

联邦学习赋能 6G 网络综述

耿光磊^{1,2}, 高博^{1,2}, 熊轲^{1,2}, 樊平毅³, 陆杨^{1,2}, 王煜炜⁴

(1. 北京交通大学计算机与信息技术学院, 北京 100044;

2. 北京交通大学高速铁路网络管理教育部工程研究中心, 北京 100044;

3. 清华大学北京信息科学与技术国家研究中心, 北京 100084;

4. 中国科学院计算技术研究所, 北京 100190)

摘要: 基于内生人工智能 (AI, artificial intelligence) 在大规模复杂异构网络中实现万物智联是 6G 的重要特征之一。联邦学习 (FL, federated learning) 因其数据处理本地化这一特有的机器学习架构, 被认为是在 6G 场景中实现分布式泛在智联的重要途径, 已成为 6G 的重要研究方向。为此, 首先分析了在未来 6G, 特别是物联网 (IoT, internet of things) 场景中引入分布式 AI 的必要性, 以此为基础论述了 FL 在满足相关 6G 指标要求的潜力, 并从架构设计、资源利用、数据传输、隐私保护、服务提供角度综述了 FL 如何赋能 6G 网络, 最后给出了 FL 赋能 6G 研究存在的一些关键挑战和未来有价值的研究方向。

关键词: 6G 网络; 物联网; 人工智能; 联邦学习

中图分类号: TP393, TN92

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2023.00323

A survey of federated learning for 6G networks

GENG Guanglei^{1,2}, GAO Bo^{1,2}, XIONG Ke^{1,2}, FAN Pingyi³, LU Yang^{1,2}, WANG Yuwei⁴

1. School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

2. Engineering Research Center of Network Management Technology for High Speed Railway of Ministry of Education, Beijing Jiaotong University, Beijing 100044, China

3. National Research Center for Information Science and Technology, Tsinghua University, Beijing 100084, China

4. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China

Abstract: It is an important feature of the 6G that how to realize everything interconnection through large-scale complex heterogeneous networks based on native artificial intelligence (AI). Thanks to the distinct machine learning architecture of data processing locally, federated learning (FL) is regarded as one of the promising solutions to incorporate distributed AI in 6G scenarios, and has become a critical research direction of 6G. Therefore, the necessity of introducing distributed AI into the future 6G especially for internet of things (IoT) scenarios was analyzed. And then, the potentials of FL in meeting the 6G requirements were discussed, and the state-of-the-arts of FL related technologies such as architecture design, resource utilization, data transmission, privacy protection, and service provided for 6G were investigated. Finally, several key technical challenges and potential valuable research directions for FL-empowered 6G were put forward.

Key words: 6G networks, internet of things, artificial intelligence, federated learning

收稿日期: 2022-09-02; 修回日期: 2023-01-18

通信作者: 高博, bogao@bjtu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61872028); 中央高校基本科研业务费资助项目 (No.2021JBM008, No.2022JBXT001)

Foundation Items: The National Natural Science Foundation of China (No.61872028), The Fundamental Research Funds for the Central Universities (No.2021JBM008, No.2022JBXT001)

0 引言

近年来全球多个国家和地区已开启探索研究 6G，旨在充分利用“高-中-低”全频谱资源，构建跨地域、空域、海域全面覆盖的超灵活一体化网络架构，满足可靠安全的“人-机-物”智能连接需求^[1]。6G 网络相关报告提出要在新一代信息技术的加持下，赋予网络设备和节点信息感知能力和计算处理能力，实现网络内生智能；同时 6G 网络将逐步从基站的超密集部署向边缘计算设备的海量分布式部署演进，以上两点都需要更先进的分布式 AI 技术支持。然而，在未来 6G 业务场景中，数据通常存储在海量边缘设备中，数据分散且数据量庞大，如何实现数据分布式处理和学习，

同时遵循各国规定的数据安全法律法规、保护参与方数据隐私，成为 6G 面临的核心问题^[2]。

联邦学习 (FL, federated learning) 是一门新兴分布式机器学习技术，已成为移动网络、机器学习等交叉领域的热门研究课题。FL 通过隐私保护技术融合多方数据信息，在训练数据不离开本地的情况下，中央服务器便可完成模型训练^[3]。一方面，充分利用各参与方的数据实现模型的协同训练，在大量分散移动设备中实现数据驱动智能，解决无线网络终端单点数据标签少、训练效果差的问题；另一方面，因为数据不出本地，可以保护用户隐私和数据安全，缓解传统集中式机器学习存在的隐私安全问题。

FL 赋能 6G 网络如图 1 所示，随着 6G 网络的

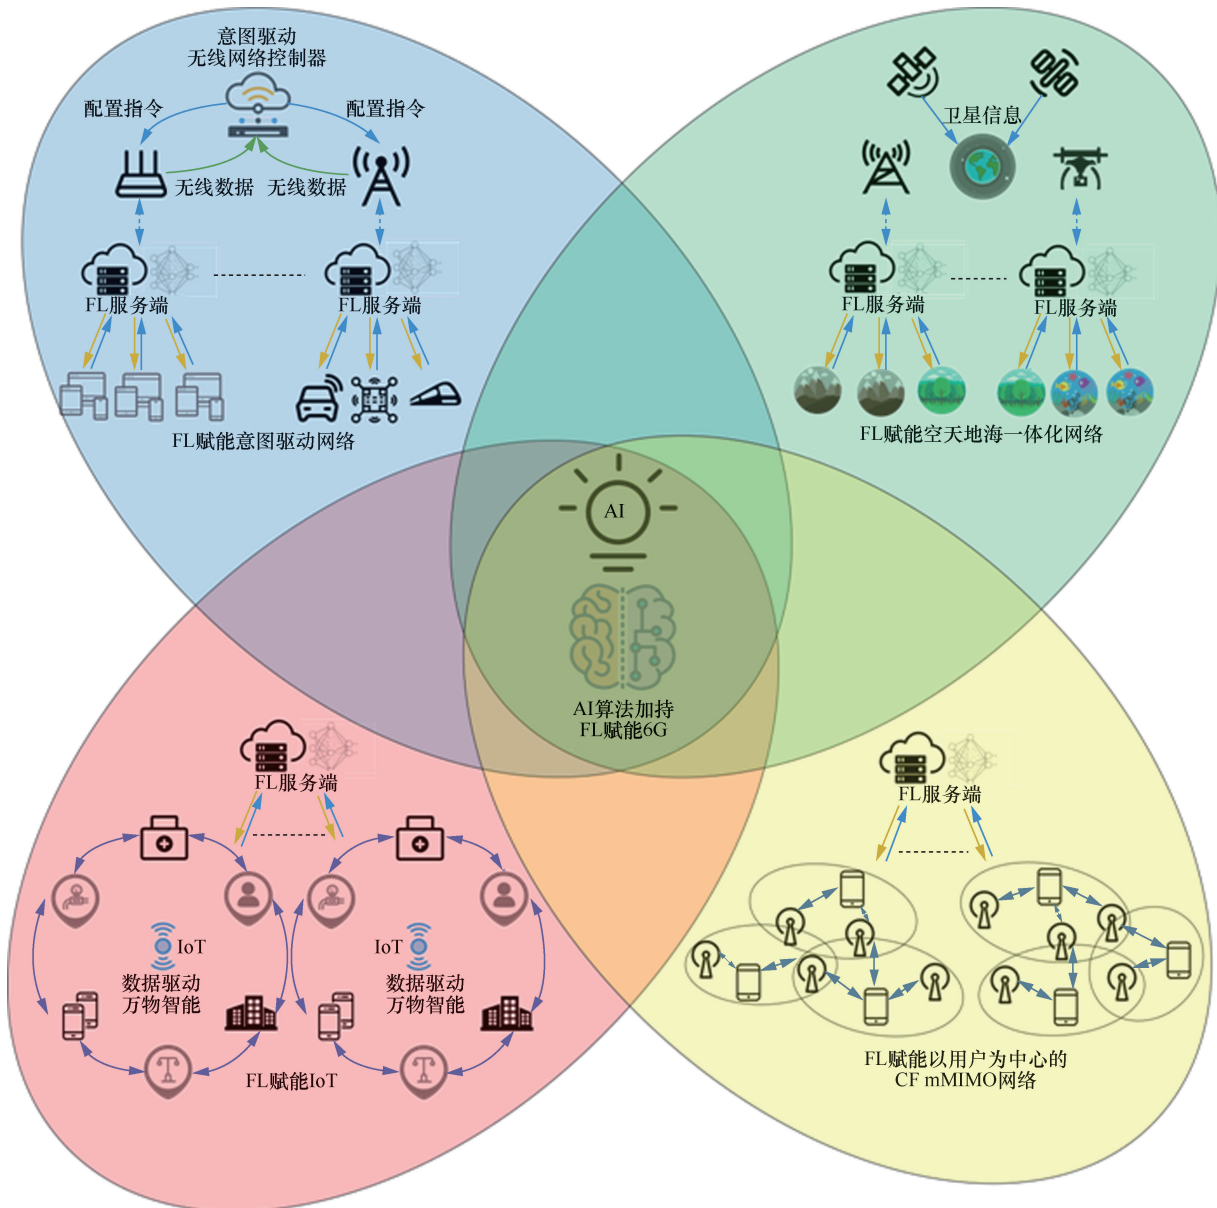


图 1 FL 赋能 6G 网络

蓬勃发展, FL 与 6G 也将紧密结合。一方面, 6G 网络将为 FL 提供更加海量的数据资源和更加丰富的应用场景, 将极大拓宽 FL 的应用范围和使用场景; 同时 6G 网络中更多样的网络算力和更完备的基础设施, 可满足 FL 传输模型的高带宽需求, 促进跨多领域的分布式 AI 应用; 另一方面, FL 支持海量设备之间的隐式数据共享, 能够在保证数据隐私和安全监管要求的同时, 基于海量设备数据进行分布式模型训练, 进而使边缘设备智能化, FL 这一天然优势为 6G 网络合理合法地利用数据、实现网络内生智能提供了关键思路; FL 支持大规模节点部署, 适合海量边缘设备部署的 6G 场景。综上所述, FL 被认为是一种与 6G 网络非常适配的分布式机器学习方法, 本文重点关注 FL 如何赋能并推动未来 6G 网络由万物互联走向泛在智联, 进而实现高效可信的分布式内生智能网络。

目前国内外关于 6G 网络结合 FL 的综述类文章如下: 文献[4]介绍了 FL 在无线通信网络中的潜在应用和建设方向, 提出了未来 6G 结合 FL 的愿景。文献[5]概述了 FL 赋能 6G 网络的优势, 并简要列举了 6G 网络中潜在的 FL 应用。文献[6]综述了由 FL 驱动 6G 边缘内生智能的趋势和挑战, 总结了 FL 在 6G 关键技术中的应用。文献[7]指出 FL 是在 6G 中实现无处不在 AI 的重要解决方案之一, 介绍了 6G 与 FL 融合的潜在应用。文献[8]提出 FL 有望在异构大规模网络中实现数据驱动 AI, 讨论了 FL 解决 6G 中一些关键问题的潜力。

FL 为 6G 智能化带来了巨大潜力, 然而目前, FL 在赋能 6G 网络领域仍缺乏较为系统性的综述, 现有综述并没有完整的阐述 FL 赋能 6G 网络的动机、研究现状和未来挑战, 特别是从 6G 的关键要求出发全面概述 FL 应用于 6G 网络的突出优势和研究挑战。为此, 本文结合国内外研究近况, 首先分析了在未来 6G 特别是 IoT 场景中引入分布式 AI 的必要性, 以此为基础论述了 FL 在满足相关 6G 指标要求的潜力, 并从多角度详细阐述了 FL 如何赋能 6G 网络, 最后给出了 FL 赋能 6G 研究存在的一些挑战和未来有价值的研究方向, 以提供全面概述和参考。论文主要贡献如下。

1) 按照自底向上的网络层次结构, 从网络架构、资源优化、数据传输、安全隐私、个性化服务方面, 描述了无线网络在引入 6G 后的新要求和新影响, 多角度分析了 FL 赋能 6G 网络的重要性和必要性。

2) 综述了近年来 FL 与边缘 IoT 场景结合的技术类文章, 具体分析了当前 FL 赋能无线网络不同领域研究方向的最新进展, 为该领域的工作者们提供一定参考。

3) 从数据、算法、算力、新技术角度出发, 提出了目前 FL 赋能 6G 物联场景存在的技术挑战, 讨论了未来 FL 赋能 6G 具有潜力的研究热点。

1 6G 网络的要求

目前, IoT 在 5G 技术的加持下迅猛发展, 海量 IoT 设备提供了无处不在的分布式感知和通信能力, 同时 AI 技术广泛应用于智能 IoT 系统中的数据分析和提供服务, 以构建智能 IoT 系统。为了降低 IoT 设备之间数据传输和加密的开销, FL 已被应用到边缘 IoT 中^[9]。FL 通过聚合 IoT 设备更新上传的本地模型, 协作训练高质量模型, 将模型训练与直接访问数据的需求分离, 从技术角度实现对数据的隐私保护; 同时由于无须向服务器传输 IoT 设备的本地数据, 仅需在中央服务器和客户端之间传输共享的 AI 模型, 减少了通信数据量, 降低了数据通信时延, 节省了频谱等网络资源; 加之 FL 天然的分布式学习特性, 提高了 IoT 的可扩展性, 采用众包收集数据的思想降低了数据收集成本, 这对于训练高精度的深度神经网络模型非常重要, 能够提高收敛速度, 达到更好的学习效果。

预计到 2025 年, 全球 IoT 连接数量约为 270 亿^[10]。为海量 IoT 设备提供优质的分布式智能服务, 需要 6G 网络在上述 5G 加持的 IoT 基础上满足更复杂的要求。6G-IoT 需求的示意图如图 2 所示, 本节按照图 2 所列角度, 根据网络层次自底向上逐点分析了未来分布式智能 6G-IoT 需要满足的五大要求。

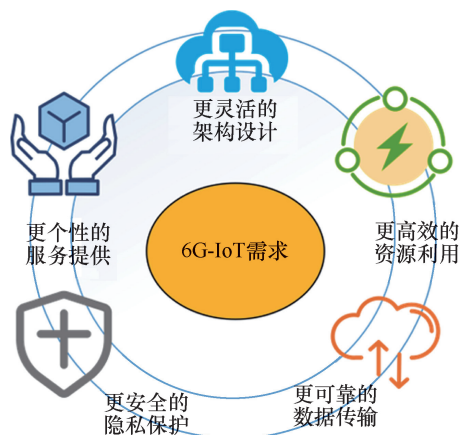


图 2 6G-IoT 需求的示意图

1.1 更灵活的架构设计

6G 作为高度复杂的网络系统，包含提供不同服务类型和覆盖范围的异构子网络和子系统。此外，6G 分布式架构中包含许多具有“通-感-算”能力的边缘服务器，需要可分解和可扩展的网络架构，以允许在多个边缘服务器之间完成并行计算^[11]。因此，在 6G 网络中，需要设计新型网络架构，进一步提升网络软件化，实现从面向基础设施的传统网络架构转变为基于软件的新型网络架构，满足未来用户对 6G 网络的新业务服务需求。

1.2 更高效的资源利用

6G 中的海量 IoT 设备将具备“通-感-算”能力，智能手机、可穿戴设备、智慧汽车、无人机、智能路侧单元、传感器等具有一定智能处理能力的设备都将参与 6G 组网，而无线设备由于续航时间有限，需要更高效的资源利用手段解决 6G 场景中设备的能效问题、资源利用以及持久工作问题^[12]，例如，基于分布式 AI 设计在动态环境和复杂目标中的无线设备能源调度机制，提高能源使用效率、延长无线设备工作时间。

1.3 更可靠的数据传输

6G 要以更高效、更可靠、更低时延的方式同时支持在设备密集区域和设备稀疏区域的分布式组网连接，6G 也将包含很多涵盖“空-天-地-海”的异构通信网络。采用传统通信手段开销巨大，因此需要引入新型分布式 AI 技术减少通信成本，实现 6G 中的可靠数据传输，从而保证在复杂异构 6G 网络中为海量分布式设备提供通畅的高质量网络服务。

1.4 更安全的隐私保护

6G 需要具备处理海量业务数据和个人数据的能力，以实现网络内生智能。然而，这些由海量 IoT 设备、网络组件和服务器生成、传输和处理的数据，可能面临着隐私保护方面的诸多挑战。例如，个别应用服务提供方可能恶意违规收集大量用户信息，导致隐私数据泄露。众所周知，数据安全和隐私问题与用户息息相关，因此必须在 6G 中实施从设备级别到网络级别的安全防护机制，开发分布式 AI 解决方案，设计更精细粒度的隐私保护算法，保护不同用户每个特定服务的所有数据^[13]。

1.5 更个性的服务提供

个性化服务是 6G 网络中“以人为本”理念的重要部分，6G 需要面向不同用户、不同设备、不

同场景甚至不同时段提供个性化智能服务。与此同时，6G 网络中海量数据集的统计特征因服务类型、业务场景、用户偏好等不同而存在很大差异，并且 6G 网络的流量模式和信道条件随时间和空间变化。这些特点都会导致在不同时空收集的数据呈现非独立同分布（Non-IID, non-identically and independently distributed）的特征，因此需要利用分布式 AI 技术，基于 6G 中的 Non-IID 数据，为不同用户提供相应的个性化服务，如个性化医疗诊断、个性化推荐等^[14]。

2 FL 赋能 6G

本文重点在于阐述 FL 如何赋能 6G 网络，详细研究进展介绍如下。

2.1 促进灵活架构设计

6G 网络需要研究新型网络架构，实现在新应用场景下动态灵活组网。随着自动驾驶、智慧金融、智慧城市和工业 4.0 等新型应用的蓬勃发展，需要组合多种不同功能的原子网络共同满足业务需求，网络架构也需要随业务变化不断进行智能灵活调整^[15-16]。

FL 是一种天然的分布式机器学习方法，基于 FL 的网络架构设计可以根据场景需求进行灵活调整，例如，客户-服务器架构、对等网络架构，因此 FL 非常适合在 6G 场景中进行网络架构设计。具体来说，移动通信网络中的 FL 架构可分为中心化网络架构和去中心化网络架构，分别适用于不同应用需求和网络部署情况。中心化 FL 网络架构适用于客户端和服务端之间需要高可靠通信的场景，中心节点负责聚合训练模型、下发聚合结果，对性能需求相对较高，而其余节点性能需求相对较低；去中心化 FL 网络架构仅需轮流挑选性能相对较高或资源空闲的节点暂时承担中心节点任务即可，适用于网络参与方数量多、网络容量不足，且对连接可靠性要求不高的小规模域内应用场景^[17]。

近年来，有相关研究在新型网络场景中基于 FL 进行网络架构改进，提高了网络架构的可拓展性并适用于大规模训练，同时在网络时延方面取得了进展。例如，文献[18]从计算和通信方面对 6G 场景进行建模，提出几种基于 FL 的 6G 网络架构设计。文献[19]设计基于 FL 的异构蜂窝网络架构，引入小蜂窝基站进一步降低分层架构的通信时延。文献[20]提出边缘云分层的 FL 架构，通过引入边

缘服务器降低了设备的训练时间。文献[21]在边缘网络架构中引入 FL 雾学习,以解决设备间计算和通信能力异质性问题,适用于大规模分布式网络拓扑。文献[22]提出一种新颖的 FL 框架,使网络边缘设备能在较少依赖中央服务器的情况下,实现在大型边缘网络中快速完成分布式学习。文献[23]在传统 FL 框架上进行动态扩展,提出根据资源条件灵活选择参与客户端的边缘网络框架,加速 FL 训练的过程。文献[24]基于 FL 提出一种新型分布式网络架构,选择在每一轮中具有更好通信质量和更大局部模型更新的参与方,提高了学习效率。

然而基于 FL 设计网络架构时,如果聚合中心发生故障,整个网络系统将陷入瘫痪无法运转;同时随着网络规模扩大,整个 FL 分布式系统的维护成本将急剧增加。未来引入 FL 参与 6G 网络架构设计时,需要着重考虑系统的高可用以及成本问题。

近年来也有相关研究在新型移动边缘场景中基于 FL 进行网络架构设计,其中车联网作为未来构建智能交通系统有前景的技术之一,FL 可以有效利用分布式车辆的计算能力,设计新型网络架构以实现超可靠和低时延的车载通信,提高车联网中的性能表现。例如,文献[25]在自动驾驶环境中,提出将 FL 和边缘缓存结合的网络框架,共同考虑边缘协作和优化,以提高车联网系统运行效率。文献[26]在车联网场景中设计基于 FL 的可扩展信息网络架构,与采用传统 FL 架构相比,性能提高了近 40%。文献[27]设计将群体学习集成到 FL 中的车联网架构,在降低边缘到全局通信开销的同时提高了模型性能。文献[28]提出两层 FL 分布式边缘云架构,实现在车联网场景中更高效、更准确地学习,同时保护数据隐私并减少通信开销。文献[29]提出基于区块链的 FL 池框架,可以在车联网环境中根据实际场景选择最合适的 FL 方法,与传统机器学习技术相比更稳定、更高效。文献[30]在车联网环境中提出基于知识共享的分层区块链 FL 框架,车辆可以彼此共享学习到的知识,提高了知识共享效率和学习质量,同时能够有效应对某些恶意攻击。

虽然 FL 应用于车联网架构设计取得了上述的进展,但由于车联网的高度动态性和复杂性,引入 FL 设计车联网架构难度大且通用性不强,当遇到新的车联网问题时,原先设计的 FL 架构往往需要重新设计,复用性不高、成本大。

2.2 促进高效资源利用

FL 作为一种天然的分布式机器学习方法,能够将 6G 网络中有限的资源通过优化算法,合理公平地分配给海量边缘设备,从而提高网络性能。目前 FL 在移动边缘网络等新型 IoT 中,结合最优化算法在解决频谱共享、功率控制、用户调度等分布式资源优化问题中取得了较好的成果。例如,文献[31]将空地集成网络与 FL 结合,利用无人机灵活按需部署空中节点,所有节点通过 FL 协同训练模型,在一定程度上解决了边缘设备资源受限问题。文献[32]提出一种用于自动驾驶的 FL 框架,基于混合整数非线性规划方法联合优化资源分配和功率分配。文献[33]为降低车联网中昂贵的通信资源成本,提出在 FL 中不同客户端采用定制的本地训练策略,以减少训练阶段的通信次数。文献[34]提出跨域知识共享的 FL 框架,用于在 6G-IoT 中进行高效流量调度,实现有效分配异构 IoT 资源。文献[35]通过联合优化计算资源和通信资源,在时延限制下基于 FL 最小化所有用户设备的总能耗。

FL 结合传统优化方法处理 6G 网络中资源利用问题的优点在于转化为数学问题后得到的解往往是最优解;缺点在于数学优化求解难度较大,且当优化问题非凸时,需要转化为凸优化问题求解,难度较大。并且每当求解新问题时,都需要针对特定的问题重新设计完整的优化算法,可迁移复用性低。

除了结合传统优化方法,目前深度强化学习(DRL, deep reinforcement learning)算法在处理决策问题中也取得了不错的进展。例如,文献[36]提出分别基于 Q 学习和 DRL 算法联合优化用户设备的能耗,解决多用户边缘移动计算中的资源分配问题。文献[37]研究基于确定性策略梯度的多智能体 DRL 算法,用于解决无人机辅助管理车联网资源问题,在满足车联网服务质量要求的同时,有效实现了资源的按需访问。文献[38]针对频谱资源利用问题,提出基于 DRL 算法减少无线网络中次用户对主用户的干扰,提高了频谱利用率。文献[39]基于深度确定性策略梯度算法,研究了电量受限的无人机资源分配策略,通过调整 CPU 运行策略最小化能耗,结果表明该策略优于传统策略。文献[40]提出一种分布式 DRL 算法,用以辅助移动边缘系统中的无人机群动态寻找最佳资源协调策略。文献[41]针对在移动边缘网络中部署多无人机存在的计算卸载策略不灵活问题,提出一种分布式 DRL 算法,

实现无人机灵活学习卸载策略。文献[42]提出基于贝叶斯学习的分布式多智能体 Q 学习算法，用于支持非正交多址的辅助缓存和任务卸载。文献[43]提出了一种结合分布式和集中式方案优势的 DRL 算法，实现功率分配控制以最大化多小区的网络下行速率。

通过 DRL 算法解决资源优化问题可能得不到最优解，但是能以较少的成本快速得到一个接近最优的次优解，且使用 DRL 算法求解，可迁移性较好，例如，基于神经网络的 DRL 算法一旦解决了其中某个问题，就可进行模型迁移，快速求解其他场景问题。

在 DRL 算法的基础上，联邦强化学习 (FRL, federated reinforcement learning) 算法在解决分布式网络资源优化问题中展现出更强的潜力，移动边缘系统与强化学习如图 3 所示，FRL 算法以联邦方式构建智能体的决策模型，同时考虑智能体之间的数据隐私，更适用于赋能 6G 网络解决资源利用问题^[44]。文献[45]讨论了工业 4.0 中的应用场景，基于 FRL 算法进行工业 IoT 中的资源分配，借助深度联邦 Q 学习动态分配网络资源，以满足工业 IoT 的服务质量要求。文献[46]在多无人机移动边缘系统中提出一种多智能体 FRL 算法，通过联合优化资源分配和用

户关联最小化系统功率。文献[47]提出在大规模动态 IoT 中基于 FRL 算法的在线任务卸载和资源分配算法，结果表明该算法在收敛速度、执行时延、计算速度和稳定性 4 个方面均优于传统 DRL 算法。文献[48]提出基于双深度 Q 网络的 FL 框架，用于解决 IoT 临床决策系统中的网络拥塞和低响应率等问题，能够获得连续稳定的临床治疗策略。综上，DRL 算法有望成为 6G 网络中资源管理和决策制定的强大工具，结合 FL 共同赋能 6G 分布式系统的资源利用。

2.3 促进可靠数据传输

6G 需要引入分布式 AI 来保证数据高可靠、低时延地传输。FL 被认为是极具优势的解决方案之一，其优势在于：从架构层面，FL 基于边缘计算单元协作学习并共享网络模型，同时直接在终端设备上执行模型决策，减少了网络中数据流量的传输、降低服务时延并提高可靠性；从算法层面，FL 通过算法优化加速收敛，减少训练模型的通信轮次，并利用梯度压缩、模型压缩、稀疏化、量化等技术降低每一轮的通信成本^[49]。

目前机器学习模型动辄由数百万个权重参数组成，模型复杂度高。加之无线网络中的边缘设备算力有限，这些因素使得通信开销成为基于 FL 赋

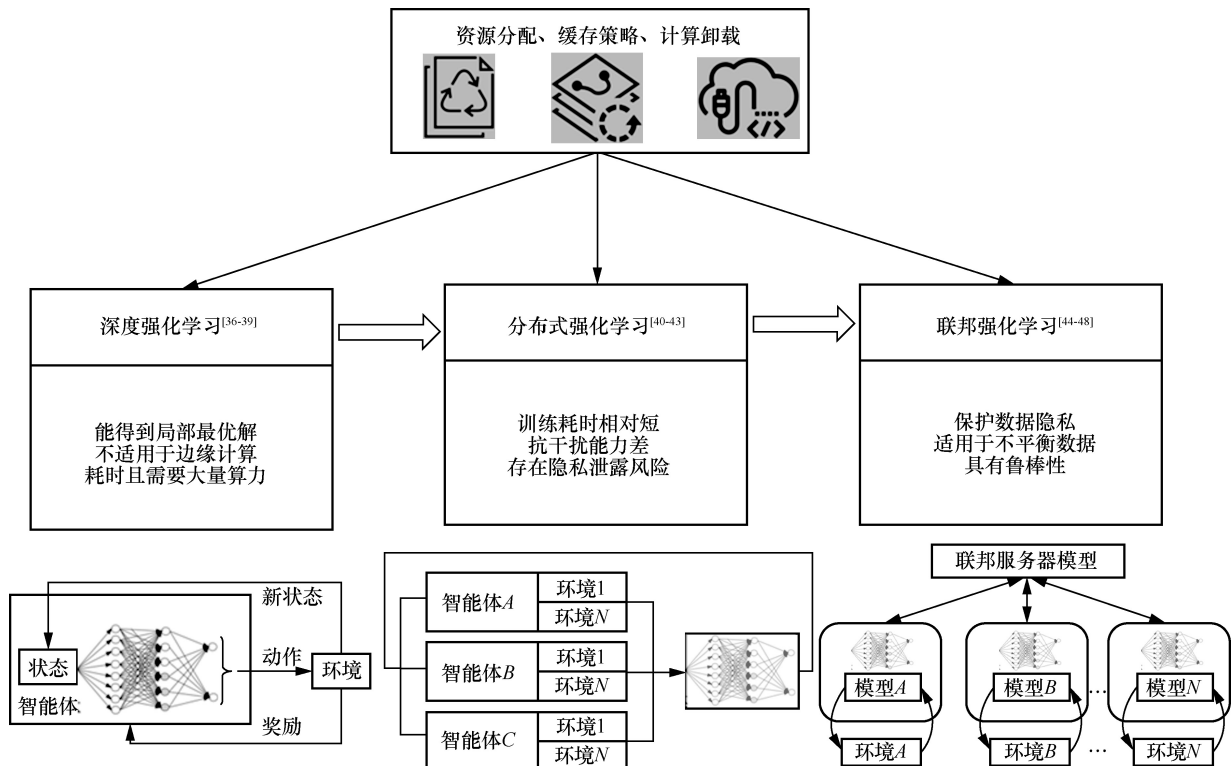


图 3 移动边缘系统与强化学习

能未来 6G 网络的主要挑战之一。由于更新的模型参数在终端设备和中央服务器之间定期交换,当设备数量多且收敛轮次高时,这种通信开销势必导致网络时延增加,从而成为限制 6G 网络时效性的一个主要瓶颈。为了减轻这种通信开销,降低时延,有关研究基于 FL 引入了多种方法来简化深度网络,如参数修剪、参数量化、知识蒸馏、模型量化等技术,以生成更紧凑轻便的学习模型^[50],进而降低 FL 训练过程中的时延。

近年来,有很多学者在联邦场景中研究如何降低时延和通信成本,这可以拓展到未来 6G 网络中,例如,文献[51]提出一种联邦随机客户端选择算法,旨在保持低通信成本的同时确保客户端之间的公平性。文献[52]对数据时效性和新鲜度要求高的移动边缘网络场景,提出基于 FRL 算法的最小化网络信息年龄算法,可应用于对时间敏感的 6G 场景。文献[53]提出优化无线传输时延的 FL 算法,针对边缘计算的通信时延问题,优化本地计算、上行链路和下行链路传输的总时延。文献[54]基于可重构智能表面(RIS, reconfigurable intelligence surface)提出降低 FL 系统通信时延的算法,证明了部署 RIS 能有效降低 FL 时延。文献[55]在车辆边缘计算场景中,提出基于联邦 Q 学习的计算卸载算法,以满足自动驾驶中对时延的要求。

另一种思路是从 FL 参与方出发降低时延。在 FL 架构中,服务器会一直等待直到所有参与者停止更新上传模型,因此一轮的训练时间由最慢的设备决定,每轮的时延以及模型收敛速度都受落后参与方短板效应的影响,计算能力有限或无线信道条件差的设备会导致整体网络系统的高时延^[56]。文献[57]基于奥恩斯坦-乌伦贝克(OU, Ornstein Uhlenbeck)过程对模型权重进行建模,得出最优抽样策略,每次抽取最优部分的客户端进行训练,减少了高达 50% 的通信消耗,同时实现不错的收敛速度和模型精度。另外如果客户端任务因为某些原因执行失败,模型的训练进度就会被浪费。为避免这种现象,异步 FL 被认为是一种可行的解决方案。异步 FL 允许参与者在任意时刻加入 FL 任务,服务器在接收到用户的本地更新后立即更新全局模型。文献[58]提出混合 FL 算法,通过引入异步更新算法从掉线的参与方中提取局部权值,缓解参与方落伍掉队现象引起的系统更新问题。文献[59]针对有偏客户端参与的 FL 移动边缘场景,设计了提高通信和计算效率的客

户端选择算法,可以灵活地在收敛速度和偏差之间进行权衡。文献[60]提出基于多臂赌博机的客户端选择算法,缩短了移动网络中 FL 的训练收敛时间。

2.4 促进安全隐私保护

6G 网络架构将融入大量分布式处理机制,网络服务更贴近用户端,这将改变传统中心式的安全架构。感知通信、全息感知以及其他全新 6G 业务要求提供跨域安全体系,同时 AI、大数据与 6G 网络的深度融合,将加剧数据隐私保护面临的挑战^[61]。

尽管 FL 中参与方不直接共享本地原始数据,但敏感信息仍可能泄露给恶意第三方,FL 结合如下隐私保护方法,可保障 6G 分布式边缘场景中模型的安全传输。

2.4.1 安全多方计算

该方法在不将输入透露给其他方的前提下,协同从每一方的隐私输入中计算函数结果,即在不暴露或移动任何私人数据的情况下,参与方通过互相关换消息学习函数值^[62]。文献[63]基于多方安全计算中的秘密共享技术,提出结合权重掩码的轻量级隐私保护框架,证明可以在智慧医疗等不稳定的边缘计算环境中很好地保护数据隐私。文献[64]基于多方安全计算中的秘密共享技术,设计了一种高效的 FL 隐私保护数据聚合机制,以抵抗数据逆向攻击。文献[65]针对传统多方计算存在的通信开销大和可拓展性差的问题,提出两阶段多方安全计算的 FL 框架,实现多个客户端在保护各自数据隐私的情况下共同训练 AI 模型。文献[66]基于多方安全计算中的秘密共享技术,通过引入加权 FL,从底层多方安全计算角度保证 FL 的安全性。文献[67]基于多方安全计算构造层级 FL 架构,通过仅在部分节点聚合全局模型缓解通信成本高和可拓展性差的问题,在不损害隐私的情况下提高通信效率、提升可拓展性。由于安全多方计算方法基于严格的密码学证明,因此在理论上保证了各参与方的数据隐私安全。

2.4.2 差分隐私

该隐私保护方法的原理在于当恶意参与方试图窃取数据时,通过加入噪声将其混淆,使恶意参与方无法从窃取的结果中辨别原始数据^[68],从而防止模型参数泄露。文献[69]将 FL 与差分隐私结合,利用生成对抗网络产生符合差分隐私要求的可控随机噪声,基于区块链的 FL 降低了云与边缘之间的通信成本。文献[70]根据不同用户的隐私要求差

异，提出混合差分隐私的 FL 技术，取得了较好的实验性能。文献[71]针对差分隐私噪声对模型精度的不利影响，提出稀疏模型扰动技术，在保持高精度模型的同时提供客户端级别的差分隐私保护。文献[72]提出结合自适应梯度下降策略和差分隐私机制的 FL 方案，提供了更具鲁棒性的可量化隐私保护方案。文献[73]提出面向车联网的异步 FL 隐私保护模型，使用自适应差分隐私机制减少噪声，保证车联网场景下数据的可信度和隐私性。差分隐私方法相比于多方安全计算，不涉及复杂的密码学算术操作，具有较低的计算复杂度，但需要考虑加入噪声后，对模型准确性的干扰。

2.4.3 同态加密

该隐私保护方法是一种基于密钥的安全机制，允许第三方在不需要事先解密的情况下对加密数据进行计算。FL 的参与方生成公钥和私钥，公钥用于加密本地模型，然后服务器端以加密模式聚合更新所有客户端发来的模型，最后客户端利用私钥解密全局模型。文献[74]在 FL 中使用同态加密技术，直接对密文执行算术运算，从而无须解密来保护模型参数，并取得了较好的性能。文献[75]提出基于同态重加密的隐私保护 FL 方案，保护数据不受 IoT 设备的影响，并解决了计算成本和存储成本高的问题。文献[76]提出基于医疗数据的同态加密 FL 算法，通过多方安全协议保护卷积神经网络模型免受恶意攻击，保护了真实医学数据集。文献[77]讨论使用 3 种不同类型的同态加密训练联邦生成对抗网络，分析了各自的性能特点，从实验数据中得出使用加密技术越复杂的同态算法，FL 会消耗更多的训练时间，这说明加密技术复杂度是一个值得关注的研究要素。同态加密直接对数据进行加密处理，在数据层面保证了隐私安全，缺点在于涉及某些复杂加密计算会导致计算效率低，现有同态加密方案在速度和性能方面存在很大的改进空间。

2.5 促进个性服务提供

FL 作为移动边缘计算中重要的分布式 AI 算法，目前大多数论文都只考虑了各参与方之间数据独立同分布 (IID, identically and independently distributed) 的理想情况。然而 6G 网络将提供个性化的智能服务，且实际无线网络场景中不同终端获取的数据特征往往 Non-IID。与基于 Non-IID 数据集的 FL 模型相比，使用 IID 数据的 FL 模型收敛速度更快、预测精度更高，但是难以适应数据 Non-IID

的 6G 场景，因此有必要详细研究数据异质性的影响和在 Non-IID 数据集下改进的 FL 方案。

6G 网络中设备间的数据分布会有很大不同，如果基于传统 FL，服务器和客户端共享单个模型，那么得到的模型对于许多客户端可能表现不佳，甚至不如直接使用本地数据训练模型的效果。因此在 6G 场景中基于 FL 对每个参与方进行个性化定制非常有必要^[78]。个性化 FL 允许各参与方根据自己的数据特征对全局模型进行调整，生成适合各参与方的个性化模型，个性化模型在本地测试的效果往往更佳。

近两年研究者们加大了 FL 数据异质性方向的研究，解决 FL 中数据异质性问题对参与方也会起到激励作用，其中个性化 FL 将是一个热门研究点。个性化 FL 分类如图 4 所示，本节将从基于聚合端角度、基于客户端角度和基于其他技术角度进行分类论述。

2.5.1 聚合端

从基于聚合端角度考虑，在传统 FL 框架中，服务器将各参与方发来的梯度信息或模型参数计算加权平均后进行聚合，再将聚合结果分发给参与方，这种方法高度依赖各参与方数据特征 IID。传统 FL 对于数据 Non-IID 的情况学习效果并不好，一些研究者认为这是因为错误地假定全局模型可以适用于所有客户端，基于这个思路，可以对传统 FL 中的全局聚合部分进行微调或定制来达到个性化 FL。文献[79]没有沿用传统的 FL 模式，允许每个客户端学习自己的模型，而不用构建一个全局模型，每个客户端的模型会传递给具有相似模型参数的云中心进行训练。文献[80]更改了传统 FL 全局聚合的损失函数，通过调整合并权值的方法降低客户端之间的误差，最小化用户本地模型准确率偏离全局模型准确率的方差。文献[81]改变了传统 FL 平均聚合的方式，使用基于贝叶斯推理的新型聚合方法，实验结果表明该方法可以在数据 Non-IID 的情况下做出比权重平均更准确地预测。文献[82]提出基于超网络的个性化 FL 方案，训练超网络模型以生成一组模型，使得每个客户端拥有特定的训练模型。

2.5.2 客户端

从 FL 客户端出发，对传统 FL 框架进行改造。文献[83]提出将客户端的训练层分为基础层和个性化层两部分，基础层由联邦平均算法集中训练，个性化层在各参与方本地进行训练。文献[84]进一步假设参与方数据间存在通用特征表示，而客户端数

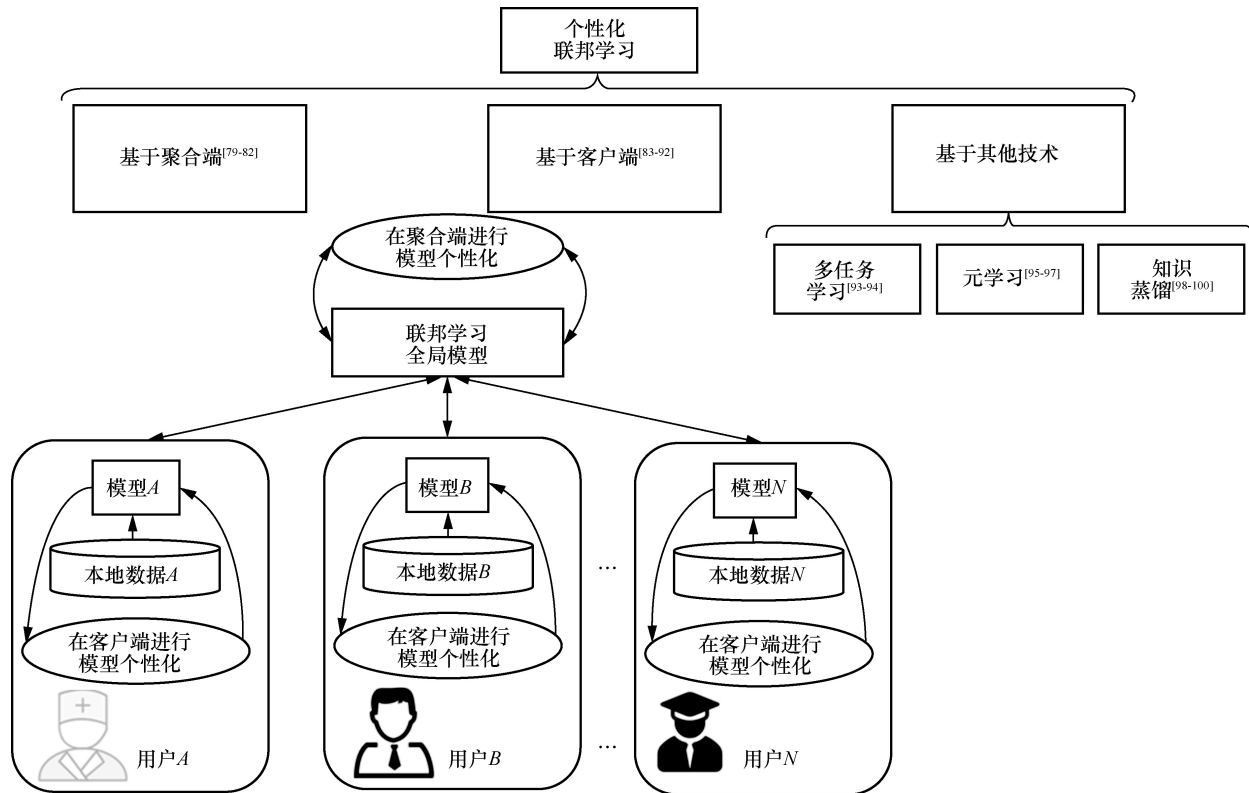


图4 个性化 FL 分类

据间的统计异质性主要集中在标签上，提出通过基础层学习数据间通用特征表示，通过个性化层缓解数据 Non-IID 对模型训练的影响。文献[85]提出根据数据特征相似度将 FL 客户端进行分组，并为每个组训练单独的模型，实验表明该方法可以提高数据 Non-IID 情况下的模型表现。文献[86]在各个客户端模型中加入“批归一化层”，使用局部批次归一化来缓解特征漂移，在数据 Non-IID 场景中获得了更优的效果。文献[87]提出参与方的正则化损失函数，有助于把个性化 FL 问题中的局部模型优化与全局模型学习分离。文献[88]为每个参与方配备一个基于深度学习内核的高斯过程分类器，在实验中将准确率提高 21%。文献[89]通过引入正则化器测量并最小化每个客户端的小批量梯度方差，在训练过程中鼓励不同客户端之间梯度对齐。文献[90]在硬聚类 FL 思路的基础上，提出软聚类 FL，假设每个客户端的数据遵循混合分布，同时采用 FedProx 进行个性化学习。文献[91]针对 6G 网络中客户端数据 Non-IID 造成的 FL 全局模型偏差问题，提出一种估计算法确定客户端的本地数据分布。文献[92]针对 FL 各参与方数据 Non-IID 问题，引入数据集信息熵捕获数据不平衡结构，并将其作为先验信息设计 FL 策略。

2.5.3 其他技术

近年来，其他机器学习方法也被迁移来解决个性化 FL 问题，如多任务学习、元学习、知识蒸馏等，并都取得了一定的成效。

1) 多任务学习

该方法的目标是同时学习不同设备的多个任务模型，利用任务之间的差异和共性来协作学习，发现任务之间的相关性从而改善模型的泛化能力。文献[93]基于多任务学习的 MOCHA 算法在 FL 环境中构建个性化模型。文献[94]利用多任务框架 Ditto 解决 FL 个性化问题，并通过引入正则项使得个性化模型能够接近全局最优模型。然而，由于多任务学习每个任务产生一个模型，因此要求所有客户端都要参与每轮迭代，为解决这个问题，在未来基于集群的多任务学习是一个有前途的研究方向。

2) 元学习

该方法旨在少数样本情况下也能训练出解决新任务的模型，利用元学习的个性化能力改进 FL 算法，文献[95]提出了模型无关元学习 (MAML, model agnostic meta learning) 算法，该算法能够找到适合一步微调的初始参数，使得训练模型在初始参数的基础上，遇到新任务时可以根据少量数据，通过一次或几次的梯度更新达到较好的效果。文献[96]指

出 FL 中的联邦平均算法本质上就是元学习 MAML 算法，在 FL 中训练得到的全局模型根据元学习算法进行几步梯度微调后，能得到性能较好的个性化模型。文献[97]基于元学习提出了一种新的 FL 算法，其中聚合端与边缘设备通过元学习算法协作训练全局模型，并在每一轮训练中动态修改损失函数，从而使各参与方的训练模型都相对无偏。基于元学习训练得到的模型更加稳健，对于那些数据样本少的设备非常有用；然而元学习方法经常利用复杂的训练算法，实施复杂度高。

3) 知识蒸馏

该方法基于已训练好的复杂模型，将其学习到决策知识迁移到另一个轻量级模型中，帮助和指导后者训练模型。通过将知识从深度网络转移到小型网络来压缩和改进模型，便于模型部署到服务中。该方法由 Hinton 等在文献[98]中提出，其核心思想是将复杂模型得到的预测概率和真实标签一起训练，使单个样本可获取更多的信息，实现通过少样本模型训练，就能达到较好的效果。文献[99]提出利用知识蒸馏解决 FL 中各参与方之间数据异质性问题，以 data-free 的方式学习异构用户的聚合知识，在服务端形成一个轻量模型，然后广播给参与方辅助进行局部训练。文献[100]提出了用于模型聚合的知识蒸馏框架，适用于数据异构的情况。由于知识蒸馏交换的是模型输出而不是模型参数，因此可以大大降低通信成本。

综上，FL 赋能 6G 网络具有代表性的研究方向见表 1。

3 挑战与趋势

尽管 FL 在面向 6G 的研究中已经取得了诸多可

喜的进展，但是仍然存在许多开放性的问题亟待研究。本节基于现有 6G 与 FL 的调研，分别从数据、算法、算力和新技术角度依次介绍目前 6G 与 FL 结合存在的技术挑战和研究趋势。

3.1 数据新鲜度

对于数据时效性极其敏感的 6G 场景，获取即时信息、保证数据新鲜度至关重要。为量化数据新鲜度，文献[101]提出了信息年龄 (AoI, age of information) 的概念，AoI 为客户端从信息产生到获取更新所经过的时间，近年来 AoI 被认为是未来衡量 6G 网络性能的新指标之一，在未来基于 FL 优化 6G 网络 AoI 存在以下挑战。

1) 在智能驾驶、工业 4.0 等对数据新鲜度要求极高的 6G 场景中，如何基于 FL 优化 AoI 指标将成为新的研究热点。进而基于 FL 结合资源分配、数据吞吐量等问题联合优化降低 AoI，这是 AoI 研究面临的挑战之一。

2) 如何在车联网、无人机以及太赫兹通信等场景下，基于 FL 结合具体网络布局和应用特点优化 AoI，这是 AoI 研究面临的又一个挑战。例如，在太赫兹通信场景中，如何适应其高度定向性、大尺度衰落、处理功耗大等特点优化 AoI^[102]；如何结合通信安全、满足区域覆盖的无人机场景下优化 AoI；如何在车联网场景中优化系统控制的 AoI 等。

3) 在某些特定的 6G 场景中研究基于 AoI 的 FL 激励机制，如何优先考虑基于数据新鲜度选择参与 FL 的客户端，以确保满足特定的场景需求，这是研究 AoI 面临的第 3 个挑战。

3.2 可解释的 AI

目前绝大多数 AI 模型是黑盒模型，AI 策略难以理解、不具备可解释性。在复杂的 6G 网络系统

表 1 FL 赋能 6G 网络具有代表性的研究方向

FL 赋能 6G	概述	分类
促进灵活架构设计	FL 针对 6G 移动边缘场景灵活设计分布式网络架构	传统网络场景架构改进 ^[18-24] 车联网场景架构设计 ^[25-30]
促进高效资源利用	FL 结合决策算法优化 6G 网络中的分布式资源利用	FL 结合传统优化方法 ^[31-35] FL 结合 DRL 算法 ^[44-48]
促进可靠数据传输	FL 在架构、算法层面，降低 6G 场景中的时延和通信成本	基于全局优化通信指标 ^[51-55] 基于参与方优化通信指标 ^[56-60]
促进安全隐私保护	FL 结合隐私保护技术，确保 6G 分布式场景模型安全传输	FL 结合安全多方计算 ^[62-67] FL 结合差分隐私 ^[68-73] FL 结合同态加密 ^[74-77]
促进个性服务提供	FL 克服 6G 数据 Non-IID 分布特点，提供个性化智能服务	基于服务端实现个性化 FL ^[79-82] 基于客户端实现个性化 FL ^[83-92] 基于其他技术实现个性化 FL ^[93-100]

中, 黑盒模型输出可解释性差的问题可能会给用户造成巨大损失。例如, 6G 中自动驾驶依靠车载视觉识别模型来确定周边车辆的运行状态, 然而由于车载黑盒模型可解释性差, 驾驶员无法理解车辆模型输出的决策, 容易造成驾驶事故^[103]。又例如, 未来基于 6G 的智能远程手术, 一个错误指令就可能引发无法挽回的医疗事故。

开发可解释 AI、建立用户和智能机器之间的信任是未来 6G 智能应用能否普及的关键。AI 决策只有被用户理解, 并且是可解释的, 才会被认为是可靠的, 目前研究可解释 AI 面临如下挑战。

1) 在 AI 数据可解释性方面, 在未来如何通过大数据技术建立智能交互式的可视化方法, 提高用户对高维复杂时空数据特征的理解, 这是未来研究可解释 AI 的一个挑战。

2) 在 AI 模型可解释性方面, 如何多使用可解释性高的白盒模型建模并提供性能保证, 或者在理论层面增加对黑盒模型的可解释性以及神经网络的运作分析, 提供最坏情况下的性能下限保证, 是未来研究可解释性 AI 的又一挑战。

3) 目前可解释性 AI 研究尚停留在概念意义上, 需要对其进一步具体化, 便于用户能够直接捕捉和利用可解释性信息; 同时目前的可解释 AI 技术研究方法之间相互孤立, 只能适用于某些特定的场景和问题, 可迁移复用性不高。

3.3 数据隐私的保护

6G 场景将更加注重保护用户的数据安全和个人隐私, 数据安全和隐私问题与用户息息相关, 保护数据安全和隐私、建立健全数据保护防御机制将成为 6G 中非常重要的一环, 在数据隐私保护方面, 目前存在如下挑战。

1) IoT 中的海量设备连接增加了新的安全威胁。例如, 可能存在不可靠的设备, 作为恶意参与者发送错误信息或虚假模型, 以降低训练效率和全局模型性能, 从而对 6G 系统中 AI 输出造成不利影响, 或通过梯度泄漏攻击或模型反演窃取本地设备的数据^[104]。因此, 必须设计基于 FL 的攻击检测和安全防御机制, 确保 6G 系统的高度安全性。

2) 如何借助 FL 促进 IoT 设备识别攻击检测, 这是存在的又一个挑战。在 FL 中每个 IoT 设备可以将本地训练得到的攻击检测模型上传给安全网关, 在安全网关中聚合模型, 以构建 IoT 场景中的通用攻击检测模型。此外 FL 可借助区块链技术进

一步提高系统安全性, 每个参与方本地模型的即时更新, 都可链接到区块链提供的分布式账本中, 即每一个模型更新都可追溯关联到单个参与方, 这将有助于检测模型的恶意篡改或替换^[105]。

3) 在更多样化的层面和更精细的粒度上提供 FL 隐私保护, 这是存在的第 3 个挑战。因为不同服务在不同时间和地点的隐私约束可能不同, 6G 场景需要在更多样化层面和更精细粒度上提供隐私保护控制。例如, 自动驾驶汽车在高速公路上行驶时主要关注道路状况, 但在交叉路口或路边单元需要和相邻车辆协调其驾驶行为^[13], 基于分布式 AI 提供更细粒度的隐私保护机制是一个悬而未决的难题。

3.4 新型的物理设备

随着智能嵌入式设备的发展, 嵌入式 AI 训练相比基于云的 AI 训练可提供更低时延的服务, 是加速 IoT 应用发展的技术之一。然而由于 IoT 设备的硬件、内存和电源限制, 无法长期持续满足分布式 6G-IoT 复杂场景的计算要求, 终将成为限制 6G 应用发展的重要因素之一^[106]。因此, 未来 6G 场景需要部署新的低功耗终端设备, 从硬件设备的角度分析, 未来存在以下挑战。

1) 从能源供给角度, 6G 网络需要采用多种能源供给技术, 如无线能量收集技术、无线电力传输、反向散射通信等, 实现在能源需求和供应之间动态切换^[107]。如何在上述能源供需场景中引入 FL 技术, 实现根据场景变化灵活决策, 从而保证网络长期可靠工作, 这是目前存在的一个挑战。

2) 从硬件加速角度, 为了实现 6G 网络中的智能服务, 需要研究分布式硬件加速训练策略。具体来说, 在大规模复杂网络模型训练时需要利用每个处理器单元不同的计算资源来分布式协同训练模型, 基于 FL 设计在不影响准确性和系统性能的情况下的硬件调度策略, 这是从硬件设备角度分析存在的另一个挑战。

3) 从设备异构角度, 6G 网络将有海量的参与方设备进行分布式边缘计算, 不同的设备存在算力、通信资源等方面的差异性, 传统的同步训练更新方式将严重降低学习效率, 因此需要在传统 FL 基础上引入异步更新和掉队参与方的实时监测, 从而使 6G 网络中的分布式训练高效进行。

3.5 “空-天-地-海”一体化网络

未来 6G 通信会实现极广的覆盖和无处不在

的连接，通信范围将不再局限陆地，而是“空-天-地-海”的超广范围^[108]。为了全面支持未来分布式 6G 场景应用，需要在空间、空中、地面以及水下等不同通信层全面部署 6G-IoT 应用，目前构建“空-天-地-海”一体化网络存在如下挑战。

1) “空-天-地-海”一体化网络会面向许多崭新的场景，如岛屿、海洋、山区等地区，不可靠的信道条件使得通过传统提供网络服务的方法变得不现实，通信瓶颈将成为在“空-天-地-海”一体化网络中部署 FL 的重大挑战。另外，在“空-天-地-海”一体化网络中，网络拓扑结构本身会随着时间的推移而改变。在未来如何使用 FL 针对特定环境和具体场景进行合理地部署和建立稳定可靠的通信网，是一个新的挑战。

2) “空-天-地-海”一体化网络中将含有海量的异构接入节点，不同层的网络之间存在高度异质异构性、资源不平衡性、拓扑结构时变性和节点状态动态变化等特点，这些特点需要基于 FL 处理设备异步通信的问题，根据“空-天-地-海”一体化网络中不同设备的可用性灵活分配负载，采用支持系统异质性的 FL 框架。

3) “空-天-地-海”一体化网络中不同子网的数据传输环境不同，所要求的业务性能需求也各不相同，如空中和 underwater 网络传输范围长，干扰和碰撞的可能性很大，稳定性较差，不宜处理高可靠性业务。如何根据不同业务的性能需求，基于 FL 等技术在一体化网络中部署相应的定制服务，这又是一个要面临的挑战。

3.6 意图驱动的网络

6G 提出了意图驱动的无线电接入网络 (ID-RAN, intent-driven radio access network)，期望借助网络功能虚拟化技术和软件定义网络技术^[109]，抽象网络功能，基于意图动态生成网络配置策略，实现 6G 网络的自配置、自管理和自优化，目前构建 ID-RAN 面临如下挑战。

1) 如何在分布式 ID-RAN 中基于 FL、自然语言处理等技术，结合网络资源现状和网络配置经验，将意图智能动态地转译为 ID-RAN 的最优配置，从而使网络以最佳状态运行，这是 FL 赋能 ID-RAN 中有前景的研究问题。

2) 未来 6G 网络是高度动态时变的，需要在 ID-RAN 部署后对网络进行动态性能评估和优化。如何在 ID-RAN 中利用监测到的网络参数分析潜在

特征，研究在分布式 ID-RAN 中基于 FL 预知网络性能的变化趋势^[110]，这是 FL 赋能 ID-RAN 面临的另一个挑战。

3) 未来 6G 网络是一个高度耦合的复杂系统，意图可能来源于不同用户，因此如何在分布式 ID-RAN 中基于 FL 检测并处理重复、互斥或者被包含的意图语义，这是未来 FL 赋能 ID-RAN 面临的第 3 个挑战。

3.7 去蜂窝大规模多输入多输出网络

去蜂窝大规模多输入多输出 (CF mMIMO, cell-free massive multiple-input multiple-output) 网络有望在 6G 中得到广泛部署^[111]。相较于集中式 MIMO 网络中部署少量接入点和大型基站的方式，CF mMIMO 网络中将配置大量接入点，有助于减少路径损耗、解决边缘设备易受小区域干扰、性能变差等问题，然而 6G 中 CF mMIMO 网络研究仍存在挑战。

1) 如何在分布式 CF mMIMO 网络中引入 FL，优化无线设备的最佳接入点选择；同时联合优化网络中的性能指标，如网络速率、功率控制、通信成本等问题，这是 FL 赋能 CF mMIMO 网络中一个新的研究方向。

2) 在 CF mMIMO 网络上行链路中，每个接入点将接收到的信号并行发送到中央处理器，这种网络架构需要大量的长电缆，实际部署的成本太大，因此需要在 CF mMIMO 网络中研究设计更实用的 FL 网络架构和基于 FL 的分布式信息处理方法。

3) CF mMIMO 网络可以在未来移动通信中实现更高速率的数据传输，但是接入点作为高精度射频器件，大量部署显然具有难度，如何通过联合 FL 和 DRL 算法制定最优的接入点部署策略，从而在成本受限的条件下减少接入点的部署数量，这是 CF mMIMO 网络面临的又一个挑战。

3.8 可重构智能表面

RIS 被认为是未来提高 6G 网络能效的关键技术之一，RIS 由众多无源反射硬件阵列单元构成，阵列单元通过软件编程实现智能配置，每个反射单元可以按照特定角度反射信号、改变输入信号的相位。6G 可以根据不同的网络设计目标使用 RIS 控制无线环境，有望进一步降低能耗^[112]，然而 6G 中的 RIS 面临着如下挑战。

1) 在 6G 分布式场景中，如何在部署 RIS 的通

信场景中引入基于 FL 的模型训练方法, 训练信道状态信息与 RIS 反射系数的最优映射配置关系, 从而规避中心化机器学习的弊端, 这是 FL 赋能 6G 值得探索的研究方向之一。

2) 由于无线信道的随机性, RIS 相移矩阵需要随无线信道的变化而改变, 如何利用信道衰落等时间相关特性、通过 FL 有效预测 RIS 的相移矩阵, 这是研究在 6G 中基于 FL 赋能部署 RIS 面临的又一挑战。

3) 如何将 RIS 集成到 6G-IoT 应用中, 寻找 IRS 相位矩阵和基站的最优功率分配, 辅助 6G 通信中的功率和频谱优化, 提高室内/外设备通信效率, 这是研究在 6G 中部署 RIS 面临的第 3 个挑战。

3.9 可见光通信

可见光通信 (VLC, visible light communication) 利用发光二极管低功耗、高亮度、长寿命等优势特性, 将其用途从照明扩展到通信, 被认为是推动构建 6G 系统的关键技术之一。VLC 依靠可见光进行数据传输, 缓解了无线网络稀缺频谱资源的使用压力, 为不断增长的 IoT 设备提供了一种新的连接方式^[113], 然而目前 VLC 技术也面临着多种挑战。

1) 引入分布式 AI 技术是未来 VLC 发展的前景之一, VLC 传播范围有限, 只能覆盖一定数量的客户端, 使用 FL 基于分布式增加参与者数量是一个思路。此外, FL 可用于训练模型预测发光二极管的熄灭时间并及时进行备用连接指示。

2) 在 VLC 中, 如何有效引入 FL 技术推动 VLC 应用的快速发展, 例如, 基于 FL 有效优化 VLC 系统中的性能指标, 包括降低通信时延、提高数据速率和保护信息隐私等, 这是在 6G 中引入 VLC 面临的又一挑战。

3) 在 VLC 中, 如何克服环境光噪声、接收器方向随机性、信道条件时变性等特点, 开发基于 FL 的分布式信道状态预测系统, 用于预估 VLC 的信道状态, 这是 FL 赋能 6G 网络又一值得探索的研究方向。

4 结束语

本文对 FL 赋能 6G 网络进行了综述, 完整地阐述了 6G 与 FL 的关系。重点针对 FL 赋能 6G 网络这一问题, 首先在非 6G 网络的 FL 基础上, 讨论了引入 6G 对无线网络的五大新要求。其次针对新要求, 重点讨论了 FL 赋能 6G 的五大方面, 以及将

FL 用于 6G 网络的动机和优势, 调研了近年来相关技术领域的最新研究进展, 最后提出了 FL 与 6G 相结合可能遇到的挑战、今后值得研究的开放性问题 and 方向。

在未来, 6G 网络会为 FL 提供更加丰富的数据资源, FL 会利用丰富的数据资源进一步赋能 6G 应用, 二者相辅相成、优势互补, 共同实现美好愿景。希望本文基于 FL 赋能 6G 网络的综述能激发研究者们更多的兴趣, 并为 FL 演变及 FL 赋能 6G 中无处不在的 AI 开辟新研究方向, 让研究者们了解 FL 在未来 6G 的应用, 并促进对新研究方向的探索。

参考文献:

- [1] 栾宁, 熊轲, 张煜, 等. 6G: 典型应用、关键技术与面临挑战[J]. 物联网学报, 2022, 6(1): 29-43.
LUAN N, XIONG K, ZHANG Y, et al. 6G: typical applications, key technologies and challenges[J]. Chinese Journal on Internet of Things, 2022, 6(1): 29-43.
- [2] SHAHRAKI A, ABBASI M, PIRAN M J, et al. A comprehensive survey on 6G networks: applications, core services, enabling technologies, and future challenges[EB]. 2021.
- [3] LI T, SAHU A K, TALWALKAR A, et al. Federated learning: challenges, methods, and future directions[J]. IEEE Signal Processing Magazine, 2020, 37(3): 50-60.
- [4] BOUZINIS P S, DIAMANTOULAKIS P D, KARAGIANNIDIS G K. Wireless federated learning (WFL) for 6G networks part I: research challenges and future trends[J]. IEEE Communications Letters, 2022, 26(1): 3-7.
- [5] YANG Z H, CHEN M Z, WONG K K, et al. Federated learning for 6G: applications, challenges, and opportunities[J]. Engineering, 2022, 8: 33-41.
- [6] AL-QURAAAN M, MOHJAZI L, BARIAH L, et al. Edge-native intelligence for 6G communications driven by federated learning: a survey of trends and challenges[EB]. 2021.
- [7] LIU Y, YUAN X L, XIONG Z H, et al. Federated learning for 6G communications: challenges, methods, and future directions[J]. China Communications, 2020, 17(9): 105-118.
- [8] XIAO Y, SHI G M, KRUNZ M. Towards ubiquitous AI in 6G with federated learning[EB]. 2020.
- [9] 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.
- [10] 白卫岗, 盛敏, 杜盼盼. 6G 卫星物联网移动性管理: 挑战与关键技术[J]. 物联网学报, 2020, 4(1): 104-110.
BAI W G, SHENG M, DU P P. Mobility management of the 6G satellite IoT: challenges and key techniques[J]. Chinese Journal on Internet of Things, 2020, 4(1): 104-110.
- [11] PATIL A, IYER S, PANDYA R J. A survey of machine learning algorithms for 6G wireless networks[J]. arXiv preprint, 2022, arXiv:2203.08429.

- [12] 中国通信学会. 通感算一体化网络前沿报告[R]. 2021.
China Institute of Communications. Synesthesia integrated network frontier report[R]. 2021.
- [13] GUO H Z, ZHOU X Y, LIU J J, et al. Vehicular intelligence in 6G: networking, communications, and computing[J]. *Vehicular Communications*, 2022, 33: 100399.
- [14] LIU T, DING J H, WANG T, et al. Towards fast and accurate federated learning with non-IID data for cloud-based IoT applications[J]. *arXiv preprint*, 2022, arXiv:2201.12515.
- [15] LIU G Y, ZHU J K, HUANG Y M, et al. Guest editorial: 6G towards 2030: from key technology to network architecture[J]. *China Communications*, 2022, 19(3): 3-6.
- [16] HOKAZONO Y, KOHARA H, KISHIYAMA Y, et al. Extreme coverage extension in 6G: cooperative non-terrestrial network architecture integrating terrestrial networks[C]//*Proceedings of 2022 IEEE Wireless Communications and Networking Conference (WCNC)*. Piscataway: IEEE Press, 2022: 138-143.
- [17] ABREHA H G, HAYAJNEH M, SERHANI M A. Federated learning in edge computing: a systematic survey[J]. *Sensors (Basel, Switzerland)*, 2022, 22(2): 450.
- [18] ZHAO B R, CUI Q M, LIANG S Y, et al. Green concerns in federated learning over 6G[J]. *China Communications*, 2022, 19(3): 50-69.
- [19] ABAD M S H, OZFATURA E, GUNDUZ D, et al. Hierarchical federated learning ACROSS heterogeneous cellular networks[C]//*Proceedings of ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Piscataway: IEEE Press, 2020: 8866-8870.
- [20] LIU L M, ZHANG J, SONG S H, et al. Client-edge-cloud hierarchical federated learning[C]//*Proceedings of ICC 2020 - 2020 IEEE International Conference on Communications (ICC)*. Piscataway: IEEE Press, 2020: 1-6.
- [21] HOSSEINALIPOUR S, BRINTON C G, AGGARWAL V, et al. From federated to fog learning: distributed machine learning over heterogeneous wireless networks[J]. *IEEE Communications Magazine*, 2020, 58(12): 41-47.
- [22] CHEN M Z, POOR H V, SAAD W, et al. Wireless communications for collaborative federated learning[J]. *IEEE Communications Magazine*, 2020, 58(12): 48-54.
- [23] NISHIO T, YONETANI R. Client selection for federated learning with heterogeneous resources in mobile edge[C]//*Proceedings of ICC 2019 - 2019 IEEE International Conference on Communications (ICC)*. Piscataway: IEEE Press, 2019: 1-7.
- [24] LIU X L, DENG Y S, MAHMOODI T. A novel hybrid split and federated learning architecture in wireless UAV networks[C]//*Proceedings of ICC 2022 - IEEE International Conference on Communications*. Piscataway: IEEE Press, 2022: 1-6.
- [25] PRATHIBA S B, RAJA G, ANBALAGAN S, et al. Cyber twin-driven federated learning based personalized service provision for 6G-V2X[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(5): 4632-4641.
- [26] BANO S, TONELLOTO N, CASSARÀ P, et al. KafkaFed: two-tier federated learning communication architecture for Internet of vehicles[C]//*Proceedings of 2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*. Piscataway: IEEE Press, 2022: 515-520.
- [27] WANG Z, LI X H, WU T H, et al. A credibility-aware swarm-federated deep learning framework in Internet of vehicles[J]. *arXiv preprint*, 2021, arXiv:2108.03981.
- [28] ZHOU X K, LIANG W, SHE J H, et al. Two-layer federated learning with heterogeneous model aggregation for 6G supported Internet of vehicles[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(6): 5308-5317.
- [29] PENG Y Q, CHEN Z Y, CHEN Z X, et al. BFLP: an adaptive federated learning framework for Internet of vehicles[J]. *Mobile Information Systems*, 2021: 1-18.
- [30] CHAI H Y, LENG S P, CHEN Y J, et al. A hierarchical blockchain-enabled federated learning algorithm for knowledge sharing in Internet of vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(7): 3975-3986.
- [31] QU Y B, DONG C, ZHENG J C, et al. Empowering the edge intelligence by air-ground integrated federated learning in 6G networks[J]. *arXiv preprint*, 2020, arXiv:2007.13054.
- [32] KHAN L U, TUN Y K, ALSHENWI M, et al. A dispersed federated learning framework for 6G-enabled autonomous driving cars[J]. *arXiv preprint*, 2021, arXiv:2105.09641.
- [33] LIU S, YU J, DENG X H, et al. FedCPF: an efficient-communication federated learning approach for vehicular edge computing in 6G communication networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(2): 1616-1629.
- [34] YU A, YANG Q K, DOU L H, et al. Federated imitation learning: a cross-domain knowledge sharing framework for traffic scheduling in 6G ubiquitous IoT[J]. *IEEE Network*, 2021, 35(5): 136-142.
- [35] YANG Z H, CHEN M Z, SAAD W, et al. Energy efficient federated learning over wireless communication networks[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(3): 1935-1949.
- [36] LI J, GAO H, LV T J, et al. Deep reinforcement learning based computation offloading and resource allocation for MEC[C]//*Proceedings of 2018 IEEE Wireless Communications and Networking Conference (WCNC)*. Piscataway: IEEE Press, 2018: 1-6.
- [37] PENG H X, SHEN X M. Multi-agent reinforcement learning based resource management in MEC- and UAV-assisted vehicular networks[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(1): 131-141.
- [38] ZARIF A H, AZMI P, MOKARI N, et al. AoI minimization in energy harvesting and spectrum sharing enabled 6G networks[J]. *arXiv preprint*, 2021, arXiv:2107.00340.
- [39] TANG S P, ZHOU W Q, CHEN L Y, et al. Battery-constrained federated edge learning in UAV-enabled IoT for B5G/6G networks[J]. *Physical Communication*, 2021, 47: 101381.
- [40] YE Y T, WEI W S, GENG D Q, et al. Dynamic coordination in UAV swarm assisted MEC via decentralized deep reinforcement learn-

- ing[C]//Proceedings of 2020 International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2020: 1064-1069.
- [41] WEI D W, MA J F, LUO L B, et al. Computation offloading over multi-UAV MEC network: a distributed deep reinforcement learning approach[J]. *Computer Networks*, 2021, 199: 108439.
- [42] YANG Z, LIU Y W, CHEN Y. Distributed reinforcement learning for NOMA-enabled mobile edge computing[C]//Proceedings of 2020 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2020: 1-6.
- [43] TEHRANI P, RESTUCCIA F, LEVORATO M. Federated deep reinforcement learning for the distributed control of NextG wireless networks[C]//Proceedings of 2021 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Piscataway: IEEE Press, 2022: 248-253.
- [44] ZHUO H K, FENG W F, XU Q, et al. Federated reinforcement learning[EB]. 2019.
- [45] MESSAOUD S, BRADAI A, AHMED O B, et al. Deep federated Q-learning-based network slicing for industrial IoT[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(8): 5572-5582.
- [46] NIE Y W, ZHAO J H, GAO F F, et al. Semi-distributed resource management in UAV-aided MEC systems: a multi-agent federated reinforcement learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(12): 13162-13173.
- [47] ZANG L Q, ZHANG X, GUO B R. Federated deep reinforcement learning for online task offloading and resource allocation in WPC-MEC networks[J]. *IEEE Access*, 2022, 10: 9856-9867.
- [48] XUE Z Y, ZHOU P, XU Z C, et al. A resource-constrained and privacy-preserving edge-computing-enabled clinical decision system: a federated reinforcement learning approach[J]. *IEEE Internet of Things Journal*, 2021, 8(11): 9122-9138.
- [49] CHEN M Z, SHLEZINGER N, POOR H V, et al. Communication-efficient federated learning[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2021, 118(17): e2024789118.
- [50] CHEN M Z, GÜNDÜZ D, HUANG K B, et al. Distributed learning in wireless networks: recent progress and future challenges[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(12): 3579-3605.
- [51] HUANG T S, LIN W W, SHEN L, et al. Stochastic client selection for federated learning with volatile clients[J]. *IEEE Internet of Things Journal*, 2022, 9(20): 20055-20070.
- [52] ZHU Z Q, WAN S, FAN P Y, et al. Federated multiagent actor-critic learning for age sensitive mobile-edge computing[J]. *IEEE Internet of Things Journal*, 2022, 9(2): 1053-1067.
- [53] LI R J, XU H B, ZHANG G P, et al. Latency optimization for federated learning over wireless power transfer[J]. *Physical Communication*, 2022, 53: 101765.
- [54] HUANG N, WANG T S, WU Y, et al. Delay minimization for intelligent reflecting surface assisted federated learning[J]. *China Communications*, 2022, 19(4): 216-229.
- [55] PRATHIBA S B, RAJA G, ANBALAGAN S, et al. Federated learning empowered computation offloading and resource management in 6G-V2X[J]. *IEEE Transactions on Network Science and Engineering*, 2022, 9(5): 3234-3243.
- [56] YANG Q, LIU Y, CHEN T J, et al. Federated machine learning: concept and applications[J]. *ACM Transactions on Intelligent Systems and Technology*, 2019, 10(2): 1-19.
- [57] RIBERO M, VIKALO H. Communication-efficient federated learning via optimal client sampling[J]. *arXiv preprint*, 2020, arXiv:2007.15197.
- [58] LI X Y, QU Z, TANG B, et al. Stragglers are not disaster: a hybrid federated learning algorithm with delayed gradients[J]. *arXiv preprint*, 2021, arXiv:2102.06329.
- [59] CHO Y J, WANG J Y, JOSHI G. Client selection in federated learning: convergence analysis and power-of-choice selection strategies[J]. *arXiv preprint*, 2020, arXiv:2010.01243.
- [60] YOSHIDA N, NISHIO T, MORIKURA M, et al. MAB-based client selection for federated learning with uncertain resources in mobile networks[C]//Proceedings of 2020 IEEE Globecom Workshops (GC Wkshps). Piscataway: IEEE Press, 2021: 1-6.
- [61] WEI K, LI J, DING M, et al. Federated learning with differential privacy: algorithms and performance analysis[J]. *IEEE Transactions on Information Forensics and Security*, 2020, 15: 3454-3469.
- [62] MA C, LI J, DING M, et al. On safeguarding privacy and security in the framework of federated learning[J]. *IEEE Network*, 2020, 34(4): 242-248.
- [63] WANG R J, LAI J S, ZHANG Z Y, et al. Privacy-preserving federated learning for Internet of medical things under edge computing[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022.
- [64] SONG J C, WANG W Z, GADEKALLU T R, et al. EPPDA: an efficient privacy-preserving data aggregation federated learning scheme[J]. *IEEE Transactions on Network Science and Engineering*, 2022, PP(99): 1.
- [65] KANAGAVELU R, LI Z X, SAMSUDIN J, et al. Two-phase multi-party computation enabled privacy-preserving federated learning[C]//Proceedings of 2020 20th IEEE/ACM International Symposium on Cluster, Cloud and Internet Computing (CCGRID). Piscataway: IEEE Press, 2020: 410-419.
- [66] ZHU H F, MONG GOH R S, NG W K. Privacy-preserving weighted federated learning within the secret sharing framework[J]. *IEEE Access*, 2020, 8: 198275-198284.
- [67] KANAGAVELU R, WEI Q S, LI Z X, et al. CE-Fed: communication efficient multi-party computation enabled federated learning[J]. *Array*, 2022, 15: 100207.
- [68] MENG Q, ZHOU F, REN H N, et al. Improving federated learning face recognition via privacy-agnostic clusters[J]. *arXiv preprint*, 2022, arXiv:2201.12467.
- [69] WAN Y C, QU Y Y, GAO L X, et al. Privacy-preserving blockchain-enabled federated learning for B5G-Driven edge computing[J]. *Computer Networks*, 2022, 204: 108671.
- [70] LIU W Y, CHENG J H, WANG X L, et al. Hybrid differential privacy based federated learning for Internet of Things[J]. *Journal of Systems Architecture*, 2022, 124: 102418.

- [71] HU R, GONG Y M, GUO Y X. Federated learning with sparsified model perturbation: improving accuracy under client-level differential privacy[J]. arXiv preprint, 2022, arXiv:2202.07178.
- [72] WU X, ZHANG Y T, SHI M Y, et al. An adaptive federated learning scheme with differential privacy preserving[J]. Future Generation Computer Systems, 2022, 127: 362-372.
- [73] HUANG J, XU C, JI Z H, et al. AFLPC: an asynchronous federated learning privacy-preserving computing model applied to 5G-V2X[J]. Security and Communication Networks, 2022, 2022: 1-11.
- [74] PARK J, LIM H. Privacy-preserving federated learning using homomorphic encryption[J]. Applied Sciences, 2022, 12(2): 734.
- [75] KU H C, SUSILO W, ZHANG Y D, et al. Privacy-preserving federated learning in medical diagnosis with homomorphic re-Encryption[J]. Computer Standards & Interfaces, 2022, 80: 103583.
- [76] WIBAWA F, CATAK F O, SARP S, et al. Homomorphic encryption and federated learning based privacy-preserving CNN training: COVID-19 detection use-case[J]. arXiv preprint, 2022, arXiv:2204.07752.
- [77] PEJIC I, WANG R, LIANG K. Effect of homomorphic encryption on the performance of training federated learning generative adversarial networks[EB]. 2022.
- [78] ONOSZKO N, KARLSSON G, MOGREN O, et al. Decentralized federated learning of deep neural networks on non-iid data[J]. arXiv preprint, 2021, arXiv:2107.08517.
- [79] 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.
- [80] LI T, SANJABI M, BEIRAMI A, et al. Fair resource allocation in federated learning[J]. arXiv preprint, 2019, arXiv:1905.10497.
- [81] CHEN H Y, CHAO W L. FedBE: making Bayesian model ensemble applicable to federated learning[J]. arXiv preprint, 2020, arXiv:2009.01974.
- [82] SHAMSIAN A, NAVON A, FETAYA E, et al. Personalized federated learning using hypernetworks[J]. arXiv preprint, 2021, arXiv:2103.04628.
- [83] ARIVAZHAGAN M G, AGGARWAL V, SINGH A K, et al. Federated learning with personalization layers[J]. arXiv preprint, 2019, arXiv:1912.00818.
- [84] COLLINS L, HASSANI H, MOKHTARI A, et al. Exploiting shared representations for personalized federated learning[J]. arXiv preprint, 2021, arXiv:2102.07078.
- [85] 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.
- [86] LI XX, JIANG M R, ZHANG X F, et al. FedBN: federated learning on non-IID features via local batch normalization[J]. arXiv preprint, 2021, arXiv:2102.07623.
- [87] DINH C T, TRAN N H, NGUYENT D. Personalized federated learning with Moreau envelopes[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM Press, 2020: 21394-21405.
- [88] ACHITUVE I, SHAMSIAN A, NAVON A, et al. Relational learning with Gaussian processes[M]//Advances in Neural Information Processing Systems 19. Vancouver: The MIT Press, 2007.
- [89] DANDI Y, BARBA L, JAGGI M. Implicit gradient alignment in distributed and federated learning[J]. arXiv preprint, 2021, arXiv:2106.13897.
- [90] RUAN Y C, JOE-WONG C. FedSoft: soft clustered federated learning with proximal local updating[J]. arXiv preprint, 2021, arXiv:2112.06053.
- [91] YANG M, WANG X M, QIAN H, et al. An improved federated learning algorithm for privacy preserving in cybertwin-driven 6G system[J]. IEEE Transactions on Industrial Informatics, 2022, 18(10): 6733-6742.
- [92] AAMER B, CHERGUI H, BENJILLALI M, et al. Entropy-driven stochastic federated learning in non-IID 6G edge-RAN[J]. Frontiers in Communications and Networks, 2021, 2: 739414.
- [93] SMITH V, CHIANG C K, SANJABI M, et al. Federated multi-task learning[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM Press, 2017: 4427-4437.
- [94] LI T, HU S Y, BEIRAMI A, et al. Ditto: fair and robust federated learning through personalization[J]. arXiv preprint, 2020, arXiv:2012.04221.
- [95] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[J]. arXiv preprint, 2017, arXiv:1703.03400.
- [96] JIANG Y H, KONEČNÝ J, RUSH K, et al. Improving federated learning personalization via model agnostic meta learning[J]. arXiv preprint, 2019, arXiv:1909.12488.
- [97] ACAR D A E, ZHAO Y, ZHU R, et al. Debiasing model updates for improving personalized federated training[C]//International Conference on Machine Learning. New York: PMLR, 2021: 21-31.
- [98] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. arXiv preprint, 2015, arXiv:1503.02531.
- [99] ZHU Z D, HONG J Y, ZHOU J Y. Data-free knowledge distillation for heterogeneous federated learning[J]. Proceedings of Machine Learning Research, 2021, 139: 12878-12889.
- [100] LIN T, KONG L J, STICH S U, et al. Ensemble distillation for robust model fusion in federated learning[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM Press, 2020: 2351-2363.
- [101] KAUL S, GRUTESER M, RAI V, et al. Minimizing age of information in vehicular networks[C]//Proceedings of 2011 8th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks. Piscataway: IEEE Press, 2011: 350-358.
- [102] 熊轲, 胡慧敏, 艾渤, 等. 6G 时代信息新鲜度优先的无线网络设计[J]. 物联网学报, 2020, 4(1): 80-91.
- XIONG K, HU H M, AI B, et al. Information freshness orientated wireless network design for 6G[J]. Chinese Journal on Internet of Things, 2020, 4(1): 80-91.
- [103] KHAN L U, SAAD W, HAN Z, et al. Federated learning for internet of things: recent advances, taxonomy, and open challenges[J]. IEEE Communications Surveys & Tutorials, 2021, 23(3): 1759-1799.

- [104]REN H C, DENG J J, XIE X H. GRNN: generative regression neural network—a data leakage attack for federated learning[J]. ACM Transactions on Intelligent Systems and Technology, 2022, 13(4): 1-24.
- [105]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.
- [106]STRINATI E C, BELOT D, FALEMPIN A, et al. Toward 6G: from new hardware design to wireless semantic and goal-oriented communication paradigms[C]//Proceedings of ESSCIRC 2021 - IEEE 47th European Solid State Circuits Conference (ESSCIRC). Piscataway: IEEE Press, 2021: 275-282.
- [107]ZHANG H N, WANG F. Wireless sensor energy harvesting and management[EB]. 2022.
- [108]ZHU X M, JIANG C X, KUANG L L, et al. Cooperative transmission in integrated terrestrial-satellite networks[J]. IEEE Network, 2019, 33(3): 204-210.
- [109]PANG L, YANG C G, CHEN D Y, et al. A survey on intent-driven networks[J]. IEEE Access, 2020, 8: 22862-22873.
- [110]周洋程, 闫实, 彭木根. 意图驱动的 6G 无线接入网络[J]. 物联网学报, 2020, 4(1): 72-79.
ZHOU Y C, YAN S, PENG M G. Intent-driven 6G radio access network[J]. Chinese Journal on Internet of Things, 2020, 4(1): 72-79.
- [111]VU T T, NGO D T, TRAN N H, et al. Cell-free massive MIMO for wireless federated learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6377-6392.
- [112]NI W L, LIU Y W, YANG Z H, et al. Integrating over-the-air federated learning and non-orthogonal multiple access: what role can RIS play?[J]. IEEE Transactions on Wireless Communications, 2022, 21(12): 10083-10099.
- [113]JAMES SINGH K, HUANG Y M, AHMED T, et al. Micro-LED as a promising candidate for high-speed visible light communication[J]. Applied Sciences, 2020, 10(20): 7384.

[作者简介]



耿光磊 (1999–), 男, 北京交通大学计算机与信息技术学院硕士生, 主要研究方向为联邦学习、车联网资源分配等。



高博 (1984–), 男, 博士, 北京交通大学计算机与信息技术学院副教授, 主要研究方向为无线网络、移动计算、机器学习等。



熊轲 (1981–), 男, 博士, 北京交通大学计算机与信息技术学院教授、博士生导师、副院长, 主要研究方向为绿色物联网、网络资源优化、网络智能与移动计算等。



樊平毅 (1965–), 男, 博士, 清华大学电子工程系教授、博士生导师, 主要研究方向为网络信息论、无线通信、大数据理论、分布式机器学习等。



陆杨 (1992–), 男, 博士, 北京交通大学计算机与信息技术学院教授, 主要研究方向为优化理论、机器学习赋能移动通信系统等。



王煜炜 (1980–) 男, 博士, 中国科学院计算技术研究所高级工程师、硕士生导师, 主要研究方向为边缘智能、无人系统网络协同、未来网络体系架构等。