

基于选举策略的低空物联网稳定联邦学习方法

申凌峰^{1,2}, 王光辉^{1,2}, 白天水^{1,2}, 朱政宇³, 张千坤⁴

(1. 河南大学软件学院, 河南 开封 475004; 2. 河南省智能网络理论与关键技术国际联合实验室, 河南 开封 475004;
3. 郑州大学电气与信息工程学院, 河南 郑州 450001; 4. 中迅邮电咨询设计院有限公司, 北京 100048)

摘要: 随着无人机 (UAV, unmanned aerial vehicle) 与物联网 (IoT, Internet of things) 技术的深度融合, 低空物联网中传输了大量包含敏感信息的数据, 存在严重的隐私泄露风险。联邦学习 (FL, federated learning) 允许多个参与者共同训练模型而无须共享敏感数据, 为低空物联网安全应用提供了隐私保护的方案。但是, 随着应用场景越来越丰富, 节点异构性、网络动态性等特点导致低空物联网下的联邦学习非常不稳定。提出了一种结合 Raft 选举算法和权重计算的新型联邦学习方法 (FedPRE-W, federated fearning based on proxy Raft election and weight calculation), 提高了联邦学习的稳定性和效率。针对遮挡、网络动态变化以及节点能量耗尽等导致的代理设备中断问题, 通过 Raft 选举算法选举新的代理设备, 保障联邦学习的稳定性。结合节点异构性, 通过计算节点权重, 选举性能强的节点当选代理, 提升了联邦学习的效率。最后, 在公开数据集上对所提方法进行验证, 结果显示, FedPRE-W 算法在减少通信轮数、加速模型收敛以及提高系统稳定性等方面有显著优势。该方法为低空物联网进行安全、稳定、高效的联邦学习提供了一种可行的解决方案。

关键词: 低空物联网; 联邦学习; 设备选举策略; 稳定性; 训练效率

中图分类号: TN915.08

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2024.00415

Stable federated learning method for low-altitude IoT networks based on election strategy

SHEN Lingfeng^{1,2}, WANG Guanghui^{1,2}, BAI Tianshui^{1,2}, ZHU Zhengyu³, ZHANG Qiankun⁴

1. School of Software, Henan University, Kaifeng 475004, China

2. Henan International Joint Laboratory of Intelligent Network Theory and Key Technology, Kaifeng 475004, China

3. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China

4. China Information Technology Designing & Consulting Institute Co., Ltd., Beijing 100048, China

Abstract: The deep integration of UAV and Internet of things (IoT) transmits a large amount of sensitive data in the air-to-ground intelligent network, posing a serious risk of privacy leakage. The proposal of federated learning (FL) provides a privacy-preserving solution for low-altitude IoT applications, allowing multiple participants to jointly train models without sharing sensitive data. However, the federated learning performance is unstable because of various application scenarios, heterogeneous nodes and dynamic environments. An federated fearning based on proxy Raft election and weight calculation (FedREP-W) method was proposed, which combined classical Raft election and weight calculation, signifi-

收稿日期: 2024-08-26; 修回日期: 2024-09-15

通信作者: 王光辉, gwang@vip.henu.edu.cn

基金项目: 国家自然科学基金重大研究计划 (No. 92367302); 河南省科技攻关项目 (No. 242102210139, No. 242102211097); 河南省高等学校重点科研项目 (No. 25A510015, No. 25A520008); 河南省交通运输厅科技项目 (No. 2023-3-2)

Foundation Items: The Major Research Plan of the National Natural Science Foundation of China (No. 92367302), The Key Technology Research and Development Project of Henan Province (No. 242102210139, No. 242102211097), The Key Research Project Plan for Higher Education Institutions of Henan Province (No. 25A510015, No. 25A520008), The Science and Technology Project of Henan Provincial Transportation Department of China (No. 2023-3-2)

cantly improving the stability and efficiency of federated training. To be more specific, the use of Raft to choose new agent devices kept federated learning stable. By incorporating the concept of weight elections, the effectiveness of federated learning could be enhanced by designating the most powerful node as an agent. The experimental results publicly available datasets show that the proposed strategy and algorithm perform well in lowering the number of communication rounds, speeding up model convergence, and making the system stable. This provides a feasible solution for efficient, secure, and stable federated learning in low-altitude IoT networks.

Key words: low-altitude IoT, federated learning, device election strategy, stability, training efficiency

0 引言

无人机 (UAV, unmanned aerial vehicle) 行业和市场在过去几年迅速发展。伴随着无人机生态系统的建立, 以无人机为核心的低空经济正在成为我国经济社会发展的新增长引擎。得益于高度的机动性和灵活部署特性, 无人机在辅助地面网络通信中得到了广泛应用, 通过构建低空一体化网络, 显著提升了传统网络的服务质量^[1-2]。无人机通过连接地面基础设施形成的低空物联网, 为智慧低空建设提供了关键的数字服务基础, 成为推动低空经济高质量发展的重要支撑^[3-6]。

为充分彰显低空物联网的应用价值, 打造低空经济战略性新兴产业, 如何提升低空物联网的智慧化水平是当前面临的关键挑战。首先, 应用人工智能技术的前提是获取高精度的 AI 模型, 这既需要强大算力的支持, 又需要大量的训练数据^[7-9]。然而, 无人机和物联网节点通常载荷有限, 难以支撑 AI 模型的集中式训练。另外, 大量数据在空地无线信道中传输, 可能会导致严重的隐私泄露风险, 不仅损害了用户的隐私, 还对企业的声誉和运营造成了重大影响^[10-13]。因此, 集中式 AI 训练方式无法应对智能低空物联网提出的安全和高效需求, 急需新的模型训练模式以促进低空物联网智能化水平的提升。

联邦学习 (FL, federated learning) 作为一种新兴的分布式机器学习范式, 为这个问题提供了一种可能的解决方案^[14-16]。FL 允许多个设备共同训练一个模型, 既降低了对每个节点算力的要求, 又无须将数据集中到一个服务器上。这表示每个设备的数据都可以留在本地, 不需要与其他设备共享, 从而降低了数据泄露的风险。

尽管 FL 在数据隐私保护上具有巨大的潜力, 但在低空物联网中实现一个既高效又鲁棒的 FL 系统面临着重大挑战。首先, 参与训练的设备可能具

有不同的计算和传输能力。其次, FL 训练需要代理设备聚合和上传模型参数, 低空物联网环境和节点天然存在的高动态性特点导致代理节点不稳定, 进而影响 FL 的效率和精度。

为了解决上述问题, 设计出面向低空物联网的稳定 FL 系统, 本文结合基于分组的 FL 架构以及 Raft 选举算法, 提出了一种新型代理设备选举方案。具体来说, 将 Raft 选举算法嵌入组内设备中, 当负责上传模型参数的代理设备离线时, Raft 选举算法及时在组内选举出新的设备作为代理与外界通信, 确保代理离线的小组仍能参与联邦训练, 以维护 FL 的稳定性。

另外, FL 训练效率也是影响低空物联网智能化水平的重要技术指标。当 FL 训练过程中出现离线代理设备时, 经典 Raft 选举算法可以通过心跳机制来选举新代理客户端负责 FL 训练, 从而降低代理设备离线导致的 FL 训练效率下降的影响。然而, 经典 Raft 选举算法在通过心跳机制选举新代理客户端时没有考虑低空物联网设备的异构性, 无法保障新代理客户端具有较高的计算能力, 可能出现算力不足的设备成为新代理客户端, 导致 FL 训练效率下降。针对这一问题, 本文提出一种基于权重计算的 Raft 选举算法改进策略。首先, 基于节点计算能力、闲置时长 (能量) 等因素, 通过马氏距离计算每个设备的权重值。其次, 基于权重值设计选举机制, 保证权重值大的设备被优先选举为代理设备。通过权重计算与 Raft 选举算法的结合, 进一步提升联邦学习的效率。

综上所述, 本文基于一种新型选举策略, 在高动态的低空物联网中提出了一种安全、稳定、高效的 FL 训练方法。首先, 考虑了智能低空物联网中基于分组的 FL 训练架构, 以确保数据安全。其次, 引入了 Raft 选举算法以保证系统的稳定性。最后, 设计了一种权重选举策略, 进一步提高 FL 的效率。

本文主要研究内容如下：

1) 在高动态低空物联网中提出了一种基于 Raft 选举算法的稳定 FL 方案。通过实现代理设备的无感切换，保证了 FL 的稳定性，显著提高了低空物联网中 FL 的可用性。

2) 提出了一种基于权重计算的 Raft 选举算法改进策略。考虑到低空物联网中节点的异构性和不稳定性，通过权重计算和选举机制结合，在保证稳定性的基础上，显著提高了 FL 的训练效率。

3) 在 MNIST 和 CIFAR-10 公开数据集上对所提算法进行验证，基于权重选举的 Raft 选举算法可以在原始代理设备离线时实现代理的无感切换，在减少通信轮数、加速模型收敛以及提高系统稳定性方面有显著优势。

1 相关工作

联邦学习作为一种分布式机器学习范式，允许多个设备共同训练模型，而无须共享数据，从而保护用户隐私。对于低空物联网这种资源受限的网络，通过将物联网节点分组形成以簇为单位的集群进行训练，可以有效地缓解通信和能量负载，提高联邦学习的可用性^[17-18]。但在分组架构中，如何在集群内实现代理的动态选举策略对于联邦训练的效率和稳定性起着至关重要的作用。

针对如何通过设计选举策略提高 FL 训练效率的研究有很多。Marnissi 等^[19]提出一种基于梯度重要性的设备选举策略，通过选择每轮通信中梯度值最高的设备来提高学习效率。Rjoub 等^[20]针对资源受限网络中的选举策略，提出建立边缘服务器与终端设备间的信任机制，旨在检测出训练期间过度利用或资源不足的设备，通过优化调度决策以保证足够的资源进行联邦训练。对于资源受限网络下高效联邦训练的研究还有很多^[21-22]，为低空物联网这种典型资源受限网络下的联邦训练提供了很多参考。但是这些研究并没有考虑设备离线以及通信中断对联邦训练的影响。

Raft 选举算法作为最经典的选举算法之一，是克服 FL 中设备不稳定问题的一种潜在方式。Raft 选举算法作为分散机器学习范例，已经被广泛应用于分布式系统中^[23-25]。Kim 等^[23]通过将 Raft 选举算法与 FL 相结合，提出了针对模型更新一致性和可靠性的改进 Raft 选举算法，显著提高了私有区块链

的性能。Dautov 和 Husom^[24]利用 Raft 选举算法的选举和日志复制机制来实现网络故障后的自动状态恢复，实现了在动态和不可靠的网络物理条件下 FL 训练的不间断，增强了整个 FL 系统的鲁棒性。Yahata 等^[26]结合 Raft 选举算法提出了一种可扩展、安全、容错的 P2P FL 聚合系统，在系统的后端提出了一个两层 Raft，通过快速检测并替换崩溃的代理来保持可用性，提高了对随机对等体崩溃的容错性。

当前研究已经针对 FL 提出了多种设备选举策略和 Raft 选举算法改进策略，但现有研究在低空物联网下的应用仍然较少。部分学者将 Raft 这种思想引入物联网中以实现物联网节点的集中管理和控制，基于其选举思想显著提升了网络的稳定性^[27-29]。但低空物联网存在异构、高动态、资源严重受限等特点，给 Raft 选举算法在低空物联网中的应用提出新的挑战，尤其为了提升低空物联网的智能化水平，亟待突破 FL 在低空物联网中稳定应用的瓶颈。基于此背景，本文在高动态低空物联网中提出了一种基于 Raft 选举算法代理选举的稳定 FL 方案。在保证数据安全、训练稳定的同时，进一步提高训练效率。本文旨在通过结合基于分组的训练结构和新型的设备选举策略，为低空物联网进行安全、稳定、高效的联邦学习提供一种可行的解决方案。

2 系统架构和问题设置

本文提出了一种基于 Raft 选举算法代理设备选举的低空物联网 FL 系统。针对低空物联网中不稳定因素对联邦训练的影响，提出将训练设备进行分组，构建以簇为单位的集群。设计代理节点动态切换机制，通过设备心跳检测，监测代理节点是否离线，如果出现异常情况，立刻启动代理选举过程，保持联邦学习不受影响。

2.1 基础模型训练

将初始模型下发到物联网节点并和本地数据进行模型训练， ω 表示下发的初始模型， D_i 表示终端收集到的原始数据。因参数较多，为便于理解，参数定义及意义见表 1。模型学习训练过程表示为 $f_i(\omega_i) = l(\omega_i, D_i)$ ，目标函数如式(1)所示

$$\min_{\omega \in \mathbf{R}^d} f(\omega) \quad (1)$$

$$f(\omega) = \frac{1}{n} \sum_{i=1}^n f_i(\omega_i) \quad (2)$$

其中， $l(\cdot)$ 为损失函数，表示一轮训练过程中的

表1 参数定义及意义

符号	解释
i	智能设备索引
j	分组单元索引
M	代理迭代次数
N	本地迭代次数
O	代理节点数量
P	训练节点数量
D	本地设备数据
η_i	设备的局部学习效率
u_j	计算能力参数
v_j	空闲时长(能量)参数
C_{agent}	代理选举
MS	马氏距离
K	计算权重次数
ω	最终模型状态
ω_i	训练节点的模型状态
ω_j	代理聚合的模型状态
ω_T	HAP聚合的模型状态

数据损失。用 $g'_i = \nabla f_i(\omega_i)$ 表示训练终端的梯度下降, ω_i 表示终端接收到一轮训练开始时的初始模型状态, η_i 表示每个终端的局部学习效率。模型更新过程可以表示为

$$\omega_i^{t+1} \leftarrow \omega_i^t - \eta_i g'_i \quad (3)$$

每个节点在迭代过程中获得局部模型, 并将模型数据传输给集群中的代理节点进行模型聚合。

2.2 动态代理联邦学习架构

在本文所提低空物联网 FL 系统中, 模型通过分组进行训练, 所有参与联邦训练的节点都植入了 Raft 选举算法。在集群初始化过程中, 需要通过权重计算选举初始代理设备并构建分组联邦训练架构。

权重计算方法为: 根据物联网节点的计算能力和闲置时长(能量水平), 利用马氏距离算法计算每个节点的权重值。权重值越高, 表示该设备性能越强, 在训练过程中存活时间越长。

在训练过程中, 由于节点能量耗尽或者网络的动态因素, 集群中会出现代理设备离线的问题。一方面, 通过设备的计算能力和闲置时长等因素计算出每个设备的权重值, 通过权重值进行新代理设备的选举。另一方面, 为了及时发现代理设备离线, 在组间引入心跳检测机制。当发现代理设备离线时, 及时在高性能候选者中开始新一轮的选举, 选出新的代理设备。通过这种方式, 既保证了联邦训练的

稳定性, 又充分利用了有限资源以提高训练效率。

UAV 联邦训练整体架构如图 1 所示。首先, 将 UAV 定义为高空平台 (HAP, high-altitude platform), 负责任务下发以及模型集中聚合。将参与训练和组内聚合的低空物联网节点(如换电站、飞行平台、低空雷达等)定义为低空平台 (LAP, low-altitude platform)。在由 LAP 组成的集群中, 普通节点进行本地训练, 被选举出来的代理节点负责组内模型聚合并向上通信。如果代理设备突然离线, 如图 1 中灰色节点, 该集群训练的模型参数将无法继续参与模型更新, 从而导致整体训练的准确率无法随着训练轮次继续提高, 影响训练结果。

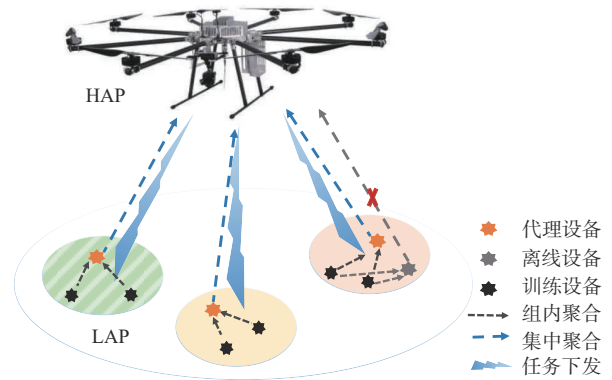


图1 UAV 联邦训练整体架构

通过本文所提的解决方案, 对离线的代理设备进行替换, 可以重新恢复集群内的 LAP 与上层 HAP 的通信, 从而使所有集群训练后的模型继续参与到最终的聚合过程, 提高整体训练的准确率, 确保整体联邦训练的稳定性, 具体流程如下。

1) 集群初始化: 通过马氏距离计算参与训练设备的权重值, 采用的变量为 CPU 计算能力与设备闲置时长。权重值越大, 表明该设备的计算能力越强, 网络存活时间越长。通过计算出的权重值设置每个设备发起投票的超时等待时长。权重值越大, 超时时长越短, 这样可以保证权重值最大的设备当选为代理设备。

2) 代理离线选举: 当心跳监测反馈出现异常, 集群内出现代理设备离线情况时, 结合 Raft 选举算法和权重计算的新型联邦学习方法 (FedREP-W, federated learning based on proxy Raft election and weight calculation) 会根据权重值, 为超时时长最短的设备发起投票。当获得的票数超过组内设备总数的一半时, 将该设备选举为代理设备。通过上述

机制，可以保证在代理设备突然离线时，联邦学习依旧可以稳定训练。

3) 本地训练：在集群内，拥有计算能力的设备在本地进行模型训练，没有计算能力的设备将本地数据传输给选举出来的代理节点，在代理设备上训练模型，从而与其他设备训练后的模型进行更新聚合，解决算力不同导致的设备异构性问题。

4) 模型聚合：集群内模型聚合由训练节点以及代理节点共同完成。聚合后的模型由代理节点上传至HAP。最后，HAP进行集中聚合并将更新后的最新模型下发至终端设备。至此，完成一轮模型的更新。

2.3 问题设置

本文在低空物联网不稳定场景下提出一种高效稳定的联邦学习训练方法，提出一种基于权重计算的新型代理设备选举算法FedPRE-W，提升了联邦训练的稳定性、效率和安全性，本文旨在解决的问题如下。

1) 稳定性：针对遮挡、网络环境动态变化以及节点能量耗尽等导致的代理设备通信中断问题，本文提出适应不稳定场景的训练架构，并设计适配的稳定处理算法FedPRE-W，当设备离线或通信中断时，实现无感的代理设备切换，保证联邦训练的稳定性。

2) 高效性：通过提出的FedPRE-W算法，对低空物联网中设备的异构性进行充分利用。当集群内出现较高能力和能量的设备时，该算法可保证能力最强的设备当选代理，提高整体联邦训练效率。值得注意的是，除了提升效率，该算法也保证了系统的可扩展性。

3) 隐私性：在分组训练架构下，联邦训练算法通过在终端本地进行训练，有效地保证了数据安全。在基于分组训练的模式下，本地数据只在组内传输，有效地降低了数据泄露的风险。

3 FedPRE-W算法设计

3.1 算法基本思想

FedPRE-W算法的提出主要是解决不稳定因素影响联邦学习训练的问题，解决设备突然离线对训练结果的影响，同时在选举代理设备时考虑设备能力对训练效率的影响。当代理设备不稳定时，FedPRE-W算法会主动选举新的代理设备，以保证训练稳定进行。FedPRE-W算法在组内设备间利用心跳检测

监测各个设备的运行状态，根据每个设备的权重值设置投票选举的超时时间，权重值大的设备对应的投票超时时间短，这样可以提前发起投票，保证能力较强的设备顺利成为代理设备。相较于传统的FedSGD算法、FedAVG算法以及其他基于分组的算法，FedPRE-W算法能够保证训练稳定且高效。

3.2 动态代理选举

本文提出在分组架构下利用心跳检测监测节点的离线状态，若一个集群内出现代理离线的情况，集群内便触发代理选举流程。首先通过马氏距离算法计算得到每个设备的权重值，根据权重值设置超时时长，然后根据时序发起投票，直到产生新的代理。

具体的动态选举过程如下，当存在设备的超时时长消耗完毕时，便会向集群内其他终端发起投票请求，其他设备在收到投票请求时进行回应。FedPRE-W算法依据终端设备权重值为代理设备设置不同的选举投票超时时长。代理设备选举初始化如图2所示，绿色部分长度代表设备发起投票的超时等待时长。当该设备的权重值最大时，说明该设备的计算力等资源相较于其他终端更有优势，进而FedPRE-W算法设置该设备的超时时长最短，以便于更早发起投票。当投票发起后，如果设备收到的投票数超过集群内终端数量的一半，该设备便从普通设备被设定为代理设备。

在代理设备不稳定的情况下，代理设备应对离线情况选举过程如图3所示。假设代理设备在 T_2 时刻离线，FedPRE-W算法根据心跳检测获取代理设备离线状态，并根据每个终端设备提前计算的权重值，设置发起投票等待时长，并按照时序依次发起投票。这样集群内便会触发新的选举流程，选举方式与初始化过程一致，最终选择新的代理设备代替原来的代理设备向上通信，确保该集群的训练不会脱离整体训练。

3.3 模型聚合

FedPRE-W算法的模型训练过程分别在普通参与训练的节点、代理节点以及HAP上各执行一次。训练节点的原始数据不出本地，在集群内训练后与代理节点进行交互和模型更新，代理节点接收到模型更新参数后在集群内进行聚合。由于动态代理设备的出现，FedPRE-W算法设定每一轮模型聚合开始之前，将监测的设备在线状态提前发送给其他终端，如果出现离线或者新加入设备的情况，选举机

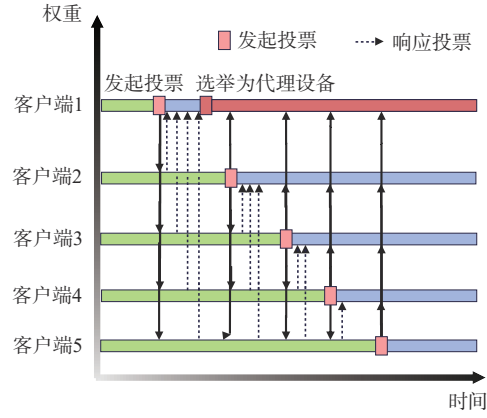



图2 代理设备选举初始化

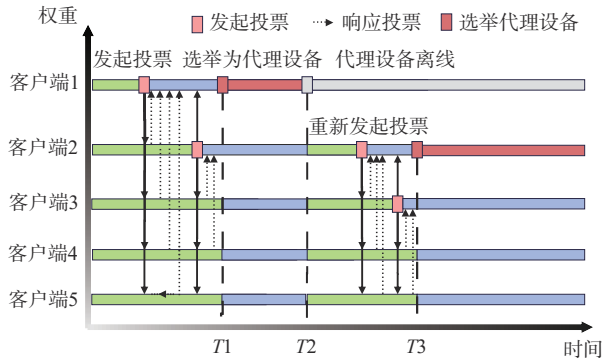


图3 代理设备应对离线情况选举过程

制和本地联邦训练并行进行。在训练后模型更新参数发送前完成选举过程，保证每个终端稳定发送数据，防止代理设备离线导致数据丢失，影响联邦训练过程。代理聚合后的模型如式(4)所示，每个代理循环迭代出一个最新模型

$$\omega_s \leftarrow \sum_{p=1}^P \frac{\omega_i^{t+1}}{P} \quad (4)$$

接下来，HAP进行二次更新聚合。首先，获取各组代理传入的最新模型参数，其次，进行二次聚合和模型更新，集中聚合后的模型结果如式(5)所示

$$\omega_T \leftarrow \sum_{o=1}^O \frac{\omega_j}{O} \quad (5)$$

基于分组训练的设备代理选举联邦学习如算法1所示，给出了FedPRE-W算法本地计算、代理选举以及模型聚合的伪代码步骤。将设备代理选举流程嵌入本地训练与模型聚合过程中，保证代理设备离线或者新设备加入的情况下，不影响联邦训练结果。通过实现代理设备的无感切换，提高联邦训练的效率及稳定性。

算法1 基于分组训练的设备代理选举联邦学习

输入 MINST数据，初始模型 ω ，代理节点数量 O ，代理迭代次数 M ，参与训练节点数量 P ，本地迭代次数 N ，学习效率 η_i ，用于权重计算的参数，如计算能力 u_i 与闲置时长（能量） v_j

输出 最终全局模型

HAP将训练任务下发，并下发初始模型为 ω_0 ;

for $m = 1, 2, 3, \dots, M$

for $n = 1, 2, 3, \dots, N$

if $C_{\text{agent}} = \text{down}$

$$c_i = \sum_{j=0}^K \text{MS}(u_i, v_j), i \neq j;$$

$$C_{\text{agent}} = \text{Raft}(c_i, c_j), i \neq j;$$

$$\omega_i^{t+1} \leftarrow \omega_i^t - \eta_i \nabla(\omega, D);$$

$$\omega_s \leftarrow \sum_{p=1}^P \frac{\omega_i^{t+1}}{P};$$

$$\omega_j = \sum_{n=1}^N \frac{\omega_s}{N};$$

end for

$$\omega_T \leftarrow \sum_{o=1}^O \frac{\omega_j}{O};$$

$$\omega \leftarrow \sum_{m=1}^M \frac{\omega_T}{M};$$

end for

return ω

4 算法分析

4.1 算法收敛性分析

为确定加入代理选举后模型训练的收敛性，本文对FedPRE-W算法进行了理论分析，研究了FedPRE-W算法在非凸损失函数上的收敛性。为了

便于分析，将客户端筛选率设置为 $q = 1$ ，即每一轮训练中所有的客户端都会被选择。本次分析可以映射到 $q < 1$ 的场景。

假设 1 关于梯度信息 ω 的损失函数 l 是 L 光滑的，那么对于任意的 ω ， $\hat{\omega} \in R^d$ ，以及本地数据 $X \in D$ ，可以得到式(6)

$$\|\nabla l(\omega; X)\| \leq L\|\omega - \hat{\omega}\| \quad (6)$$

假设 2 对于损失函数 l ，可以得到式(7)

$$E[\tilde{\nabla} f_i(\omega)] = \nabla f(\omega), E\|\tilde{\nabla} f_i(\omega) - \nabla f_i(\omega)\|^2 \leq \sigma^2 \quad (7)$$

假设 1 表明梯度 $\nabla l(\omega)$ 是利普希茨连续 (Lip-schitz continuous) 的。因此对应的局部 f_i 和全局 f 也是利普希茨连续的。假设 2 表明客户端的无偏随机梯度具有一致的二阶上限。

现在分析非凸损失函数的收敛行为，注意到，对于非凸损失函数，通常将预期的梯度范数作为指标来评估收敛性。

定理 1 若假设 1 和假设 2 成立，当客户端学习率 ξ_t 设置为 $1/L(T)^{1/4}$ 时，通信轮次 T 具有以下关系

$$\frac{1}{(T)^{1/2}} \leq \frac{\sqrt{17} - 1}{8} \quad (8)$$

具有非凸损失函数的 FedPRE-W 算法的收敛性满足

$$\frac{1}{T} \sum_{t=0}^{T-1} E\|\nabla f(\bar{\omega}_t)\|^2 \leq \frac{2L^2(f(\omega_0) - f^*)}{(T)^{1/4}} + \frac{\sigma^2}{nL(T)^{3/4}} \quad (9)$$

在给出定理 1 的完整证明之前，首先建立以下引理。

引理 1 从假设 1 中，可以引申获得

$$f(\omega_{t+1}) \leq f(\bar{\omega}_t) + \frac{L}{2}\|\omega_{t+1} - \bar{\omega}_t\|^2 \quad (10)$$

其中， $\bar{\omega}_t$ 表示通过聚合每个上传的梯度而获得的第 t 个全局模型。 ω_{t+1} 表示通过聚合每个上传的梯度而获得的第 $t+1$ 个全局模型。通过引理 1，我们得到了 ω_{t+1} 和 $\bar{\omega}_t$ 之间的关系。

引理 2 当假设 1 和假设 2 成立时，可以获得

$$Ef(\bar{\omega}_t) \leq Ef(\omega_t) - \frac{1}{2}\xi_t E\|\nabla f(\bar{\omega}_t)\|^2 - \xi_t \left(\frac{1}{2n} - \frac{1}{2n}L\xi_t\right) \sum_{i \in n} E\|\nabla f(\omega_i^t)\|^2 + \frac{L}{2n}\xi_t^2 \sigma^2 \quad (11)$$

通过引理 2，我们获得了 $\bar{\omega}_t$ 和通过聚合每个上传的梯度而获得的第 t 个全局模型 ω_t 之间的关系。

证明：开始证明定理 1。通过将式(11)代入式

(10)来得到 ω_{t+1} 和 ω_t 之间的关系

$$Ef(\omega_{t+1}) \leq Ef(\omega_t) - \frac{1}{2}\xi_t E\|\nabla f(\bar{\omega}_t)\|^2 - \xi_t \frac{1}{2n} (1 - L\xi_t) \sum_{i \in n} E\|\nabla f(\omega_i^t)\|^2 + \frac{L}{2n}\xi_t^2 \sigma^2 \quad (12)$$

对于足够小的 ξ_t ，使

$$1 - L\xi_t \geq 0 \quad (13)$$

满足

$$Ef(\omega_{t+1}) \leq Ef(\omega_t) - \frac{1}{2}\xi_t E\|\nabla f(\bar{\omega}_t)\|^2 + \frac{L}{2n}\xi_t^2 \sigma^2 \quad (14)$$

通过求和式(14)并重新排列获得

$$\frac{1}{2}\xi_t \sum_{t=0}^{T-1} E\|\nabla f(\bar{\omega}_t)\|^2 \leq f(\omega_0) - f^* + \frac{L}{2n}T\xi_t^2 \sigma^2 \quad (15)$$

通过变换得到式(16)

$$\frac{1}{T} \sum_{t=0}^{T-1} E\|\nabla f(\bar{\omega}_t)\|^2 \leq \frac{2(f(\omega_0) - f^*)}{\xi_t T} + \frac{L}{n}\xi_t \sigma^2 \quad (16)$$

当客户端学习率 ξ_t 被设置为 $1/L(T)^{1/4}$ 时，得到式(17)

$$\frac{1}{T} \sum_{t=0}^{T-1} E\|\nabla f(\bar{\omega}_t)\|^2 \leq \frac{2L^2(f(\omega_0) - f^*)}{(T)^{1/4}} + \frac{\sigma^2}{nL(T)^{3/4}} \quad (17)$$

若将客户端的学习率 ξ_t 设置为 $1/L(T)^{1/4}$ ，当 $T \rightarrow \infty$ 时，客户端学习率趋于无穷小，FedPRE-W 算法随着通信轮次的增加最终可以达到收敛，收敛速率为 $O(1/T^{1/4})$ 。

4.2 算法复杂度分析

本文所提的 FedPRE 算法是基于分组的分布式训练结构，终端训练后的模型在集群中的代理设备上进行一次模型聚合，聚合轮次为参与训练的设备数量，此时算法的时间复杂度为 $O(n)$ 。当模型在代理设备上完成聚合后，代理设备将模型上传至 HAP，进行第二次模型聚合，在此轮模型聚合时，聚合轮次为参与聚合的代理数量，代理数量明显少于训练设备数量，因此，HAP 上模型聚合的复杂度为 $O(\log n)$ 。权重计算是在训练时并行计算，马氏距离计算所消耗的时间忽略，即最终的整体时间复杂度为 $O(n \log n)$ 。

本文所提的基于分组的 FL 架构采用分压聚合的训练方式，HAP 下发训练指令以及初始模型，通过分组以及代理转发，由终端设备节点执行训练过程，最终由 HAP 与代理负责模型聚合获得精准的 AI 模型。本文所提的架构和算法可避免 HAP 与每一个训练终端进行通信，显著地降低了通信负载。

5 实验评估

5.1 实验设置

为了验证 FedPRE-W 算法的有效性，采用的实验环境为：CPU 为 Intel Core i7-1165G7 @2.80 GHz、GPU 为 NVIDIA GeForce MX450、RAM 为 16 GB，软件环境信息为 Python 3.9。

首先在公开数据集 MNIST 上对本文所提的算法进行验证，该数据集为手写体数字识别数据集，含有 70 000 张训练图像数据用于联邦训练实验，可通过 TensorFlow 获取。根据算法 1，在参与训练设备数量为 50、100 和 200 时分别进行实验。在分组设置上，假设每个集群由 5 个节点组成。进行本地训练时，每次迭代时间设置为 0.5 s，基本通信耗时常量设置为 0.02 s。训练 100 轮之后，通过指定代理设备离线来模拟动态代理的环境。

在联邦训练过程中，代理设备离线率分别设置为 50% 和 100%，通过实验对比，验证了该算法能够有效地提高联邦训练的稳定性。

5.2 实验结果

首先，假设代理设备在进行 100 轮迭代后 100% 离线，通过改变参与训练的设备数量进行实验，在设备数量分别为 50、100 和 200 时，将本文所提的 FedPRE-W 算法与 FedSGD 算法、FedAVG 算法、FedAE 算法和 FedPRE 算法进行对比^[30]，验证本文所提算法的性能，不同情况下的模型准确率分别如图 4 至图 6 所示。




图 4 离线率 100%、终端数量 50 时模型准确率

仿真结果表明，没有引入 Raft 选举算法时，迭代 100 轮后联邦训练结果的准确率趋于平衡，如 FedSGD 算法、FedAVG 算法和 FedAE 算法。这是因为代理设备离线，集群内的训练结果不能参与模型的更新。而本文所提的 FedPRE 算法和 FedPRE-W 算法引入了 Raft 选举算法，可以实现代理设备的




图 5 离线率 100%、终端数量 100 时模型准确率




图 6 离线率 100%、终端数量 200 时模型准确率

无感切换，保证了 FL 的稳定性。但 FedPRE 算法没有考虑权重选举策略，整体训练性能弱于 FedPRE-W 算法。这是由于不同种类的低空设备（如换电站、飞行平台、低空雷达等）存在天然的异构性。FedPRE 算法无法选举出较高性能的代理设备，从而影响整体训练精度和效率。而基于权重值计算的 FedPRE-W 算法可以保证能力最强的设备当选代理，提高整体联邦训练效率。总的来说，在训练迭代过程中，当所有代理设备全部离线时，FedPRE-W 算法能够选举出新的并且高性能的代理设备参与联邦训练，保证训练精度和稳定性。另外，以上结论在终端数量不同的场景下，均得到了证实。

其次，假设代理设备在迭代过程中离线率为 50%，其他实验设置不变，进一步验证代理设备部分离线情况下的算法性能，不同情况下的准确率分别如图 7 至图 9 所示。

当代理设备离线率为 50% 时，FedSGD 算法、




图 7 离线率 50%、终端数量 50 时准确率




图8 离线率50%、终端数量100时准确率




图9 离线率50%、终端数量200时准确率

FedAVG算法和FedAE算法在迭代100轮后训练准确率依然会有所提高。这与代理设备离线率为100%时有明显不同，说明代理设备离线率显著影响联邦训练的结果。本文所提的FedPRE-W算法，在代理设备离线率为50%时，表现的性能与离线率为100%时保持一致，都可以选举出新的高性能代理设备，保证联邦训练结果的准确率平稳提高。

最后，本文验证了FedPRE-W算法的泛化性，将其在CIFAR-10数据集上进行性能评估。CIFAR-10数据集是普适物体识别数据集，包含60 000张RGB彩色图案，分为10类，可通过PyTorch自动下载。设置参与训练设备的数量为100，代理设备离线率分别为100%和50%时，数据集模型准确率分别如图10和图11所示。

设定在迭代50轮后更改代理设备离线情况。仿真结果显示，离线率为100%时，没有引入Raft选举的算法的训练精度趋于收敛。但离线率为50%




图10 离线率100%、CIFAR-10数据集下模型准确率




图11 离线率50%、CIFAR-10数据集模型准确率

时，即使没有引入Raft选举算法，训练精度依旧会提高，但是提高趋势在迭代50轮后逐渐减小。在不同离线率情况下，FedPRE-W算法都能够选举出新的高性能的代理设备参与联邦训练，保证训练精度稳步提升。仿真结果表明，FedPRE-W算法在更改仿真数据集后依旧具有可行性，FedPRE算法可以扩展到更为复杂的数据集上。

6 结束语

本文在动态低空物联网中提出了一种基于Raft选举算法的新型设备选举算法FedPRE-W，不仅克服了低空物联网中设备异构性和网络状态不稳定带来的挑战，还提高了模型训练的效率 and 精度。针对遮挡、网络动态变化以及物联网节点能量耗尽等导致的代理设备中断问题，通过Raft选举算法选举新的代理设备，保障联邦训练的稳定性。针对节点异构性，通过权重选举策略，保证能力更强的设备当选代理，显著提升了联邦训练的效率。通过在公开数据集上进行仿真实验，证明了本文所提方法能有效地减少通信轮数，加速模型收敛，显著地提高了系统的稳定性及FL的训练精度。本文为低空物联网中实现高效、稳定的联邦学习提供了新的方法论，并为未来在资源有限或网络条件不稳定的其他典型场景中实施联邦学习提供了参考。

参考文献：

- [1] WANG J Y, SU D P, FENG P, et al. Optimal height of UAV in covert visible light communications[J]. IEEE Communications Letters, 2023, 27(10): 2682-2686.
- [2] DO Q T, SHUMEYE LAKEW D, TIEN TRAN A, et al. A review on recent approaches in mmWave UAV-aided communication networks and open issues[C]//Proceedings of the 2023 International Conference on Information Networking (ICOIN). Piscataway: IEEE Press, 2023: 728-731.
- [3] 王巍, 谷壬倩, 彭力, 等. 基于无人机的物联网空基中继鲁棒优

- 化[J]. 物联网学报, 2022, 6(1): 101-112.
- WANG W, GU R Q, PENG L, et al. Robust optimization of air based relay for Internet of things based on UAV[J]. Chinese Journal on Internet of Things, 2022, 6(1): 101-112.
- [4] SHEN L F, WANG N, ZHANG D, et al. Energy-aware dynamic trajectory planning for UAV-enabled data collection in mMTC networks[J]. IEEE Transactions on Green Communications and Networking, 2022, 6(4): 1957-1971.
- [5] 梅海波, 杨鲲, 范新宇. 基于深度增强学习的无人机赋能无线电接入网络的能效优化[J]. 物联网学报, 2021, 5(2): 48-59.
- MEI H B, YANG K, FAN X Y. Deep reinforcement learning to enhance the energy-efficient performance of UAV-enabled F-RAN[J]. Chinese Journal on Internet of Things, 2021, 5(2): 48-59.
- [6] SHEN L F, WANG N, ZHU Z Y, et al. UAV-enabled data collection over clustered machine-type communication networks: AEM modeling and trajectory planning[J]. IEEE Transactions on Vehicular Technology, 2022, 71(9): 10016-10032.
- [7] HANIF S, ILYAS T, ZEESHAN M. Intrusion detection in IoT using artificial neural networks On UNSW-15 Dataset[C]//Proceedings of the 2019 IEEE International Conference on Smart Cities: Improving Quality of Life Using ICT & IoT and AI (HONET-ICT). Piscataway: IEEE Press, 2019:152-156.
- [8] JACKSON G, VALLES D. Dataset enlargement with generative adversarial neural networks[C]//Proceedings of the 2024 IEEE World AI IoT Congress (AIoT). Piscataway: IEEE Press, 2024: 0045-0051.
- [9] KAUR N, GUPTA L. Enhancing IoT security in 6G environment with transparent AI: leveraging XGBoost, SHAP and LIME[C]//Proceedings of the 2024 IEEE International Conference on Network Softwarization (NetSoft). Piscataway: IEEE Press, 2024: 180-184.
- [10] ADIL M, AHMAD JAN M, LIU Y X, et al. A systematic survey: security threats to UAV-aided IoT applications, taxonomy, current challenges and requirements with future research directions[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(2): 1437-1455.
- [11] ZHU Z Y, WANG N, HAO W M, et al. Robust beamforming designs in secure MIMO SWIPT IoT networks with a nonlinear channel model[J]. IEEE Internet of Things Journal, 2021, 8(3): 1702-1715.
- [12] HUANG Y, LI Y J, CAI Z P. Security and privacy in metaverse: a comprehensive survey[J]. Big Data Mining and Analytics, 2023, 6(2): 234-247.
- [13] LI X W, ZHANG J Y, HAN C Z, et al. Reliability and security of CR-STAR-RIS-NOMA-assisted IoT networks[J]. IEEE Internet of Things Journal, 2024, 11(17): 27969-27980.
- [14] GUO X H. Federated learning for data security and privacy protection[C]//Proceedings of the 2021 12th International Symposium on Parallel Architectures, Algorithms and Programming (PAAP). Piscataway: IEEE Press, 2021: 194-197.
- [15] TIAN Y L, WANG S, XIONG J B, et al. Robust and privacy-preserving decentralized deep federated learning training: focusing on digital healthcare applications[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2024, 21(4): 890-901.
- [16] NGUYEN D C, DING M, PATHIRANA P N, et al. Federated learning for Internet of Things: a comprehensive survey[J]. IEEE Communications Surveys & Tutorials, 2021, 23(3): 1622-1658.
- [17] WANG K I K, YE X, SAKURAI K. Federated learning with clustering-based participant selection for IoT applications[C]//Proceedings of the 2022 IEEE International Conference on Big Data (Big Data). Piscataway: IEEE Press, 2022:6830-6831.
- [18] HE Z, WANG L, CAI Z. Clustered federated learning with adaptive local differential privacy on heterogeneous IoT data[J]. IEEE Internet of Things Journal, 2024, 11(1):137-146..
- [19] MARNISSI O, EL HAMMOUTI H, HOUCINE BERGOU E. Client selection in federated learning based on gradients importance[J]. ArXiv e-Prints, 2021: arXiv: 2111.11204.
- [20] RJOUB G, ABDEL WAHAB O, BENTAHAR J, et al. Trust-driven reinforcement selection strategy for federated learning on IoT devices[J]. Computing, 2024, 106(4): 1273-1295.
- [21] FU L, ZHANG H L, GAO G, et al. Client selection in federated learning: principles, challenges, and opportunities[J]. IEEE Internet of Things Journal, 2023, 10(24): 21811-21819.
- [22] CHEN C, JIANG B H, LIU S L, et al. Efficient federated learning in resource-constrained edge intelligence networks using model compression[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 2643-2655.
- [23] KIM D, DOH I, CHAE K. Improved raft algorithm exploiting federated learning for private blockchain performance enhancement[C]//Proceedings of the 2021 International Conference on Information Networking (ICOIN). Piscataway: IEEE Press, 2021: 828-832.
- [24] DAUTOV R, HUSOM E J. Raft protocol for fault tolerance and self-recovery in federated learning[C]//Proceedings of the 2024 IEEE/ACM 19th Symposium on Software Engineering for Adaptive and Self-Managing Systems (SEAMS). Piscataway: IEEE Press, 2024: 110-121.
- [25] LIU C, GUO S Y, GUO S, et al. LTSM: lightweight and trusted sharing mechanism of IoT data in smart city[J]. IEEE Internet of Things Journal, 2022, 9(7): 5080-5093.
- [26] YAHATA Y, SUGIURA K, MATSUTANI H. A scalable secure fault tolerant aggregation for P2P federated learning[C]//Proceedings of the 2024 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW). Piscataway: IEEE Press, 2024: 222-231.
- [27] XU X, HOU L, LI Y, et al. Weighted raft: An improved blockchain consensus mechanism for Internet of things application[C]//Proceedings of the 2021 International Conference on Computer and Communications (ICCC). Piscataway: IEEE Press, 2021:1520-1525.
- [28] HOU L, XU X, ZHENG K, et al. An intelligent transaction migration scheme for raft-based private blockchain in Internet of things applications[J]. IEEE Communications Letters, 2021, 25(8):2753-2757.
- [29] BUTTAR H M, AMAN W, RAHMAN M M U, et al. Countering active attacks on raft-based IoT blockchain networks[J]. IEEE

Sensors Journal, 2023, 23(13):14691-14699.

[30] 王光辉, 白天水, 丁爽, 等. 基于代理选举的高效异构联邦学习方法[J]. 计算机应用研究, 2024, 41(3): 688-693.

WANG G H, BAI T S, DING S, et al. Efficient and heterogeneous federated learning based on agent election[J]. Application Research of Computers, 2024, 41(3): 688-693.

[作者简介]



申凌峰(1992-), 男, 博士, 河南大学软件学院讲师、硕士生导师, 主要研究方向为无人机通信、物联网、联邦学习等。



王光辉(1987-), 男, 博士, 河南大学软件学院副教授、硕士生导师, 主要研究方向为物联网、联邦学习与智能交通等。



白天水(1995-), 男, 河南大学软件学院硕士生, 主要研究方向为物联网技术、联邦学习。



朱政宇(1988-), 男, 博士, 郑州大学电气与信息工程学院副教授、博士生导师, 主要研究方向为智能无线通信及应用。



张千坤(1992-), 男, 中讯邮电咨询设计院有限公司工程师, 主要研究方向为物联网、高精度定位与智能网络等。