

面向智能服务的雾无线接入网络：原理、技术与挑战

刘晨熙, 刘炳宏, 张贤, 龙新南, 彭木根

(北京邮电大学网络与交换技术国家重点实验室, 北京 100876)

摘要: 大数据和人工智能的兴起推动了智能服务的蓬勃发展。然而由于数据管理和模型训练成本高昂, 以及用户对时延和隐私等的需求愈加突出, 基于现有的集中式网络架构难以实现整体网络的智能化。为此, 提出了一种支持分布式机器学习的基于人工智能的雾无线接入网络 (AI-FRAN) 架构, 并探讨了支撑该架构的基础理论, 明确了充分利用雾无线接入网络 (F-RAN) 中通信资源、计算资源以及缓存资源的关键赋能技术。最后, 讨论了 AI-FRAN 未来的发展机遇与挑战。

关键词: 智能服务; 雾无线接入网; 人工智能; 分布式机器学习

中图分类号: TN929.5

文献标识码: A

doi: 10.11959/j.issn.2096-6652.202102

Intelligent service oriented fog radio access network: principles, technologies and challenges

LIU Chenxi, LIU Binghong, ZHANG Xian, LONG Xinnan, PENG Mugen

State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunication, Beijing 100876, China

Abstract: Big data and artificial intelligence has promoted the development of intelligent service. However, due to the high cost of data management and model training, as well as the increasing demands of users for latency and privacy, it is difficult to achieve the intelligent network based on the existing centralized network architecture. To address this issue, an artificial intelligence-based fog radio access network (AI-FRAN) architecture that supported distributed machine learning was proposed, and the fundamental principles that support the architecture were discussed. The key enabling techniques were identified that can realize the full utilization of communication resources, computing resources and cache resources in fog radio access network (F-RAN). Finally, the opportunities and challenges of AI-FRAN were discussed.

Key words: intelligent service, fog radio access network, artificial intelligence, distributed machine learning

1 引言

人工智能 (artificial intelligence, AI) 在语音/图像识别、自然语言处理以及推荐/搜索引擎等领域取得了突破性进展, 并由此衍生了包括无人驾驶、增强现实 (augmented reality, AR)、虚拟现实 (virtual reality, VR)、智能写作、智能物联网、数字卫生

系统、智能搜索引擎以及个性化推送等在内的一系列智能服务。随之产生的大量数据和庞大的终端接入设备可能会在安全、隐私、服务供应和网络管理等方面带来挑战。

智能服务按照通信需求可以分为以下 3 类: 海量机器通信 (massive machine type communication, mMTC) 业务、增强型移动宽带 (enhanced mobile

收稿日期: 2020-07-02; 修回日期: 2020-07-28

通信作者: 彭木根, pmg@dupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61671074); 北京市自然科学基金资助项目 (No.JQ18016); 中央高校基本科研业务费资助项目 (No.2020RC09)

Foundation Items: The National Natural Science Foundation of China (No.61671074), The Natural Science Foundation of Beijing (No.JQ18016), The Fundamental Research Funds for the Central Universities (No.2020RC09)

broadband, eMBB) 业务以及与低时延高可靠通信 (ultra reliable and low latency communication, uRLLC) 业务, 人工智能与通信需求的结合如图 1 所示。其中, 以智慧城市、环境监测以及智慧农业为代表的 mMTC 业务, 要求设备密度达到每平方千米数百万个, 相较于传统的上一代移动通信, 设备密度提升了 10~100 倍。以 VR/AR、高清视频以及全息投影为代表的 eMBB 业务要求为用户提供 1 Gbit/s 的传输速率、数十 Gbit/s 的峰值速率和每平方千米数十 Tbit/s 的流量密度。以自动驾驶、智能工厂以及远程控制等智能服务为主的 uRLLC 业务, 要求空口时延达到 1 ms、端到端时延达到数十毫秒级, 可靠性接近 100%。

为了满足这些智能服务的需求, 保证用户体验, 需要将 AI 技术与大数据结合, 共同实现网络的智能化。其中, 边缘智能化是网络智能化的一个重要组成部分, 边缘智能化可以有效解决过载和用户隐私安全等问题。然而, 当前关于网络智能化的研究主要考虑集中式的网络架构, 例如云无线接入网 (cloud radio access network, C-RAN) 架构^[1]将全部的计算和处理能力集中于中央云, 中央云基于全局信息进行数据的处理并做出相应决策。这种集中式的网络架构在实现网络智能化时存在如下问题。一是难以进行数据的有效管理, 未来进入物联网时代, 数据源更加复杂多样, 将具有稀疏性、异构性、移动性以及波动性等特征^[2], 传统的基于云计算的处理模式难以有效处理这些海量数据; 二是时延较长, 服务时延是影响用户服务质量 (quality of service, QoS) 的重要因素, 尽管云计算庞大的处理能力能够有效缩短处理时延, 但是考虑到用户位于网络边缘的场景, 传输

时延仍然过长; 三是用户隐私保护受到威胁。为解决上述问题, 本文引入雾无线接入网络 (fog radio access network, F-RAN) 架构^[3]。雾无线接入网络架构是一种分布式网络架构, 通过充分利用网络边缘节点的无线信号处理、协作无线资源管理以及分布式缓存计算等能力, 实现网络边缘按需处理和业务分发, 减轻回传链路以及中央云的负担, 实现灵活自适应的网络管理。因此, 可以将人工智能技术与雾无线接入网络结合, 在满足智能服务需求的同时, 更加安全、智能、高效地进行网络运营与管理。

2 AI 驱动的雾无线接入网络

本节从基于人工智能的雾无线接入网络 (artificial intelligence-based fog radio access network, AI-FRAN) 的网络架构、理论和性能几个方面, 来阐述 AI 驱动的雾无线接入网络。

2.1 AI-FRAN 的网络架构

智能服务对巨容量、极低时延、超高可靠和海量链接, 以及网络的动态可重构特性和智能化水平, 提出了更高的要求。当前 5G 网络依旧难以满足上述需求, 需要进一步增强, 并在无线网络技术和服务提供等方面产生颠覆性的技术革新。传统 F-RAN 的网络架构虽然在降低时延、提升网络容量和改善用户 QoS 等方面表现出了较大潜力, 但也存在如下缺陷: 一是网络节点类型、协议分割方式以及节点服务能力之间的异构性, 使得 F-RAN 在复杂的环境下难以实现智能化协同, 网络性能受限; 二是网络资源维度增加, 资源之间的空间、时间尺度存在差异并相互耦合, 使得多维度多目标跨场景的资源调配十分复杂, 并且难以保证性能需求; 三




图1 人工智能与通信需求的结合

是网络规划优化和运维参数剧增,传统的结构单一的集中式或分布式的网络规划优化方案难以满足未来网络对性能进行智能监测、故障预警和提前自主优化的需求,同时网络运营维护成本高、难度大。因此,为了应对网络异构性、多维资源调配等带来的未来网络协同难度大的挑战,同时降低网络管理和运维成本,急需提升网络智能化水平,以满足未来智能服务的需求。

AI-FRAN 的网络架构的核心思想是充分利用 F-RAN 的架构优势和 AI 基于大数据驱动的认知、学习、推理的智能特性,在传统 F-RAN 的网络架构^[3]的基础上,借助 AI 方法参与组网,提升网络智能化水平,特别是网络边缘的智能化能力,以满足智能服务的差异化需求。AI-FRAN 的网络架构如图 2 所示,该网络架构由 F-RAN 中的各类节点(包括高功率节点(high power node, HPN)、射频拉远头(remote radio head, RRH)、雾接入节点(fog access point, F-AP),以及基带单元池(baseband unit pool, BBU pool))组成,同时在 HPN 和 F-AP 中部署了本地 AI 引擎,在 BBU pool 和核心网中部署了全局 AI 引擎。RRH 通过前传链路(fronthaul)与基带单元池连接,实现集中式通信、缓存和计算功能;F-AP

不仅具备无线信号处理能力,还具备边缘缓存、计算及资源管理能力。F-AP 通过回程链路(backhaul)与核心网相连。HPN 通过回程链路(backhaul)与核心网相连,HPN 可以由传统的宏基站配置一定的边缘计算能力来实现,HPN 除了提供广域覆盖和对低速移动用户的支持外,还负责网络控制面信令的分发。

AI-FRAN 的网络架构的显著特征在于通过在 BBU pool、HPN 和 F-AP,甚至是在各类雾终端节点上部署 AI 算法和功能,借助网络各层级数据采集处理、建模、线下/线上训练与分析决策,提升环境、终端、网络、服务的智能感知能力,增强网络适配能力,真正实现网络中多维资源的动态协同。

具体地,全局 AI 引擎主要负责收集网络中的全局信息,包括网络中的业务属性信息(业务种类、性能指标需求、对应业务的负载等)、网络故障预警监测信息,以及 F-AP、终端上报的测量信息等。部署在 HPN 中的本地 AI 引擎主要负责对全局 AI 引擎下沉部分进行控制和决策,以降低控制面时延和决策时延,为广域覆盖和大链接场景下的智能业务提供支撑。部署在 F-AP 上的本地 AI 引




图2 AI-FRAN 的网络架构

擎主要负责为 uRLLC 业务提供本地控制以及执行其对应的 AI 算法。随着智能终端的计算能力和存储能力不断增强, AI-FRAN 的智能终端节点也具有了一定的 AI 能力, 包括基础的数据收集、预处理和模型训练, 甚至简单的基于 AI 模型的决策能力。

通过在 F-RAN 中部署集中式和分布式自适应的 AI 算法, 面向不同的业务需求, 在不同空间、时间和资源维度进行智能化数据采集、模型训练和决策, 可以更有针对性地提升网络性能, 同时可以维持较低的 AI 算法设计和部署的复杂度, 从而为包括超高清视频、VR/AR、智能车联网、工业物联网等在内的广泛智能服务提供支撑。

2.2 AI-FRAN 理论

本节将从 AI-FRAN 组网基本原理, AI-FRAN 的信号处理、资源调配和网络管理, 以及面向智能服务的 AI-FRAN 层间协同 3 个方面来阐述 AI-FRAN 理论。首先, AI-RAN 组网基本原理主要概述了 AI 与 F-RAN 结合的必要性和优势。然后, 从 AI 在无线网络中应用的角度, 依次介绍了 AI-FRAN 的信号处理、资源调配和网络管理, 阐述 AI 如何与 F-RAN 结合以提升网络智能化水平。最后, 为了实现 AI 与 F-RAN 的深度融合, 满足智能服务苛刻的性能需求, 根据未来智能服务的特征, 重点阐述了 AI-FRAN 的核心特征——AI-FRAN 层间协同在 AI 算法部署、训练和智能决策中如何提供柔性可重构的网络架构保障。

2.2.1 AI-FRAN 组网基本原理

F-RAN 充分利用网络边缘分布式的存储和计算能力, 为网络边缘智能化提供了计算能力, 这是传统蜂窝网络不具备的优势。F-RAN 为数据采集、本地处理、传输以及根据智能服务的性能需求借助 AI 技术进行训练和决策等提供架构优势和性能保障。比如, 通过将全局 AI 引擎的部分功能下沉到 F-AP 中的本地 AI 引擎中进行部署, 一方面可以降低数据采集和传输过程对回程链路的负载, 另一方面可以降低部署完成后的 AI 算法感知、响应和决策等整个过程的时延, 从而提升网络效率和用户服务质量。

从网络架构的角度来看, 集中式网络架构下的 AI 功能部署存在一些突出问题: 一方面, 通信成本过高, 大量的数据采集、反馈和传输占用了大量的

通信资源; 另一方面, 数据需要被集中收集和训练, 在数据采集、传输、反馈等过程中存在数据安全、终端用户隐私泄露的问题。而 F-RAN 结合分布式智能学习技术(如联邦学习)能较好地解决该问题。同时 AI 技术本身具有较强的可扩展性、可迁移性以及通过网络环境和样本数据的泛化能力, 特别是通过线上数据采集、线下数据分析训练, 然后迁移部署, 可以降低 AI 功能的部署成本和缩短维护周期。此外, 借助轻量级的线上训练模型, AI 算法可以被在线更新, 从而提升 AI 功能对环境的适配能力, 当 AI 技术和 F-RAN 结合后, AI-FRAN 能够在满足较低复杂度要求的同时, 保持较高的网络弹性和智能化水平。

因此 AI-FRAN 组网方案将充分发挥 F-RAN 的架构优势和 AI 技术智能化, 可扩展可迁移, 在线实时训练、更新、决策等显著优势为智能服务提供更高的性能保障和网络效率。

2.2.2 AI-FRAN 的信号处理、资源调配和网络管理

信号处理、资源调配和网络管理是网络系统设计的 3 个重要方面, AI 在其中的应用已受到广泛关注, 本文将重点从这 3 个方面阐述 AI 与 F-RAN 如何结合, 以提升 F-RAN 的智能化水平。

(1) AI-FRAN 的信号处理

AI-FRAN 的信号处理主要包括基于 AI 和大数据的无线信号检测、无线信道估计、无线信号的解调解码等。AI-FRAN 的信号处理的核心思想是利用基础 AI 和大数据分析技术, 收集时间、空间、频率等维度的无线大数据, 基于深度神经网络模型来自主分析和提取信道特征, 进行信道的辅助建模、信号检测和信道估计等。以信道估计为例, 通过人工智能的方法来实现传统通信系统中的信道估计算法, 可以在信道先验信息未知的情况下, 只通过少量的参考信号(甚至不需要参考信号), 就能够较准确地估计当前信道。

(2) AI-FRAN 的资源调配

AI-FRAN 的资源调配主要包括基于 AI 算法的多用户调度、单维度资源管理和多维度资源的联合分配等。为了满足未来差异化的智能业务需求, 除了需要充分利用 AI-FRAN 的多种接入方式、传输方式和灵活的网络架构, 还需要充分考虑资源的调配以及资源本身的特性(包括时间尺度属性、资源之间的耦合特性等), 利用人工智能方法建立不同的智能业务模型, 用于感知、预测不同业务对的性

能需求,实现通信、存储、计算资源的协同编排调度,实现多性能指标的联合优化,以满足目标智能业务的性能需求。

(3) AI-FRAN 的网络管理

AI-FRAN 的网络管理主要包括基于 AI 技术的 F-RAN 网络规划优化和运维等。无线大数据分析和人工智能方法是实现未来智慧移动通信网络的重要方法。随着移动网络越来越复杂,网络参数剧增,网络规划优化和运维成本占据着运营商成本的很大比例。考虑到 AI-FRAN 在网络架构上的灵活性,单一集中式或分布式的网络管理架构将很难满足网络管理对网络性能自主优化、网络故障预警、网络故障自动治愈的性能需求。通过全局 AI 引擎和本地 AI 引擎的协作,按照时间尺度信息、网络覆盖范围和网络状态信息属性进行分层收集和训练,一方面能降低网络数据隐私泄露的风险,另一方面能降低网络数据传输负载和单点故障造成的影响。

2.2.3 面向智能服务的 AI-FRAN 层间协同

随着智能服务的不断涌现,不同的智能服务在传输速率、时延、可靠性、连接数等方面存在较大差异,这对 AI-FRAN 的网络架构提出了柔性可重构的要求。从智能业务需求的角度来看,通过 AI-FRAN 层间协同,可以实现 AI-FRAN 的网络功能动态适配业务的需求。

针对大容量智能业务,例如热点地区超高清视频业务, AI-FRAN 的全局 AI 引擎通过终端感知和业务感知,将基于雾计算的用户设备(fog computing based-user equipment, F-UE)智能终端调配给多个 RRH 协作服务,以提供高速率。在这个过程中,智能终端根据网络需求采集的数据可以在本地进行模型训练,然后将模型参数上传给全局 AI 引擎;智能终端也可以直接将采集的数据上传到 AI 全局控制器进行全局模型的训练。

针对高速率且低时延的智能服务,例如 VR/AR,模型的训练和决策可以在 F-AP 中的本地 AI 引擎中进行,也可以根据时延需求的严苛程度,将部分决策集中在全局 AI 引擎中执行。

针对超低时延高可靠智能业务,例如智能车联网业务, AI-FRAN 的全局 AI 引擎通过终端感知和业务感知,将车联网智能终端调配给 F-AP 进行服务,考虑到车联网智能终端的移动性,可以由多个 F-AP 组成雾计算簇,通过 F-AP 之间的协作保证低

时延和高可靠的性能需求。

针对海量连接智能业务,例如工业物联网业务,上行数据可以先在本地簇头节点上进行汇聚处理,包括数据的压缩、基础模型的训练等操作。考虑到工业物联网大链接场景对时延的要求,可以在 HPN 中的本地 AI 引擎或全局 AI 引擎中进行模型的训练和决策。

2.3 AI-FRAN 的性能研究

传统 F-RAN 的性能指标主要包括能量效率、频谱效率、时延、吞吐量、能耗等,这些指标是传统网络的常用性能指标,维度较为单一,侧重某一方面的性能,缺少对网络整体性能的刻画。当 AI 与 FRAN 结合后,网络将更加注重感知能力以及对大数据的采集、分析、训练和推理决策。因此, AI-FRAN 需要在关注多维度性能指标、网络整体性能的同时,关注 AI 本身以及 AI 与 FRAN 结合带来的新的综合性能指标,例如 AI-FRAN 性能的确定性、可预测性、感知灵敏性甚至复杂性等。

当前对 AI 方法的性能的可解释性研究还处于初始阶段,无法直接通过理论分析给出普遍的性能规律,因此需要考虑基于仿真和半定性的性能分析方法,借助现有的确定性结论,例如性能上下限、算法的收敛性等理论基础,再通过大量的仿真来模拟网络环境,通过仿真实验来获取统计性能结果,并初步探究影响性能的因素,然后基于该实验结果来设计新的性能分析方法。AI-FRAN 的性能分析可以考虑使用类似的方法。然而,当前的研究多集中在借助 AI 方法来解决传统的优化问题^[4-5],例如用户接入方式选择、无线资源分配、缓存方案、计算资源分配等问题,没有将 AI 与 F-RAN 深度融合,对 AI-FRAN 本身的理论性能的分析研究还十分欠缺。对 AI-FRAN 网络系统层级的性能研究有待进一步深入,可以考虑在传统随机几何理论分析方法的基础上,提出引入 AI 后的新的性能量化分析方法。

3 AI-FRAN 关键技术

通过在 F-RAN 中引入 AI 技术,面向智能服务的雾无线接入网络可以实现灵活自适应的信号处理与网络管理。为了进一步满足未来 6G 支持从核心到网络终端设备的无处不在的人工智能服务的需求,充分发挥移动通信、计算和控制的潜力^[6],必须采用

一些关键技术来实现对 F-RAN 中通信资源、计算资源以及缓存资源的充分、合理利用。

3.1 分布式的人工智能技术

未来关于无线通信的演进将从物物互联 (connected things) 向智能互联 (connected intelligence) 进行彻底变革, 由此带来了新的挑战。在大数据和大模型的双重挑战之下, 大规模的机器学习的训练对计算能力和存储容量都提出了新的要求: 第一, 计算复杂度高, 传统的单机模式计算能力难以满足需求, 导致耗时过长, 需要采用计算机集群来完成训练任务; 第二, 海量数据的存储对存储容量提出了较高要求, 传统的单机存储容量难以满足需求, 需要使用分布式存储。由此, 分布式机器学习应运而生。分布式机器学习主要被应用于 3 种场景: 训练数据较多的场景, 需要对数据进行划分; 模型规模较大的场景, 需要对模型进行划分; 计算量较大的场景, 需要采用多线程/多机并行运算。分布式机器学习框架如图 3 所示, 包含数据与模型的划分模块、独立优化模块、通信模块以及数据与模型的融合模块。当单机无法支撑海量训练数据/大规模机器学习模型时, 需要对数据/模型进行划分并将其分配至各个工作节点上。之后, 每个工作节点根据所分配到的局部数据/子模型进行单机机器学习训练。通信模块涉及通信内容、拓扑结构、同步/异步通信方式以及频率等。最后, 将来自多个工作节点的局部数据/子模型进行整合, 以获得全局模型。

联邦学习也是分布式机器学习的典型代表, 其需要网络边缘设备提供强大的计算能力和灵活的协作能力, 这些需求恰好契合了 F-RAN 的架构。

联邦学习本质上是一种数据级别的加密的分布式机器学习技术, 它可以在不共享原始数据的情况下, 从属于不同方的大量数据中实现协作学习。联邦学习可以充分利用多个学习代理 (agent) 的计算能力来提高学习效率, 同时为数据所有者提供更好的隐私解决方案。在联邦学习中, 首先, 每个用户基于本地数据训练自己的模型, 训练结果将被上传至服务器; 然后, 服务器会更新全局模型, 将改进后的全局参数返回给用户, 开始新一轮的局部训练; 最后, 通过用户和服务器之间的协作, 可以生成准确的学习模型。

3.2 多维资源多目标差异优化

随着下一代移动通信和人工智能等技术的发展, mMTC、eMBB 以及 uRLLC 等具有不同性能需求的应用场景对未来的通信网络的多维资源多目标差异优化提出了新的挑战。考虑到对通信、计算以及缓存等资源的分配在时间尺度和空间尺度上存在较大差异, 并且 3 种资源难以解耦合等问题, 针对跨场景跨业务的 AI-FRAN 需要根据其不同的性能需求 (例如高容量、低时延、高可靠、大连接等), 对通信、计算和缓存资源进行多维资源多目标差异优化, 构建基于 AI 的智能资源调配模型, 对整体参数进行系统化的智能训练, 在解决多维资源耦合以及其时空差异特性等问题的同时, 实现对不同业务的多目标优化。

3.3 智能信号处理

传统的信号处理过程包括信号的检测、估计、调制解调以及波束赋型设计等。然而, 随着自动驾驶、智慧城市、VR/AR 等一系列智能服务的发展, 传统的信号处理难以应对随之而来的快速变化的




图3 分布式机器学习框架

动态环境以及差异化的业务需求。而在 AI-FRAN 中, 这些问题皆可以通过引入机器学习/深度学习技术来更好地解决。与传统的信号处理相比, 机器学习/深度学习减少了算法对信号的假设, 通过对训练数据进行分析 and 处理, 将传统信号处理中的参数从固定参数逐渐变成可学习参数, 增加了算法的灵活性和可扩展性, 进而达到更好的效能优化。例如, 在信道估计中, 传统的基于导频的信道估计在 mMTC 场景下会占用大量频谱资源, 导致传输效率低下, 此时可以通过引入机器学习/深度学习, 利用信道特性降低信道维度, 实现准确且实时的无线信道估计。此外, 在波束赋型设计中, 考虑到未来车联网场景的高动态特性, 频繁的波束赋型设计更新会导致高开销高过载等问题, 难以智能地适应频繁变化的车联网场景, 可以通过引入机器学习/深度学习, 实现波束赋型设计的智能化。

4 未来挑战

面向差异化的智能服务, AI-FRAN 具有灵活的网络架构和泛在的边缘网络智能优势和潜力。然而, 当前对 AI-FRAN 的研究和应用仍处于初始阶段, 存在如下挑战。

4.1 轻量级的人工智能算法

未来网络结构和功能将变得更加复杂, 如何设计轻量级的人工智能算法进行智能信号处理、资源调配、网络管理等, 充满了挑战。以 AI-FRAN 的多维度资源调配为例, 在实际应用人工智能算法时, 首先, 由于行动空间的连续性, 需要进行大量计算以完成行动决策, 而终端设备不支持在理想的时间内完成计算^[7]; 其次, 训练模型往往包含数以万计的参数, 终端设备不具备庞大的存储空间; 最后, 网络环境动态变化, 而终端设备能量受限, 难以支持机器学习训练产生的能耗^[8]。因此, 需要提出轻量级的机器学习算法。

4.2 性能的可解释性

传统基于随机几何的网络性能分析方法具有很强的可解释性, 相比于 F-RAN, 面向智能服务的 AI-FRAN 借助 AI 技术将带来性能增益, 但大数据驱动的 AI 方法本身性能的可解释性还很缺乏, 这将导致 AI-FRAN 的系统层级的性能分析难度大且难以解释性能成因规律。因此, 需要从 AI 方法本身着手, 针对 AI-FRAN 的网络性能分析提出新的性能可解释分析方法。

4.3 网络安全

在 AI-FRAN 中, 为进行人工智能模型的训练, 需要收集用户和网络的数据。在机器学习训练和预测阶段, 恶意攻击者可能通过窃取训练数据来截获用户隐私信息^[9]。因此, 存储用户大数据的云中心和边缘节点需要可靠的隐私保护机制。另外, 恶意攻击者可能会伪装成合法智能终端向边缘节点和云中心反馈错误信息, 这会干扰信息采集过程, 而且影响智能服务的性能。非法侵入行为的动态变化将对网关的用户身份认证机制带来巨大挑战^[10]。

5 结束语

面向智能服务巨大容量、极低时延、超高可靠及海量连接数等差异化性能需求, 未来移动网络架构、网络功能将变得更加复杂, 传统 F-RAN 的组网架构和组网方案将面临巨大挑战, 需要不断地演进。本文在传统 F-RAN 的基础上, 提出了 AI-FRAN 的网络架构, 介绍了其基本原理和关键技术, 并探讨了 AI-FRAN 在轻量级的人工智能算法设计、性能的可解释性以及网络安全等方面面临的技术挑战。希望通过本文的探讨, 推动 AI-FRAN 的进一步探索和研究。

参考文献:


- [1] YANG Z, DING Z G, FAN P Z. Performance analysis of cloud radio access networks with uniformly distributed base stations[J]. IEEE Transactions on Vehicular Technology, 2016, 65(1): 472-477.
- [2] SUN C, LI H, LI X H, et al. Convergence of recommender systems and edge computing: a comprehensive survey[J]. IEEE Access, 2020, 8: 47118-47132.
- [3] PENG M G, YAN S, ZHANG K C, et al. Fog-computing-based radio access networks: issues and challenges[J]. IEEE Network, 2015, 30(4): 46-53.
- [4] SUN Y H, PENG M G, MAO S W. Deep reinforcement learning-based mode selection and resource management for green fog radio access networks[J]. IEEE Internet of Things Journal, 2019, 6(2): 1960-1971.
- [5] XIANG H Y, PENG M G, SUN Y H, et al. Mode selection and resource allocation in sliced fog radio access networks: a reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 4271-4284.
- [6] LETAIEF K B, CHEN W, SHI Y M, et al. The roadmap to 6G: AI empowered wireless networks[J]. IEEE Communications Magazine, 2019, 57(8): 84-90.
- [7] WEI Y F, YU R, SONG M, et al. Joint optimization of caching, computing, and radio resources for fog-enabled IoT using natural actor-critic deep reinforcement learning[J]. IEEE Internet of Things Journal, 2018, 6(2): 2061-2073.
- [8] LUONG N C, HOANG D T, GONG S M, et al. Applications of deep reinforcement learning in communications and networking: a survey[J]. IEEE Communications Surveys & Tutorials, 2019(99): 1.

- [9] YU Y, LI H L, CHEN R N, et al. Enabling secure intelligent network with cloud-assisted privacy-preserving machine learning[J]. IEEE Network, 2019, 33(3): 82-87.
- [10] LIU X, XU Y H, JIA L L, et al. Anti-jamming communications using spectrum waterfall: a deep reinforcement learning approach[J]. IEEE Communications Letters, 2018, 22(5): 998-1001.

[作者简介]



刘晨熙（1989-），男，博士，北京邮电大学网络与交换技术国家重点实验室副研究员、博士生导师，主要研究方向为雾无线接入网络、网络智能、超可靠低时延通信以及网络安全。



刘炳宏（1995-），女，北京邮电大学网络与交换技术国家重点实验室博士生，主要研究方向为无人机组网、无线资源分配、非正交多址接入、移动边缘计算。



张贤（1992-），男，北京邮电大学网络与交换技术国家重点实验室博士生，主要研究方向为雾无线接入网络、网络智能优化和无人机组网等。



龙新南（1997-），男，北京邮电大学网络与交换技术国家重点实验室硕士生，主要研究方向为雾无线接入网络、无人机组网。



彭木根（1978-），男，北京邮电大学网络与交换技术国家重点实验室教授、博士生导师，主要研究方向为智能化无线组网理论与关键技术。