

基于分层联邦学习的无人机小基站RAN切片方法

殷珉, 沈航, 王天荆, 白光伟
(南京工业大学计算机与信息工程学院, 江苏南京 210000)

摘要: 针对多架无人机共同为地面用户提供差异化服务的场景, 本文提出一种基于分层联邦学习的动态RAN(Radio Access Network)切片框架, 目的是提升切片性能隔离效果、减少协同训练过程的通信代价。考虑到无人机动态部署和数据不足等特点, 本文通过数据增广促进本地模型训练。为了使得距离地面基站较远的无人机有更多机会参与联邦学习并降低通信代价, 本文根据位置和数据分布信息设计支持边缘模型聚合的无人机分簇策略。在此基础上, 本文探索基于注意力机制的边缘和全局模型聚合方案, 以增强全局模型的泛化能力。仿真结果表明, 与联邦平均和分布式LSTM(Long Short-Term Memory)相比, 所提方案在切片性能隔离的时长占比上分别有8.4%和16.5%的提升, 并降低了无人机协同训练的通信代价。

关键词: 无人机小基站; RAN切片; 分层联邦学习; 边缘模型聚合; 注意力机制

基金项目: 国家自然科学基金(No.61502230, No.61501224); 江苏省自然科学基金(No.BK20201357); 江苏省六大大才高峰高层次人才资助项目(No.RJFW-020)

中图分类号: TP393

文献标识码: A

文章编号: 0372-2112(2023)07-1774-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221083

Hierarchical Federated Learning-Based RAN Slicing for Drone-Small-Cells

YIN Min, SHEN Hang, WANG Tian-jing, BAI Guang-wei

(College of Computer and Information Engineering, Nanjing Tech University, Nanjing, Jiangsu 210000, China)

Abstract: For the scenario where multiple drone-small-cell provide differentiated services for ground users, a dynamic radio access network (RAN) slicing framework based on hierarchical federated learning is proposed. The goal is to improve slice performance isolation and reduce the communication cost in collaborative model training. Data augmentation is introduced to promote local model training and improve model performance, considering the dynamic deployment and insufficient data of drones. Then, a clustering strategy for drone-small-cell depending on geographic location and data distribution is designed to support edge model aggregation. Hence, member drones at the edge have more opportunities to participate in federated learning with reduced communication costs. On this basis, an attention mechanism-based aggregation scheme for edge and global models is explored to improve the generalization ability of the global model. Simulation results show that compared with federated averaging and distributed long short-term memory (LSTM), the duration of slice performance isolation of the proposed scheme increases by 8.4% and 16.5%, respectively, with reduced communication cost of drone collaborative model training.

Key words: drone-small-cell; radio access network slicing; hierarchical federated learning; edge model aggregation; attention mechanism

Foundation Item(s): National Natural Science Foundation of China (No.61502230, No.61501224); Natural Science Foundation of Jiangsu Province (No.BK20201357); Six Talent Peaks Project in Jiangsu Province (No.RJFW-020)

1 引言

第五代移动通信系统(5G)支持多样化的场景, 促使数以百亿计的物联网设备接入网络^[1], 对资源提供和

服务质量(Quality of Service, QoS)保障提出了更高要求。尽管地面无线接入网(Radio Access Networks, RAN)可以基本满足大多数应用的服务需求, 但在缺乏

基础设施或出现临时性热点时便显得力不从心. 此时, 配置有无线收发装置和计算模块的无人机小基站 (drone-small-cell)^[2]可以拓展网络覆盖范围和缓解资源分配压力, 满足终端设备的 QoS 需求. 这种场景是后 5G RAN 的重要组成部分.

RAN 切片将共享的物理无线网络分割成多个隔离的逻辑网络, 并为其动态、弹性地分配资源^[3]. 在网络发展过程中, 一个自然的步骤是将 RAN 切片“延伸”至无人机, 使其可以支持多样化的服务. 机器学习方法在复杂环境建模、状态跟踪与智能调度等方面具有优势. 在资源切片方面, 机器学习方法可以根据网络态势变化准确地预测切片资源需求^[4], 实现多时间尺度的资源分配^[5]和自适应的资源调度^[6], 但现有 RAN 切片方案大多针对地面网络设计.

与地面基站不同, 无人机计算和存储能力受限、依赖机载电池供电和动态部署等特性限制了本地模型的质量提升. 现有的无人机 RAN 切片方法主要包括单机独立决策和依赖地面基站管控的模式. 对于前者, 每架无人机作为独立的个体进行模型训练^[7]. 这种模式实现简单、灵活性高, 但受限于数据量, 模型性能难以令人满意. 对于后者, 无人机的切片策略由地面基站决定^[8], 但部署范围受制于地面基站. 针对多无人机场景, 如何设计协同优化的分布式 RAN 切片方法还有待进一步研究.

作为一种典型的分布式协同训练框架, 联邦学习 (Federated Learning, FL)^[9]支持跨域模型聚合, 为无人机模型质量提升开辟了新途径. 然而, FL 与无人机的高效融合仍然面临诸多挑战, 主要包括以下三点. (1) 参数的频繁交换导致高通信代价^[10]. 如何在保证训练效果的同时减少通信代价是需要考虑的关键问题. 现有方法主要从梯度压缩^[11]和客户端调度^[12]入手. 前者会产生一定的梯度损失, 导致精度下降. 后者需要训练更多轮次^[13], 会降低模型收敛速度. (2) 不同无人机数据的差异性会导致模型聚合时出现权重偏差^[14]. FL 客户端分簇^[15]是常见的解决方案, 但主要考虑位置固定的客户端, 与动态部署且资源有限的无人机有本质不同. (3) 数据量和计算存储能力受限导致的无人机本地模型性能不佳必然影响全局模型的性能. 不同无人机之间还存在计算、存储和通信能力的差异性^[16], 因而带来模型的差异.

针对上述问题, 本文提出基于分层 FL 的无人机小基站 RAN 切片方法, 以提升切片性能隔离效果、减少协同训练的通信代价. 本文主要贡献如下.

(1) 针对问题 1, 构建一种基于分层 FL 的协同训练框架. 除了自主地进行本地训练, 无人机可以利用中继与基站交换参数, 从而减少通信代价.

(2) 针对问题 2, 设计一种基于数据分布和地理位置的无人机分簇策略. 充当簇头的无人机负责接收簇内成员的模型参数, 执行边缘模型聚合.

(3) 针对问题 3, 通过数据增广帮助本地训练, 提升模型质量. 针对边缘和全局模型聚合, 探索基于注意力机制的模型聚合方案, 与分层 FL 框架协同工作, 提升全局模型的泛化能力.

仿真结果表明, 在切片性能隔离 (performance isolation)、通信代价等方面, 所提方案优于现有典型的分布式机器学习方法.

2 系统模型与问题描述

2.1 无人机小基站 RAN 架构

如图 1 所示, 考虑一个无人机小基站 RAN 场景. 其中无人机按照预设的轨迹动态部署, 为地面设备提供差异化服务. 当无人机进入基站覆盖范围时, 可通过握手协议^[17]与基站建立连接. 若无人机无法直接同基站交互, 可通过中继的方式将信息传递给基站, 从而有更多机会参与本地协同优化.

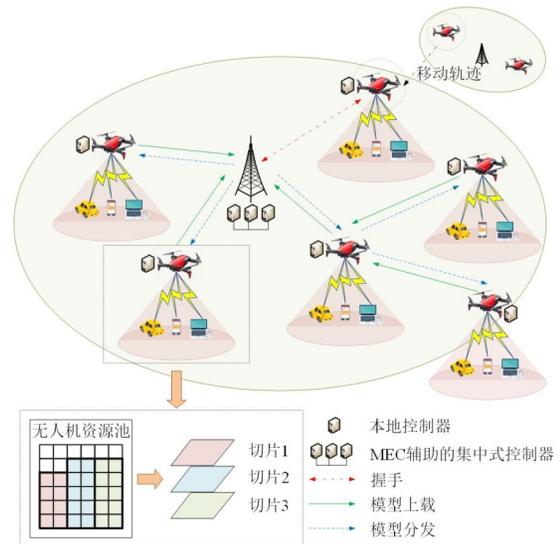


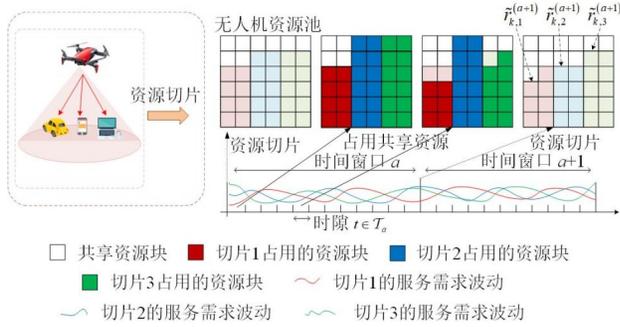
图1 无人机小基站RAN架构

在上述RAN架构下, 每个无人机小基站上的物理资源被虚拟化为多个切片. 每个切片支持一类定制化服务. 无人机采用模型驱动方法动态切分资源, 为覆盖范围内的终端设备提供差异化 QoS 保障. 在移动边缘计算 (Mobile Edge Computing, MEC) 控制器的帮助下, 基站执行模型聚合和无人机分簇操作.

2.2 面向服务的动态RAN切片框架

下面以图2为例解释面向服务的RAN切片. 假设时间被划分为多个切片窗口, 每个切片窗口被划分为多个离散时隙. 切片窗口 a 包含的时隙集合和集合元素的个数分别为 T_a 和 T_a . 无人机在当前切片窗口 a 运

行过程中预测下一窗口 $a+1$ 内各切片所需的资源块数量. 在窗口 $a+1$ 开始时, 根据资源需求预测值重新分配切片资源. 在窗口 a 以内, 每个切片分配的资源块数量维持不变. 在切片窗口内的各个时隙 t 开始时, 无人机上的本地控制器为接收的任务分配资源块. 在资源不足的情况下, 切片可以临时占用无人机预留的共享资源块.



2.3 问题建模与评估方法

假设无人机 k 的资源块数量为 B_k , 这些资源块被编排成 M_k 个切片, 切片集合为 \mathcal{M}_k . 假设在切片窗口 a , 无人机 k 上切片 m 在窗口 $a+1$ 的资源需求预测值为 $\tilde{r}_{k,m}^{(a+1)}$. 若在时隙 t 的实际资源分配量为 $r_{k,m}^{(t)}$, 则有 $\sum_{m \in \mathcal{M}_k} r_{k,m}^{(t)} \leq B_k$. 切片资源分配需要考虑2种情况:

(1) $r_{k,m}^{(t)} > \tilde{r}_{k,m}^{(a+1)}$ 代表所需的资源块数量大于预测值, 此时切片 m 需要临时占用共享资源块;

(2) $r_{k,m}^{(t)} < \tilde{r}_{k,m}^{(a+1)}$ 代表所需的资源块数量小于预测值, 即切片 m 的资源能够满足当前需求.

假设无人机 k 预留的共享资源块数量为 B'_k . 对于情况(1), 若所有共享资源块都不足以应对突发的资源需求 ($\sum_{m \in \mathcal{M}_k} |r_{k,m}^{(t)} - r_{k,m}^{(t-1)}| > B'_k$), 则切片性能隔离将无法得到保障. 令二元变量 $\phi_k^{(t)} = 1$ 为在时隙 t 无人机 k 上的各切片可以维持性能隔离, 否则为 0, 即

$$\phi_k^{(t)} = \begin{cases} 1, & \sum_{m \in \mathcal{M}_k} |r_{k,m}^{(t)} - r_{k,m}^{(t-1)}| \leq B'_k \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

由式(1)可知, 在窗口 $a+1$ 内, 切片性能隔离时长占比越高, 意味着资源分配方案越有效. 于是, 切片性能隔离优化问题可以描述为

$$\text{P1: } \max \frac{1}{T} \sum_{t \in \mathcal{T}_{a+1}} \phi_k^{(t)} \quad (2)$$

在窗口 a 运行过程中, $\tilde{r}_{k,m}^{(a+1)}$ 和 $r_{k,m}^{(t)}$ 之间的差距越小, $\phi_k^{(t)}$ 为 1 的概率越大. 因此, 通过最小化预测值和真实值之间的均方误差 (Mean Square Error, MSE), 问题

P1 被转化为

$$\text{P2: } \min_{\tilde{r}_{k,m}^{(a+1)}} \frac{1}{T} \frac{1}{M_k} \sum_{t \in \mathcal{T}_{a+1}} \sum_{m \in \mathcal{M}_k} |r_{k,m}^{(t)} - \tilde{r}_{k,m}^{(a+1)}|^2 \quad (3)$$

$$\text{s.t. } \sum_{m \in \mathcal{M}_k} \tilde{r}_{k,m}^{(a+1)} \leq B_k$$

问题 P2 的实质是在资源总量约束下如何缩小模型预测误差, 以提升切片性能隔离的时间占比.

3 设计方案

如图 3 所示, 本节设计分层联邦学习框架, 在提升无人机模型质量的同时降低通信代价.

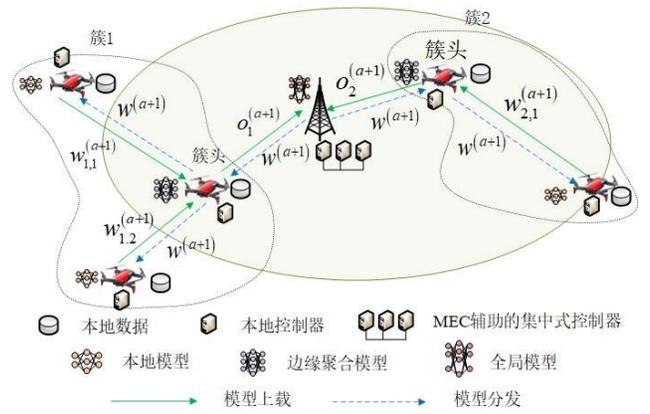


图3 分层协同训练框架

3.1 本地数据增广和模型训练

在切片窗口 a , 无人机 k 利用全局模型参数 $w^{(a)}$ 初始化自身模型, 并根据所采集的数据进行本地训练. 令 $\mathbf{R}_{k,m}^{(a)} = [r_{k,m}^{(1)}, r_{k,m}^{(2)}, \dots, r_{k,m}^{(T_a)}]$ 代表无人机 k 上切片 m 在窗口 a 的实际资源需求. 进一步, 无人机 k 上所有切片的实际资源需求矩阵为

$$\mathbf{R}_k^{(a)} = (\mathbf{R}_{k,1}^{(a)}, \mathbf{R}_{k,2}^{(a)}, \dots, \mathbf{R}_{k,M_k}^{(a)}) \quad (4)$$

无人机 k 上切片 m 在窗口 $a+1$ 所需的资源块数量被预测为

$$\tilde{r}_{k,m}^{(a+1)} = f(r_{k,m}^{(T)}, r_{k,m}^{(T-1)}, \dots, r_{k,m}^{(1)}; w_k^{(a)}) \quad (5)$$

其中, $f(\cdot)$ 和 $w_k^{(a)}$ 分别为无人机 k 的预测模型和模型参数.

考虑到无人机数据量受限, 采用基于滑动窗口的数据增广方法^[18]在序列上滑动采样. 若子序列长度设置为 s , 则可以产生 $T-s+1$ 个时间序列, 即

$$\mathcal{X}_{k,m} = \{x_{k,m,1}, x_{k,m,2}, \dots, x_{k,m,T-s+1}\} \quad (6)$$

每个子序列代表原始数据片段, 可表示为

$$x_{k,m,n} = \{r_{k,m}^{(p)}, r_{k,m}^{(p+1)}, \dots, r_{k,m}^{(q)}\} \quad (7)$$

结合式(7), $\mathbf{R}_{k,m}^{(a)}$ 对应的“输入-输出对”的集合可表示为 $\{x_{k,m,n}, y_{k,m,n}\}_{n=1}^N$. 于是, 式(5)可重新表述为

$$\tilde{y}_{k,m,n} = f(x_{k,m,n}; w_k^{(a)}) \quad (8)$$

接着,引入损失函数 $l(\tilde{y}_{k,m,n}, y_{k,m,n})$ 度量无人机 k 上所有切片的预测误差为

$$\mathcal{L}_k(w_k^{(a)}) = \frac{1}{N} \frac{1}{M} \sum_{m \in \mathcal{M}_k} \sum_{n \in \mathcal{R}_k} l(\tilde{y}_{k,m,n}, y_{k,m,n}) \quad (9)$$

最后,采用梯度下降法更新无人机 k 的模型参数为

$$w_k^{(a+1)} = w_k^{(a)} - \eta \nabla_{w^{(a)}} \mathcal{L}_k(w_k^{(a)}) \quad (10)$$

其中 η 为学习率, $\nabla_{w^{(a)}}$ 为损失函数相对 $w^{(a)}$ 的梯度.

3.2 面向边缘模型聚合的分簇

通过考虑无人机的数据分布和位置,本小节设计加权 k -means^[19] 算法,使距离地面基站较远的无人机有机会参与模型聚合,减少模型上传的通信代价.

首先,基站随机选择 C 个无人机作为初始质心. 然后,计算其它无人机的数据距离质心的加权欧式距离,将其归入与其加权欧式距离最近的一类. 假设无人机 k 的数据分布和位置信息为 θ_k 和 g_k . 地面基站依据各无人机数据分布和位置信息的离散程度来确定加权系数. 位置和数据分布的权值 ρ_1 和 ρ_2 被量化为标准差形式. 基于此,无人机 k (非质心) 与无人机 k' (质心) 之间的加权欧氏距离计算为

$$D_{k,k'} = \sqrt{\frac{1}{2} (\rho_1 (g_k - g_{k'})^2 + \rho_2 (\theta_k - \theta_{k'})^2)} \quad (11)$$

接着,计算每个簇中无人机数据的平均值,作为新质心. 最后,重复以上步骤,直到距离平方和最小.

基站依据无人机剩余能量和与基站间的距离选举簇头. 假设簇 c 中无人机 k 与基站间距离为 d_k , 无人机的剩余能量为 ζ_k , 无人机 k 的分数计算为

$$\pi_k = \frac{\alpha \zeta_k}{\zeta^{(\max)}} + \frac{(1-\alpha)(d^{(\max)} - d_k)}{d^{(\max)}} \quad (12)$$

其中, $\zeta^{(\max)}$ 代表无人机能量的上限, $d^{(\max)}$ 代表无人机与基站之间距离的上限. 最后,簇 c 中分数最高的无人机被基站选为簇头.

3.3 基于注意力机制的分层联邦学习方法

本小节提出基于注意力机制的分层联邦学习方法. 簇头接收到簇内成员的模型参数后进行边缘模型聚合. 之后,边缘聚合模型参数被上传至基站,用于构建全局模型. 为了提高全局模型的泛化性,注意力机制^[20] 被应用于簇内 FL 聚合和簇间模型 FL 聚合.

在切片窗口 $a+1$ 内,假设簇 c 的边缘聚合模型参数为 $o_c^{(a+1)}$, C 个簇的边缘聚合模型参数为 $\mathbf{O}^{(a+1)} = [o_1^{(a+1)}, o_2^{(a+1)}, \dots, o_C^{(a+1)}]$. 假设簇 c 包含的无人机的集合和数量为 \mathcal{K}_c 和 K_c . 无人机 $i \in \mathcal{K}_c$ 的本地模型参数为 $w_{c,i}^{(a+1)}$, 簇 c 中无人机本地模型参数的集合为 $\mathbf{W}_c^{(a+1)} = [w_{c,1}^{(a+1)}, w_{c,2}^{(a+1)}, \dots, w_{c,K_c}^{(a+1)}]$.

实现基于注意力机制的 FL 聚合需要计算 $\langle o_c^{(a)}, \mathbf{W}_c^{(a+1)} \rangle$ 和 $\langle w^{(a)}, \mathbf{O}^{(a+1)} \rangle$ 的相关性. 以 $o_c^{(a)}$ 和 $\mathbf{W}_c^{(a+1)}$ 为例,基于注意力打分函数,两者的相关性计算为

$$s(o_c^{(a)}, \mathbf{W}_c^{(a+1)}) = \mathbf{V}^T \tanh(\lambda o_c^{(a)} + \phi \mathbf{W}_c^{(a+1)}) \quad (13)$$

其中, \mathbf{V} , λ 和 ϕ 为可学习参数矩阵. 先计算 $\mathbf{W}_c^{(a+1)}$ 和 $\mathbf{O}^{(a+1)}$ 的分值 $[s_1, s_2, \dots, s_{K_c}]$ 和 $[s'_1, s'_2, \dots, s'_C]$. 接着,使用 Softmax 函数对分值做归一化处理,得到两者的注意力分布 $\gamma = [\gamma_1, \gamma_2, \dots, \gamma_{K_c}]$ 和 $\beta = [\beta_1, \beta_2, \dots, \beta_C]$, 其中

$$\gamma_i = \frac{\exp(s(o_c^{(a)}, w_{c,i}^{(a+1)}))}{\sum_{i \in \mathcal{K}_c} \exp(s(o_c^{(a)}, w_{c,i}^{(a+1)}))}, i \in \mathcal{K}_c \quad (14)$$

通过最小化 $o_c^{(a)}$ 和 $\mathbf{W}_c^{(a+1)}$ 之间的期望距离,可以获得与本地模型在参数空间上较为接近的边缘聚合模型. 然后,将式(14)输出的注意力分数作为权重来最小化 $o_c^{(a)}$ 和 $\mathbf{W}_c^{(a+1)}$ 之间的距离,表示为

$$\min_{o_c^{(a+1)}} \sum_{i \in \mathcal{K}_c} \left[\frac{1}{2} \gamma_i \sigma(o_c^{(a)}, w_{c,i}^{(a+1)})^2 \right] \quad (15)$$

其中, $\sigma(\cdot, \cdot)$ 表示两组参数之间的欧氏距离. 对式(15)的目标函数求导,得到梯度为

$$\nabla_{o_c^{(a+1)}} = \sum_{i \in \mathcal{K}_c} \gamma_i (o_c^{(a)} - w_{c,i}^{(a+1)}) \quad (16)$$

最后,执行梯度下降算法更新边缘聚合模型的参数. 全局模型参数更新为

$$\begin{cases} o_c^{(a+1)} = o_c^{(a)} - \varepsilon \sum_{i \in \mathcal{K}_c} \gamma_i (o_c^{(a)} - w_{c,i}^{(a+1)}) \\ w^{(a+1)} = w^{(a)} - \varepsilon \sum_{c \in \mathcal{C}} \beta_c (w^{(a)} - o_c^{(a+1)}) \end{cases} \quad (17)$$

其中, ε 为 $o_c^{(a+1)}$ 和 $w^{(a+1)}$ 每次迭代中在相反方向移动的步长. 之后, $w^{(a+1)}$ 由基站下发给簇头,并由簇头分发给簇内成员,以更新本地模型. 具体细节见算法 1.

算法 1 基于注意力机制的分层模型聚合

输入: $w_k^{(a)}, o_c^{(a)}, w^{(a)}; \varepsilon$

输出: $w^{(a+1)}$

- 1) for each $c \in \mathcal{C}$ do
- 2) for each $i \in \mathcal{K}_c$ do
- 3) 根据式(13)得到 \mathcal{K}_c 中无人机本地模型的注意力分数 $[s_1, s_2, \dots, s_{K_c}]$;
- 4) 根据式(14)对 $[s_1, s_2, \dots, s_{K_c}]$ 进行归一化得到注意力分布 $[\gamma_1, \gamma_2, \dots, \gamma_{K_c}]$;
- 5) 根据式(16)得到 $o_c^{(a+1)}$ 的梯度
- 6) 根据式(17)更新簇 c 边缘聚合模型参数为 $o_c^{(a+1)}$
- 7) end for
- 8) 得到 C 个簇的边缘聚合模型参数 $\mathbf{O}^{(a+1)}$
- 9) 重复步骤 3-9 得到全局模型参数 $w^{(a+1)}$
- 10) end for

3.4 模型驱动的RAN切片

无人机 k 将本地模型参数更新为 $w_k^{(a+1)}$,在此基础上,预测 M_k 个切片在窗口 $a+1$ 所需的资源块数量为 $\tilde{\mathbf{R}}_k^{(a+1)}=(\tilde{r}_{k,1}^{(a+1)}, \tilde{r}_{k,2}^{(a+1)}, \dots, \tilde{r}_{k,M_k}^{(a+1)})$. 在窗口 $a+1$ 开始时,无人机 k 根据模型输出重新分配每个切片的资源.

4 仿真实验和结果分析

本节设计仿真实验评估方案的性能. 为了分析不同功能对总体性能的影响,所提方案被分为3种:

- (1) HierFed-1: 缺省模式, 具备所有预设功能;
- (2) HierFed-2: 模型聚合省略了注意力机制;
- (3) HierFed-3: 距基站近的无人机被选为簇头.

为了便于对比和分析,选取的基准方法包括:

- (1) FedAvg^[21]: 模型聚合采用联邦平均方法;
- (2) LSTM^[22]: 无人机采用分布式的模型训练.

各无人机采用相同的LSTM模型结构,包含2个LSTM层和1个将特征映射到预测的线性层. 数据集采用意大利特伦蒂托省的通信数据,包括数据服务、语音通话等业务^[23]. 不同类型的业务数据被用来模拟切片的资源需求波动. 细节的参数设置见表1.

4.1 切片性能隔离的时间占比

本组实验考察无人机资源块数量对切片性能隔离的影响. 如图4所示,从资源块数量为50起,各方法的切片性能隔离效果开始快速提升. HierFed-1下的切片性能隔离的时间占比均高于其它方法,在资源块数量为150时优势更加明显.

图5给出了资源块数量为250时切片性能隔离时间占比随切片窗口的变化. 由于在初期无人机缺乏训练数据,在第3个窗口开始时,切片性能隔离的时间占

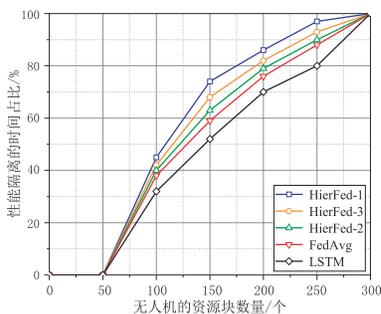


图4 资源块数量对性能隔离的影响

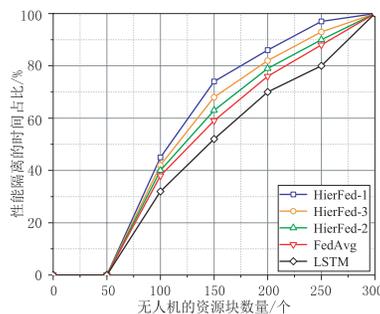


图5 性能隔离的时间占比

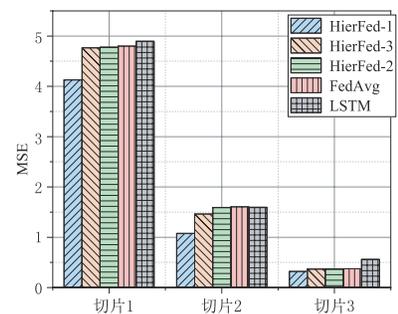


图6 切片的资源需求预测误差

4.3 簇的数目对性能的影响

接下来考察不同簇数目下的资源需求预测性能. 由图7可见,不分簇时的预测误差最高. 簇数目为4时,预测误差最低. 这是因为所提分簇策略降低了数据异构性对全局模型泛化性的负面影响.

表1 参数设置

参数	默认设置
无人机数量	10
切片数量	3
切片窗口长度	600 s
资源块数量	250
通信轮次	100
本地训练轮次	10
本地批量	20
学习率	0.01

比开始快速上升,直至趋于稳定. LSTM的资源需求预测准确性相对较弱,降低了性能隔离效果. 在迭代收敛后,相比FedAvg和LSTM, HierFed-1在切片性能隔离的时间占比上有8.4%和16.5%的提升,主要得益于资源需求的准确预测. 此外, HierFed-1的表现优于HierFed-2和3,表明分簇策略和基于注意力机制的模型聚合方案具有互促进作用.

4.2 资源需求预测精度分析

本组实验采用MSE衡量各切片所需资源的总体预测误差. 如图6所示, HierFed-1通过模型聚合方式共享知识,相比LSTM鲁棒性更强,在3个切片上

分别实现了15.67%, 32.64%, 43.00%的性能增益; 与FedAvg相比,实现了13.96%, 32.98%, 14.64%的增益. 这主要因为:(1)分簇策略在一定程度上缓解了因数据异构导致的模型精度下降;(2)基于注意力机制的模型聚合增强了全局模型的泛化能力. 与HierFed-2相比, HierFed-1实现了13.34%, 33.11%, 13.52%的增益. 与HierFed-3相比, HierFed-1在边缘聚合时考虑了不同的数据分布,增强了边缘模型的泛化能力,实现了13.59%, 26.43%, 12.58%的增益.

本组实验采用文献[24]中的通信能耗方法量化不同簇数目下的通信能耗. 如表2所示, HierFed-1的通信能耗略高于HierFed-3,但预测误差更低. 另外,在所提方法下,距离基站较远的无人机可以将参数信息上载至簇头,产生的通信能耗均低于FedAvg. 该组结果证实

了所提方法可以减少无人机整体通信代价。

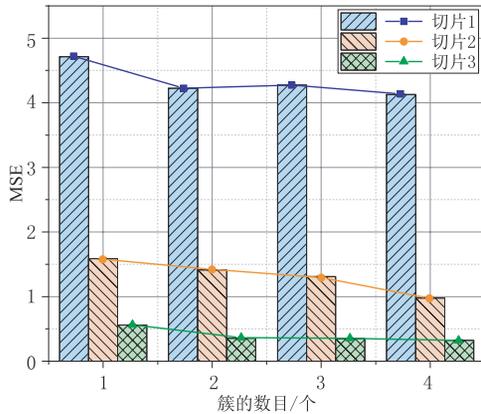


图7 簇数目对预测误差的影响

表2 簇数目对通信能耗的影响 单位:KJ

方法	簇数目		
	2	3	4
HierFed-1	0.74	0.645	0.61
HierFed-2	0.74	0.645	0.61
HierFed-3	0.72	0.650	0.60

注: FedAvg方案下通信能耗为0.76 KJ

5 结论

本文提出了一种基于分层联邦学习的无人机RAN切片方法。仿真结果表明,与2种基准方法相比,本文所提方案提升了切片的性能隔离效果,且具有更低的通信代价。所提方案不受无人机数量和移动轨迹限制,可进一步用于支持任务卸载、内容分发等。

参考文献

- [1] XIA T T, WANG M M, JIANG C L, et al. Practical machine-type communication for energy internet of things: An introduction[J]. IEEE Communications Standards Magazine, 2019, 3(1): 48-59.
- [2] SHEN H, YE Q, ZHUANG W H, et al. Drone-small-cell-assisted resource slicing for 5G uplink radio access networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(7): 7071-7086.
- [3] SHEN X M, GAO J, WU W, et al. AI-assisted network-slicing based next-generation wireless networks[J]. IEEE Open Journal of Vehicular Technology, 2020, 1: 45-66.
- [4] GUTTERMAN C, GRINSHPUN E, SHARMA S, et al. RAN resource usage prediction for a 5G slice broker[C]// Proceedings of the Twentieth ACM International Symposium on Mobile Ad Hoc Networking and Computing. New York: ACM, 2019: 231-240.
- [5] 元伟敬, 宋清洋, 郭磊. 面向软件定义多模态车联网的双时间尺度RAN切片资源分配[J]. 通信学报, 2022, 43(4): 60-70.
- QI W J, SONG Q Y, GUO L. Dual time scale resource allocation for RAN slicing in software-defined oriented polymorphic IoV[J]. Journal on Communications, 2022, 43(4): 60-70. (in Chinese)
- [6] NASSAR A, YILMAZ Y. Deep reinforcement learning for adaptive network slicing in 5G for intelligent vehicular systems and smart cities[J]. IEEE Internet of Things Journal, 2022, 9(1): 222-235.
- [7] CARRILLO MELGAREJO D, POKORNY J, SEDA P, et al. Optimizing flying base station connectivity by RAN slicing and reinforcement learning[J]. IEEE Access, 2022, 10: 53746-53760.
- [8] BELLONE L, GALKIN B, TRAVERSI E, et al. Deep reinforcement learning for combined coverage and resource allocation in UAV-aided RAN-slicing[EB/OL]. (2022) [2022]. <https://arxiv.org/abs/2211.09713>.
- [9] YANG H L, ZHAO J, XIONG Z H, et al. Privacy-preserving federated learning for UAV-enabled networks: Learning-based joint scheduling and resource management[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(10): 3144-3159.
- [10] LIAN Z T, WANG W Z, SU C H. COFEL: Communication-efficient and optimized federated learning with local differential privacy[C]// ICC 2021 - IEEE International Conference on Communications. Piscataway: IEEE, 2021: 1-6.
- [11] LU Y Q, LIU Z B, HUANG Y M. Parameters compressed mechanism in federated learning for edge computing[C]// 2021 8th IEEE International Conference on Cyber Security and Cloud Computing (CSCloud)/2021 7th IEEE International Conference on Edge Computing and Scalable Cloud (EdgeCom). Piscataway: IEEE, 2021: 161-166.
- [12] LU Y L, HUANG X H, ZHANG K, et al. Blockchain empowered asynchronous federated learning for secure data sharing in internet of vehicles[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 4298-4311.
- [13] LUO S Q, CHEN X, WU Q, et al. HFEL: Joint edge association and resource allocation for cost-efficient hierarchical federated edge learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6535-6548.
- [14] YEGANEH Y, FARSHAD A, NAVAB N, et al. Inverse distance aggregation for federated learning with non-IID

data[M]//Domain Adaptation and Representation Transfer, and Distributed and Collaborative Learning. Cham: Springer International Publishing, 2020: 150-159.

- [15] BRIGGS C, FAN Z, ANDRAS P. Federated learning with hierarchical clustering of local updates to improve training on non-IID data[C]//2020 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE, 2020: 1-9.
- [16] LI T, SAHU A K, TALWALKAR A, et al. Federated learning: Challenges, methods, and future directions[J]. IEEE Signal Processing Magazine, 2020, 37(3): 50-60.
- [17] SONG Q H, ZENG Y, XU J, et al. A survey of prototype and experiment for UAV communications[J]. Science China Information Sciences, 2021, 64(4): 1-21.
- [18] WEN Q, SUN L, YANG F, et al. Time series data augmentation for deep learning: A survey[EB/OL]. (2021) [2022]. <https://doi.org/10.48550/arXiv.2002.12478>.
- [19] VOUIROS A, LANGDELL S, CROUCHER M, et al. An empirical comparison between stochastic and deterministic centroid initialisation for K-means variations[J]. Machine Learning, 2021, 110(8): 1975-2003.
- [20] JI S X, PAN S R, LONG G D, et al. Learning private neural language modeling with attentive aggregation[C]//2019 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE, 2019: 1-8.
- [21] MCMAHAN 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.
- [22] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1235-1270.
- [23] BARLACCHI G, DE NADAI M, LARCHER R, et al. A multi-source dataset of urban life in the city of Milan and the Province of Trentino[J]. Scientific Data, 2015, 2: 150055.
- [24] THAMMAWICHAI M, BALIYARASIMHUNI S P, KERRIGAN E C, et al. Optimizing communication and computation for multi-UAV information gathering applications[J]. IEEE Transactions on Aerospace and Electronic Systems, 2018, 54(2): 601-615.

作者简介



殷 珉 男,1998年10月出生于江苏省盐城市.现为南京工业大学计算机与信息工程学院硕士研究生.主要研究方向为无人机通信网络、分布式机器学习.

E-mail: 202061220036@njtech.edu.cn



沈 航(通讯作者) 男,1984年3月出生于江苏省南京市.现为南京工业大学计算机与信息工程学院副教授.主要研究方向为空地一体化网络.

E-mail: hshen@njtech.edu.cn



王天荆 女,1977年7月出生于江苏省南通市.现为南京工业大学计算机与信息工程学院副教授.主要研究方向为无线网络、分布式机器学习.

E-mail: wangtianjing@njtech.edu.cn



白光伟 男,1961年11月出生于辽宁省沈阳市.现为南京工业大学计算机与信息工程学院教授.主要研究方向为移动互联网.

E-mail: bai@njtech.edu.cn