

基于自适应联邦学习的环境监测群智感知算法

蒋伟进^{1,2,3}, 杜熙晨^{1,2*}, 蒋意容⁴, 杨璇^{2,3}, 聂彩燕^{1,2}, 刘茜^{1,2}

(1. 湖南工商大学计算机学院, 湖南长沙 410205; 2. 湘江实验室, 湖南长沙 410205;

3. 湖南工商大学前沿交叉学院, 湖南长沙 410205; 4. 湖南信息学院, 湖南长沙 410151)

摘要: 随着工业化和城市化的快速发展, 环境监测的重要性日益凸显, 然而传统监测方法受限于高昂成本、布局困难和维护挑战, 难以实现全面和实时的监测。群智感知作为一种新兴的环境监测方法, 利用广泛使用的高度智能设备和集成传感器进行环境数据的大规模收集和实时传输。但现有研究很少同时考虑到数据隐私保护、工作平衡以及系统成本, 导致在实际应用中难以达到预期效果。为解决这一问题, 本文提出一种能适用于环境监测群智感知的低成本、高效率方法(Adaptive Federated Learning based Crowd Sensing algorithm for Environmental Monitoring, AFL-CSEM)。具体而言, 考虑系统中的资源限制、设备异构性和数据非独立同分布等挑战, 本文结合群智感知与联邦学习技术进行了系统建模, 在用户设备上本地模型训练, 仅共享模型参数, 有效保护数据隐私; 进行系统的收敛性分析, 得到基于联邦学习的群智感知算法在非独立同分布数据分布下的收敛界限; 为了减少设备异构性影响, 依据收敛性分析的结果, 设计一种自适应控制方法, 动态调整局部更新频率和批大小, 以适应异构与动态的监测环境。通过在真实数据集上的比较, 所有实验结果一致证明了本文所提出算法的有效性, AFL-CSEM算法在减少计算和通信开销、降低经济成本的同时, 提升了模型训练的效率与精度, 为环境监测领域的群智感知提供了一种新颖且具有参考价值的解决方案。

关键词: 环境监测; 群智感知; 联邦学习; 自适应算法; 收敛性分析

基金项目: 国家自然科学基金(No.61772196); 湖南省自然科学基金(No.2020JJ4249); 湖南省社会科学成果评审委员会课题重点项目(No.XSP19ZD1005); 湖南省教育厅科学研究重点项目(No.21A0374); 长沙市哲学社会科学规划课题(No.2024CSSKKT31)

中图分类号: TP301; X328

文献标识码: A

文章编号: 0372-2112(2025)03-0821-15

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

DOI: 10.12263/DZXB.20240946

Adaptive Federated Learning Based Crowd Sensing Algorithm for Environmental Monitoring

JIANG Wei-jin^{1,2,3}, DU Xi-chen^{1,2*}, JIANG Yi-rong⁴, YANG Xuan^{2,3}, NIE Cai-yan^{1,2}, LIU Qian^{1,2}

(1. School of Computer Science, Hunan University of Technology and Business, Changsha, Hunan 410205, China;

2. Xiangjiang Laboratory, Changsha, Hunan 410205, China;

3. College of Frontier Intersection, Hunan University of Technology and Business, Changsha, Hunan 410205, China;

4. Hunan University of Information Technology, Changsha, Hunan 410151, China)

Abstract: With the rapid development of industrialization and urbanization, the importance of environmental monitoring is becoming more and more prominent. However, traditional monitoring methods are limited by high costs, difficult layout and maintenance challenges, making it difficult to achieve comprehensive and real-time monitoring. Crowd Sensing, an emerging environmental monitoring method, utilizes widely used highly intelligent devices and integrated sensors for large-scale collection and real-time transmission of environmental data. However, existing studies seldom consider data privacy protection, work balance, and system cost at the same time, which makes it difficult to achieve the expected results in practical applications. To solve this practical problem, this paper proposes a low-cost and high-efficiency method that can be applied to crowd sensing for environmental monitoring (Adaptive Federated Learning based Crowd Sensing algorithm for Environmental Monitoring, AFL-CSEM). Specifically, we first consider the challenges of resource constraints, device heterogeneity, and non-independent and homogeneous distribution of data in the system, and model the system by combin-

ing crowd sensing and federated learning techniques, and train the model locally on user's devices, sharing only the model parameters to effectively protect data privacy. Then, the convergence analysis of the system is carried out, and the convergence bounds of the crowd sensing algorithm based on federated learning are obtained for non-independently and identically distributed data distributions. Then, in order to reduce the impact of device heterogeneity, based on the results of the convergence analysis, an adaptive control method is designed to dynamically adjust the local update frequency and batch size to adapt to the heterogeneous and dynamic monitoring environment. By comparing on real datasets, all the experimental results consistently prove the effectiveness of the proposed algorithm in this paper, and the AFL-CSEM algorithm improves the efficiency and accuracy of model training while reducing the computation and communication overhead and lowering the economic cost. It provides a novel and informative solution for environmental monitoring in resource-constrained edge computing environments.

Key words: environmental monitoring; crowdsensing; federated learning; adaptive algorithm; convergence analysis

Foundation Item(s): National Natural Science Foundation Basic Science Center Project (No.61772196); Hunan Provincial Natural Science Foundation (No.2020JJ4249); Key Project of Hunan Provincial Social Science Achievement Review Committee Subjects (No.XSP19ZD1005); Key Project of Hunan Provincial Department of Education for Science and Technology Research (No.21A0374); Philosophy and Social Sciences Planning Project of Changsha City (No.2024CSSKKT31)

1 引言

随着工业化和城市化进程的加速,有效的环境监测变得尤为重要.传统的监测方法往往依赖于固定的传感器网络和专业监测设备.受限于监测点的布局、设备成本和维护困难等问题^[1],难以实现全面监控.为了弥补传统监测方法的不足,群智感知(Crowded Sensing, CS)技术的运用受到越来越多关注^[2],已经广泛应用于环境监测^[3]、城市规划^[4]、智能农业^[5]、医疗保健^[6]等领域.

作为一种新兴的监测方法,群智感知^[7]利用了普遍使用的高度智能设备,借助5G等无线通信标准的进步,实现环境数据的大规模收集和实时传输.目前使用的群智感知技术仍然存在一些问题,例如数据隐私保护^[8]和数据质量控制^[9].在现有的群体智能感知系统中,原始数据在参与者和中心服务器之间的传输过程中面临泄露风险,这种风险主要来自数据在传输过程中可能遭受的窃听或篡改.同时,由于参与者的自由性和行为不可控,数据质量控制方面存在着数据完整性受损、数据可信度不足和数据噪声等挑战.

联邦学习^[10](Federated Learning, FL)作为一种分布式机器学习方法,允许在不泄漏原始数据情况下,通过协作训练模型,从分布式的数据源中学习全局知识.在环境监测领域,联邦学习可有效解决数据隐私保护^[11]、数据质量控制^[12]和参与度不足^[13]等问题,提高环境监测系统的效率和性能.首先,在数据隐私保护方面,联邦学习采用本地模型训练的策略,即在参与者的本地设备上对模型进行训练,只共享模型参数的更新而不共享原始数据^[14].提高数据的隐私保护水平.其次,联邦学习利用分布式学习和加密技术对模型训练过程进行安全保护,保护数据传输过程,提高安全性.在数据质量控制方面,联邦学习根据参与者贡献度调整其

在模型聚合中的权重,使模型训练趋向于高质量参与者,可有效控制数据质量,提升整体模型的性能和可靠性.

因此,本文将充分利用联邦学习的优势,将其与群智感知方法结合,建立安全和高效的环境监测系统.针对不同参与者的异构问题,本文将考虑联邦学习中的自适应方法,设计一种控制算法在一定经济预算下确定自适应的局部更新频率,确保算法更好贴近异构场景需求,提高训练效率.

本文的主要贡献如下:

(1)深度融合联邦学习高效、高隐私性的分布式计算方式,创新环境监测群智感知方法,构建了环境监测数据的即时获取、快速处理与模型迭代训练模型,有效缓解数据传输压力与中心计算负担,在数据采集、模型训练和隐私保护等关键环节为环境监测提供一体化解决方案.

(2)考虑中心方与参与者动态变化下的时间和能量(资源)优化,构建了时间与能量的加权成本模型,提出自适应资源管理与动态调整策略,最大程度降低计算时间与能量开销.

(3)针对参与者设备异构性和数据非独立同分布的复杂状况,设计了考虑实际训练数据贡献量的聚合方案.在此方案基础上分析模型收敛性,推导出环境监测群智感知在固定更新频率下的收敛上界.以此设计控制算法,依据参与者训练参数(时间、能量等)确定异构参与者每轮聚合的最优更新频率,提升模型训练效率,增强对复杂动态监测环境的适应性.

2 相关工作

2.1 环境监测领域的群智感知

群智感知作为一种极具前途的感知范式,近年来

引起了相当大的关注^[15],随着许多环境监测传感器快速融入并应用于便携智能设备,将这些智能设备的拥有者发展为环境监测群智感知的参与者,能有效解决传统监测手段成本过高和监测范围等限制。

Fascista 等人^[16]提出,众感节点是配备不同类型传感器的通用移动设备,可重复用于不同的环境监测任务,无需部署特定的基础设施,代表一种具有成本效益与可扩展性的环境监测解决方案。然而,一些重要的挑战仍然需要妥善解决,如用户隐私、工作平衡^[17]。

针对环境监测,Bian 等人^[18]提出一种新的社区感知范式(Aggregation-Free spatial-temporal mobile Community Sensing, AFCS),该范式在数据收集环节只需获取目标区域每个子区域的环境信息,而无需聚合社区成员收集的传感器和位置数据。Morselli 等人^[19]分析了一种利用车辆位移和多维随机抽样的方法,过扩展多维随机抽样的最新结果,提出一个用于分析传感器随机分散的车辆人群传感框架,对密度高的区域分配更多的任务,实现区域级别的工作平衡。虽然该文在采样过程和数据处理环节进行了一定隐私保护,但数据的集中处理仍然会引起对隐私的担忧。

隐私保护作为群智感知领域的重要研究内容,现有的方案主要有加密、差分隐私、区块链等,可以改善数据共享中的隐私问题。Zhang 等人^[20]提出了一种基于差分隐私的轨迹隐私保护方法,确保用户在本地处理轨迹信息后上传,降低对可信服务器依赖。在结合区块链的研究中,Tong 等人^[21]通过注册认证、Pedersen 承诺、可链接环签名等技术,实现用户认证、出价信息保护、数据提交安全和激励机制安全。Luo 等人^[22]利用盲签名设计的匿名行为记录证书,设计了基于效用分析的黑名单惩罚措施,精准约束参与者行为,从激励机制层面保障了隐私环境的稳定性。区块链的去中心化特性虽然为群智感知开拓新的研究思路,但其开放性对隐私保护方案提出了新的要求,会一定程度增加成本。联邦学习作为一种同样可融入群智感知的架构,其数据隔离与本地计算的特性在数据收集与分析环节的隐私保护方面具有先天优势。由此思路,Montaser 等人^[23]在工业环境领域探索了基于联邦学习的环境监测方案,验证了联邦学习在接近集中式模型的准确率基础上,能有效保护隐私并具有良好扩展性。不同于工业环境领域适配固定传感器,本文将在更广泛的环境监测领域结合群智感知这一数据收集范式,更为灵活也更为复杂。

2.2 结合联邦学习的群智感知

作为分布式机器学习的一种实用技术,联邦学习能有效改善个体感知欠智能^[24]的群智感知研究现状。这一概念最早由 McMahan 等人^[10]提出,得到了学术界

及工业界的广泛关注,但针对环境监测与群智感知的相关研究较少。环境监测下的群智感知过程中,参与者需要传输大量数据,这不仅容易被通信限制效率,更存在着较大的隐私泄露担忧^[25],联邦学习的分布式学习、数据隐私保护和跨设备学习等特性与环境监测和群智感知十分适配,为保护隐私和降低成本提供了新思路^[26]。

Hu 等人^[27]提出了一种利用区块链技术和联邦学习的新型移动群智感知(Mobile Crowd Sensing, MCS)学习框架,指出引入联邦学习不仅有助于解决 MCS 的主流研究挑战,如质量控制、隐私保护,还对以往研究容易忽略的部分——原始数据传输所消耗的巨大通信资源具有极强的优化作用,进一步降低系统成本。然而,与现有群智感知相比,由于不仅需要搜集数据,还要进行局部模型训练,部分成本不可避免地转移到了参与者身上,因此需要某种方案来平衡参与者工作。

从参与者角度出发,Li 等人^[28]探讨了如何激励掌握丰富高质量数据和强大计算资源的数据持有者参与到联邦学习驱动的群智感知系统。证实了在所提出的激励机制框架内,所有参与者的策略集合能够达到一个稳定状态,即纳什均衡。但该文研究在隐私保护方面具有一定局限性,如中央协调器使用的用于评估本地模型质量的数据来自模型训练的发起者,发起者需要将数据上传到中央协调器,一定程度上存在隐私泄露的风险。

在隐私保护上,群智感知系统中的联邦学习面临两大难题:一方面是任务发起者的隐私问题,另一方面是群智感知参与者的隐私问题。针对任务发起者的隐私,应当尽量减少任务发起所需的初始数据。针对参与者隐私,Zhang 等人^[29]提出一种用于 MCS 中联邦学习的隐私增强聚合,通过将同态密码系统与哈希 Diffie-Hellman 密钥交换协议相结合,设计了一种抗合谋的数据聚合方法,然而,这些加密技术需要进行大量数学运算,在移动设备等资源受限且设备异构的环境中,这些运算时间差异会进一步扩大。因此,需要一种自适应方法来适应不同参与者的资源异构与设备异构。

相关研究对比总结至表 1,这些研究在特定领域中都具有一定优势,但引入联邦学习方法优化环境检测领域的群智感知却鲜有人研究。使用联邦学习技术优化群智感知算法方面虽然已经有部分学者对用户招募、隐私保护等方面进行研究,但仍然缺乏对复杂动态环境的适应性研究^[30],本研究将面对的多种挑战进行综合考量,提出一种自适应联邦学习优化策略,旨在提升环境监测群智感知的性能,使其更贴合实际监测场景的需求。该方法在设计上也考虑到了跨领域的应用潜力,对其他相关领域的发展具有指导和借鉴意义。

表 1 相关研究对比

文献	隐私保护	工作平衡	系统成本
文献[18]	●	○	◐
文献[19]	◐	◐	◐
文献[20]	●	◐	◐
文献[21]	●	●	◐
文献[22]	●	◐	○
文献[23]	●	○	◐
文献[27]	●	○	●
文献[28]	◐	◐	◐
文献[29]	●	○	○
AFL-CSEM(ours)	●	●	●

表 2 本文主要符号说明

符号	说明
$F(\mathbf{w})$	全局损失函数
$F_i(\mathbf{w})$	P_i 处局部损失函数
$f_j(\mathbf{w})$	数据样本 j 的损失函数
$\mathbf{w}(t)$	第 t 次迭代中的全局模型
$\mathbf{w}_i(t)$	第 t 次迭代中, P_i 处局部模型
\mathbf{w}^f	学习结束后获得的最终模型
\mathbf{w}^*	使 $F(\mathbf{w})$ 最小化的最优模型
η	梯度下降步长
t	迭代索引
τ	2个全局聚合之间本地迭代次数
T	每个节点的本地迭代总次数
K	全局聚合次数
P	总预算
Q_i	P_i 训练的数据量
c_i	P_i 训练1个数据消耗的时间资源
e_i	P_i 训练1个数据消耗的能量资源
c	CSP全局聚合1次消耗的时间资源
e	CSP全局聚合1次消耗的能量资源
S	成本分析权重
ρ	Lipschitz系数
β	smooth系数
δ	梯度散度
$h(\tau)$	分布式梯度下降与集中式梯度下降的模型差距
φ	控制参数
$G(\tau)$	控制目标

3 基于自适应联邦学习的环境监测群智感知

3.1 系统框架

在传统环境监测系统的基础上,本文创新设计了结合联邦学习的环境监测群智感知架构,首次在群智感知背景下进行了联邦学习收敛性分析并设计了自适应算法,使用的主要符号说明见表2.

系统模型如图1所示,有3种类型的实体,实体的角色说明和系统运行逻辑如下.

任务请求者 (Task Requester, TR): 政府的环保部门、企业或科研机构等,目的是获取更丰富的数据和更准确的分析结果以制定决策、优化服务或推动科学研究.

任务参与者 (Task Participant, TP): 配备了智能设备的用户,在不同环境中搜集数据以建立本地数据集 D_i ,并在本地进行模型训练.

群智感知服务提供者 (Crowdsensing Service Pro-

vider, CSP): 专业的环境数据处理平台或具备强大计算能力和数据分析能力的机构,在每个迭代周期选取参与者、广播模型与参数、接收并聚合本地模型,计算控制参数等.

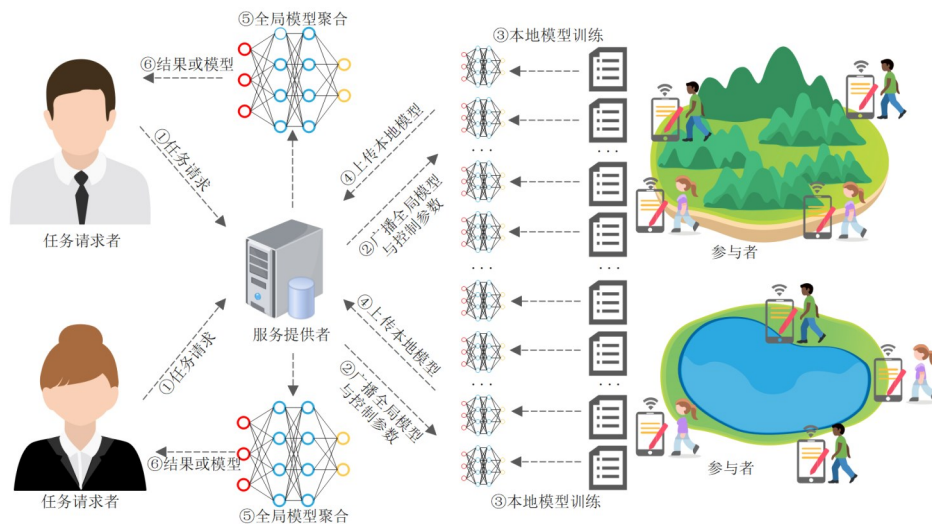


图 1 系统模型图

Step 1: TR 向 CSP 发起任务请求;

Step 2: CSP 接受任务请求, 确定初始模型, 并在每个迭代周期中选择一些活跃的参与者 P_i , 广播全局模型与控制参数;

Step 3: P_i 使用本地数据集 D_i 进行模型训练, 迭代本地模型;

Step 4: P_i 在一定训练轮次后将本地模型 $w_i(t)$ 上传给 CSP;

Step 5: 在接收到第 t 轮每个参与者 P_i 返回的模型 $w_i(t)$ 后, CSP 将其聚合成全局模型并计算控制参数;

Step 6: 重复 Step 2 至 Step 5, 直至达到预设停止条件, 将最终结果或模型返回给任务请求者。

3.2 问题定义

本地模型的参数是通过训练数据学习得到的. 每个训练数据样本由输入向量 x_j 和期望输出标量 y_j 组成. 模型在参数向量 w 上定义了损失函数, 该函数衡量模型在训练数据样本上的误差. 训练过程旨在通过最小化训练数据样本集合上的损失函数 $f(w, x_j, y_j)$, 简写为 $f_j(w)$ 来优化模型的参数. 假设有 N 个具有本地样本 D_i 的参与者 P_i , 每个参与者数据样本集合上的损失函数为

$$F_i(w) = \frac{1}{|D_i|} \sum_{j \in D_i} f_j(w) \quad (1)$$

则全局损失函数定义为

$$F(w) = \frac{\sum_{i=1}^N |D_i| F_i(w)}{|D|} \quad (2)$$

其中, $|\cdot|$ 表示集合的大小, D 为宏观上的全局数据集, $D \triangleq \sum_{i=1}^N D_i$. 相较于联邦学习, 群智感知中的参与者设备性能差异更加突出, 因此, 重新定义全局损失函数:

$$F(w) = \frac{\sum_{i=1}^N Q_i |F_i(w)|}{|Q|} \quad (3)$$

其中, $Q = \sum_{i=1}^N Q_i$, Q_i 为一个聚合轮次中 P_i 的训练量. 由此, 分布式梯度下降的学习目标定义为最小化 $F(w)$, 即寻找最优模型 w^* :

$$w^* \triangleq \operatorname{argmin} F(w) \quad (4)$$

由于模型的复杂性, 可能存在多个局部最小值, 或者目标函数非常不规则, 很难找到一个全局最优解. 因此, 在本文中采用一个典型的分布式梯度下降算法求解. 模型迭代总体可分为 2 个步骤, 第 1 个步骤为本地更新, 每个参与者 P_i 本地维护一个局部模型参数 $w_i(t)$, 其中, $i=0, 1, \dots, N$ 为参与者索引, $t=0, 1, \dots, T$ 为迭代索

引. $t=0$ 时, 所有参与者初始化 $w_i(0) = w(0)$; $t \neq 0$ 时, 基于 $w_i(t-1)$ 由下述局部损失函数的梯度下降更新公式计算 $w_i(t)$, 称为本地模型更新:

$$w_i(t) = \tilde{w}_i(t-1) - \eta \nabla F_i(\tilde{w}_i(t-1)) \quad (5)$$

在经过一定次数的本地更新之后进行第 2 个步骤, 即群智感知服务提供者 CSP 通过聚合器进行全局聚合, 将各参与者上传的本地模型 $w_i(t)$ 进行加权平均, 计算出 $w(t)$ 并广播给全体参与者, 同时参与者本地模型更新为 $w_i(t) = w(t)$, 经典的加权聚合算法如下:

$$w(t) = \frac{\sum_{i=1}^N D_i w_i(t)}{D} \quad (6)$$

与损失函数聚合的考量相同, 考虑到群智感知参与者的设备异构性, 采用以下聚合方案:

$$w(t) = \frac{\sum_{i=1}^N Q_i w_i(t)}{Q} \quad (7)$$

综上, 对于参与者 P_i 而言, 每个迭代应分为以下 2 种情况: (1) 迭代轮次 t 进行全局聚合, 则 $\tilde{w}_i(t) = w(t)$; (2) 迭代轮次 t 没有进行全局聚合, 则 $\tilde{w}_i(t) = w_i(t)$.

为了研究不同更新间隔对系统的影响, 定义在一个群智感知任务中参与者 P_i 共执行 T 次本地模型迭代, 群智感知服务提供者 CSP 共执行 K 次聚合, 则参与者 P_i 每执行 $\tau = T/K$ 步本地更新, CSP 进行一次全局聚合, 其中 T 为 τ 的整数倍. 分布式梯度下降如算法 1 所示.

算法 1 分布式梯度下降

输入: τ, T

输出: w^f

1. 初始化 w^f , 每个 P_i 的 $w_i(t)$ 与 $\tilde{w}_i(t)$
2. FOR $t \in [1, T]$ DO
3. 对于并行的每个 P_i 使用式(5)计算本地更新
4. IF $t \% \tau = 0$ THEN
5. CSP 使用式(7)聚合全局模型 $w(t)$
6. P_i 更新本地模型 $\tilde{w}_i(t) = w(t)$
7. ELSE
8. P_i 更新本地模型 $\tilde{w}_i(t) = w_i(t)$
9. END IF
10. END FOR

在群智感知系统中, 本地的模型训练过程可能会消耗参与者大量的资源, 为群智感知服务提供者增加了潜在成本压力, 这些资源包括数据采集与计算相关的时间、金钱、精力等成本. 为了寻求感知平台的利益最大化, 同时减少系统成本, 有必要对每个参与者模型训练资源进行限制, 这在资源异构的边缘环境中尤为重要. 因此, 对群智感知系统中使用的上述分布式梯度

下降学习方法,定义优化问题为在给定资源限制下寻求使得全局损失函数最小化的 T 与 τ ,使得由算法 1 得到的 \mathbf{w}^f 满足:

$$\mathbf{w}^f \triangleq \operatorname{argmin}_{\mathbf{w} \in \{\mathbf{w}(k\tau), k=0,1,\dots,K\}} F(\mathbf{w}) \quad (8)$$

在第 k ($k < K$) 次全局聚合完成后,为了计算全局损失值 $F(\mathbf{w}(k\tau))$,需要参与者 P_i 在 $k+1$ 次通信时额外发送 $F_i(\mathbf{w}(k\tau))$ 并通过式(3)进行计算,为了计算最后第 K 次聚合的全局模型损失值,则需要额外进行第 $K\tau+1$ 轮局部和全局更新.

为了最大化群智感知系统的收益,本文构建了更贴合实际场景的加权成本模型.假设选取 N 个参与者,每一个参与者 P_i 的每个数据训练消耗 c_i 个单位的时间资源与 e_i 个单位的能量资源,CSP 在全局模型聚合时消耗 c 个单位时间资源与 e 个单位能量资源^[31],则 T 轮后的 N 个参与者与 CSP 的时间成本总和 C_{all} 为

$$C_{\text{all}} = \sum_{i=1}^N (T+1)c_i Q_i + (K+1)c \quad (9)$$

经过 T 轮后的 N 个参与者与 CSP 的能量消耗总和 E_{all} 为

$$E_{\text{all}} = \sum_{i=1}^N (T+1)e_i Q_i + (K+1)e \quad (10)$$

记 P 为资源总预算,引入成本分析权重 $S \in [0,1]$,计算总成本 M_{all} 如下:

$$\begin{aligned} & \min F(\mathbf{w}^f)\tau \\ & K \in \{1,2,\dots,T\} \\ & \text{s.t. } M_{\text{all}} = C_{\text{all}}(N,T)S + (1-S)E_{\text{all}}(N,T) \leq P \\ & T = K\tau \end{aligned} \quad (11)$$

即在一定的成本预算下,最大化训练准确率,本文将研究 τ 、 T 和 K 如何影响损失函数 $F(\mathbf{w}^f)$,并在随后分析分布式梯度下降(算法 1)的收敛界,利用该收敛界近似求解式(11),并提出一种自适应选择 τ 和 T 的最优值以实现最优资源利用的优化算法.

3.3 收敛性分析

本节将对算法 1 进行收敛性分析.本节首先定义了算法中使用的关键参数和假设,然后通过数学证明来展示算法的收敛性,并最终计算出 $F(\mathbf{w}^f) - F(\mathbf{w}^*)$ 的上界.

首先将算法 1 划分 K 个聚合区间,定义 $[k]$ 表示第 k 个聚合区间,每个区间的末尾进行全局聚合.引入 $\mathbf{v}_{[k]}(t)$ 表示在 $[k-1]$ 区间聚合的全局模型基础上在 $[k]$ 区间训练的中心梯度下降模型,满足:

$$\mathbf{v}_{[k]}(t) = \mathbf{w}(t-1) - \eta \nabla F(\mathbf{v}_{[k]}(t-1)) \quad (12)$$

其中, $\mathbf{w}(t)$ 是由式(7)定义的聚合模型参数,因为全局

聚合或初始化是在 $(k-1)\tau$ 轮迭代进行的,因此,对于所有的参与者 P_i 有 $\tilde{\mathbf{w}}_i(k-1)\tau = \mathbf{w}(k-1)\tau$.此外,还定义 δ_i 来描述局部损失函数和全局损失函数的差值,即对于任意的 \mathbf{w} 和 P_i 有

$$\|\nabla F_i(\mathbf{w}) - \nabla F(\mathbf{w})\| \leq \delta_i \quad (13)$$

为了综合考量每个 P_i 的 δ_i ,定义:

$$\delta \triangleq \frac{\sum_{i=1}^N D_i \delta_i}{D} \quad (14)$$

通过以上定义,寻找算法 1 的收敛界.第 1 步是找到每个 $[k]$ 末尾处分布式梯度下降与集中式梯度下降的差距;第 2 步将分析 $\mathbf{v}_{[k]}(k\tau)$ 的收敛性间接得到 $\mathbf{w}(k\tau)$ 的收敛界.为了便于分析,做出以下假设.

假设 1

(1) $F_i(\mathbf{w})$ 为凸函数.

(2) $F_i(\mathbf{w})$ 是 ρ -Lipschitz 的,即对于任意的 \mathbf{w}, \mathbf{w}' 有 $\|F_i(\mathbf{w}) - F_i(\mathbf{w}')\| \leq \rho \|\mathbf{w} - \mathbf{w}'\|$.

(3) $F_i(\mathbf{w})$ 是 β -smooth 的,即对于任意 \mathbf{w}, \mathbf{w}' 有 $\|\nabla F_i(\mathbf{w}) - \nabla F_i(\mathbf{w}')\| \leq \beta \|\mathbf{w} - \mathbf{w}'\|$.

由以上假设以及三角不等式可得 $F(\mathbf{w})$ 是凸的、 ρ -Lipschitz 以及 β -smooth 的.由此可证引理 1.

引理 1 对于任意区间 $[k]$, $t \in [(k-1)\tau, k\tau]$, 有

$$\|\tilde{\mathbf{w}}_i(t) - \mathbf{v}_{[k]}(t)\| \leq g_i(t - (k-1)\tau) \quad (15)$$

其中,设 a 表示变量, $g_i(a)$ 定义为

$$g_i(a) \triangleq \frac{\delta_i}{\beta} ((\eta\beta + 1)^a - 1) \quad (16)$$

证明 当 $t = (k-1)\tau$ 时,由 $\mathbf{v}_{[k]}(t)$ 定义可知,在每个区间 $[k]$ 的最初 $\mathbf{v}_{[k]}(t) = \mathbf{w}_i(t)$,又因为当 $t \in [(k-1)\tau, k\tau]$ 时,这个区间内没有发生全局聚合,即 $\tilde{\mathbf{w}}_i(t) = \mathbf{w}_i(t)$,因此 $\|\tilde{\mathbf{w}}_i(t) - \mathbf{v}_{[k]}(t)\| = g_i(0)$,引理 1 成立.

用数学归纳法,假设:

$$\|\tilde{\mathbf{w}}_i(t-1) - \mathbf{v}_{[k]}(t-1)\| \leq g_i(t-1 - (k-1)\tau) \quad (17)$$

那么对于 $t \in ((k-1)\tau, k\tau)$,引入该假设有

$$\begin{aligned} & \|\tilde{\mathbf{w}}_i(t) - \mathbf{v}_{[k]}(t)\| \\ &= \|\tilde{\mathbf{w}}_i(t-1) - \mathbf{v}_{[k]}(t-1)\| \\ & \quad + \eta \|\nabla F_i(\tilde{\mathbf{w}}_i(t-1)) - \nabla F_i(\mathbf{v}_{[k]}(t-1))\| \\ & \quad + \eta \|\nabla F_i(\mathbf{v}_{[k]}(t-1)) - \nabla F(\mathbf{v}_{[k]}(t-1))\| \\ & \leq g_i(t - (k-1)\tau) \end{aligned} \quad (18)$$

由上述归纳法,引理 1 证毕,利用其结果即可证明定理 1.

定理 1 对于任意区间 $[k]$, 时间节点 $t \in$

$[(k-1)\tau, k\tau]$, 有

$$\|\mathbf{w}(t) - \mathbf{v}_{[k]}(t)\| \leq h(t - (k-1)\tau) \quad (19)$$

其中, 对于任意的 $a=1, 2, \dots, T$ 有

$$h(a) = \frac{\delta}{\beta}((\eta\beta+1)^a - 1) - \eta\delta a \quad (20)$$

此外, 由于 $F(\cdot)$ 是 ρ -Lipschitz 的, 故

$$\begin{aligned} \|\mathbf{w}(t) - \mathbf{v}_{[k]}(t)\| &= \left\| \mathbf{w}(t-1) - \eta \frac{\sum_{i=1}^N Q_i \nabla F_i(\tilde{\mathbf{w}}_i(t-1))}{Q} - \mathbf{v}_{[k]}(t-1) + \eta \nabla F(\mathbf{v}_{[k]}(t-1)) \right\| \\ &\leq \left\| \mathbf{w}(t-1) - \mathbf{v}_{[k]}(t-1) \right\| + \eta\beta \left(\frac{\sum_{i=1}^N Q_i g_i(t-1 - (k-1)\tau)}{Q} \right) \\ &= \left\| \mathbf{w}(t-1) - \mathbf{v}_{[k]}(t-1) \right\| + \eta\delta \left((\eta\beta+1)^{t-1-(k-1)\tau} - 1 \right) \end{aligned} \quad (23)$$

其中, 最后一步等式成立是因为对于任意的 a 有

$$\begin{aligned} \eta\beta \left(\frac{\sum_{i=1}^N Q_i g_i(a)}{Q} \right) &= \eta \left(\frac{\sum_{i=1}^N Q_i \delta_i}{Q} \right) \left((\eta\beta+1)^a - 1 \right) \\ &= \eta\delta \left((\eta\beta+1)^a - 1 \right) \end{aligned} \quad (24)$$

对于式(23), 将式子最开始与最末尾移项可得:

$$\begin{aligned} \|\mathbf{w}(t) - \mathbf{v}_{[k]}(t)\| - \|\mathbf{w}(t-1) - \mathbf{v}_{[k]}(t-1)\| \\ \leq \eta\delta \left((\eta\beta+1)^{t-1-(k-1)\tau} - 1 \right) \end{aligned} \quad (25)$$

定义 $\theta(t) = \|\mathbf{w}(t) - \mathbf{v}_{[k]}(t)\| - \|\mathbf{w}(t-1) - \mathbf{v}_{[k]}(t-1)\|$

则

$$\begin{aligned} \theta(t) + \theta(t-1) + \dots + \theta(1) \\ \leq \eta\delta \sum_{y=(k-1)\tau+1}^t \left((\eta\beta+1)^{y-1-(k-1)\tau} - 1 \right) \\ = \frac{\delta}{\beta} \left((\eta\beta+1)^{t-(k-1)\tau} - 1 \right) (\eta\beta+1)^{t-(k-1)\tau} - 1 \\ - \eta\delta(t - (k-1)\tau) \\ = h(t - (k-1)\tau) \end{aligned} \quad (26)$$

即 $\|\mathbf{w}(t) - \mathbf{v}_{[k]}(t)\| \leq h(t - (k-1)\tau)$, 定理 1 证毕.

由定理 1 可知在每个迭代区间 $[k]$ 之间分布式梯度下降与集中式梯度下降的差异存在一个上界 $h(t - (k-1)\tau)$, 为了全面评估算法的全局收敛性能, 需要进一步证明定理 2, 这将为研究提供全局损失函数与最优解之间差异的上界, 确保算法的总体效率和实用性. 为证明定理 2, 首先引入引理 2^[32]:

引理 2 当满足以下条件时:

(1) $\eta \leq \frac{1}{\beta}$;

$$F(\mathbf{w}(t)) - F(\mathbf{v}_{[k]}(t)) \leq \rho h(t - (k-1)\tau) \quad (21)$$

证明 由式(5)和式(7), 可得

$$\mathbf{w}(t) = \mathbf{w}(t-1) - \eta \frac{\sum_{i=1}^N Q_i \nabla F_i(\tilde{\mathbf{w}}_i(t-1))}{Q} \quad (22)$$

对于 $t \in [(k-1)\tau, k\tau]$, 有

- (2) $\eta\phi - \frac{\rho h(\tau)}{\tau\epsilon^2} > 0$;
- (3) $F(\mathbf{v}_{[k]}(k\tau)) - F(\mathbf{w}^*) \geq \epsilon$;
- (4) $F(\mathbf{w}(T)) - F(\mathbf{w}^*) \geq \epsilon$;

对于 $\epsilon > 0$, 定义

$$\varphi = \omega \left(1 - \frac{\beta\eta}{2} \right), \omega = \min_{k=1,2,\dots,k} \frac{1}{\|\mathbf{v}_{[k]}((k-1)\tau) - \mathbf{w}^*\|^2},$$

算法 1 迭代 T 次后的收敛上界为

$$F(\mathbf{w}(T)) - F(\mathbf{w}^*) \leq \frac{1}{T \left(\eta\phi - \frac{\rho h(\tau)}{\tau\epsilon^2} \right)} \quad (27)$$

定理 2 当 $\eta \leq \frac{1}{\beta}$ 时, 有

$$F(\mathbf{w}^l) - F(\mathbf{w}^*) \leq \frac{1}{2\eta\phi T} \sqrt{\frac{1}{4\eta^2\phi^2 T^2} + \frac{\rho h(\tau)}{\eta\phi\tau}} + \rho h(\tau) \quad (28)$$

证明 将伯努利不等式 $(1+n)^a \geq 1+na (n>1)$ 代入式(20)可知:

$$h(a) = \frac{\delta}{\beta}((\eta\beta+1)^a - 1) - \eta\delta a \geq \frac{\delta}{\beta}(\eta\beta a) - \eta\delta a = 0 \quad (29)$$

又因为 ρ 是由二范数得来的 Lipschitz 系数, 所以 $\rho h(\tau) \geq 0$. 当 $\rho h(\tau) = 0$ 时, 可以选择足够小但大于 0 的 ϵ 以满足引理 2 的条件 (2)~(4), 代入式(27)可得 $F(\mathbf{w}(T)) - F(\mathbf{w}^*) \leq \frac{1}{T\eta\phi}$, 代入式(28)合并后可得

$$F(\mathbf{w}^l) - F(\mathbf{w}^*) \leq \frac{1}{T\eta\phi},$$

可以发现两式右侧相等. 当 $\rho h(\tau) > 0$ 时, 令 ϵ_0 满足:

$$\varepsilon_0 = \frac{1}{T \left(\eta\varphi - \frac{\rho h(\tau)}{\tau \varepsilon_0^2} \right)} \quad (30)$$

移项、约分、合并、代入求根公式并舍去负值可以解得

$$\varepsilon_0 = \frac{1}{2\eta\varphi T} + \sqrt{\frac{1}{4\eta^2\varphi^2 T^2} + \frac{\rho h(\tau)}{\eta\varphi\tau}} \quad (31)$$

假设存在满足引理2条件(3)和条件(4)的 ε 有 $\varepsilon > \varepsilon_0$,由引理2可知 $F(\mathbf{w}(T)) - F(\mathbf{w}^*) \leq \varepsilon_0$,显然这与条件(4)矛盾,因为 $\varepsilon \leq F(\mathbf{w}(T)) - F(\mathbf{w}^*) \leq \varepsilon_0$ 在 $\varepsilon > \varepsilon_0$ 条件下无法成立,所以 ε 无法同时满足引理2条件(3)和条件(4).这意味着存在 k 有 ε_0 满足 $F(\mathbf{v}_{[k]}(k\tau)) - F(\mathbf{w}^*) \leq \varepsilon_0$ 或 $F(\mathbf{w}(T)) - F(\mathbf{w}^*) \leq \varepsilon_0$,记为

$$\min \left\{ \min_{k=1,2,\dots,K} F(\mathbf{v}_{[k]}(k\tau)); F(\varepsilon_0(T)) \right\} - F(\mathbf{w}^*) \leq \varepsilon_0 \quad (32)$$

由定理1可知对于任意的 k ,有 $F(\mathbf{w}(k\tau)) \leq F(\mathbf{v}_{[k]}(k\tau)) + \rho h(\tau)$,将2个不等式相加可得:

$$\min \left\{ \min_{k=1,2,\dots,K} F(\mathbf{v}_{[k]}(k\tau)); F(\mathbf{w}(T)) \right\} - F(\mathbf{w}^*) + F(\mathbf{w}(k\tau)) \leq \varepsilon_0 + F(\mathbf{v}_{[k]}(k\tau)) + \rho h(\tau) \quad (33)$$

理论上,集中式梯度下降的收敛速度更快,那么在相同的迭代次数下,它会达到更低的损失值,所以得到:

$$\min_{k=1,2,\dots,K} F(\mathbf{w}(k\tau)) - F(\mathbf{w}^*) \leq \varepsilon_0 + \rho h(\tau) \quad (34)$$

结合式(8)和式(31)即可使定理2证毕.在式(20)中不难发现, $h(\tau)$ 总是大于等于0并且不下降,与 δ 成比例.因此,可以直观看到在给出的局部更新步骤总数 T 后,在 τ 和 δ 较大时,最优间隔会变大.对于给定的 τ 和 δ ,当 T 偏大时,最优间隔变小.在 $\tau=1$ 时,得出 $h(\tau)=0$,最优性间隔收敛到0,即 T 趋于无穷.当 $\tau>1$ 时,有 $h(\tau)>0$,从式(28)可以看出,在这种情况下,当 T 趋于无穷时,收敛性只能保障在不为零的最佳性间隔,这意味着资源消耗会很大.但是,群智感知任务在时间资源预算被限制时,在有限次数的迭代之后训练就会结束,为满足式(11)的需求, T 的值是有限制的,因此,研究需要减少全局聚合的频率,使CSP在本地模型进行一定轮次的训练后达到较高水平再聚合,在给定资源的条件下得到更优的最终模型.

3.4 控制算法

首先,假设每个参与者 P_i 训练1个数据的单位时间资源 b 与单位能量资源 μ 以及1个 $[k]$ 内训练的参数量 Q_i 是已知的,然后求解 τ 和 T 的值,考虑成本权重 S 、全

局模型聚合消耗资源量 b 和其他一些参数未知且可能随时间变化的实际场景,提出一种动态调整聚合频率 τ 值的控制算法.

由于式(28)中的 $F(\mathbf{w}^*)$ 可以看作一个较小的常数,可以把式(11)近似为

$$\begin{aligned} \min_{k=1,2,\dots,K} \frac{1}{2\eta\varphi T} + \sqrt{\frac{1}{4\eta^2\varphi^2 T^2} + \frac{\rho h(\tau)}{\eta\varphi\tau}} + \rho h(\tau), \\ \text{s.t. } M_{\text{all}} = K \leq R, T = K\tau \\ R = \frac{P - S \sum_{i=1}^N c_i Q_i - (1-S) \sum_{i=1}^N e_i Q_i - Sc + Se}{\tau \sum_{i=1}^N Q_i (Sc_i + e_i - Se_i) + e - Se} \end{aligned} \quad (35)$$

显然,式(35)中的目标函数随着训练轮次 T 的增加而减少,因为 $T=K\tau$.即 T 与 K 正相关,所以目标函数也与 K 成反比,又因为 K 的上界为 R ,因此最优的 K 取值应为 $K^*=R$,为了便于分析,忽略向下取整运算,将 $T=K\tau \approx R\tau$ 代入式(35)得到:

$$G(\tau) = \frac{1}{2\eta\varphi R\tau} + \sqrt{\frac{1}{4\eta^2\varphi^2 R^2\tau^2} + \frac{\rho h(\tau)}{\eta\varphi\tau}} + \rho h(\tau) \quad (36)$$

由此可以定义 τ 的最优解为

$$\tau^* = \underset{\tau \in \{1,2,\dots,\tau_{\max}\}}{\operatorname{argmin}} G(\tau) \quad (37)$$

则最优 T 为 $T^*=K^*\tau^*=R\tau^*$.由式(37)可以在一定范围内线性搜索 τ^* ,理论上,当资源预算趋向于无穷时,分布式梯度下降的效果应该无限接近于集中式梯度下降,即 $\lim_{P \rightarrow \infty} \tau^* = 1$.

3.5 基于自适应联邦学习的环境监测群智感知算法

根据上述理论与分析,本小节将给出完整算法,这个算法的核心思想是通过实时估计关键参数并根据资源消耗情况调整 τ^* ,平衡资源消耗和模型训练性能.算法2和算法3将分别给出CSP与 P_i 的实施过程.

在CSP端,对于任务请求者TR拟定的环境监测任务,首先初始化模型与算法的关键参数:设置初始的 τ^* 为1,迭代索引 t 为0,资源计数器 M_{all} 为0.初始化模型参数 $\mathbf{w}(0)$ 为一个随机值.设置最终模型 \mathbf{w}^f 为当前初始模型 $\mathbf{w}(0)$.这些初始化是为了保障第1轮计算的顺利进行,然后开始重复执行的循环.CSP将当前模型参数 $\mathbf{w}(t)$ 和 τ^* 发送给所有参与的节点 P_i ,更新 t_0 为当前的迭代索引 $t_0 + \tau^*$,记录上一次发送模型参数的时间.更新时间计数器 t 为 $t + \tau^*$,表示在 τ^* 轮本地训练后进行全局聚合.从每个节点 P_i 收集资源消耗参数 c_i, e_i ,训练数据量 Q_i 和模型参数 $\mathbf{w}_i(t)$,根据式(7)计算全局模型参数 $\mathbf{w}(t)$.如果 t_0 大于0,即已经进行了至少1轮训练,则开始收集性能指标.从每个节点收集局部损失函数 $F_i(\mathbf{w}(t_0))$,梯度 $\nabla F_i(\mathbf{w}(t_0))$,以及参数 ρ_i 和 β_i .根据式(2)

算法 2 CSP端自适应联邦学习环境监测群感知算法输入:总预算 P ,控制参数 φ, τ^* 的搜索范围 τ_{\max} 输出:最终模型 \mathbf{w}^f

```

1. 初始化  $\tau^* = 1, t = 0, M_{\text{all}} = 0$ 
2. 初始化  $\mathbf{w}(0)$  为随机量
3. 初始化  $\mathbf{w}^f = \mathbf{w}(0)$ 
4. REPEAT
5.   发送  $\mathbf{w}(t)$  和  $\tau^*$  给每个  $P_i$ 
6.    $t_0 = t //$ 更新索引
7.    $t = t + \tau^* // \tau^*$  轮训练后聚合
8.   从  $P_i$  处收集  $c_i, e_i, Q_i, \mathbf{w}_i(t)$ , 由式(7)计算  $\mathbf{w}(t)$ 
9.   IF  $t_0 > 0$  THEN
10.    从  $P_i$  处收集  $F_i(\mathbf{w}(t_0)), \nabla F_i(\mathbf{w}(t_0)), \rho_i, \beta_i$ 
11.    由式(2)计算  $F(\mathbf{w}(t_0))$ 
12.    IF  $F(\mathbf{w}(t_0)) < F(\mathbf{w}^f)$  THEN
13.      $\mathbf{w}^f = \mathbf{w}(t_0)$ 
14.    IF STOP FLAG 已设置 THEN
15.     BREAK
16.    估计  $\rho = \frac{1}{Q} \sum_{i=1}^N Q_i \rho_i$ 
17.    估计  $\beta = \frac{1}{Q} \sum_{i=1}^N Q_i \beta_i$ 
18.    计算  $\nabla F(\mathbf{w}(t_0)) = \frac{1}{Q} \sum_{i=1}^N Q_i \nabla F_i(\mathbf{w}(t_0))$ 
19.    估计  $\delta_i = \|\nabla F_i(\mathbf{w}(t_0)) - \nabla F(\mathbf{w}(t_0))\|$ 
20.    计算  $\delta = \frac{1}{Q} \sum_{i=1}^N \delta_i$ 
21.    在  $[1, \tau_{\max}]$  内由式(37)线性搜索  $\tau^*, \tau = \tau^*$ 
22.   END IF
23.   由式(11)计算  $M_{\text{all}}$ 
24.   IF  $M_{\text{all}} \geq P$  THEN
25.    将  $\tau^*$  减小到可能值, 设置 STOP FLAG
26. END REPEAT
27. 向所有  $P_i$  发送  $\mathbf{w}(t)$ 
28. 从每个节点收集  $F_i(\mathbf{w}(t))$ 
29. 由式(3)计算  $F(\mathbf{w}(t))$ 
30. IF  $F(\mathbf{w}(t)) < F(\mathbf{w}^f)$  THEN
31.   $\mathbf{w}^f = \mathbf{w}(t)$ 
32. END IF

```

计算全局损失函数 $F(\mathbf{w}(t_0))$. 如果当前的全局损失 $F(\mathbf{w}(t_0))$ 小于最佳全局损失 $F(\mathbf{w}^f)$, 则更新最佳模型 \mathbf{w}^f 为当前模型 $\mathbf{w}(t_0)$. 如果此时已设置了停止标志, 则退出循环. 为了优化训练过程, 算法将估计全局 Lipschitz 系数 ρ 和 smooth 系数 β . 计算全局梯度 $\nabla F_i(\mathbf{w}(t_0))$, 估计每个节点的梯度偏差 δ_i 和全局偏差 δ .

在给定的搜索范围 $[1, \tau_{\max}]$ 内, 使用式(37)通过线性搜索找到最优的 τ^* . 然后, 计算所有资源的总消耗 M_{all} . 如果总消耗 M_{all} 大于或等于总预算 P , 则减小 τ^* 的值, 并设置停止标志. 最终, CSP 将向所有节点发送更新后的模型参数 $\mathbf{w}(t)$. 从每个节点收集局部损失函数 $F_i(\mathbf{w})$. 根据式(3)计算全局损失函数 $F_i(\mathbf{w}(t))$. 如果当前的全局损失 $F_i(\mathbf{w}(t))$ 小于最佳全局损失 $F(\mathbf{w}^f)$, 则更新最佳模型 \mathbf{w}^f 为当前模型 $\mathbf{w}(t)$.

每次循环中的操作包括发送和接收数据、计算全局模型参数、评估模型性能、估计系数、搜索最优 τ^* 以及计算资源消耗等. 其中, 计算全局模型参数的时间复杂度、评估模型性能的时间复杂度、估计系数、计算资源消耗的时间复杂度均为 $O(N)$, 而搜索最优 τ^* 的时间复杂度与式(36)和式(37)相关, 式(36)中, η, φ 为超参数, τ 是要线性搜索的目标, ρ 是 Lipschitz 系数, 由参与者在算法 3 中计算并上传, 在算法 2 第 16 行已求出, 这里视为常数, $h(\tau)$ 由式(20)定义. 式(20)中 δ, β, η 均可视为常数, τ 仍然要线性求解的目标, 所以式(36)中的 $h(\tau)$ 的时间复杂度可以看作 $O(1)$. 对于 R , R 定义于式(35), 分子中有 $2N$ 个求和项, 分母中有 N 个求和项, 整体计算 R 的时间复杂度主要由这些求和操作决定, 为 $O(2N)$, 所以式(36)的总体计算复杂度为 $O(N)$. 综上, 由于算法 2 在 K 个全局聚合轮次中都要在 $[1, 2, \dots, \tau_{\max}]$ 内线性搜索 τ^* 的值, 所以算法 2 的总体时间复杂度为 $O(KN\tau_{\max})$.

在最坏情况下, 假设 τ_{\max} 非常大, 例如 $\tau_{\max} = N^b$, b 为常数, 那么算法 2 的时间复杂度可能会达到 $O(KN^{b+1})$, 但这种情况一般不太可能发生, 因为 τ^* 的值往往在 100 以内就能找到.

算法 2 的空间复杂度主要源于模型参数和数据收集等. 其中, 假设模型的维数为 m , 则模型参数存储的空间复杂度为 $O(m)$. 从每个 P_i 处收集 c_i, e_i 等变量时, 由于参与者数量为 N , 则这一部分的空间复杂度为 $O(N)$. 其余的参数存储占用的空间相对较少, 线性搜索也不需要额外开辟空间. 最后, 由于模型的维数往往小于参与者数量, 所以总的空间复杂度可以视为 $O(N)$. 假设系统需要存储大量中间计算结果或者由于某种原因导致额外的大量数据被存储, 那么空间复杂度可能会更高. 但在一般合理的算法执行情况下, 这种情况不太可能发生, 所以通常认为算法 2 的空间复杂度在最坏情况下仍为 $O(N)$.

算法 3 在每个参与者 P_i 上运行, 负责执行本地模型的训练和参数估计. 在主要的训练循环中, 节点接收来自 CSP 的全局模型参数 $\mathbf{w}(t)$ 和聚合频率 τ^* , 使用本地数据进行 τ^* 次局部更新, 生成局部模型 $\mathbf{w}_i(t)$. 在

每次更新中, P_i 记录当前迭代索引 $t_0=t$, 如果 $t>0$, 则估计 Lipschitz 系数 ρ_i 与 smooth 系数 β_i , 这些指标反映了模型在本地数据上的表现和平滑性. 在接下来的训练轮中, 参与者在 τ^* 内多次迭代本地模型 $w_i(t)$, 并记录资源消耗 c_i, e_i, Q_i , 这些信息会定期发送给 CSP. 最后, 如果已经设置了停止标签, 算法将退出循环.

算法3 P_i 端自适应联邦学习环境监测群智感知算法

输入: $\tau^*, w(t)$

输出: $F_i(w(t)), w_i(t), c_i, e_i, Q_i$

1. 初始化 $t=0$;

2. REPEAT

3. 从 CSP 接收 $w(t)$ 与 τ^*

4. $\tilde{w}_i(t) = w(t)$

5. $t_0 = t$ //更新索引

6. IF $t > 0$ THEN

$$7. \quad \rho_i = \frac{\|F_i(w_i(t)) - F_i(w(t))\|}{\|w_i(t) - w(t)\|}$$

$$8. \quad \beta_i = \frac{\|\nabla F_i(w_i(t)) - \nabla F_i(w(t))\|}{\|w_i(t) - w(t)\|}$$

9. FOR $\tau = 1, 2, \dots, \tau^*$ DO

10. $t = t + 1$

11. 由式(5)以及本地数据训练 $w_i(t)$

12. IF $\tau < \tau^*$

13. $\tilde{w}_i(t) = w_i(t)$

14. 记录 c_i, e_i, Q_i

15. 发送 $w_i(t), c_i, e_i, Q_i$ 至 CSP

16. IF $t_0 > 0$ THEN

17. 发送 $\rho_i, \beta_i, F_i(w(t_0))$ 至 CSP

18. IF STOP FLAG 已被设置 THEN

19. BREAK

在 P_i 端, 算法3的时间复杂度主要源于 T 次本地更新与 K 次全局更新, 全局更新时的额外步骤包括发送模型参数与训练参数, 这些额外的时间复杂度可以视为 $O(1)$, 又因为全局更新次数 K 显然小于总更新次数 T , 所以 K 相对于 T 可以忽略不计. 此外, 每次更新中估计 ρ_i 与 β_i 的时间复杂度与参与者的本地数据集大小 D_i 和模型维数 m 相关, 由于模型维数往往小于数据集大小, 所以参数估计的时间复杂度记为 $O(D_i)$. 综上, 算法3的时间复杂度为 $O(TD_i)$. 假设在更新过程中出现异常情况, 时间复杂度会进一步恶化. 但在一般合理的算法执行情况下, 通常认为算法3的时间复杂度在最坏情况下仍为 $O(TD_i)$.

算法3的空间复杂度主要来自模型参数和数据的存储, 同理, 由于模型的维数往往小于数据集的大小,

所以算法3的空间复杂度为 $O(D_i)$. 在最坏情况下, 如果本地数据集的存储方式出现问题, 空间复杂度可能会增加. 例如, 如果需要存储每个数据样本的多个备份或者额外的大量索引信息, 空间复杂度可能会变为 $O(D_i^2)$ 或更高.

4 实验结果与分析

4.1 实验设置

本节从理论分析和实验测试的角度来评价基于自适应联邦学习的群智感知算法的有效性和效率.

配置: 为全面评估系统在各种监测环境的性能, 实验构建了2个场景, 分别是空气质量预测与真实垃圾分类, 涉及5个真实网络节点以及5~100个虚拟节点. 实验设计考虑了参与者设备的多样性, 采用了5台安卓手机, 通过实验室的WiFi网络连接, 并配备有骁龙8+SoC处理器和12GBRAM, 用以模拟不同参与者 P_i 并处理收集到的感知数据. 每个节点独立训练其本地模型, CSP端则在台式电脑上进行操作, 使用Windows11, Intel(R)Core(TM)i5-12490FCPU@3.20GHz, RTX3060TI和16.0GBRAM作为CSP, 具体参数如表3所示.

表3 参与者与服务器硬件参数

身份	硬件	计算资源	RAM/GB	ROM
参与者	安卓手机	SoC:骁龙8+	12	256 GB
服务器	PC	CPU:i5-12490F GPU:RTX3060TI	16	1 TB

资源: 在给定时间预算的现实环境中进行联邦学习训练每一个模型, 模拟环境中的资源消耗是根据高斯分布产生的.

不同节点数据集分布情况设置: 一共分为3种案例.

案例1: 代表一个开放的环境监测任务, 参与者没有特定的数据收集目标, 而是随机地收集各种类型的数据.

案例2: 代表一个有针对性的数据收集任务, 所有参与者都被要求针对某一种数据类型进行收集.

案例3: 代表一个混合的监测任务, 在这个案例中, 参与者被分为2组: 一组进行随机的数据收集, 类似于案例1中的开放性任务; 另一组则专注于监测具体的指标, 如案例2, 尽管数据标签相同, 但因收集位置不同导致数据内容存在差异.

模型与数据集: 采用了卷积神经网络(Convolutional Neural Network, CNN)与平方支持向量机(Support Vector Machine, SVM)作为算法模型, 损失函数如表4所示. 卷积神经网络用于训练北京PM2.5数

数据集^[32],包含 591 个带有相关的 PM2.5 数据的北京城市图像,根据 PM2.5 浓度范围将图像分为 3 类,即良好(<75)、中等(75~115)和严重(>115). PM2.5 浓度范围为 2~634. 为了增强训练图像,将每个图像分成 2 个相等的子图像,并额外复制一个左右翻转的图像,这个步骤共计产生 2 364 个图像,其中 1 650 个用于训练,剩余 714 个用于测试. 平方支持向量机用于训练 RealWaste 垃圾分类数据集^[33],包含 4 752 个图像,涵盖纸板、有机食品、玻璃等多个标签,其中 3 500 个图像用于模型的训练阶段,剩余 1 252 个图像则被用于评估模型的性能测试.

表 4 模型损失函数

模型	损失函数($f(w, x_j, y_j) = f_j(w)$)
卷积神经网络	详见式(11)
平方支持向量机	$\frac{\lambda}{2} \ w\ ^2 + \frac{1}{2} \max\{0, 1 - y_j w^T x_j\}^2$

基线:

(1) 固定 τ 值的联邦平均算法^[10](Federated Averaging, FedAvg). 由 McMahan 等人提出的 FedAvg 替换自适应联邦学习,也就是 $\tau (\tau \neq 1)$ 值固定的联邦学习算法,用以评估自适应联邦学习在群智感知系统中的作用.

(2) 异步联邦学习算法^[34](Asynchronous Federated Learning, AsyncFL). 异步联邦学习算法是一种允许多个参与者在没有中心协调者的条件下进行模型训练的分布式机器学习框架. 在异步联邦学习中,每个参与者可以独立地进行本地模型的训练和更新,异步地将更新发送到服务器. 服务器随后聚合收到的更新,改进全局模型,将新模型分发给参与者进行下一轮的训练.

(3) 近端优化联邦学习算法^[35](Federated Proximal optimization, FedProx). FedProx 的核心思想是在传统的 FedAvg 算法的基础上引入了近端项. 近端项可以帮助算法在每个参与者上进行更精细的优化,减少由于参与者异构性带来的负面影响.

(4) 统一编码空间联邦学习算法^[36](Federated learning framework with a Unified Coding Space, FedUCS). 该算法旨在解决数据异质性问题,通过引入一个跨客户端协调器,在多个客户端之间学习统一的编码规则,减少由于数据分布差异导致的学习目标发散问题.

训练与控制参数:资源预算为 15 个单位,搜索范围 $\gamma = 10$, τ_{\max} 值为 100,支持向量机 $\phi = 0.025$,卷积神经网络 $\phi = 5 \times 10^{-5}$,步长 $\eta = 0.01$,成本分析权重 S 取 0.5.

4.2 实验结果

本文在实际环境中对 CNN+空气质量预测任务与 SVM+垃圾分类任务进行了模拟,对 3 种案例中的集中式随机梯度下降(Stochastic Gradient Descent, SGD)就

损失函数和准确率进行了对比分析,结果展示在图 2 和图 3 中,标点为算法得到的近似解. 实验结果显示最优 τ 值总是随着不同的案例、场景和模型发生变化,验证了动态调整 τ 值在多种环境监测场景的必要性,同时,实验也表明算法在各种场景和模型下都能找到并靠近最优的取值范围,证实本文方法在各种环境监测场景的泛化能力,以及处理多种环境监测信息的能力.




图 2 不同 τ 值下 3 种案例的损失值与准确率


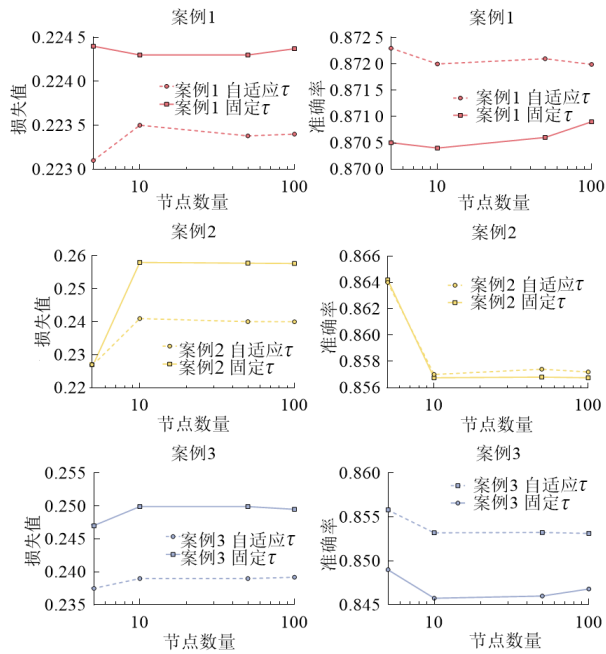


图 3 不同 τ 值下 3 种案例的损失值与准确率

案例 2 展现了数据不平衡对模型性能的负面影响,其中一些节点因数据稀缺而难以作为全局模型提供重要更新. 这不仅限制了模型捕捉数据全局特征的能力,尤其是在数据较少的类别上. 类似地,在案例 3 中,部分节点数据量较大而其他节点数据量较小的情况造成了数据分布的不均匀,这可能会影响模型的整体表现. 为应对这一挑战,需要开发能够自动调整以适应不同数据条件的算法. 后续实验将检验在自适应 τ^* 值配置下的时间效率,并将其与固定 $\tau = 10$ 时的模型性能进行比较,观察不同设置下的损失和准确度,由于评估卷积神经网络的高度复杂性,本文将重点在支持向量机上展开研究. 这些实验旨在验证动态调整 τ 值的重要性,展示在不同情况下选择合适策略的必要性,确保在各种场景的群智感知系统中能实现最优的性能表现.

节点数变化. 在模拟环境下,节点数变化为 5~100 的 SVM(SGD)结果如图 4 所示. 因为根据图 2 和图 3 中的结果,同时依据经验 $\tau = 10$ 在不同情况下都是非自适应 τ 的良好值,所以选择固定 $\tau = 10$ 作为本评估和以下评估的基线,通过对比可知,本文提出的方法在所有情况下都优于或类似于固定 $\tau = 10$ 的基线.

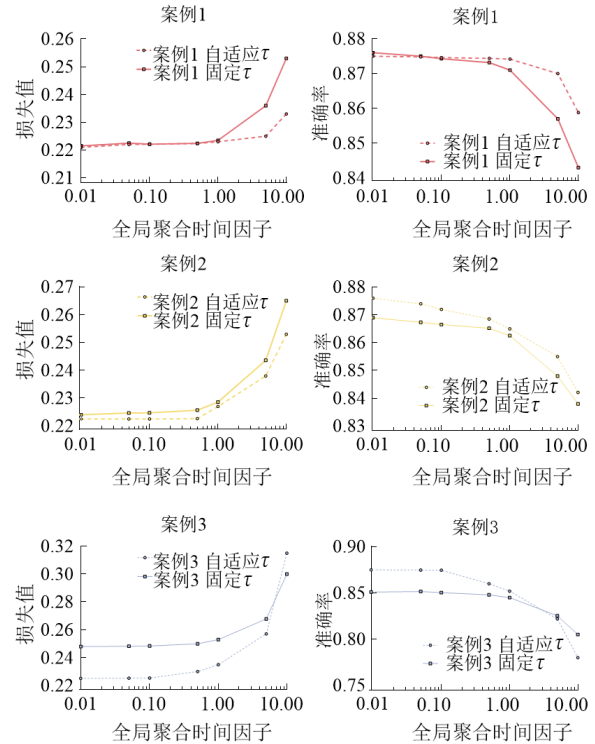
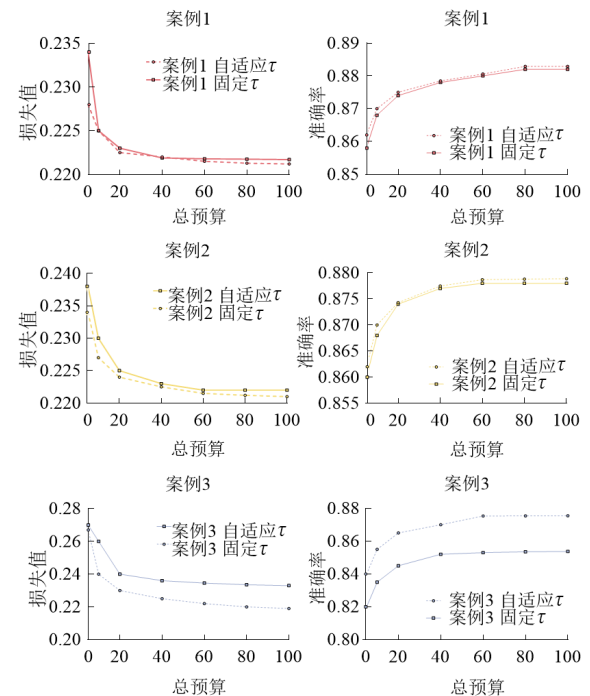
变化的全局聚合时间. 为了探讨服务提供者(Crowdsensing Service Provider, CSP)全局聚合对整个算法的影响,引入时间调整因子对全局聚合进行缩放,新

图4 不同节点数量下自适应 τ 与固定 τ 的损失值与准确率

的全局聚合时间等于原本时间与调整因子之积. 结果如图5所示, 不难观察到较大的全局聚合时间通常会导较大的 τ^* , 这是因为当全局聚合的代价提升时, 系统应该将资源自适应分配给相对更有性价比的参与者本地迭代, 只有当再进行本地迭代的性价比再度下降时, 系统才会考虑高代价的全局聚合, 如图5所示, 相较于固定 $\tau=10$ 的基线, 显然可以证明在各种情况下的CSP全局聚合能耗, 本文所提出的自适应算法都能在一定预算内提升训练效果.

变化的总时间预算. 评估总资源预算对系统的影响SVM(SGD)的结果如图6所示, 可以看到除了所有节点具有相同数据集的案例3外, τ^* 值随着总时间预算增加而增加, 这与本文中的讨论一致, 即当资源预算足够大时, τ^* 接近于1即趋向于集中式梯度下降. 此外, 在所有情况下AFL-CSEM算法的性能都优于或类似于固定 $\tau=10$ 基线.

参数 φ 敏感度. 在系统上评估的控制参数 φ 的敏感度如图7所示, 不同案例下 τ^* 大小一般维持在一定的范围内, 随 φ 近似线性减小. 由式(36)可知目标函数 $G(\tau)$ 包含多个与 τ 反比的项, 随着 φ 的增加, 这些反比项的值会减小, 降低 $G(\tau)$ 的值. 根据式(16), 需要找到使 $G(\tau)$ 最小的 τ , 由于 φ 增加使得反比项减小, $G(\tau)$ 在较小的 τ 上会达到其最小值, 因此, 随着控制参数 φ 的增加, τ^* 会减小, 式(16)中的函数 $h(\tau)$ 也显示了 τ 的指数增长特性, 进一步支持这一结论. 此外, 还可以看到 τ^* 随着 φ 的微小变化不会改变太多, 这表明在调整该参数时可以采用较大的步长.

图5 不同全局聚合时间下自适应 τ 与固定 τ 的损失值与准确率图6 不同时间预算下自适应 τ 与固定 τ 的损失值与准确率

为了全面评估提出的AFL-CSEM算法在群智感知中的性能, 本文采用了能更好地模拟群智感知系统实际情况的案例2数据集划分方式, 与4种经典的联邦学习算法进行了对比实验. 这些算法包括联邦平均算法(Federated Averaging, FedAvg)、异步联邦学习算法




图7 τ^* 对控制参数 ϕ 的敏感度

(Asynchronous Federated Learning, Async FL)、近端优化联邦学习算法(Federated Proximal optimization, FedProx)和统一编码空间联邦学习(Federated learning framework with a Unified Coding Space, FedUCS). 对比实验结果如图8和表5所示,AFL-CSEM算法相较于以上算法,在模型收敛速度、经济成本等方面表现更优越. 这也证明本文算法能够更快地训练模型并达到较高的准确性.




图8 不同算法的对比

在联邦学习中一个经典的问题便是不同参与者的性能不同,可能面临高性能参与者早早训练完毕而为了等待低性能参与者训练完毕产生所谓的等待时间,这个问题在群智感知中尤为突出. 为此本文引入一种异步聚合联邦学习算法进行对比,然而,出乎意料的是,异步聚合联邦学习在数据异构情况下有可能损害整体性能. 虽然在理想情况下,也就是案例1一样所有数据标签一致时,异步聚合联邦学习的损失函数更低且准确率更高,然而一旦数据存在异构性,也就是如案例2与案例3一样存在相互冲突的标签,模型可能过度拟合于高性能的参与者数据,而这个数据有可能是错误的.

FedProx算法通过近端优化来消除参与者的异构性,同时也增加了每个客户端的计算负担,特别是当近端项需要复杂的操作或优化时. 因此,综合考虑案例1~

表5 SVM+垃圾分类任务中与现有算法的比较

训练轮数	损失值			准确率			平均成本
	50	500	1 000	50	500	1 000	
FedAvg ^[10]	27.99	15.01	15.46	72.10	85.00	84.71	1 735
Async FL ^[35]	28.08	18.95	17.38	72.00	81.10	82.80	2 228
FedProx ^[36]	26.42	15.11	13.71	73.31	84.50	86.33	2 053
FedUCS ^[37]	27.28	14.51	13.38	73.04	85.75	86.60	1 872
Ours	24.74	13.64	12.71	75.18	86.48	87.45	1 603
差值	↓ 1.68	↓ 0.87	↓ 0.67	↑ 1.87	↑ 0.73	↑ 0.85	↓ 132

案例3,由于环境监测群智感知的数据异构性,使用同步梯度下降的学习效果综合更优. 本文提出的AFL-CSEM算法针对边缘计算系统中的资源限制问题,采取了精细化的资源管理和通信成本控制措施,确保各参与节点的训练工作得到均衡合理安排. 通过动态调整局部更新次数和通信频次,该算法有效提升了模型的收敛速率.

AFL-CSEM算法在100个节点3种案例中的成本效益实验如图9所示. 算法通过优化资源分配和任务调度策略,有效减少了能源消耗和相关成本,保证模型更新和学习效果,实现了成本效益的优化,原因如下:该算法在资源配置和任务调度时,深入考虑了能耗因素. 通过动态指派任务和资源,更加高效地使用边缘设备的能源,从而减少能耗. 与此相比,一些传统算法并未特别针对能耗进行优化,因此在成本效益方面可能存在不足,而本算法通过其灵活的资源管理策略,有效降低了经济成本.




图9 经济成本

在模型和算法的可扩展性方面,由于本模型引入了联邦学习架构,本质上是分布式的,随着环境监测范围的扩大或监测任务复杂度的增加,方便增加参与者节点. 例如,在城市空气质量监测中,若要从覆盖部分区域扩展到整个城市,只需要让更多位于不同区域的设备加入群智感知网络. 新加入的节点能利用本地数据进行模型训练,并通过联邦学习机制与其他节点协同,共同提升全局模型的性能,不会对整体架构造成巨大冲击. 这种分布式特性使系统能够轻松应对大规模数据收集和处理需求,理论上可以扩展到海量设备参与的场景. 同时,在数据量不断增长时,模型的分布式训练方式可以充分利用各节点的计算资源,避免集中式处理的瓶颈.

在跨领域应用中,针对不同群智感知任务,可依据特定领域资源需求、输入特征及任务导向选择合适的损失函数进行调整,在各类群智感知应用中展现出良好适应性与可扩展性,为多领域提供有力技术支撑.

5 结论

本文综合考虑了资源限制、设备多样性和数据非独立同分布等挑战,提出一种结合群智感知和联邦学习技术的环境监测系统,旨在解决传统环境监测方法的局限

和群智感知技术中的数据隐私与质量控制问题,该系统在给定资源预算的情况下进行群智感知任务,采用一种自适应迭代的方式来平衡不同任务的资源需求,有效利用边缘设备的计算和通信资源,减少通信和计算的开销,具有较高实用价值,能应用于更广泛的场景.

参考文献

- [1] MAMUN M A AL, YUCE M R. Sensors and systems for wearable environmental monitoring toward IoT-enabled applications: A review[J]. *IEEE Sensors Journal*, 2019, 19(18): 7771-7788.
- [2] SUHAG D, JHA V. A comprehensive survey on mobile crowdsensing systems[J]. *Journal of Systems Architecture*, 2023, 142: 102952.
- [3] ANTONIĆ A, BILAS V, MARJANOVIĆ M, et al. Urban crowd sensing demonstrator: Sense the Zagreb air[C]//2014 22nd International Conference on Software, Telecommunications and Computer Networks (SoftCOM). Piscataway: IEEE, 2014: 423-424.
- [4] JIANG Z H, ZHU H, ZHOU B B, et al. CrowdPatrol: A mobile crowdsensing framework for traffic violation hot-spot patrolling[J]. *IEEE Transactions on Mobile Computing*, 2021, 22(3): 1401-1416.
- [5] SIVAGNANASUNDARAM J, GINIGE A, GOONETIL-LAKE J. Farmers as sensors: A crowdsensing platform to generate agricultural pest incidence reports[C]//2019 International Conference on Internet of Things Research and Practice (iCIOTRP). Piscataway: IEEE, 2019: 13-18.
- [6] RASHID M T, WANG D. CovidSens: A vision on reliable social sensing for COVID-19[J]. *Artificial Intelligence Review*, 2021, 54(1): 1-25.
- [7] GUO B, WANG Z, YU Z W, et al. Mobile crowd sensing and computing: The review of an emerging human-powered sensing paradigm[J]. *ACM Computing Surveys*, 2015, 48(1): 1-31.
- [8] YAN X F, NG W W Y, ZENG B, et al. P2SIM: Privacy-preserving and source-reliable incentive mechanism for mobile crowdsensing[J]. *IEEE Internet of Things Journal*, 2022, 9(24): 25424-25437.
- [9] LUO Z Y, XU J, ZHAO P C, et al. Towards high quality mobile crowdsensing: Incentive mechanism design based on fine-grained ability reputation[J]. *Computer Communications*, 2021, 180: 197-209.
- [10] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[EB/OL]. (2016-02-17)[2024-10-16]. <https://arxiv.org/abs/1602.05629v4>.
- [11] MOTHUKURI V, PARIZI R M, POURIYEH S, et al. A survey on security and privacy of federated learning[J]. *Future Generation Computer Systems*, 2021, 115: 619-640.
- [12] ZHANG Z X, CHEN G, XU Y J, et al. FedDQA: A novel regularization-based deep learning method for data quality assessment in federated learning[J]. *Decision Support Systems*, 2024, 180: 114183.
- [13] ZHAN Y F, LI P, GUO S, et al. Incentive mechanism design for federated learning: Challenges and opportunities[J]. *IEEE Network*, 2021, 35(4): 310-317.
- [14] WANG K I, ZHOU X K, LIANG W, et al. Federated transfer learning based cross-domain prediction for smart manufacturing[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(6): 4088-4096.
- [15] JIANG W J, CHEN J P, LIU X L, et al. Participant recruitment method aiming at service quality in mobile crowd sensing[J]. *Wireless Communications and Mobile Computing*, 2021, 2021(1): 6621659.
- [16] FASCISTA A. Toward integrated large-scale environmental monitoring using WSN/UAV/crowdsensing: A review of applications, signal processing, and future perspectives[J]. *Sensors*, 2022, 22(5): 1824.
- [17] JIANG W J, ZHANG W Q, CHEN P P, et al. Quantity sensitive task allocation based on improved whale optimization algorithm in crowdsensing system[J]. *Concurrency and Computation: Practice and Experience*, 2023, 35(20): e6637.
- [18] BIAN J, XIONG H Y, WANG Z Y, et al. Aggregation-free spatial-temporal mobile community sensing[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(9): 5017-5034.
- [19] MORSELLI F, ZABINI F, CONTI A. Environmental monitoring via vehicular crowdsensing[C]//2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). Piscataway: IEEE, 2018: 1382-1387.
- [20] ZHANG Q, WANG T C, TAO Y, et al. Trajectory privacy protection method based on differential privacy in crowdsensing[J]. *IEEE Transactions on Services Computing*, 2024, 17(6): 4423-4435.
- [21] TONG F, ZHOU Y H, WANG K M, et al. A privacy-preserving incentive mechanism for mobile crowdsensing based on blockchain[J]. *IEEE Transactions on Dependable and Secure Computing*, 2024, 21(6): 5071-5085.
- [22] LUO B, YU Y, JIANG Z L, et al. Crowd-BT: A bilateral trustworthy ensured scheme for blockchain assisted mobile crowdsensing[J]. *IEEE Internet of Things Journal*, 2024, 99: 1.
- [23] MONTASER N A, RAMADAN A, MOHAMMED A H, ALI A, SHIN YEE KHOO A B, et al. SecureIoT-FL: A federated learning framework for privacy-preserving real-time environmental monitoring in industrial IoT applications[J]. *Alexandria Engineering Journal*, 2025, 114: 681-701.
- [24] 马华东, 赵东, 王新兵, 等. 一种新型群智感知系统架构模型和实现方法[J]. *中国科学: 信息科学*, 2023, 53(7): 1262-1280.

- MA H D, ZHAO D, WANG X B, et al. A novel crowdsensing system architecture model and its implementation methods[J]. *Scientia Sinica (Informationis)*, 2023, 53(7): 1262-1280. (in Chinese)
- [25] XIE X, BAI T, GUO W W, et al. Cooperative computing for mobile crowdsensing: Design and optimization[J]. *IEEE Transactions on Mobile Computing*, 2023, 23(5): 6437-6454.
- [26] PICAUT J, FORTIN N, BOCHER E, et al. An open-science crowdsourcing approach for producing community noise maps using smartphones[J]. *Building and Environment*, 2019, 148: 20-33.
- [27] HU Q, WANG Z L, XU M H, et al. Blockchain and federated edge learning for privacy-preserving mobile crowdsensing[J]. *IEEE Internet of Things Journal*, 2023, 10(14): 12000-12011.
- [28] LI L, YU X, CAI X L, et al. Contract-theory-based incentive mechanism for federated learning in health crowd sensing[J]. *IEEE Internet of Things Journal*, 2023, 10(5): 4475-4489.
- [29] ZHANG M W, CHEN S J, SHEN J, et al. PrivacyEAF: Privacy-enhanced aggregation for federated learning in mobile crowdsensing[J]. *IEEE Transactions on Information Forensics and Security*, 2023, 18: 5804-5816.
- [30] 公茂果, 高原, 王炯乾, 等. 基于进化策略的自适应联邦学习算法[J]. *中国科学: 信息科学*, 2023, 53(3): 437-453. GONG M G, GAO Y, WANG J Q, et al. Adaptive federated learning algorithm based on evolution strategies[J]. *Scientia Sinica (Informationis)*, 2023, 53(3): 437-453. (in Chinese)
- [31] 蒋伟进, 韩裕清, 吴玉庭, 等. 基于边缘计算的环境监测自适应联邦学习算法[J]. *电子学报*, 2023, 51(11): 3061-3069.
- JIANG W J, HAN Y Q, WU Y T, et al. Federated learning scheme for environmental monitoring based on edge computing[J]. *Acta Electronica Sinica*, 2023, 51(11): 3061-3069. (in Chinese)
- [32] CHAKMA A, VIZENA B, CAO T T, et al. Image-based air quality analysis using deep convolutional neural network[C]//2017 IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2017: 3949-3952.
- [33] Single S, Iranmanesh S, Raad R. RealWaste. UCI machine learning repository[EB/OL]. (2023-10-17)[2024-10-16]. <https://doi.org/10.24432/C5SS4GSingle>.
- [34] XU C H, QU Y Y, XIANG Y, et al. Asynchronous federated learning on heterogeneous devices: A survey[J]. *Computer Science Review*, 2023, 50: 100595.
- [35] LIT, SAHU A K, ZAHEER M, et al. Federated optimization in heterogeneous networks[EB/OL]. (2020-04-21)[2024-10-16]. <https://arxiv.org/abs/1812.06127v5>.
- [36] HUANG S, FU L L, LI Y C, et al. A cross-client coordinator in federated learning framework for conquering heterogeneity[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 1: 1-15.

作者简介



蒋伟进 男, 1964年7月出生, 湖南益阳人. 湖南工商大学计算机学院二级教授、博士生导师. 主要研究方向为群智感知、联邦学习、边缘计算.
E-mail: jwjndt@163.com



杨璇 男, 1999年4月出生, 湖南长沙人. 湖南工商大学前沿交叉学院硕士研究生. 主要研究方向为群智感知、信息安全.
E-mail: 1064174495@qq.com



杜熙晨 男, 2001年5月出生, 湖南长沙人. 湖南工商大学计算机学院硕士研究生. 主要研究方向为群智感知、联邦学习.
E-mail: dxestu@163.com



聂彩燕 女, 2001年5月出生, 湖南株洲人. 湖南工商大学计算机学院硕士研究生. 主要研究方向为群智感知、隐私保护.
E-mail: 516278890@qq.com



蒋意容 男, 1996年8月出生, 湖南株洲人. 湖南信息学院教师. 主要研究方向为人工智能、群智感知、数字音乐.
E-mail: 307553803@qq.com



刘茜 女, 2001年10月出生, 湖南衡阳人. 湖南工商大学计算机学院硕士研究生. 主要研究方向为信息安全、群智感知.
E-mail: 726956360@qq.com