

车联网联邦学习的数据异质性问题及 基于个性化的解决方法综述

刘淼, 林婉茹, 王琴, 桂冠

(南京邮电大学通信与信息工程学院, 江苏 南京 210003)

摘要: 在车联网 (IoV) 场景中, 不同设备存在海量非独立同分布的数据, 容易引发数据异质性问题, 影响模型训练性能并威胁交通安全, 对此聚焦于车联网联邦学习 (FL) 的数据异质性问题, 通过对问题归因溯源提出了基于个性化的解决方法体系与研究新思路。首先, 论述了联邦学习用于车联网的必要性, 调研总结了车联网联邦学习中典型的数据异质性问题; 其次, 从感知、计算和传输 3 个环节对车联网联邦学习的数据异质性问题进行了分类和追踪; 再次, 引入个性化方法作为解决各类车联网联邦学习数据异质性问题的核心手段, 并分析了现有个性化联邦学习的优点与不足; 最后, 讨论了个性化联邦学习在车联网场景中面临的研究挑战, 并结合无线通信等相关技术展望了未来研究方向。

关键词: 车联网; 联邦学习; 个性化方法; 数据异质性

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024170

Survey on data heterogeneity problems and personalization based solutions of federated learning in Internet of vehicles

LIU Miao, LIN Wanru, WANG Qin, GUI Guan

School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: In Internet of vehicles (IoV) scenario, there was a massive amount of non-independent and identically distributed data among devices, leading to data heterogeneity problems of federated learning (FL). This problem affected the performances of model training and might pose threats to traffic safety. Therefore, the focus lied on the data heterogeneity problem of FL in IoV, the personalized solution system and new research ideas were proposed through problem attribution. Firstly, the necessity of applying FL to IoV was discussed. Through an examination of current applications, identified the data heterogeneity problems of FL in IoV. Secondly, classified and traced the data heterogeneity problems of FL in IoV, from the perspective of perception, computation, and transmission respectively. Thirdly, personalized methods were introduced as the core approaches to address the data heterogeneity problems of FL in IoV, and analyzed the advantages and disadvantages of existing personalized federated learning (PFL). Finally, the challenges encountered by PFL in IoV were outlined, along with the future research prospection related to advanced technologies on wireless communications.

Keywords: Internet of vehicles, federated learning, personalized solution, data heterogeneity

收稿日期: 2024-06-05; 修回日期: 2024-09-03

通信作者: 桂冠, guiguan@njupt.edu.cn

基金项目: 科技创新 2030—“新一代人工智能”重大基金资助项目 (No.2021ZD0113003)

Foundation Item: Scientific and Technological Innovation 2030—“New Generation Artificial Intelligence” the National Key Research and Development Program of China (No.2021ZD0113003)

0 引言

车联网 (IoV, Internet of vehicles) 是建立在车辆和互联网之间通信和数据交换基础上的物联网, 实现了车辆间的数据交互, 提高了交通的安全性和便利性。而将以深度学习为代表的人工智能技术应用于 IoV 不仅促进了智能交通业务的发展, 而且为用户提供了更及时、精准、可靠的功能和服务^[1]。随着 IoV 设备数量及其密度、业务数量及其类型、数据量及其模态的不断增长, 人们对 IoV 及其所承载的智能交通服务在节能、安全、智能化、个性化等方面也提出了更高的网络性能及服务质量需求^[2]。

深度学习架构的不同会对所训练的神经网络模型 (下文简称模型) 及其所处的无线网络产生不同的性能影响。许多研究工作致力于通过改进或优化深度学习架构来提升 IoV 的网络性能和智能交通业务的服务质量。当前深度学习的主要架构包括集中式、分布式和集中-分布混合式学习^[3]。集中式学习架构将任务相关的所有数据汇聚在云服务器上进行面向智能交通业务的神经网络训练。相对于教育、家居、电力等行业, 智能交通业务对网络时延更加敏感, 要求 IoV 在动态且复杂的无线网络环境下实现低时延、高可靠的数据传输^[4-5]。由于集中式训练的模型部署在云端, 长距离的服务请求和响应数据传输会造成较高时延^[4]。若在 IoV 中采用分布式学习架构部署模型, 多元化和个性化的智能交通业务需要频繁采集大量用户的本地信息并广泛传输用于分布式模型训练, 极易导致隐私泄露, 威胁智能交通的安全性^[6-7]。集中-分布混合式学习架构允许少量具有相关性的用户形成群组并在群组内共享数据, 但由于数据量不充分、训练集难以反映分析对象的真实分布, 造成 IoV 中的“数据孤岛”问题^[7], 导致模型训练性能难以满足服务需求。表 1 总结了传统学习架构的优缺点及在 IoV 中应用的不足。

联邦学习 (FL, federated learning) 由于具有较高的隐私性而备受关注, 其独特之处在于用户终端可以利用自身有限的算力基于个人数据集进行本地模型的初始化训练, 此时用户作为 FL 客户端仅与中央服务器进行少量的参数交互。这样不仅降低了海量数据上传造成的通信开销, 同时避免了设备中的用户隐私信息因共享而被窃取或泄露^[8], 因此更适合作为模型训练架构应用于面向智能交通服务的 IoV。

由于 FL 在保证设备中数据隐私安全的前提下通过联合训练解决“数据孤岛”问题, 许多学者将 FL 技术引入 IoV, 以达到更加高效和安全的网络性能, 实现智能、多元的交通应用需求^[9-11]。然而在实际应用中, 由于客户端的数据和模型可能存在异质性, FL 的训练准确性和收敛性都可能受到影响。在 IoV 中, 不同车载终端、用户设备和路边单元 (RSU, road side unit) 所拥有的数据由于时空来源不同等因素, 样本具有不同的特征分布^[5], 即不同 FL 客户端的本地数据集之间服从非独立同分布 (Non-IID, non-independent identically distribution) 关系^[12], 会引起 FL 的数据异质性问题。而不同设备参与 FL 训练的模型神经网络的结构类型或参数设置不同, 会引起 FL 的模型异质性问题, 导致 FL 训练后客户端的模型性能存在显著差异^[13]。由于模型结构类型和参数的设置主要受设计者的主观影响, 在面向智能交通业务的 IoV 中可以通过政策法规等手段进行约束。而引起 IoV 中 FL 数据异质性问题原因较为复杂且难以应对, 因此本文主要探讨 IoV 中的 FL 数据异质性问题, 下文中的 FL 异质性问题均默认为数据异质性问题。

本文针对 IoV-FL 相关的现有研究进行了调研^[14-24], 将这些工作根据应用范围、主要技术、架构形式及是否考虑异质性问题进行区分, 如表 2 所示。从表 2 可以看出, 只有文献^[14-15,18,20,24]考

表 1 传统学习架构的优缺点及在 IoV 中应用的不足

架构	优点	缺点	在 IoV 中应用的不足
集中式学习 ^[4-5]	部署结构简单, 数据易备份, 隐私泄露风险低	传输数据量大, 传输时延高, 配置要求高	需要实时通信, 无法承担高时延代价, 易造成车辆拥堵、车祸等情况
分布式学习 ^[6-7]	支持多用户同时使用, 传输时延低	数据交互频繁, 数据量大, 通信开销大, 隐私泄露风险高	通信资源有限, 训练性能差, 隐私泄露风险高, 泄露用户信息并威胁生命安全
集中-分布混合式学习 ^[2]	通信开销低, 传输时延低	数据量不充分, 易造成“数据孤岛”问题, 隐私泄露风险高	设备异构程度高, 不适用于环境复杂的 IoV 场景, 训练性能差导致交通业务性能差

虑了 IoV-FL 的异质性问题，其中文献[18,20]提供了单一的解决对策，普适性和实际指导意义有限。IoV-FL 的异质性问题仍需结合实际应用场景、关键业务需求和动态环境因素，在明确异质性问题具体成因的基础上，从数据、模型、架构等不同层面进行分析，形成体系化的解决方法。

为了适应大规模高动态场景、低时延高可靠接入和多元化强安全需求，同时考虑到智能交通业务

对车路云协同的需求，云边端分层架构将成为智能 IoV 的基本组成形式。在此基础上，IoV-FL 采用基于云边端按需灵活交互的组织架构。如图 1 所示，本文将 IoV 划分为 4 层，即 IoV 智能业务层、中心计算层、边缘智能层和终端设备层，涵盖 3 种 FL 架构，包括传统的单层架构 (①)、分层架构 (②) 和分簇架构 (③) [15]。基于车与车、车与基础设施等不同形式的车联通信能够根据不同的实际情况

表 2 在 IoV 中部署 FL 的异质性问题研究现状

文献	应用范围	主要技术	架构形式(单层/多层)	是否考虑异质性问题
文献[14]	智慧出行	区块链、移动边缘计算(MEC, mobile edge computing)双聚合框架	云服务器-MEC 服务器-车辆终端, 多层	是
文献[15]	智慧出行	差分隐私、MEC	云服务器-MEC 服务器-车辆终端, 多层	是
文献[16]	自动驾驶	同态加密、区块链、零知识证明	MEC 服务器-车辆终端, 单层	否
文献[17]	交通流预测	长短期记忆、车辆控制局域网	中心服务器-车辆终端, 单层	否
文献[18]	交通流预测	Gale-Shapley 算法、多维契约	中心服务器-车辆终端, 单层	是
文献[19]	交通预测及路线规划	聚类、多任务 FL、A* 算法	交通服务器-交通站点-车辆终端, 多层	否
文献[20]	智慧出行	差分隐私、局部微调的个性化技术	中心服务器-车辆终端, 单层	是
文献[21]	自动驾驶	深度强化学习	MEC 服务器-车辆终端, 单层	否
文献[22]	智慧出行	基于哈希-RSA 的对齐方法	中心服务器-车辆终端, 单层	否
文献[23]	交通流预测	联邦能源需求算法、聚类	充电站供应商-充电站, 单层	否
文献[24]	入侵检测系统	区块链、联邦森林、对抗学习	系统-FL 节点-FL 客户端, 多层	是

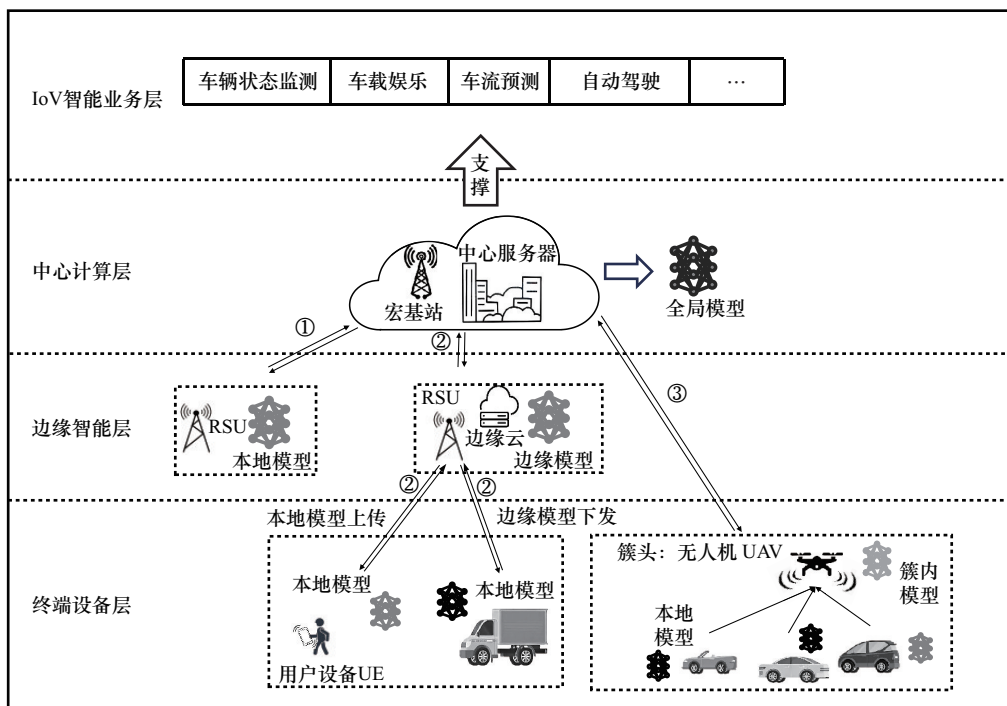


图 1 面向 IoV 的 FL 组织架构

选择不同的架构，实现在提高网络资源利用率的同时优化 FL 的训练效率与性能，提高智能交通业务的服务性能。这些异构的 FL 能够实现高效、灵活且适应性强的模型聚合，以适应具有多样化业务场景的 IoV 模型需求。其中，第一种单层架构即只有 RSU 到基站一层链路；第二种分层架构即本地终端设备-边缘云-宏基站 3 层链路；第三种分簇架构即没有边缘云，而是对终端设备进行分簇，选出簇头，由簇头与基站进行交互。

终端设备能够实时采集和处理用户相关的本地数据，用于更新/上传本地模型参数。在边缘智能层中存在 2 种情况：一种是边缘设备参与模型训练，并将训练结果与接收到的模型参数共同聚合后上传至中心/下发至终端；另一种是仅作为边缘服务器不参与模型训练，直接进行边缘聚合后将模型上传/下发。中心服务器则根据接收到的模型参数进行模型聚合，更新全局模型并下发。IoV 智能业务层则根据实时的业务需求和网络状况，动态调配 FL 任务并协调云边缘相关的通信、感知、计算、存储等资源。

具体来说，终端设备在本地训练模型，上传本地模型参数至边缘智能层。对于不同的应用场景，边缘设备需要进行不同的处理方式，当进行交通状态监测时，需要实时传输数据和快速响应，参与模型训练的边缘设备利用本地数据进行边缘模型训练后聚合。而车流预测不需要实时交互信息，且边缘服务器/基站不参与训练，接收本地模型参数后直接聚合。以上 2 种情况边缘设备均将聚合后的模型下发至客户端再进行训练，并将边缘模型上传至中心服务器进行全局聚合。中心服务器得到全局模型后，可以将模型参数下发至边缘智能层，边缘智能层再下发至终端设备层。当某一区域终端移动性不高且较为密集时（如泊车管理），中心服务器可以利用高质量的下行通信链路及时将全局模型下发至边缘智能层和终端设备层。经过多轮训练达到收敛的全局模型可以有效执行各类智能交通业务并通过 IoV 高效地服务用户。

已有研究表明，个性化方法可以有效缓解 FL 的异质性问题，因而个性化联邦学习（PFL, personalized federated learning）受到了广泛的关注与研究^[25]。PFL 允许参与方根据其数据分布在本地生成适合自己的个性化训练模型^[26]，能够有效提高

全局模型训练的准确性和收敛性。

本文面向智能交通服务需求，聚焦于 IoV 中的 FL 异质性问题，对其成因、类型、影响及个性化解决方法进行研究分析。本文的主要贡献如下。

1) 在调研现有 IoV 场景下 FL 研究工作的基础上，揭示了 FL 异质性问题普遍存在于各类 IoV 场景中，对智能交通业务产生了难以忽视的负面影响。

2) 分析了 IoV 中引起 FL 异质性问题原因和相应后果，并从 IoV-FL 流程的感知、计算和传输 3 个环节对造成异质性问题原因进行分类。

3) 引入基于个性化的多元方案，从本地数据预处理、本地模型微调、全局模型优化和训练架构动态组织 4 个层面构建完整的 IoV-PFL 技术体系解决异质性问题，提高 FL 性能，赋能 IoV 提供更加个性、安全、可靠、高效的智能交通服务，并分析了每种技术的不足之处，进而从无线网络优化的视角提出了新的探索方向及研究思路。

4) 讨论了 IoV-PFL 值得关注的研究方向，包括安全隐私增强、安全性及隐私性测评标准、全局模型动态优化、智能交通专用数据集构建、基于前沿无线技术的融合增强等方面，并阐述了其中的研究难点与相应的解决建议。

1 IoV-FL 存在的异质性问题分析

如图 2 所示，IoV-FL 存在的异质性问题主要源于参与 FL 训练的各客户端本地数据服从 Non-IID。造成 FL 数据集 Non-IID 的原因有多种，本文根据 FL 过程中的感知、计算和传输 3 个环节将客观原因为客户端数据集异质、可用计算资源差异和通信方式异构 3 类^[5]，并进一步将造成客户端数据集异质问题的原因基于其自身状态和能力的差异性细分为 6 种情况，具体分析如下。

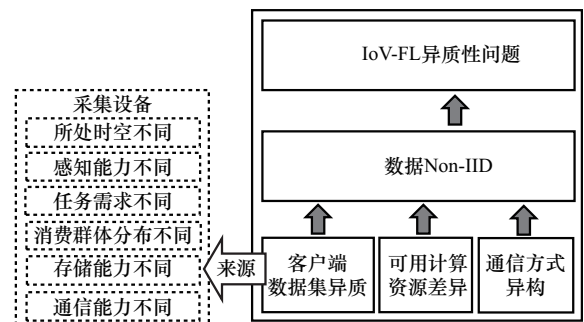


图 2 IoV-FL 存在的异质性问题

1.1 感知环节:客户端数据集异质引起

在 IoV-FL 中,各终端形成异质数据集的情形十分常见。假设将具有相同计算能力和稳定链路质量的车辆作为 FL 的终端设备,RSU 作为不参与模型训练的边缘设备,中心服务器可以可靠地接收所有来自 RSU 的聚合模型。然而由于 RSU 的位置不同,获取的数据也有差异,从而造成所构建本地数据集的不同^[27]。考虑到不同的车辆终端或边缘服务器也存在类似于 RSU 的情况,因此本文根据数据源的设备差异性将形成异质数据集的原因分为以下几类。

1) 设备所处时空不同。数据在时间和空间上具有相关性,不同时空的设备会生成不同分布的数据集^[28]。即使在相同时间,不同空间的设备所在地区的天气、温度等不同,也会导致所采集的数据存在异质性,而同一设备在不同时间所采集的数据分布也可能存在 Non-IID 情况。

2) 设备感知能力不同。IoV 中不同种类设备配备的传感器各不相同,导致不同设备间的感知能力和存储的数据模态存在差异,这进一步造成了设备存储的数据模态异质情况。例如,道路上的监控设备存储的数据模态为视频,而停车场闸机存储的数据模态为图像。

3) 设备任务需求不同。不同 IoV 应用场景的设备具有不同的 FL 任务需求^[29],也会导致设备所存储的数据分布不同。例如,在高速公路和城市交叉路口部署的监控设备虽然型号相同,但是高速公路监控任务是测速,而城市交叉路口监控任务是闯红灯拍照,这 2 种不同的任务会导致存储的数据模态和数据分布产生差异。

4) 设备消费群体分布不同。IoV 中的设备各不相同,不同设备终端的品牌、型号、配备的服务类型等存在较大差异。由于消费者在购买设备时会对某种特定品牌和型号存在偏好,出现某些设备使用人群固定、不同型号设备中参与训练的数据分布不平衡甚至类缺失等情况。例如,不同国家的消费者使用本国品牌车辆的情况相较于他国品牌更多,参与 FL 训练的数据会有地域及品牌等属性的划分,导致数据存在 Non-IID 情况。

5) 设备存储能力不同。不同 IoV 终端设备的存储能力存在差异^[30],存储能力较弱的设备只能在短期内存储,且存储的都是最新数据,历史数据量

有限难以反映真实的长期分布。而存储能力较强的设备,如边缘服务器或者中心服务器,其能够存储长期数据,较存储能力较弱的设备更能反映数据的真实分布,因此可以认为设备的存储能力差异也会造成 FL 过程中的数据 Non-IID。

6) 设备通信能力不同。IoV 中不同设备的通信能力存在差异,如设备的发送功率、天线增益、通信体制等。在无线环境复杂多变的 IoV 中,发送功率和天线增益较弱的设备可能因为无线通信质量过差而无法持续上传本地模型的参数信息,从而造成 FL 过程中发生数据 Non-IID 情况^[31]。

1.2 计算环节:可用计算资源差异引起

车辆终端自身的计算资源不同,会导致部分车辆终端无法完成预期的本地训练任务。同时由于车辆具有移动性,同一边缘服务器的覆盖范围内车辆终端不断变化。当未完成本地训练任务的车辆驶离其所在地区的边缘服务器覆盖范围时,无法上传最新的模型参数信息,也会造成异质性问题。

此外,边缘服务器中可用的计算资源可能不同,会影响边缘服务器处理和上传模型参数信息的效率。一方面,对于边缘设备需要参与训练的情况,部分边缘设备由于计算资源有限,可能无法持续参与训练,导致其贡献的模型参数信息变少或停滞,进而影响全局模型的一致性,造成异质性问题。另一方面,对于不参与训练的边缘设备,由于计算资源限制,部分车辆终端无法上传训练完成后的模型参数信息,从而造成异质性问题。

1.3 传输环节:通信方式异构引起

异步 FL 允许客户端在任何时间上传和下载模型参数,不需要等待与其他参与者联合训练^[32]。这种灵活性使得异步 FL 更适用于不稳定的网络环境或算力不均的 IoV 环境。然而,对于信息新鲜度和紧迫度要求较高的 FL 任务^[33],信道条件较差的客户端所上传的模型参数信息在全局聚合时可能已经过时,从而引起通信方式异构导致的异质性问题^[34]。

2 基于个性化解决 IoV-FL 异质性的方案体系

针对 FL 的数据异质性问题,一类有效的解决方法是在客户端本地数据和模型上进行个性化处理,在不改变各客户端原始数据分布的同时充分利

用其本地数据和模型的特征，对数据、模型参数及 FL 架构进行动态调整，减小异质性问题对全局模型训练性能造成的失衡影响，并使每个客户端都获得高质量的个性化模型，进而提高各客户端本地模型执行任务的性能^[25]。

Tan 等^[25]调研了现有的各种 PFL 方法，但并未针对 IoV 场景进行分析应用。为了提高 IoV-FL 性能，实现更加精准、高效的智能交通业务，亟须对 IoV-PFL 方法进行总结分析，解决异质性问题的不良影响。受文献^[25]的启发，本文将现有 PFL 方法归纳为基于本地数据预处理、本地模型微调、全局模型优化和训练架构动态组织 4 类，并从无线网络优化的视角出发，提出了解决 IoV-FL 数据异质性问题新的研究方法和思路，在此基础上构建了如图 3 所示的基于个性化解决 IoV-FL 异质性的方案体系。

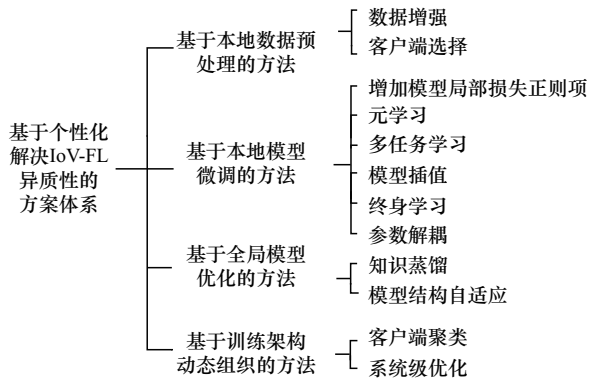


图3 基于个性化解决IoV-FL异质性的方案体系

2.1 基于本地数据预处理的方法

基于本地数据预处理的方法旨在 FL 执行前通过修改数据分布来解决异质性问题，数据增强和客户端选择是 2 类主要手段。

2.1.1 数据增强

数据增强^[35]是通过随机变换或知识转移来增

加数据多样性的技术，可用于缓解 IoV 中的数据不平衡问题^[36]。PFL 中常见的数据增强方法有 3 种，分别为 vanilla^[37]、mixup^[38]和生成式对抗网络^[39]。汤凌韬等^[36]提出了面向 FL 的数据增强框架，并基于生成式对抗网络设计了隐私保护的样本生成算法，在保证原数据隐私的前提下生成虚拟样本并共享，有效缓解了训练过程中数据分布差异导致的模型偏移问题。Aliyu 等^[24]提出了通过集成统计检测器来检测和提取未知的对抗样本，通过将未知样本包含到检测器的数据集中来增强 IoV-FL 方法的入侵检测能力，使系统能够在不可预见的攻击下保持可靠性。

2.1.2 客户端选择

客户端选择基于特定准则挑选实际参与训练的客户端，以便得到更均匀的全局数据分布，提高中心模型的泛化能力^[25]。基于本地数据预处理的 FL 异质性问题个性化解决方法^[40-42]如表 3 所示。

在 IoV 中，由于终端设备类型复杂、数据量庞大且分布不均匀，可以采用客户端选择来筛选出高质量用户。Song 等^[42]提出了基于上下文的客户端选择算法，通过预测 IoV-FL 中车辆到万物（V2X, vehicle to everything）链路的通信时延对客户端进行选择，以解决 IoV 中由客户端数据集异质和通信方式异构导致的异质性问题。

2.2 基于本地模型微调的方法

尽管基于本地数据预处理的方法可以提高 FL 全局模型的训练性能，但修改局部的数据分布可能丢失与用户行为多样性相关的重要信息^[25]。在 IoV 中，训练单一模型的 FL 难以向用户提供多元化的业务类型和定制化的服务内容。而在面向多模型的 FL 架构中，如何进行本地模型微调实现用户个性化需求，是亟待解决的问题。基于本地模型微调的

表3 基于本地数据预处理的 FL 异质性问题个性化解决方法

方法	文献	是否考虑 IoV 场景	主要贡献	针对的 FL 异质性类型
数据增强	文献[24]	是	通过安全增强模型检测 FL 训练中的入侵行为，从而提高 IoV 安全性	—
	文献[36]	否	隐私保护的样本生成算法，客户端在本地生成虚拟样本并在节点间共享	客户端数据集异质
	文献[40]	否	设置激励机制奖励训练性能高的客户端，惩罚需要更多轮通信的客户端	客户端数据集异质/信道差异导致的异质
客户端选择	文献[41]	否	将声誉与契约理论相结合，以激励具有高质量数据的高信誉客户端	—
	文献[42]	是	基于延迟预测选择客户端，以减少通信轮数和缩短每轮时间来提高效率	客户端数据集异质/信道差异导致的异质

PFL 方法旨在帮助客户端获得个性化和自适应能力强的本地模型,具体包括增加模型局部损失正则项、元学习、多任务学习 (MTL, multi-task learning)、模型插值、终身学习和参数解耦。

2.2.1 增加模型局部损失正则项

模型正则化是防止机器学习过拟合并提高收敛性的常用策略^[43],可以抑制模型局部更新对全局模型产生的不平衡影响,提高收敛稳定性和全局模型的泛化能力,进而生成性能更好的个性化模型^[25]。

由于 IoV 中不同终端的数据感知方式不同,在部署 FL 时可能会形成客户端数据集异质问题,蓝梦婕等^[44]针对这一问题提出了动态联邦自正则算法,在 FL 的训练过程中引入自正则化惩罚项,通过计算本地模型和全局模型的相似度来确定自正则项系数,动态地修改本地损失函数,从而缓解 Non-IID 数据集带来的客户端偏移问题。

在 IoV 中,通过增加模型局部损失正则项可以增强 FL 的泛化能力,使模型更好地满足车辆在复杂道路和多变路况下的实时决策需求,同时缓解网络性能波动造成的决策滞后,确保智能交通系统的高效稳定运行。

2.2.2 元学习

元学习旨在通过接触各种任务 (即相应的数据集) 来改进学习策略^[45],使得算法或模型的自适应能力更强,能够快速有效地学习新任务。

Chen 等^[46]提出了一种面向 Non-IID 数据集的联邦元学习框架,允许移动设备和中央服务器进行模型参数交互共享的同时利用元学习提高模型的收敛性与准确性。Yue 等^[47]设计了一种基于非均匀设备选择的联邦元学习算法,旨在加速模型训练收敛,提高面向异质数据集的全局模型训练收敛速度。

在 IoV 高可靠低时延的要求下,元学习可以节省 FL 的训练时间,并提高全局模型的泛化能力^[48]。但目前联邦元学习仍存在许多难点^[49],还没有在 IoV 领域应用的研究。考虑到用户对智能交通业务长久性和多样性的需求,未来可以利用元学习在持续的 FL 过程中学习如何进行训练策略动态优化^[50]。

2.2.3 多任务学习

多任务学习旨在面向多个具有相关性的任务训练一个通用模型^[51]。基于 MTL 的 FL (MTL-FL) 将每个 FL 客户端的本地模型训练视为 MTL 中的一

项任务,并通过给客户端分配不同的本地训练任务来解决设备异构造成的异质性问题^[51-52]。

Zeng 等^[19]提出了一种新型的 MTL-FL 框架,能够在不共享本地数据的情况下优化交通预测模型。为了在面向 6G 的 IoV 中提升 MTL-FL 的训练效率与通信效率并保护用户的安全隐私, Li 等^[52]设计了一种考虑客户端调度和频谱分配的车辆联邦算法。由于 MTL-FL 为客户端分配不同的训练任务并生成不同的本地模型,每个客户端都参与一轮训练会显著增加 IoV-FL 的通信开销。因此,在总算资源有限的 IoV 中可以考虑结合降低通信开销的技术 (如雾计算、空中计算等),以提高 MTL-FL 的整体性能。

2.2.4 模型插值

虽然上述个性化方法能够缓解 IoV-FL 异质性问题,但可能导致模型泛化能力下降和过拟合^[53]。为了平衡 PFL 泛化和个性化程度,模型插值^[54]在已有的模型参数之间进行插值,基于局部模型和全局模型之间的相似度计算来提高模型的泛化能力。Hanzely 等^[55]提出了每个 FL 客户端学习一个单独的本地模型,用惩罚参数 λ 作为本地模型和全局模型参数之间的插值,用于避免局部模型与全局模型的严重不相似情形,从而提高异质数据的训练性能。

根据前期调研,目前尚未出现基于模型插值的 IoV-FL 个性化方法研究,但在智能家居领域已有相关工作开展。Yang 等^[56]提出了基于聚类和模型插值的 PFL 算法,利用智能网关和摄像头将该算法用于智能家居场景的火焰识别任务,能有效避免家居环境中火灾的发生。在 IoV 中,车辆终端的移动性也会造成类似的数据处理低效率问题,基于该方法对 RSU 及车辆终端构建面向交通监测或轨迹预测任务的 PFL,可提升辅助驾驶的响应速度和决策准确性。

然而,在 IoV-FL 中引入模型插值解决异质性问题时,需要将算法复杂度纳入考虑范围,模型插值复杂度过高会造成 FL 的通信时延增大,难以满足 IoV 业务的实时性要求。

2.2.5 终身学习

终身学习的主要目的是在不忘记旧任务的情况下保持模型面向新任务的准确性^[7]。现有研究发现,借鉴终身学习的理念能够有效克服 Non-IID 数据集对 FL 的影响。

弹性权重巩固 (EWC, elastic weight consolidation) [57] 是一种缓解灾难性遗忘的有效方法。为了避免非目标数据的灾难性遗忘, Shoham 等[58]将 FL 和终身学习进行类比, 提出了一种基于 EWC 的联邦算法, 在每个本地训练的损失函数中都添加惩罚项, 以促使各个本地模型均收敛到一个共同的全局最优结果。对于移动机器人的自主导航问题, Liu 等[59]结合终身学习和强化学习提出了一种终身联邦强化学习算法, 使移动机器人能够快速适应新环境, 提高训练效率。Yu 等[60]针对移动机器人基于视觉的避障任务, 探索了 FL 在分布式移动机器人系统中的应用潜力, 利用移动机器人对虚拟场景和现实场景的探索与交互不断学习面向自适应避障策略的 AI 模型, 并在执行任务时获取面向动态环境的自主导航新数据, 从而构建持续学习流程。

考虑到终身学习可以保证在模型训练过程中积累新知识, 因此可以在 IoV-FL 中将终身学习用于道路目标识别、行车路径规划等应用, 以应对不断变化的道路环境, 从而解决相应的数据异质性问题, 实现更智能、适应性更强的个性化业务。

2.2.6 参数解耦

参数解耦通过分离客户端的私有模型参数与全局模型参数来实现个性化训练[25], 即将模型参数区分为私有模型参数和上传全局参数, 以提升客户端本地的个性化学习能力。其中私有模型参数仅在客户端本地训练。

具体实现参数解耦通常有 2 种方法。第一种是文献[61]提出的“基础层+个性化层”方法, 个性化层用于本地学习个性化的特定任务表征, 而基础层参数被上传至 FL 服务器共享, 用于学习低级通用特征。针对视觉图像分析中的数据异质性问题, Su 等[62]提出了基于参数解耦策略的 PFL 方法, 利用基础层来适应个性化模型, 能够在保护本地隐私的同时减少异质性问题带来的影响。然而, 该方法需要每个客户端长期存储个性化层且不能释放它们, 导致存储资源的占用空间过大。在资源有限的 IoV 中, 客户端可能会由于存储资源不足而无法存储数据和模型参数, 从而影响 FL 的准确性和收敛速度。

第二种是为每个客户端分别构建个性化特征。为了应对由于传感器不同姿态和数量所带来的异质性问题, Song 等[63]将 Transformer 模型中的位置嵌

入作为私有参数, 而其他参数则共享并聚合到服务器, 为每个客户端提供一个定制化的模型, 从而提高本地模型的准确性。

由于这 2 种参数解耦方法都会在一定程度上增加 FL 复杂度, 且相关研究较少, 目前通过参数解耦应对 IoV-FL 异质性问题的个性化方法仍然有限。未来可以考虑在 IoV 中的道路目标识别、信号灯及交通指示牌识别等应用中研究基于参数解耦的 PFL, 面向特定车辆、驾驶员、行人构建个性化层, 同时提高在异质性场景下 IoV-FL 的收敛速度和准确性。基于本地模型微调的 FL 异质性问题个性化解决方法如表 4 所示。

2.3 基于全局模型优化的方法

基于全局模型优化的个性化方法能够对 FL 中每个客户端进行模型定制化设计, 提升全局模型整体性能[25]。其中知识蒸馏 (KD, knowledge distillation) 可支持个性化模型架构, 而模型结构自适应能动态调整模型结构, 满足 IoV-FL 的分布式应用需求。

2.3.1 知识蒸馏

在 FL 中使用知识蒸馏可以通过知识积累减轻数据异质性和对全局模型性能产生的影响, 提升模型训练的通信效率和计算效率[64-65]。联邦蒸馏示意如图 4 所示, 将 FL 视为一个 KD 中的知识积累过程, 中心服务器上的模型视为教师模型, 客户端上的模型视为学生模型, 从教师模型上学习、继承所积累的知识, 可以克服灾难性遗忘造成的模型训练性能差的问题[66]。

在 FL 中, KD 常与迁移训练相结合, 利用预训练模型实现知识迁移, 避免从头构建模型。Shuai 等[66]提出了一种新的 FL 框架, 用 KD 应对数据异质性造成的知识遗忘, 在长尾数据集上进行模型训练, 保证多数类训练精度的同时提高尾部类的训练准确率。Lin 等[67]提出了基于鲁棒联邦模型的蒸馏框架, 利用集成蒸馏策略对多个模型进行鲁棒融合, 降低了隐私泄漏风险和 FL 计算成本。

此外, KD 还能解决对抗性样本造成的模型训练效果不佳的问题。文献[68]在车辆图像数据中只增加了少量扰动, 训练得到的模型就会将车辆误识别为猫。因此, 在安全性敏感的 IoV 应用场景中, 采用 KD 可以减少对抗性样本引起的模型推理错误, 缓解安全隐患。

表 4 基于本地模型微调的 FL 异质性问题个性化解决方法

方法	文献	是否考虑 IoV 场景	主要贡献	针对的 FL 异质类型
增加模型局部损失正则项	文献[44]	否	基于本地-全局模型相似度引入自正则化惩罚项动态调节本地损失函数	客户端数据集异质/可用计算资源差异
元学习	文献[46]	否	模型参数在终端和服务器间传输,不将原始数据收集到服务器上	客户端数据集异质/通信方式异构/可用计算资源差异
	文献[47]	否	基于多址技术的非均匀客户端选择与无线资源分配联合优化 FL	客户端数据集异质/通信方式异构/可用计算资源差异
多任务学习	文献[19]	是	引入分层聚类,利用 MTL-FL 框架与 A*算法预测最短行驶路径	—
	文献[52]	是	设计面向车辆和无线资源联合调度的 MTL-FL 算法,提高 FL 效率	客户端数据集异质/通信方式异构
模型插值	文献[55]	否	提出基于变式 SGD 的 FL 模型优化算法,利用个性化降低通信开销	—
	文献[56]	否	对异构客户端先分类再聚合,通过聚类间模型插值实现 PFL	客户端数据集异质
终身学习	文献[58]	否	在损失函数中加入惩罚项,迫使所有局部模型收敛到共享最优	客户端数据集异质/通信方式异构/可用计算资源差异
	文献[59]	否	设计终身联邦强化学习机制,提出知识融合算法对共享模型升级	—
	文献[60]	否	探索 FL 在分布式系统的应用,机器人在模拟/现实场景中持续学习	—
参数解耦	文献[61]	否	提出用于深度提要联合训练的“基础层+个性化层”方法	客户端数据集异质
	文献[62]	否	基于参数解耦策略的 PFL,通过元转移和基础层适应个性化模型	客户端数据集异质
	文献[63]	是	基于本地数据集为客户端定制模型,提高本地感知的准确性	客户端数据集异质/通信方式异构

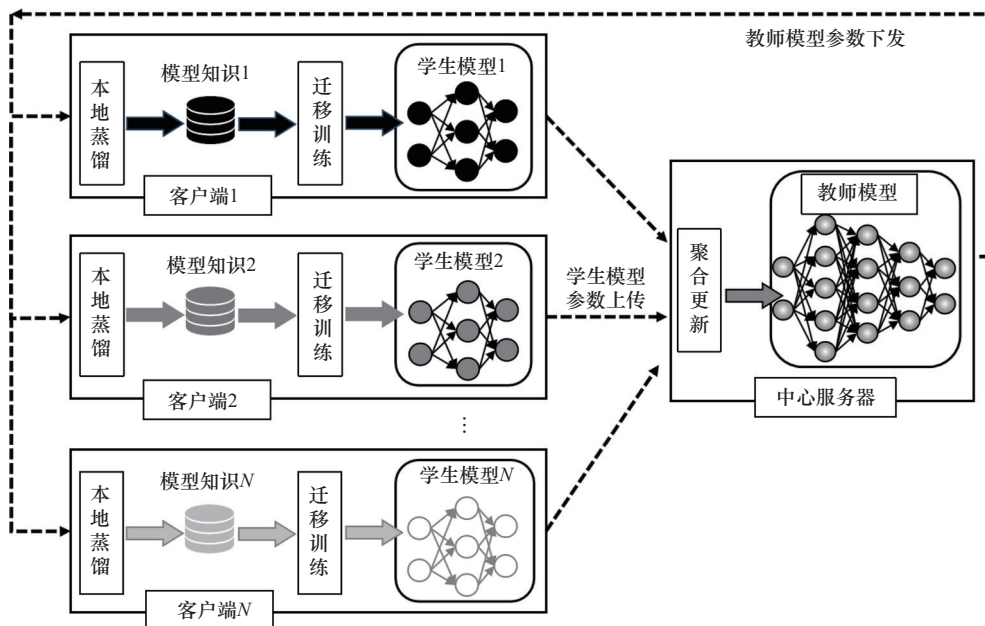


图 4 联邦蒸馏示意图

2.3.2 模型结构自适应

IoV 环境动态复杂, 模型训练涉及的参数较多, 部署 FL 需要大量的通信资源, 且海量异质数据会造成模型训练性能下降。因此, 自适应地调整模型结构成为一种重要的策略, 能够节约通信资源, 提升模型训练性能。现有 2 种通过自适应调整模型结构从而加速 FL 中模型训练收敛速度的技术。

一种是使用自适应优化器, 如 Adagrad^[69]、Adam^[70]等, 来取代随机梯度下降 (SGD, stochastic gradient descent) 优化器。然而, 这些自适应优化器往往需要对先前的梯度信息积累动量才能进行更新^[71], 这会使本地模型参数上传的通信成本增加。为解决这个问题, Reddi 等^[72]提出了一个联邦自适应框架, 基于服务器上的平均全局梯度计算累积梯度, 客户端执行 SGD 训练本地模型。不仅节省了 FL 的计算资源, 还降低了通信成本。陈飞扬等^[73]提出了一种基于 Non-IID 数据集的联邦迁移学习框架, 根据模型参数动态分配客户端模型聚合的权重, 并引入个性化迁移学习模型和动量梯度下降算法加快本地模型收敛速度。

另一种模型结构自适应技术是组归一化 (GN, group normalization)^[74-75]和批归一化 (BN, batch normalization)^[76], GN 是通过分组计算均值和方差, BN 是对比 GN 更小批次的数据进行计算, 实现对数据的标准化, 以消除客户端数据分布不均匀的影响。Du 等^[77]证明了归一化层在 FL 中是必不可少的, 其中层归一化 (LN, layer normalization) 方法是较好的选择。LN 方法是对每个特征层的数据进行标准化处理, 可以减轻外部协变量移位从而提高全局模型的训练性能。

由此可见, 模型结构自适应技术能有效应对数据异质性和网络波动, 在保障通信效率的同时提高

FL 性能, 在网络动态、资源有限的 IoV 中具有应用价值。基于全局模型优化的 FL 异质性问题个性化解决方法如表 5 所示, 这些个性化解决方法可以有效应对 IoV-FL 中的数据异质性问题。然而 KD 和模型结构自适应都会在一定程度上增加 FL 的通信成本, 如何在应用这些方法解决 IoV-FL 异质性问题同时提高通信效率是一个值得研究的方向。

2.4 基于训练架构动态组织的方法

随着网联车辆终端数量的大幅增加, 参与 FL 的服务器、客户端的种类和数量也随之增加。例如, 在 MEC-FL 中, FL 架构演变为云服务器、边缘服务器和客户端 3 层^[78]。针对这些架构优化的 PFL 称为基于训练架构动态组织的方法, 主要包括客户端聚类 and 系统级优化。

2.4.1 客户端聚类

客户端聚类是将本地训练数据特征相似的客户端分为一类, 构建一个多中心的训练框架^[25]。在客户端聚类前, 一些方法^[79-80]使用标准的 FedAvg 算法预训练全局模型, 再下发到客户端进行本地更新, 并将更新后的模型参数返回服务器。服务器基于余弦相似度等指标计算接收到的模型参数相似度, 并根据相似度得分将客户端分组。Zhu 等^[81]引入了一种两阶段解耦 FL 算法, 结合推理输出和模型权重分别执行 2 次客户端聚类, 并采用随机期望最大化算法实现客户端聚类与模型训练的同步进行。Taik 等^[82]提出了一种分簇的 IoV-FL 结构, 允许在不同车辆聚类的同时训练模型, 并且当所有聚类完成本地训练后才将模型参数发送至服务器, 提高了 FL 的通信效率和模型精确度。

考虑到生成多个全局模型有利于提高 FL 的可扩展性和灵活性, 可以为 IoV 特定的任务场景选择或集成不同的聚类模式。然而, 客户端聚类在 FL

表 5 基于全局模型优化的 FL 异质性问题个性化解决方法

方法	文献	是否考虑 IoV 场景	主要贡献	针对的 FL 异质性问题类型
知识蒸馏	文献[66]	否	在长尾数据集中训练, 同时解决全局数据和本地数据的不平衡问题	客户端数据集异质
	文献[67]	否	用客户端模型输出的无标签数据训练分类器, 提高鲁棒性	客户端数据集异质/可用计算资源差异
模型结构自适应	文献[72]	否	累积的梯度根据服务器上的平均全局梯度计算	客户端数据集异质
	文献[73]	否	引入客户端动态权重及个性化迁移模型加快本地训练速度	客户端数据集异质/可用计算资源差异
	文献[77]	否	证明归一化层对 FL 的重要性, 表明 LN 可以提高全局模型的训练性能	客户端数据集异质

模型训练中需要消耗额外的计算资源和通信资源,也可能由于过度依赖相似度分析而造成新的安全隐患风险。因此,可以将客户端聚类和其他提高计算效率、通信效率及安全隐私性的技术(如区块链技术)相结合,提高IoV-FL的整体性能。

2.4.2 系统级优化

系统级优化是指在系统设计的整体层面上进行的优化和改进。在FL中,系统级优化主要是根据FL不同的传输、计算和感知层对FL系统架构进行的优化,旨在提高FL系统的训练性能、效率、可靠性和可扩展性。微众银行推出了一个开源工业FL框架FATE(federated AI technology enabler)^[83],该框架可以通过参数化和非参数化学习模型支持横/纵向FL,实现高性能的分布式计算环境。针对数据异质性问题,Jing等^[84]使用FATE量化了联邦迁移学习在同构和异构任务上的性能,并提出可以进一步优化进程间通信和数据加密导致的计算开销、互联

组网条件等联邦迁移学习的瓶颈。

在IoV领域,Kathen等^[85]提出了一种基于多模态粒子群优化FL的水质监测系统,利用自动水面车辆监测水资源。考虑到时变数据的异质性问题 and 无人机(UAV,unmanned aerial vehicle)的算力限制,Wang等^[86]结合多无人机边缘计算,开发了一种分层嵌套PFL用于个性化模型训练,利用个性化的局部模型在无人机群中进行FL来解决算力不足和数据异质性的问题。基于训练架构动态组织的FL异质性问题个性化解决方法如表6所示。

3 关键挑战与未来研究方向

尽管现有个性化方法可以在一定程度上解决FL的异质性问题,但在IoV领域仍面临诸多挑战。如图5所示,本节对现有个性化方法处理IoV-FL异质性问题所面临的关键挑战和未来研究方向进行了直观描绘。

表6 基于训练架构动态组织的FL异质性问题个性化解决方法

方法	文献	是否考虑IoV场景	主要贡献	针对的FL异质性类型
客户端聚类	文献[81]	是	基于推理输出和模型权重进行两次聚类,用Hopkins修正优化聚类性能	客户端数据集异质
	文献[82]	是	不同聚类同时训练,全部完成后模型参数才发送到多访问MEC服务器	客户端数据集异质/通信方式异构/可用计算资源差异
系统级优化	文献[85]	是	基于多模态粒子群优化和AquaFeL-PSO算法,高斯过程作为建模基础	—
	文献[86]	是	微宏观联合优化,基于无人机群训练模型来解决算力不足及异质性问题	客户端数据集异质/可用计算资源差异

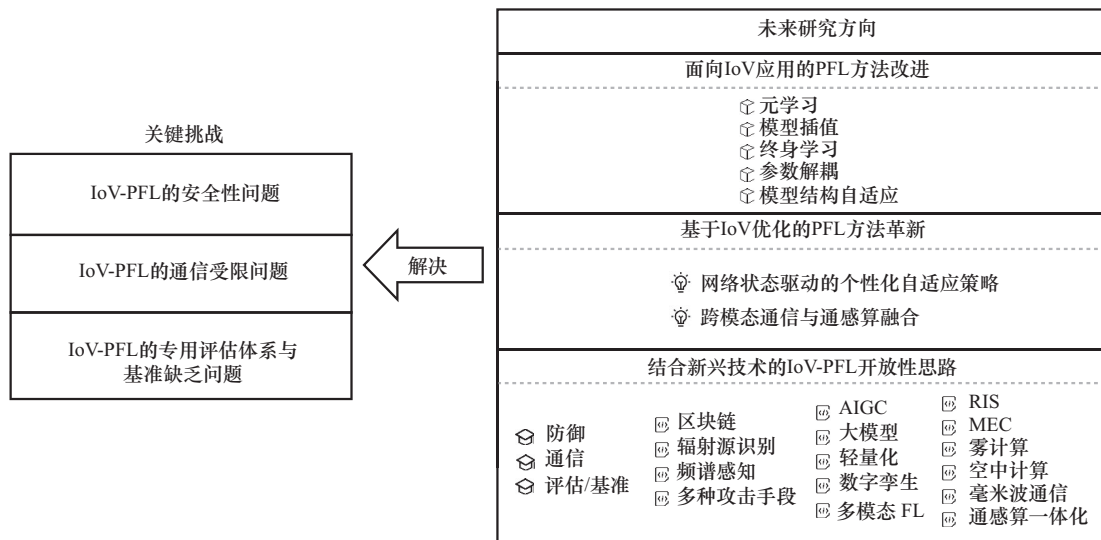


图5 在IoV中部署PFL的关键挑战及其未来研究方向

3.1 在 IoV 中部署 PFL 存在的关键挑战

在网络连接动态不可靠、通算资源相对受限和具有低时延高可靠业务需求的 IoV 场景中应用 PFL 存在多种实际部署挑战, 本文将这些关键挑战分为 IoV-PFL 的安全性问题、通信受限问题以及专用评估体系与基准缺乏问题 3 类。

3.1.1 IoV-PFL 的安全性问题

将个性化方法引入 IoV-FL 会产生新的安全漏洞。在 IoV-FL 数据增强的过程中, 会因知识共享或特征提取提高安全隐私泄露的风险^[87]。而知识蒸馏过程中存在的安全漏洞或错误配置, 可能会导致模型被恶意利用。现有 PFL 研究中多采用单一的加密或隐私保护机制, 因此难以抵御愈发智能先进的隐私攻击^[88-89]。

同时, 由于 IoV 无线信号传播的开放性和网络环境的多样性, PFL 模型信息可能遭受拦截、篡改、拒绝服务攻击或被未授权的第三方获取^[90], 而这些个性化数据往往包含更为丰富全面的用户隐私信息。因此, IoV-PFL 的防御机制需要重点关注通信的机密性、完整性和可用性。

3.1.2 IoV-PFL 的通信受限问题

得益于 6G 网络的高速、低时延和高可靠的通信能力, IoV-PFL 在地质勘测等^[91-93]领域中的应用潜力显著增加。然而, 这些未来的 IoV 应用需要实时处理和传输海量数据, 不仅要求很高的安全性和隐私性, 同时对信道的通信质量和设备的计算能力也具有极高的要求。目前尚未有研究充分探讨 6G 技术环境下的通信方式异构对 IoV-FL 异质性问题造成的影响。此外, 当 PFL 算法/模型复杂度过高时, 可能会导致不必要的资源消耗^[94], 这种资源消耗在 6G 下的 IoV-PFL 应用中更为明显, 会加剧通信受限问题。

3.1.3 IoV-PFL 的专用评估体系与基准缺乏问题

在专用评估体系与基准缺乏问题设计方面, 现有 IoV-PFL 技术缺乏在安全隐私评估、超参数设置和基准数据集构建 3 个方面的深入研究。

在安全隐私评估方面, 目前没有具体的评估方法来衡量已提出的 IoV-PFL 可能造成的隐私泄露程度。在超参数设置方面, IoV-PFL 中包含大量的超参数^[95], 如客户端总数、本地训练 epoch 数、学习率等。由于现有的不同算法中所设置的超参数各不相同, 难以对不同的 PFL 处理 Non-IID 数据集的性

能进行统一测试, 需要根据实际应用场景对不同算法设定基准超参数。在基准数据集构建方面, 当前大多数 FL 研究主要采用 CIFAR10/100、MNIST 等通用数据集, 缺乏 IoV-FL 专用的同质异构基准数据集。

3.2 未来研究方向

由上述分析可知, 现有个性化方法在解决 IoV-FL 数据异质性问题时仍存在各种挑战, 且尚有部分方法并不是针对 IoV 场景。因此, 本节从以下 3 个方面提出了未来研究方向。1) 针对未应用于 IoV 的现有 PFL 方法, 通过深入分析每种方法的优势和难点, 结合 IoV 的网络特点与性能需求提出了改进建议, 以期在 IoV-FL 的数据异质性问题中发挥价值。2) 针对现有 PFL 部署于 IoV 中的不足之处, 以 IoV 无线网络优化的视角为主探索更灵活、更具针对性的 IoV-PFL 方法。3) 针对 3.1 节中分析的关键挑战, 基于无线通信等领域的前沿技术从多个方面提出了开放性的解决思路, 以期进一步提升 IoV-FL 方法的性能。

3.2.1 面向 IoV 应用的 PFL 方法改进

元学习、模型插值、终身学习、参数解耦和模型结构自适应这 5 种 PFL 方法虽然各自具有独特的优势和适用场景, 但研究深度和广度仍有待提升。特别是在网络环境动态复杂且资源有限的 IoV 场景中, 这些方法的直接部署面临着诸多挑战。例如, 元学习和终身学习要求模型具备强大的在线学习能力和适应新任务的能力, 但在资源受限的 IoV 环境下, 如何有效地进行知识迁移和共享是一个难题。模型插值和参数解耦需要在保证模型性能的同时, 实现模型的灵活性和可扩展性, 这在复杂的动态网络环境中同样是一项艰巨的任务。而模型结构自适应则需要模型能够根据不同的任务和数据特征自动调整其结构, 这在目前的研究中仍是一个亟待突破的方向。

因此, 可以根据实际部署条件与具体应用需求, 考虑将这些方法与新兴的 IoV 技术相结合, 充分利用 IoV 中各种资源和信息的优势, 提高模型的精度、效率和泛化能力, 从而推动 PFL 在 IoV 领域的实际应用, 更好地解决其中的数据异质性问题。

3.2.2 基于 IoV 优化的 PFL 方法革新

根据调研发现, 第 2 节的 PFL 均可处理 FL 中的数据异质性问题, 模型的准确性和收敛速度均有所提高, 且许多工作结合了多种个性化方法来更好

地解决 FL 异质性问题^[17,58-59,81]。但是将这些 PFL 方法应用于 IoV 场景仍然存在不足之处, 根据上述在 IoV 中部署 PFL 的关键挑战, 本节从 4 个方面具体分析上述各 PFL 方法应用于 IoV 场景的不足之处, 如表 7 所示。

究其原因, 是目前相关研究主要从模型训练的角度, 将已有通用的 PFL 方法应用于 IoV 场景, 鲜有以无线网络优化的视角为主探索更灵活、更具针对性的 IoV-PFL 方法。因此, 本文在现有 IoV-PFL 方法的基础上提出了如下的研究新思路。

1) 网络状态驱动的个性化自适应策略。考虑到 IoV 场景具有较高的移动性、网络环境动态性等特点, 对网络传输具有低时延高可靠的要求, 可以考虑根据网络条件的动态变化自适应地选择适合的 PFL 方法, 从而提高模型训练的灵活性与鲁棒性。与现有的模型结构自适应方法相比, 在提高模型训练精度方面具有相同的效果。结合图深度学习或知识图谱等技术, 可以有效捕捉网络拓扑结构, 能够更直接地根据网络节点的链路状态来调整模型结构或参数的传输策略, 更好地适应 IoV 场景的网络状况, 避免了模型结构自适应方法在 IoV 中可能导致的过拟合或通信时延问题。

2) 跨模态通信与通感算融合。面向智能交通管理的 RSU 和面向自动驾驶的车辆终端都配备了

如传感器、摄像头、激光雷达等多种感知设备, 为 IoV-FL 提供了丰富的多源异构数据。通过这些数据跨模态融合利用, 能够有效缓解跨设备的数据异质性问题。在此基础上, 通过面向通感算融合的网络联合优化, 能够更高效地利用网络资源赋能各 IoV 设备实现多模态数据的感知融合与传输分析, 在缓解 FL 数据异质性问题同时保障网络传输性能。

3.2.3 结合新兴技术的 IoV-PFL 开放性思路

针对 3.1 节所提出的关键挑战以及 3.2.2 节提出的 PFL 方法的不足之处, 本节结合相关领域的新兴技术提出了一些可供参考的开放性解决思路。

1) 面向 IoV-PFL 的定制化防御手段

IoV 的不同应用场景对安全性、隐私性和时延敏感性的要求存在差异^[16,19]。为了适应 IoV 的多样化场景, 可以考虑将性能各异的隐私保护技术, 如区块链^[96]、安全多方计算^[97]等, 用于不同场景实现定制化的防御策略。

电磁频谱认知与管控技术^[98]可以用于提高对恶意攻击的检测能力和防御能力, 从而增强 PFL 方法的安全性和效率, 有望成为解决 IoV-PFL 安全性问题的重要手段。此外, 应该考虑用更多种类的智能攻击来测试已提出的 PFL 方法和框架, 并结合物理指纹(射频指纹和信道指纹)、可重构智能表面

表 7 各 PFL 方法应用于 IoV 场景的不足之处

类别	方法	是否适用于 IoV 场景	不足之处			
			影响模型训练开销	影响模型训练公平性	影响模型鲁棒性	影响模型复杂度
基于数据预处理	数据增强	是	√	—	—	—
	客户端选择	是	√	√	—	—
基于本地模型微调	增加模型局部损失正则项	是	—	—	—	√
	元学习	是	√	—	—	√
	多任务学习	是	√	—	√	√
	模型插值	是	—	—	—	√
	终身学习	是	√	—	√	√
基于全局模型优化	参数解耦	是	√	—	—	√
	知识蒸馏	是	√	—	—	√
基于训练架构动态组织	模型结构自适应	是	—	—	—	√
	客户端聚类	是	√	√	√	√
	系统级优化	是	√	—	—	—

注:√表示该方法存在此类性能影响,—表示该方法不存在此类影响。

(RIS, reconfigurable intelligent surface) 等技术, 通过从接收信号中提取细微差异用于信号分析从而识别恶意用户, 提高 IoV 防御攻击的能力。

2) 6G 赋能的 IoV-PFL

6G 技术有望进一步提升 IoV-PFL 的通信效率和模型训练速度^[99]。在基于 6G 技术的未来 IoV 应用中, 不同场景应考虑使用不同复杂程度的模型/算法。例如, 基于 IoV 的大气勘测需要采集某一周期的气象数据并进行分析, 对于模型复杂度没有高要求。而对于应急救援、脑-车连接等应用, 若模型复杂度较高, 会导致通信时延增大, 甚至可能会造成驾驶安全问题。因此, 未来可以根据模型复杂度情况, 结合其他提高通信效率的方法来降低通信时延, 从而在一定程度上提高道路安全性。

对于 IoV 实际通信过程中由于通信方式异构造成的异质性问题, RIS 可以实现对电磁波的精确控制, 从而扩大无线通信的覆盖范围, 提高信息传输速度^[100]。同时借助通感算一体化技术提高 IoV 设备在感知范围与模态方面的综合能力, 通过云-边-端多维感知和协作通信, 将各类感知和计算数据整合到 IoV-PFL 中, 实现新型闭环信息流智能交互与处理^[101], 有助于满足定制化 IoV 业务对 PFL 高可靠低时延的通信需求。

3) 面向 IoV 不同业务的 PFL 定制化评估体系

由于 IoV-FL 在通信过程中大量超参数的交互容易造成数据冲突, 可以考虑构建反映 IoV 场景实际需求和挑战的 PFL 基准问题, 这个基准问题应包含标准化的超参数设置, 以便研究人员可以公平地评估和比较 IoV-PFL 方法在损失函数、准确度等方面的性能。由于现有 PFL 方法采用的模型大多较为简单, 可以考虑结合基础大模型^[102]等先进 AI 方法提高模型的准确性和泛化能力。基于大模型的 IoV-PFL 方法允许每个客户端基于本地数据学习个性化的模型, 能够更好地理解和生成与特定车辆或用户相关的信息, 从而提高面向异质数据的客户端模型性能。同时可以根据不同车辆终端的通算资源限制, 定制化地调整本地模型的更新方式和聚合方式, 减少通信开销, 从而满足不同 IoV 设备的个性化需求^[103]。然而, 当模型复杂度过高时, 会造成通算资源的浪费, 因此需要考虑结合轻量化模型方法, 对复杂模型进行压缩和剪枝, 在提高 FL 训练性能的同时减少模型参数量, 提高个性化的 FL 效

率。将复杂模型纳入基准问题的构建中, 使基准问题更具代表性和挑战性, 以促进 IoV-PFL 方法的研究进展。

针对缺乏 IoV 专用数据集的问题, 可以考虑基于数字孪生^[104]技术构建面向高动态环境的 IoV 物理层、网络层及应用层仿真数据集, 通过将实际车辆数据和地理信息系统空间数据相结合, 模拟驾驶过程和监测车辆健康。进而基于强化学习模拟面向 IoV 的 PFL 执行情况, 构建基于虚实结合的智能交通业务驱动的 IoV-PFL 专用数据集。此外, 还可以结合人工智能生成式内容^[105]为不同 IoV 场景生成各种多模态的异质数据集, 并结合图联邦学习或多模态联邦学习, 面向模态不同的 IoV 数据进行 PFL 训练, 从而更好地对车辆进行实时监测和故障预警, 并提供更全面和精细化的车辆安全管理。

4 结束语

本文全面地探讨了解决 IoV-FL 中异质性问题的个性化方法, 即 IoV-PFL。首先, 调研现有研究并分析了在 IoV 中应用 FL 实现智能化业务的重要意义。然后, 基于 IoV 复杂动态的网络环境和多元异构的终端接入等特性, 分析了在 IoV 中应用 FL 面临的异质性问题及其不同类型和产生原因。在此基础上, 引入多种个性化方法解决 IoV-FL 的异质性问题, 从本地数据预处理、本地模型微调、全局模型优化以及训练架构动态组织 4 个层面对这些 IoV-PFL 技术进行了分类分析。最后, 分析了在 IoV-FL 中采用个性化方法处理数据异质性问题存在的关键挑战, 并针对性地提出了未来研究方向。本文方法不仅丰富了 IoV-PFL 的理论研究, 也为实际应用中的 FL 数据异质性问题提供了针对性的解决方法, 有望推动 IoV-PFL 的实践应用, 进而提升智能交通系统的效率和安全性。

参考文献:

- [1] 陈山枝, 葛雨明, 时岩. 蜂窝车联网(C-V2X)技术发展、应用及展望[J]. 电信科学, 2022, 38(1): 1-12.
CHEN S Z, GE Y M, SHI Y. Technology development, application and prospect of cellular vehicle-to-everything (C-V2X)[J]. Telecommunications Science, 2022, 38(1): 1-12.
- [2] 中国信息通信研究院. 车联网白皮书[R]. 2021.
China Academy of Information and Communications Technology. White paper on connected vehicles[R]. 2021.
- [3] ABDULRAHMAN S, TOUT H, OULD-SLIMANE H, et al. A survey

- on federated learning: the journey from centralized to distributed on-site learning and beyond[J]. *IEEE Internet of Things Journal*, 2021, 8(7): 5476-5497.
- [4] MAO Y Y, YOU C S, ZHANG J, et al. A survey on mobile edge computing: the communication perspective[J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(4): 2322-2358.
- [5] SONG R, ZHOU L G, LAKSHMINARASIMHAN V, et al. Federated learning framework coping with hierarchical heterogeneity in cooperative ITS[C]//*Proceedings of the 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*. Piscataway: IEEE Press, 2022: 3502-3508.
- [6] 谢雨良, 田雨晴, 张朝阳. 面向智能通信和计算的移动边缘分布式学习:现状、挑战与方法[J]. *移动通信*, 2023, 47(6): 48-55.
- XIE Y L, TIAN Y Q, ZHANG C Y. Mobile edge distributed learning for intelligent communication and computing: methods, challenges and opportunities[J]. *Mobile Communications*, 2023, 47(6): 48-55.
- [7] ZHU H Y, XU J J, LIU S Q, et al. Federated learning on non-IID data: a survey[J]. *Neurocomputing*, 2021, 465: 371-390.
- [8] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[J]. *Proceedings of Machine Learning Research*, 2017, 54: 1273-1282.
- [9] LIU Y, YU J J Q, KANG J W, et al. Privacy-preserving traffic flow prediction: a federated learning approach[J]. *IEEE Internet of Things Journal*, 2020, 7(8): 7751-7763.
- [10] HE Y H, REN J K, YU G D, et al. Importance-aware data selection and resource allocation in federated edge learning system[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(11): 13593-13605.
- [11] 莫梓嘉, 高志鹏, 杨杨, 等. 面向车联网数据隐私保护的高效分布式模型共享策略[J]. *通信学报*, 2022, 43(4): 83-94.
- MO Z J, GAO Z P, YANG Y, et al. Efficient distributed model sharing strategy for data privacy protection in Internet of vehicles[J]. *Journal on Communications*, 2022, 43(4): 83-94.
- [12] LI Q B, DIAO Y Q, CHEN Q, et al. Federated learning on non-IID data silos: an experimental study[C]//*Proceedings of the 2022 IEEE 38th International Conference on Data Engineering (ICDE)*. Piscataway: IEEE Press, 2022: 965-978.
- [13] GAO D S, YAO X, YANG Q. A survey on heterogeneous federated learning[J]. *arXiv Preprint*, arXiv: 2210.04505, 2022.
- [14] WANG R, LI H J, LIU E W. Blockchain-based federated learning in mobile edge networks with application in Internet of vehicles[J]. *arXiv Preprint*, arXiv: 2103.01116, 2021.
- [15] LU Y L, HUANG X H, DAI Y Y, et al. Differentially private asynchronous federated learning for mobile edge computing in urban informatics[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(3): 2134-2143.
- [16] LI Y J, TAO X F, ZHANG X F, et al. Privacy-preserved federated learning for autonomous driving[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 8423-8434.
- [17] DOOMRA S, KOHLI N, ATHAVALE S. Turn signal prediction: a federated learning case study[J]. *arXiv Preprint*, arXiv: 2012.12401, 2020.
- [18] LIM W Y B, HUANG J Q, XIONG Z H, et al. Towards federated learning in UAV-enabled Internet of vehicles: a multi-dimensional contract-matching approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(8): 5140-5154.
- [19] ZENG T C, GUO J L, KIM K J, et al. Multi-task federated learning for traffic prediction and its application to route planning[C]//*Proceedings of the 2021 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway: IEEE Press, 2021: 451-457.
- [20] ZHANG Z W, WANG H J, FAN Z P, et al. GOF-TTE: generative online federated learning framework for travel time estimation[J]. *IEEE Internet of Things Journal*, 2022, 9(23): 24107-24121.
- [21] LI X H, CHENG L X, SUN C, et al. Federated-learning-empowered collaborative data sharing for vehicular edge networks[J]. *IEEE Network*, 2021, 35(3): 116-124.
- [22] WANG X H, ZHENG X K, LIANG X. Charging station recommendation for electric vehicle based on federated learning[J]. *Journal of Physics: Conference Series*, 2021, 1792(1): 012055.
- [23] SAPUTRA Y M, HOANG D T, NGUYEN D N, et al. Energy demand prediction with federated learning for electric vehicle networks[C]//*Proceedings of the 2019 IEEE Global Communications Conference (GLOBECOM)*. Piscataway: IEEE Press, 2019: 1-6.
- [24] ALIYU I, ENGELENBURG S V, MU'AZU M B, et al. Statistical detection of adversarial examples in blockchain-based federated forest intrusion detection systems[J]. *IEEE Access*, 2022, 10: 109366-109384.
- [25] TAN A Z, YU H, CUI L Z, et al. Towards personalized federated learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(12): 9587-9603.
- [26] HUANG Y T, CHU L Y, ZHOU Z R, et al. Personalized cross-silo federated learning on non-IID data[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(9): 7865-7873.
- [27] LIANG Y Y, ZHANG S, WANG Y H. Data-driven road side unit location optimization for connected-autonomous-vehicle-based intersection control[J]. *Transportation Research Part C: Emerging Technologies*, 2021, 128: 103169.
- [28] LUO J, WANG H, XU X H, et al. The influence of the spatial and temporal collocation windows on the comparisons of the ionospheric characteristic parameters derived from COSMIC radio occultation and digisondes[J]. *Advances in Space Research*, 2019, 63(10): 3088-3101.
- [29] PILLONI V, NING H S, ATZORI L. Task allocation among connected devices: requirements, approaches, and challenges[J]. *IEEE Internet of Things Journal*, 2022, 9(2): 1009-1023.
- [30] SHIN H, LEE K, KWON H Y. A comparative experimental study of distributed storage engines for big spatial data processing using GeoSpark[J]. *The Journal of Supercomputing*, 2022, 78(2): 2556-2579.
- [31] WU Q, HE K W, CHEN X. Personalized federated learning for intelligent IoT applications: a cloud-edge based framework[J]. *IEEE Computer Graphics and Applications*, 2020, 1: 35-44.
- [32] 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.
- [33] 牛志升. 面向6G网络的高可靠低延时通信计算与控制[J]. *中国科学(信息科学)*, 2024, 54(5): 1267-1282.
- NIU Z S. uRLLC3: ultra-reliable and low-latency communication, computing, and control for 6G networks[J]. *Scientia Sinica (Informationis)*, 2024, 54(5): 1267-1282.

- [34] MA Q P, XU Y, XU H L, et al. FedSA: a semi-asynchronous federated learning mechanism in heterogeneous edge computing[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(12): 3654-3672.
- [35] TANNER M A, WONG W H. The calculation of posterior distributions by data augmentation[J]. *Journal of the American Statistical Association*, 1987, 82(398): 528-540.
- [36] 汤凌韬, 王迪, 刘盛云. 面向非独立同分布数据的联邦学习数据增强方案[J]. *通信学报*, 2023, 44(1): 164-176.
TANG L T, WANG D, LIU S Y. Data augmentation scheme for federated learning with non-IID data[J]. *Journal on Communications*, 2023, 44(1): 164-176.
- [37] DUAN M M, LIU D, CHEN X Z, et al. Astraea: self-balancing federated learning for improving classification accuracy of mobile deep learning applications[C]//*Proceedings of the 2019 IEEE 37th International Conference on Computer Design (ICCD)*. Piscataway: IEEE Press, 2019: 246-254.
- [38] ZHANG H Y, CISSE M, DAUPHIN Y N, et al. Mixup: beyond empirical risk minimization[J]. *arXiv Preprint, arXiv: 1710.09412*, 2017.
- [39] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *arXiv Preprint, arXiv: 1406.2261*, 2014.
- [40] WANG H, KAPLAN Z, NIU D, et al. Optimizing federated learning on non-IID data with reinforcement learning[C]//*Proceedings of the IEEE INFOCOM 2020-IEEE Conference on Computer Communications*. Piscataway: IEEE Press, 2020: 1698-1707.
- [41] KANG J W, XIONG Z H, NIYATO D, et al. Incentive mechanism for reliable federated learning: a joint optimization approach to combining reputation and contract theory[J]. *IEEE Internet of Things Journal*, 2019, 6(6): 10700-10714.
- [42] SONG R, LYU L J, JIANG W, et al. V2X-booster federated learning for cooperative intelligent transportation systems with contextual client selection[J]. *arXiv Preprint, arXiv: 2305.11654*, 2023.
- [43] SANTOS C F G D, PAPA J P. Avoiding overfitting: a survey on regularization methods for convolutional neural networks[J]. *ACM Computing Surveys*, 2022, 54(10s): 1-25.
- [44] 蓝梦婕, 蔡剑平, 孙岚. 非独立同分布数据下的自正则化联邦学习优化方法[J]. *计算机应用*, 2023, 43(7): 2073-2081.
LAN M J, CAI J P, SUN L. Self-regularization optimization methods for non-IID data in federated learning[J]. *Journal of Computer Applications*, 2023, 43(7): 2073-2081.
- [45] HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(9): 5149-5169.
- [46] CHEN F, LUO M, DONG Z H, et al. Federated meta-learning with fast convergence and efficient communication[J]. *arXiv Preprint, arXiv: 1802.07876*, 2018.
- [47] YUE S, REN J, XIN J, et al. Efficient federated meta-learning over multi-access wireless networks[J]. *IEEE Journal on Selected Areas in Communications*, 2022, 40(5): 1556-1570.
- [48] TIAN Y J, ZHAO X X, HUANG W. Meta-learning approaches for learning-to-learn in deep learning: a survey[J]. *Neurocomputing*, 2022, 494: 203-223.
- [49] 张传尧, 司世景, 王健宗, 等. 联邦元学习综述[J]. *大数据*, 2023, 9(2): 122-146.
ZHANG C Y, SI S J, WANG J Z, et al. Federated meta learning: a review[J]. *Big Data Research*, 2023, 9(2): 122-146.
- [50] MA X, SHAHBAKHTI M, CHIGAN C X. Connected vehicle based distributed meta-learning for online adaptive engine/powertrain fuel consumption modeling[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(9): 9553-9565.
- [51] ZHANG Y, YANG Q. A survey on multi-task learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(12): 5586-5609.
- [52] LI Z J, WU H, LU Y L. Coalition based utility and efficiency optimization for multi-task federated learning in Internet of vehicles[J]. *Future Generation Computer Systems*, 2023, 140: 196-208.
- [53] CHEN M H, JIANG M R, DOU Q, et al. FedSoup: improving generalization and personalization in federated learning via selective model interpolation[C]//*Lecture Notes in Computer Science*. Berlin: Springer, 2023: 318-328.
- [54] MANSOUR Y, MOHRI M, RO J, et al. Three approaches for personalization with applications to federated learning[J]. *arXiv Preprint, arXiv: 2002.10619*, 2020.
- [55] HANZELY F, RICHTÁRIK P. Federated learning of a mixture of global and local models[J]. *arXiv Preprint, arXiv: 2002.05516*, 2020.
- [56] YANG Z K, LIU Y P, ZHANG S, et al. Personalized federated learning with model interpolation among client clusters and its application in smart home[J]. *World Wide Web*, 2023, 26(4): 2175-2200.
- [57] KEUPER J, PREUNDT F J. Distributed training of deep neural networks: theoretical and practical limits of parallel scalability[C]//*Proceedings of the 2016 2nd Workshop on Machine Learning in HPC Environments (MLHPC)*. Piscataway: IEEE Press, 2016: 19-26.
- [58] SHOHAM N, AVIDOR T, KEREN A, et al. Overcoming forgetting in federated learning on non-IID data[J]. *arXiv Preprint, arXiv: 1910.07796*, 2019.
- [59] LIU B Y, WANG L J, LIU M. Lifelong federated reinforcement learning: a learning architecture for navigation in cloud robotic systems[J]. *IEEE Robotics and Automation Letters*, 2019, 4(4): 4555-4562.
- [60] YU X J, QUERALTA J P, WESTERLUND T. Towards lifelong federated learning in autonomous mobile robots with continuous sim-to-real transfer[J]. *Procedia Computer Science*, 2022, 210: 86-93.
- [61] ARIVAZHAGANMG, AGGARWALV, SINGHAK, et al. Federated learning with personalization layers[J]. *arXiv Preprint, arXiv: 1912.00818*, 2019.
- [62] SU R Z, PANG X W, WANG H. A novel parameter decoupling approach of personalized federated learning for image analysis[J]. *Institution of Engineering and Technology Computer Vision*, 2023: 1-12.
- [63] SONG R, XU R S, FESTAG A, et al. FedBEVT: federated learning bird's eye view perception transformer in road traffic systems[J]. *IEEE Transactions on Intelligent Vehicles*, 2024, 9(1): 958-969.
- [64] BUCILUÁ C, CARUANA R, NICULESCU-MIZIL A. Model compression[C]//*Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2006: 535-541.
- [65] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. *arXiv Preprint, arXiv: 1503.02531*, 2015.
- [66] SHUAI X, SHEN Y L, JIANG S Y, et al. BalanceFL: addressing class imbalance in long-tail federated learning[C]//*Proceedings of the 2022*

- 21st ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN). Piscataway: IEEE Press, 2022: 271-284.
- [67] LIN T, KONG L J, STICH S U, et al. Ensemble distillation for robust model fusion in federated learning[J]. arXiv Preprint, arXiv: 2006.07242, 2020.
- [68] PAPERNOT N, MCDANIEL P, WU X, et al. Distillation as a defense to adversarial perturbations against deep neural networks[C]//Proceedings of the 2016 IEEE Symposium on Security and Privacy (SP). Piscataway: IEEE Press, 2016: 582-597.
- [69] DUCHI J, HAZAN E, SINGER Y. Adaptive subgradient methods for online learning and stochastic optimization[J]. The Journal of Machine Learning Research, 2011(12): 2121-2159.
- [70] KINGMA D P, BA J. Adam: a method for stochastic optimization[J]. arXiv Preprint, arXiv: 1412.6980, 2014.
- [71] SUTSKEVER I, MARTENS J, DAHL G, et al. On the importance of initialization and momentum in deep learning[C]//Proceedings of the 30th International Conference on Machine Learning (ICML). Piscataway: IEEE Press, 2013: 1139-1147.
- [72] REDDI S, CHARLES Z, ZAHEER M, et al. Adaptive federated optimization[J]. arXiv Preprint, arXiv: 2003.00295, 2020.
- [73] 陈飞扬, 周晖, 张一迪. FCAT-FL: 基于 Non-IID 数据的高效联邦学习算法[J]. 南京邮电大学学报(自然科学版), 2022, 42(3): 90-99.
- CHEN F Y, ZHOU H, ZHANG Y D. FCAT-FL: an efficient federated learning algorithm based on Non-IID data[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2022, 42(3): 90-99.
- [74] WU Y X, HE K M. Group normalization[C]//European Conference on Computer Vision. Berlin: Springer, 2018: 3-19.
- [75] ZHANG Z M, YANG Y Q, YAO Z W, et al. Improving semi-supervised federated learning by reducing the gradient diversity of models[C]//Proceedings of the 2021 IEEE International Conference on Big Data. Piscataway: IEEE Press, 2021: 1214-1225.
- [76] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. New York: ACM Press, 2015: 448-456.
- [77] DU Z X, SUN J W, LI A, et al. Rethinking normalization methods in federated learning[C]//Proceedings of the 3rd International Workshop on Distributed Machine Learning. New York: ACM Press, 2022: 1-9.
- [78] LIU L M, ZHANG J, SONG S H, et al. Client-edge-cloud hierarchical federated learning[C]//Proceedings of the ICC 2020-2020 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2020: 1-6.
- [79] SATTLER F, MULLER K R, SAMEK W. Clustered federated learning: model-agnostic distributed multitask optimization under privacy constraints[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(8): 3710-3722.
- [80] BRIGGS C, FAN Z, ANDRAS P. Federated learning with hierarchical clustering of local updates to improve training on non-IID data[C]//Proceedings of the 2020 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2020: 1-9.
- [81] ZHU H Y, FAN Y X, XIE Z P. Federated two-stage decoupling with adaptive personalization layers[J]. Complex & Intelligent Systems, 2024, 10(3): 3657-3671.
- [82] TAIK A, MLIKA Z, CHERKAOU S. Clustered vehicular federated learning: process and optimization[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 25371-25383.
- [83] FedAI. An industrial grade federated learning framework[R]. 2019.
- [84] JING Q H, WANG W Y, ZHANG J X, et al. Quantifying the performance of federated transfer learning[C]//Proceedings of the 1st International Workshop on Federated Machine Learning for User Privacy and Data Confidentiality. Piscataway: IEEE Press, 2019:1-7.
- [85] KATHEN M J T, JOHNSON P, FLORES I J, et al. AquaFeL-PSO: a monitoring system for water resources using autonomous surface vehicles based on multimodal PSO and federated learning[J]. Data Analytics and Computational Intelligence: Novel Models, Algorithms and Applications, 2023, 132: 405-431.
- [86] WANG S, HOSSEINALIPOUR S, GORLATOVA M, et al. UAV-assisted online machine learning over multi-tiered networks: a hierarchical nested personalized federated learning approach[J]. IEEE Transactions on Network and Service Management, 2023, 20(2): 1847-1865.
- [87] STADLER T, TRONCOSO C. Why the search for a privacy-preserving data sharing mechanism is failing[J]. Nature Computational Science, 2022, 2: 208-210.
- [88] SUN P J. Security and privacy protection in cloud computing: discussions and challenges[J]. Journal of Network and Computer Applications, 2020, 160: 102642.
- [89] BOSE S, MARIJAN D. A survey on privacy of health data lifecycle: a taxonomy, review, and future directions[J]. arXiv Preprint, arXiv: 2311.05404, 2023.
- [90] 金梁, 楼洋明, 孙小丽, 等. 6G 无线内生安全理念与构想[J]. 中国科学(信息科学), 2023, 53(2): 344-364.
- JIN L, LOU Y M, SUN X L, et al. Concept and vision of 6G wireless endogenous safety and security[J]. Scientia Sinica (Informationis), 2023, 53(2): 344-364.
- [91] TZIAVOU O, PYTHAROULI S, SOUTER J. Unmanned aerial vehicle (UAV) based mapping in engineering geological surveys: considerations for optimum results[J]. Engineering Geology, 2018, 232: 12-21.
- [92] LI T, HU H T. Development of the use of unmanned aerial vehicles (UAVs) in emergency rescue in China[J]. Risk Management and Healthcare Policy, 2021, 14: 4293-4299.
- [93] MEKIKER B, PATEL A, WITTIE M P. Cost-effective situational awareness through IoT COTS radios[J]. arXiv Preprint, arXiv: 2308.12328, 2023.
- [94] HU X, CHU L Y, PEI J, et al. Model complexity of deep learning: a survey[J]. Knowledge and Information Systems, 2021, 63(10): 2585-2619.
- [95] LI Z H, HE Y H, YU H F, et al. Data heterogeneity-robust federated learning via group client selection in industrial IoT[J]. IEEE Internet of Things Journal, 2022, 9(18): 17844-17857.
- [96] NGUYEN D C, DING M, PHAM Q V, et al. Federated learning meets blockchain in edge computing: opportunities and challenges[J]. IEEE Internet of Things Journal, 2021, 8(16): 12806-12825.
- [97] 黄磊, 易文姣, 王英, 等. 基于联邦学习和多方安全计算的海铁联运数据安全共享方法研究[J]. 铁道运输与经济, 2024, 46(4): 58-67.
- HUANG L, YI W J, WANG Y, et al. Research on secure data sharing methods for sea-rail intermodal transportation based on federated learn-

ing and multi-party secure computation[J]. Railway Transport and Economy, 2024, 46(4): 58-67.

[98] 黄知涛, 柯达, 王翔. 电磁信号对抗样本攻击与防御发展研究[J]. 信息对抗技术, 2023, 2(4): 37-52.

HUANG Z T, KE D, WANG X. Survey of electromagnetic signal adversarial example attack and defense[J]. Information Countermeasure Technology, 2023, 2(4): 37-52.

[99] 尤肖虎, 许威, 相红, 等. 6G发展趋势与候选关键技术分析[J]. 信息通信技术, 2023, 17(12): 11-27.

YOU X H, XU W, XIANG H, et al. Analysis of 6G development trend and candidate key technologies[J]. Information and Communication Technology, 2023, 17(12): 11-27.

[100] HUANG C W, ZAPPONE A, ALEXANDROPOULOS G C, et al. Reconfigurable intelligent surfaces for energy efficiency in wireless communication[J]. IEEE Transactions on Wireless Communications, 2019, 18(8): 4157-4170.

[101] 中国通信学会. 通感算一体化网络前沿报告[R]. 2021.

Chinese Society of Communications. Advanced report on integrated network of sensing computing[R]. 2021.

[102] ZHUANG W M, CHEN C, LYU L J. When foundation model meets federated learning: motivations, challenges, and future directions[J]. arXiv Preprint, arXiv: 2306.15546, 2023.

[103] JIANG F B, DONG L, TU S W, et al. Personalized wireless federated learning for large language models[J]. arXiv Preprint, arXiv: 2404.13238, 2024.

[104] XU H S, WU J, PAN Q Q, et al. A survey on digital twin for industrial Internet of things: applications, technologies and tools[J]. IEEE Communications Surveys & Tutorials, 2023, 25(4): 2569-2598.

[105] ZHANG Z C, LI C Y, SUN W, et al. A perceptual quality assessment exploration for AIGC images[C]//Proceedings of the 2023 IEEE International Conference on Multimedia and Expo Workshops (ICMEW). Piscataway: IEEE Press, 2023: 440-445.


[作者简介]



刘森 (1988-), 男, 江苏淮安人, 博士, 南京邮电大学讲师、硕士生导师, 主要研究方向为智能无线通信、联邦学习、车联网、工业物联网等。



林婉茹 (2000-), 女, 安徽淮北人, 南京邮电大学博士生, 主要研究方向为深度学习、车联网、联邦学习等。



王琴 (1988-), 女, 河南周口人, 博士, 南京邮电大学副研究员, 主要研究方向为低空智联网、工业互联网、资源可信共享等。



桂冠 (1982-), 男, 安徽安庆人, 博士, 南京邮电大学教授、博士生导师, 主要研究方向为人工智能、深度学习、智能通信、智能物联网等。