leq T^{\max} \quad (13)$$

1.3.2 能耗约束

(1) 感知能耗

设备 k 在通信回合 r 的感知能耗为：

$$E_{s,k}^{(r)} = T_{cp,k}^{(r)} p_{s,k} = T_0 b^{(r)} p_{s,k} \quad (14)$$

(2) 本地计算能耗

依据文献[8]，本地计算能耗为：

$$E_{cp,k}^{(r)} = \tau \theta \nu f_{cpu}^2 b^{(r)} \quad (15)$$

其中， θ 代表有效切换电容，为固定值。

(3) 模型上传能耗

设备 k 在通信回合 r 的模型上传能耗为：

$$E_{cm,k}^{(r)} = T_{cm,k} p_{c,k} \quad (16)$$

我们也为训练过程中的整体能耗设置了上限 E^{\max} 以进行约束：

$$(C3) \sum_{r=1}^R (E_{s,k}^{(r)} + E_{cp,k}^{(r)} + E_{cm,k}^{(r)}) \leq E^{\max}, \forall k \in \mathcal{K} \quad (17)$$

1.3.3 功率峰值约束

用于通信的传输功率峰值约束为:

$$(C4) \quad 0 \leq p_{c,k} \leq P_{c,k}^{\max}, \quad \forall k \in \mathcal{K}. \quad (18)$$

基于1.2.2节中的分析,用于感知的功率峰值约束为:

$$(C5) \quad P_{s,k}^{\min} \leq p_{s,k} \leq P_{s,k}^{\max}, \quad \forall k \in \mathcal{K}. \quad (19)$$

1.3.4 优化问题建模

依据上述约束条件,我们建模以下优化问题以加速训练过程:

$$(P1) \quad \min_{\{b^{(r)}\}, \{p_{c,k}\}, \{p_{s,k}\}, \{T_{cm,k}\}} \min_{r \in \{1,2,\dots,R\}} F(\mathbf{w}^{(r)})$$

$$\text{s.t. (C1)—(C5)}, \quad (20)$$

其中,需优化的参数包括感知与通信的功率配置、感知样本数量,以及模型上传时间。下文中,我们介绍基于文献[7]的一种解法。

1.4 通感算资源联合优化

文献[7]首先将原优化问题进行拆解,引入变量 $b_{\text{sum}} = \sum_{r=1}^R b^{(r)}$, 并给出相关约束:

$$b_{\text{sum}} (T_0 p_{s,k} + \tau \theta \nu f_{\text{cpu}}^2) + RT_{cm,k} p_{c,k} \leq E^{\max}, \quad \forall k \in \mathcal{K}. \quad (21)$$

一方面,由于 $p_{s,k}$ 仅与公式(21)及(C5)相关,我们可得最优感知功率 $p_{s,k}^* = P_{s,k}^{\min}$ 。另一方面,通过变换,求解最优通信发射功率的问题可转化为如下的优化问题:

$$p_{c,k}^* = \arg \max_{p_{c,k}} \Phi_k(p_{c,k}), \quad \forall k \in \mathcal{K}, \quad (22)$$

其中,

$$\Phi_k(p_{c,k}) \triangleq \min \left\{ \frac{T^{\max} - \frac{RD_b}{C_k(p_{c,k})}}{T_0 + \frac{\nu\tau}{f_{\text{cpu}}}}, \frac{E^{\max} - \frac{Rp_{c,k}D_b}{C_k(p_{c,k})}}{T_0 P_{s,k}^{\min} + \tau \theta \nu f_{\text{cpu}}^2} \right\}. \quad (23)$$

考虑到该问题是一维优化问题,复杂度较低,因此我们直接采取网格搜索方法在 $[0, P_{c,k}^{\max}]$ 范围内寻找最优解。另外,最优的模型上传时间为:

$$T_{cm,k}^* = \frac{D_b}{C_k(p_{c,k}^*)}, \quad \forall k \in \mathcal{K}. \quad (24)$$

最后,为优化感知样本数量 $b^{(r)}$,文献[7]给出如下引理:当学习率满足 $\eta L + \eta^2 L^2 \tau (\tau - 1) \leq 1$ 时,经历 R 个通信回合后,损失函数对应的梯度满足

$$\mathbb{E} \left[\frac{1}{\tau R} \sum_{r=1}^R \sum_{\ell=1}^{\tau} \left\| \nabla F(\bar{\mathbf{w}}^{(r,\ell)}) \right\|^2 \right] \leq$$

$$\frac{2(F(\mathbf{w}^{(1)}) - F_{\text{inf}})}{\eta R \tau} + \frac{\eta L \sigma^2}{Kb} + \frac{\eta^2 L^2 \sigma^2 \tau}{b}, \quad (25)$$

其中, $\bar{\mathbf{w}}^{(r,\ell)} = \frac{1}{K} \sum_{k \in \mathcal{K}} \mathbf{w}_k^{(r,\ell)}$, 我们进一步假设 $b'_{\text{sum}} = bR'$, 则可得:

$$\mathbb{E} \left[\frac{1}{\tau R'} \sum_{r=1}^{R'} \sum_{\ell=1}^{\tau} \left\| \nabla F(\bar{\mathbf{w}}^{(r,\ell)}) \right\|^2 \right] \leq$$

$$\frac{2(F(\mathbf{w}^{(1)}) - F_{\text{inf}})b}{\eta \tau b'_{\text{sum}}} + \frac{\eta L \sigma^2}{Kb} + \frac{\eta^2 L^2 \sigma^2 \tau}{b}. \quad (26)$$

由公式(26)可得,当处于第1回合前与第 r 回合前时,最优的感知样本数分别为:

$$b^{(1)} = \sqrt{\frac{\eta^2 L \sigma^2 \tau b'_{\text{sum}} (1 + \eta KL \tau)}{2K(F(\mathbf{w}^{(1)}) - F_{\text{inf}})}}, \quad (27)$$

和

$$b^{(r)} = \sqrt{\frac{\eta^2 L \sigma^2 \tau b'_{\text{sum}} (1 + \eta KL \tau)}{2K(F(\mathbf{w}^{(r)}) - F_{\text{inf}})}}. \quad (28)$$

因而可得如下关系:

$$b^{(r)} \approx \sqrt{\frac{F(\mathbf{w}^{(1)})}{F(\mathbf{w}^{(r)})}} b^{(1)}. \quad (29)$$

根据文献[7]中的结论,损失函数 $F(\mathbf{w})$ 的值随通信回合数 r 增长而减小的比例服从 $\mathcal{O}(1/r)$ 。根据公式(29),结合该结论可知,最优的感知样本数应当随通信回合数的增长而呈 $\mathcal{O}(\sqrt{r})$ 的趋势增长。因此,给定初始回合的感知样本数 b_0 , 则后续任一回合 r 的感知样本数表达式应服从公式(30):

$$b^{(r)} \approx \alpha \sqrt{r} + b_0. \quad (30)$$

系数 α 可求解得:

$$\alpha \approx \frac{b_{\text{sum}} - b_0 R}{\sum_{r=1}^R \sqrt{r}}. \quad (31)$$

因此,通信回合 r 的感知样本数应设置为:

$$b^{(r)} \approx \left[\frac{(b_{\text{sum}} - b_0 R) \sqrt{r}}{\sum_{r=1}^R \sqrt{r}} + b_0 \right]. \quad (32)$$

综上所述,基于无线反射信号的动作感知任务,我们给出了在多场景多设备情况下,利用横向联邦学习架构训练感

知模型的解决方案，并对无线通信系统下的通信感知计算资源进行了联合优化，以降低训练时延，提升对感知任务的响应速度。

2 纵向协作感知

2.1 系统模型

2.1.1 纵向联邦学习架构

利用处于不同位置或视角的设备，纵向联邦学习架构对同一场景的观测信号进行联合信号处理，以训练一个分布式的神经网络。该神经网络由每个设备处的本地神经网络与服务器端的中心神经网络拼接而成^[9]。纵向联邦学习的目标是训练该整体的神经网络，以实现公式 (33) 中最小化问题：

$$(P2) \min_{\Theta} \mathcal{L}(\Theta; \mathcal{D}) \triangleq \frac{1}{M} \sum_{i=1}^M f(\theta_0, \dots, \theta_k; \mathcal{D}_i) + \lambda \sum_{k=0}^K \gamma(\theta_k) \quad (33)$$

其中， $\Theta = [\theta_0, \dots, \theta_k]$ 代表整体神经网络， θ_0 为中心神经网络， $\theta_k (k \geq 1)$ 为设备 k 的本地神经网络。 $\mathcal{D} = \{\mathcal{D}_i\}_{i=1}^M$ 代表完整的数据集，包含 M 个数据样本，其中每个样本 $\mathcal{D}_i \triangleq \{\mathbf{x}_i, y_i\}$ 分散于各设备中，即每个设备 k 观测到的数据特征为 \mathbf{x}_i^k ，完整的数据特征 $\mathbf{x}_i = [\mathbf{x}_i^1, \dots, \mathbf{x}_i^K]^T$ 由所有设备中的数据特征拼接而成，标签 y_i 存储于服务器端。该整体神经网络的循环训练过程包含多个通信回合，每一个通信回合分为向前传播与向后传播两个阶段。不失一般性地，我们以均方误差损失函数为例，简要论述单个通信回合的过程。

(1) 向前传播阶段：对于任一数据样本 i ，各设备 k 利用最新的本地网络 θ_k 计算出本地输出 $\mathbf{p}_i^k = C_1(\theta_k; \mathbf{x}_i^k)$ ，并将其发送至服务器端，服务器端在接收到所有设备的本地结果后，通过中心神经网络 θ_0 计算出最终判决结果 $\hat{y}_i = C_2(\theta_0; \mathbf{p}_i^1, \dots, \mathbf{p}_i^K)$ 。基于该结果的损失函数值可表示为：

$$\mathcal{L}(\Theta; \mathcal{D}) = -\frac{1}{M} \sum_{i=1}^M \|y_i - \hat{y}_i\|^2 + \lambda \sum_{k=0}^K \gamma(\theta_k) \quad (34)$$

(2) 向后传播阶段：根据公式 (34) 的损失函数值，我们可计算出中心网络对应的梯度 $\mathbf{g}(\theta_0) = \frac{\partial \mathcal{L}(\Theta; \mathcal{D})}{\partial \theta_0}$ 。接着，服务器端将信息 $\frac{\partial \mathcal{L}(\Theta; \mathcal{D})}{\partial \mathbf{p}_i^k}$ 发送至各设备 k ，使设备 k 能够计算出本地梯度 $\mathbf{g}(\theta_k) = \frac{\partial \mathcal{L}(\Theta; \mathcal{D})}{\partial \theta_k} \cdot \frac{\partial \mathbf{p}_i^k}{\partial \theta_k}$ 。最后，设备端与服务器端均使用梯度下降法对网络进行更新：

$$\theta_k \leftarrow \theta_k - \eta \mathbf{g}(\theta_k), \quad k = 0, \dots, K, \quad (35)$$

其中， η 为学习率。

2.1.2 无线通信模型

本文中，我们默认下行传输为高信噪比的情形，并主要关注上行传输中的时延控制问题。

考虑任一通信回合的上行阶段，我们假设各设备的本地模型输出维度均为 d ，用于当前回合训练的样本数为 M ，且每个输出结果均采用 q 比特进行量化。我们考虑采用二进制相移键控调制，则每个设备需上传的比特数量为 $D = qMd$ 。设备 k 与服务器端之间的信道可表示为 $H_{k,t} = \sqrt{\rho_{k,t}} h_{k,t}$ 。其中， $\rho_{k,t} = \phi_{k,t} d_{k,t}^\kappa$ 为大尺度衰落系数， $\phi_{k,t}$ 为阴影衰落系数， κ 为路损系数， $h_{k,t} \in \mathcal{CN}(0,1)$ 为小尺度衰落系数。给定传输信号 $\mathbf{s}_{k,t} \in \mathbb{C}^{D \times 1}$ ，则服务器端接收信号可表示为：

$$\mathbf{y}_{k,t}^{(i)} = H_{k,t} p_{k,t} \mathbf{s}_{k,t} + \mathbf{z}_{k,t}, \quad 1 \leq k \leq K, t \geq 1, \quad (36)$$

其中， $\mathbf{z}_{k,t} \in \mathbb{C}^{D \times 1}$ 为接收端噪声，功率为 σ^2 。令各设备传输带宽为 B 且传输频段互不干扰，则各设备上传链路对应的理想传输速率为：

$$r_{k,t} = B \log_2 \left(1 + \frac{p_{k,t}^2 |H_{k,t}|^2}{\sigma^2} \right), \quad (37)$$

其中， $p_{k,t}$ 为功率系数。另外，设备端上行传输需要满足如下平均功率约束：

$$\mathbb{E}_t [p_{k,t}^2] \leq P, \quad (38)$$

其中， P 为平均功率上限。

2.2 用户调度策略与收敛性分析

在纵向联邦学习架构下，每一通信回合的上行阶段均需所有设备向服务器端上传本地输出。服务器端需要接收到所有设备上传的数据后才能进行下一步的判决过程，因此信道衰落最严重的链路就决定了当前回合的上行传输时延。为避免训练过程受到上行传输时延过长的影响，我们首先提出一种基于信道截断^[10]的用户调度策略，并推导出该用户调度策略下的模型训练收敛情况，最后基于收敛性分析，给出了一些针对纵向联邦学习的神经网络结构设计准则。

2.2.1 用户调度策略

我们首先为各设备 k 设置信道增益阈值 $G_{k,t}$ ，当信道增益高于阈值时，就在当前回合调度该用户，否则静默该用户。该用户调度策略的数学描述如公式 (39) 所示：

$$p_{k,t} = \begin{cases} \frac{\sqrt{P_{k,t}^{\text{rx}}}}{\sqrt{\rho_{k,t}} h_{k,t}}, & |h_{k,t}|^2 \geq G_{k,t} \\ 0, & |h_{k,t}|^2 < G_{k,t} \end{cases} \quad (39)$$

进一步地, 为满足公式 (38) 中的功率约束, 可推导出:

$$P_{k,t}^{\text{rx}} = \frac{\rho_{k,t} P}{\text{Ei}(G_{k,t})}, \quad (40)$$

其中, $\text{Ei}(X) = \int_x^\infty \frac{1}{x} \exp(-x) dx$ 为指数积分。功率 $P_{k,t}^{\text{rx}}$ 决定了有效传输速率, 而上行传输时延由速率最慢的链路决定, 因此使各设备的传输速率一致为最高效的方案, 从而有公式 (41) 中的等式约束:

$$\frac{\rho_{1,t}}{\text{Ei}(G_{1,t})} = \frac{\rho_{k,t}}{\text{Ei}(G_{k,t})}. \quad (41)$$

假设备 1 经历的大尺度衰落最为严重, 则各设备的信道增益阈值 $G_{k,t}$ 可以根据设备 1 的阈值 $G_{1,t}$ 及公式 (41) 的关系式进行调整。

2.2.2 收敛性分析

假设整体神经网络满足 L -光滑性与 μ -凸性, 且满足以下有界性:

$$|\mathcal{L}(\Theta_{t+1}) - \mathcal{L}(\Theta_t)| \leq C, \quad \forall \Theta_t, \Theta_{t+1}, \quad (42)$$

$$\text{Var}[\nabla \mathcal{L}(\Theta_t)] \leq c, \quad \forall \Theta_t. \quad (43)$$

若每通信回合调度的设备集表示为 $\mathcal{K}_t(t)$, 学习率满足 $\eta \leq \frac{1}{L}$, 则训练过程的收敛情况满足如下不等式:

$$\mathbb{E}[\mathcal{L}(\Theta_{t+1}) - \mathcal{L}(\Theta^*)] \leq \left[1 - \frac{\mu v}{L}\right]^{t+1} \mathbb{E}[\mathcal{L}(\Theta_0) - \mathcal{L}(\Theta^*)] + \frac{c}{2\mu v}. \quad (44)$$

参数 v 为一个下界, 其表达式为:

$$v \leq v_{0,t} + \sum_{k \in \mathcal{K}_t} v_{k,t}, \quad \forall t, \quad (45)$$

其中, $v_{k,t} = \frac{\|\nabla_k \mathcal{L}(\Theta_n)\|^2}{\sum_{k \in \mathcal{K}} \|\nabla_k \mathcal{L}(\Theta_n)\|^2}$ 。详细证明过程可参考文献[11]。

2.2.3 网络结构设计准则

首先, 基于信道截断的用户调度策略, 我们可得出单回合传输时延:

$$T_{\text{comm}} = \frac{qMd}{B \log_2 \left(1 + \frac{P}{\sigma^2} \frac{\rho_{1,t}}{\text{Ei}(G_{1,t})}\right)}. \quad (46)$$

进一步地, 单回合时延可表示为 $T_{\text{total}} = T_{\text{comm}} + T_{\text{comp}}$, 其中 T_{comp} 为计算时间 (本工作中考虑其为固定值)。根据公式 (44) 可得, 为达到精确度 ε , 即 $\mathbb{E}[\mathcal{L}(\Theta_t) - \mathcal{L}(\Theta^*)] \leq \varepsilon$, 所需通信回合数满足:

$$N_{\text{expect}} \leq \frac{\ln \left[\frac{\varepsilon}{C} - \frac{c}{2\mu v C} \right]}{\ln \left[1 - \frac{\mu v}{L} \right]}. \quad (47)$$

根据以上结果, 我们可得出为达到精确度 ε 的整体训练时间的一个上界表达式:

$$T_{\text{expect}} \leq N_{\text{expect}} T_{\text{round}} = \left[\frac{qMd}{B \log_2 \left(1 + \frac{P}{\sigma^2} \frac{\rho_{1,t}}{\text{Ei}(G_{1,t})}\right)} + T_{\text{comp}} \right] \times \frac{\ln \left[\frac{\varepsilon}{C} - \frac{c}{2\mu v C} \right]}{\ln \left[1 - \frac{\mu v}{L} \right]}. \quad (48)$$

由于不等式 (48) 本身较为复杂, 各类参数对整体训练时间 T_{expect} 的具体影响不明确, 因此难以直接求解。另外, 以上结果均只在各项假设都满足的情况下成立。不同于直接优化, 我们通过观察公式 (48) 的形式, 给出了如下的一些神经网络设计/选择准则。

准则 1: 参数 d 应当尽量小。本地神经网络的作用为特征提取, 仅需较为完整地将本地数据包含的有效特征传递至服务器端。

准则 2: 中心神经网络的模型应尽量大。我们观察公式 (45) 后可知, 用户调度策略不会影响中心神经网络参与训练。由公式 (44) 可知, 用户调度会影响参数 v 的值, 其值由参与训练的模型对应的梯度二范数与整体神经网络对应的梯度二范数的比例决定, 比例越高收敛越快。由于训练过程中梯度信息难以调控, 因此我们提出增大中心网络比重的方案。这种做法能够增强算法的鲁棒性, 使信道增益阈值的设置有更大的可选择范围。

准则 3: 在中心网络的规模较大时, 我们可将信道增益阈值设至较高水平, 将各设备激活程度调至较低水平。该操作可有效降低单回合的训练时延, 减少调度的用户数, 且不会显著影响训练所需回合数, 因此能够有效加速整体训练过程。

3 仿真验证

在本节中, 我们通过具体的感知仿真任务来检验提出

的算法的有效性。其中，横向联邦学习架构相关的仿真采用动作识别任务，纵向联邦学习架构相关的仿真采用频谱联合感知任务。首先，我们验证在横向联邦学习架构下，采用1.4节中的资源配置优化方案是否能够有效加速训练过程。

我们设置如下3个对照方案：

方案1，采用最大通信功率，其他参数按提出的最优方案设置；

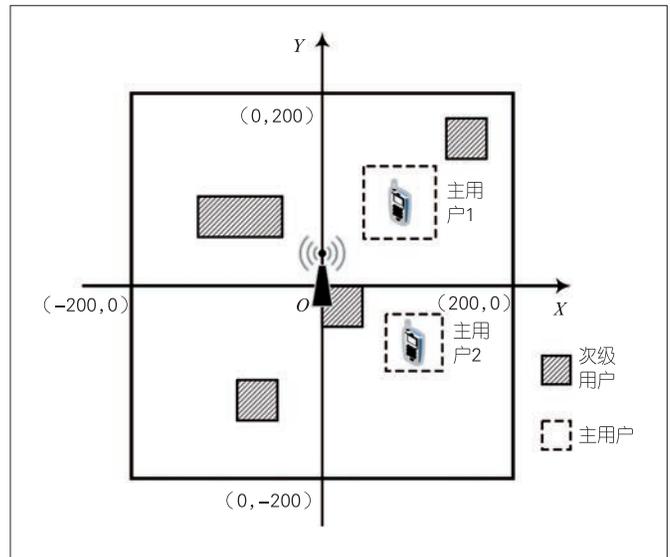
方案2，每回合采用相同的感知样本数，其他参数按提出的最优方案设置；

方案3，每回合采用递减的感知样本数，其他参数按提出的最优方案设置。

图6给出了所提的资源配置优化方案与各对照方案在训练集与测试集上的对比效果。其中，所提的资源优化方案的收敛速度明显快于对照方案1。其原因是方案1分配了过多的功率用于通信，这导致感知样本数量较少，更快地耗尽能

量，提前终止训练过程。另外，相比于对照方案2和3，所提方案具有更好的收敛效果，这体现了提出的感知样本数量调节设置能够有效地加快训练过程的收敛。

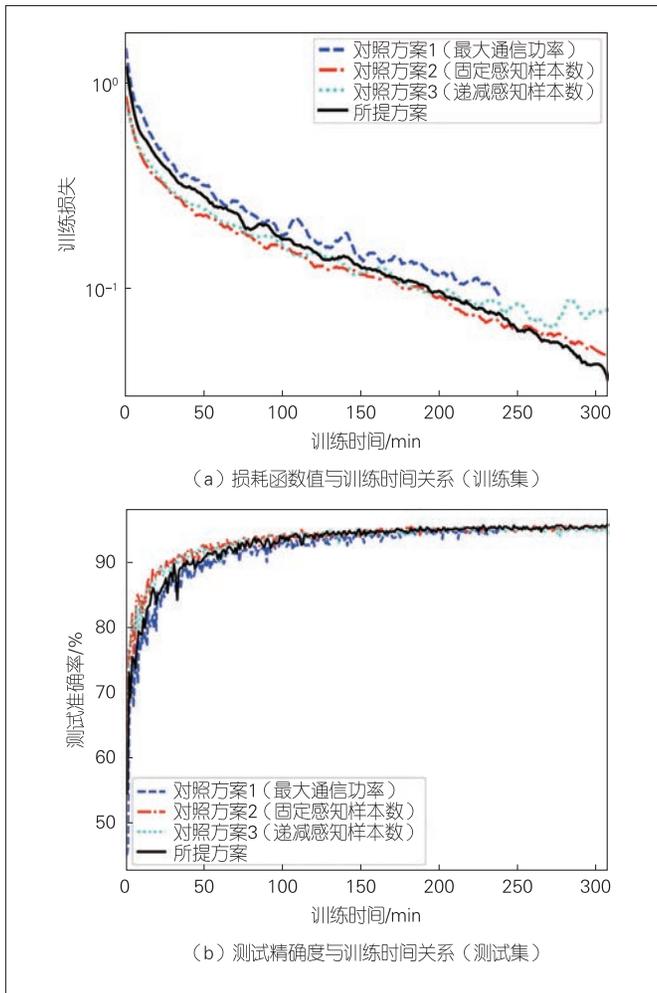
另外，在纵向联邦学习架构下，考虑频谱联合感知任务，我们验证了2.2节中的用户调度策略与神经网络设计的实际效果，具体如图7所示。



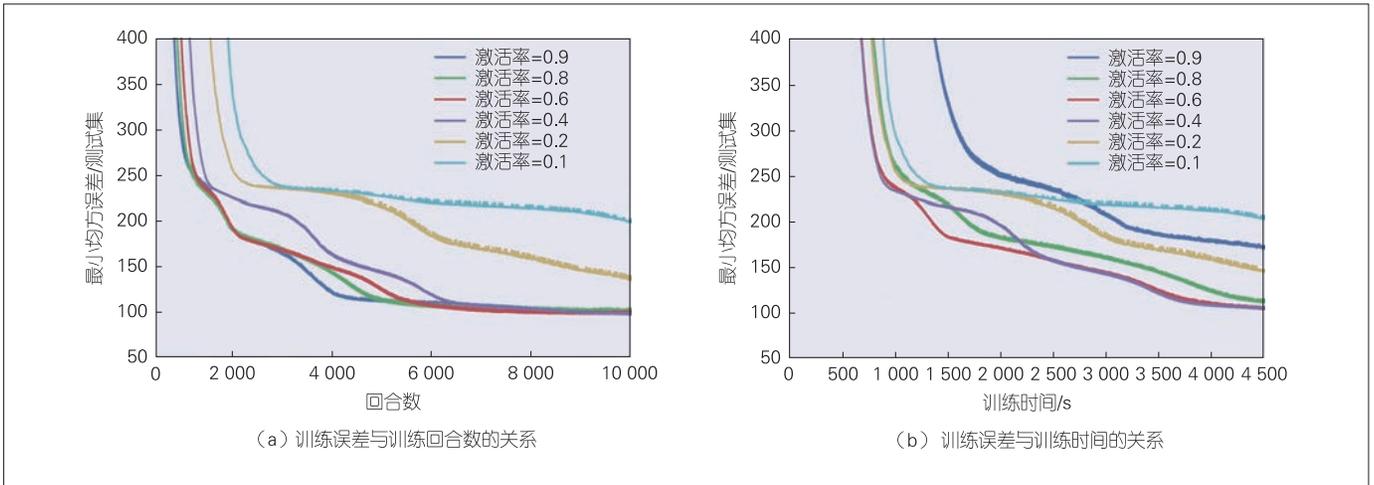
▲图7 频谱联合感知任务场景示意图

我们考虑两个神经网络设置，并对比不同神经网络设置下的训练收敛速率：神经网络1的设备端采用(203,2 048,8)的全连接网络，服务器端采用(32,24,8)的全连接网络；神经网络2的设备端采用(203,32,8)的全连接网络，服务器端采用(32,512,8)的全连接网络。我们将设备1的激活率(Activation Ratio)设置为 $\epsilon_{1,i} = \{0.9, 0.8, 0.6, 0.4, 0.2, 0.1\}$ 。其中，激活率为0.9的为对照方案可近似为未采用用户调度的方案。两种神经网络设置下的模型训练收敛速率分别如图8及图9所示。

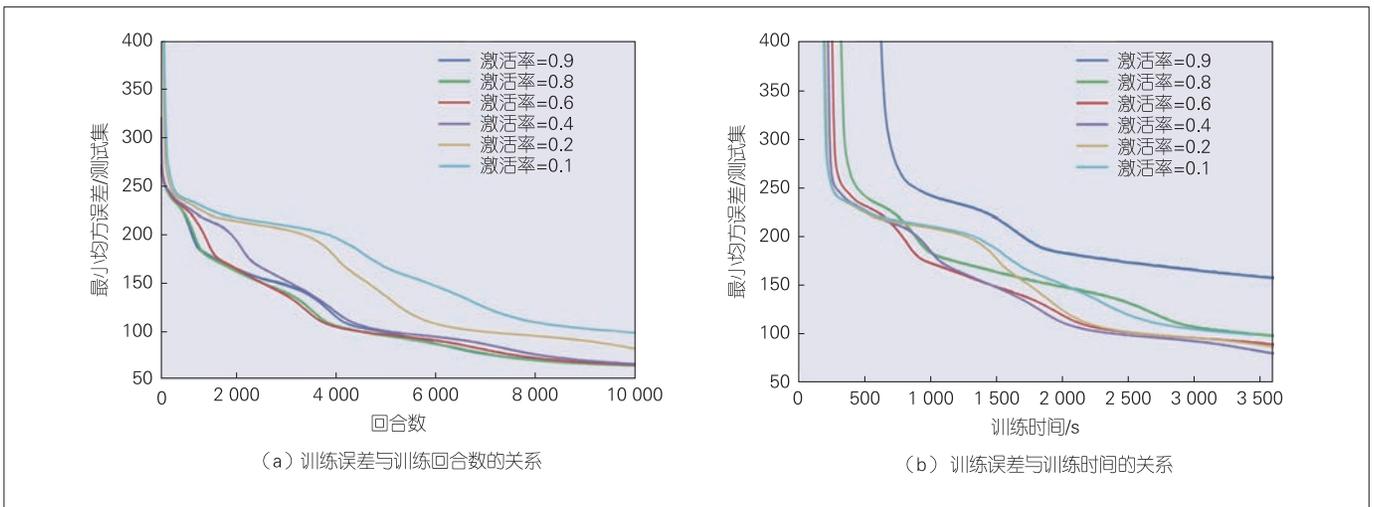
观察图9后我们可知，采用用户调度方案能够有效加速整体训练过程，且设备激活概率在一个较大范围([0.1,0.8])内调节均可以达到或接近最优收敛速率的效果。另外，对比图8和图9可知，采用神经网络2结构时能够取得更为稳定的收敛效果，其原因是在神经网络2结构中中心神经网络占更大比重，因此即使遇到用户调度策略设置得较为极端的情况，也能够保证训练过程的收敛不会过慢，这与2.2.3节中的设计准则2相吻合。另外，在该频谱联合感知任务中，需感知发射机的位置信息，我们考虑两台发射机的情况，并在图10中体现了增加感知机设备数量对感知准确度的影响。由图10中的结果对比可知，增加感知机数量能够有效提升



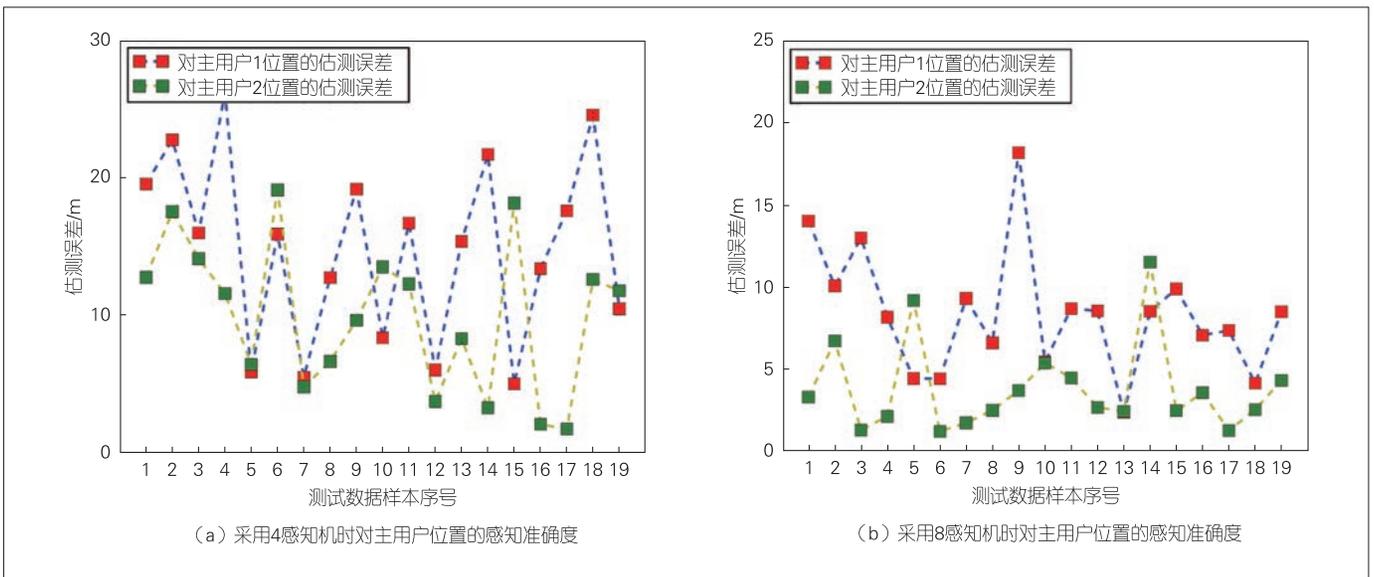
▲图6 两类典型的数据分布示意图



▲图8 采用神经网络1结构时纵向联邦学习算法收敛情况



▲图9 采用神经网络2结构时纵向联邦学习算法收敛情况



▲图10 采用不同数量感知机对感知准确度的影响

感知准确度，这也是采用纵向联邦学习架构进行联合感知相较于传统单感知机方案的主要优势所在。

4 结束语

在5G及未来的6G时代，边缘网络中基于无线通信的感知相关的智能应用将成为主流。因此，探索新型分布式学习架构，并设计与之相匹配的无线通信方案，联合优化系统资源分配，实现感知准确度与感知响应速率的有效提升，是未来通信技术发展的一个重要方向。本文提供的设计是通信感知一体化道路上的初步尝试，也为未来更为系统化多样化的设计提供了思路。

参考文献

- [1] ZHOU Z, CHEN X, LI E, et al. Edge intelligence: paving the last mile of artificial intelligence with edge computing [J]. Proceedings of the IEEE, 2019, 107(8): 1738–1762. DOI: 10.1109/JPROC.2019.2918951
- [2] ZHANG T, WANG S, LI G L, et al. Accelerating edge intelligence via integrated sensing and communication [C]//Proceedings of ICC 2022–IEEE International Conference on Communications. IEEE: 1586–1592. DOI: 10.1109/ICC45855.2022.9839016
- [3] LIU F, CUI Y H, MASOUIROS C, et al. Integrated sensing and communications: toward dual-functional wireless networks for 6G and beyond [J]. IEEE journal on selected areas in communications, 2022, 40(6): 1728–1767. DOI: 10.1109/JSAC.2022.3156632
- [4] MCMANHAN B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]//Artificial Intelligence and Statistics. PMLR, 2017: 1273–1282
- [5] YANG Q, LIU Y, CHEN T J, et al. Federated machine learning [J]. ACM transactions on intelligent systems and technology, 2019, 10(2): 1–19. DOI: 10.1145/3298981
- [6] GRADSHTEYN I S, RYZHIK I M, ROMER R H. Tables of integrals, series, and products [J]. American journal of physics, 1988, 56(10): 958. DOI: 10.1119/1.15756
- [7] LIU P, ZHU G, WANG S, et al. Toward ambient intelligence: federated edge learning with task-oriented sensing, computation, and communication integration [EB/OL]. (2022-06-13) [2022-08-10]. <https://arxiv.org/abs/2206.05949v1>
- [8] MAO Y Y, ZHANG J, LETAIEF K B. Dynamic computation offloading for mobile-edge computing with energy harvesting devices [J]. IEEE journal on selected areas in communications, 2016, 34(12): 3590–3605. DOI: 10.1109/

- JSAC.2016.2611964
- [9] LIU Y, KANG Y, ZHANG X W, et al. A communication efficient collaborative learning framework for distributed features [EB/OL]. [2022-09-20]. <https://arxiv.org/abs/1912.11187>
- [10] 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. DOI: 10.1109/TWC.2019.2946245
- [11] ZHANG Z, ZHU G, CUI S. Low-latency cooperative spectrum sensing via truncated vertical federated learning [EB/OL]. (2022-08-07) [2022-09-20]. <https://arxiv.org/abs/2208.03694v1>

作者简介



张泽中，香港中文大学（深圳）博士后，工学博士；主要研究领域为边缘智能、联邦学习、车联网及通信感知一体化等前沿技术；已发表论文17篇，拥有专利5项。



刘沛西，北京大学电子学院博士毕业生；主要研究领域为联邦边缘学习、通信感知计算一体化等；已发表论文7篇。



朱光旭，深圳市大数据研究院副研究员；主要从事无线通信理论研究，包括智能通信、5G/B5G通信技术等；先后主持国家自然科学基金、广东省面上基金等资助，并作为骨干成员参与国家重点研发计划及广东省重点领域项目；曾获香港政府奖学金资助，获国际会议（WCSP）最佳论文奖；发表论文50余篇。