



综述

OSI-RM 视角下的移动通信网络 AI 技术应用综述

章坚武¹, 张天恒¹, 章谦骅², 郭春生¹, 傅剑峰^{2,3}, 詹明⁴

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 浙江大学信息与电子工程学院, 浙江 杭州 311121;

3. 中国电信股份有限公司义乌分公司, 浙江 义乌 321000;

4. 台州学院, 浙江 台州 318000)

摘要: 人工智能 (artificial intelligence, AI) 凭借其强大的推理、学习及自我修正能力, 已成为解决复杂问题的重要技术, 并广泛应用于尖端科技领域。移动通信网络作为现代信息社会的核心基础设施, 其复杂性对网络构建、管理和优化提出了更高要求。开放系统互连参考模型 (open systems interconnection reference model, OSI-RM) 通过分层结构实现网络功能的模块化和标准化, 为移动通信网络的设计与实现提供了重要理论框架, 并指导多协议、多设备的互联互通。首先从 OSI-RM 的视角, 系统梳理了 AI 技术在移动通信网络各层中的应用现状, 分析了 AI 在解决移动通信网络复杂问题中的作用。同时, 指出部分 AI 技术具备跨层应用的潜力, 突破了单一层次的限制, 为 AI 技术在移动通信网络中的深入研究与应用提供了新的方向。

关键词: 人工智能; 开放系统互连参考模型; 移动通信

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025111

A review of artificial intelligence applications in mobile communication networks from the perspective of the OSI-RM

ZHANG Jianwu¹, ZHANG Tianheng¹, ZHANG Qianhua², GUO Chunsheng¹,
FU Jianfeng^{2,3}, ZHAN Ming⁴

1. College of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. College of Information Science & Electronic Engineering, Zhejiang University, Hangzhou 311121, China

3. Yiwu Branch of China Telecom, Co., Ltd. Yiwu 321000, China

4. Taizhou University, Taizhou 318000, China

Abstract: Artificial intelligence (AI), with its powerful capabilities in reasoning, learning, and self-correction, has become a key technology for addressing complex problems and is widely applied in cutting-edge scientific and technological fields. As the core infrastructure of modern information society, mobile communication networks face increas-

收稿日期: 2024-12-01; 修回日期: 2025-04-07

基金项目: 浙江省自然科学基金重点项目 (No.LZ23F010001)

Foundation Item: The Natural Science Foundation of Zhejiang Province (No.LZ23F010001)



ing challenges in their construction, management, and optimization due to their complexity. The open systems interconnection reference model (OSI-RM), with its layered structure, enables the modularization and standardization of network functions, providing a fundamental theoretical framework for the design and implementation of mobile communication networks and guiding the interoperability of multiple-protocols and multi-device systems. From the perspective of OSI-RM, the current applications of AI technologies across different layers of mobile communication networks were systematically reviewed, and the roles of AI in addressing complex issues in mobile communication networks were analyzed. Furthermore, it was highlighted that some AI technologies demonstrated potential for cross-layer applications, breaking the limitations of single-layer approaches, and offering new directions for advancing the research and application of AI in mobile communication networks.

Key words: artificial intelligence, OSI-RM, mobile communication

0 引言

人工智能 (artificial intelligence, AI) 技术通过模仿生物神经网络的运行模式 (如深度学习), 或利用其他机器学习方法 (如强化学习、进化算法等), 实现自我学习并不断优化算法参数, 从而逼近理想性能或使系统达到最佳状态。目前, AI 技术已广泛应用于人们生活的各个领域, 诸如聊天机器人、机器翻译、智能驾驶、智能家居等。下一代移动通信技术 (6G) 的愿景是超越传统移动通信, 以 AI、边缘计算和物联网 (Internet of things, IoT) 为核心技术基础, 实现智能应用与网络的深度融合。6G 将支持虚拟现实 (virtual reality, VR)、增强现实 (augmented reality, AR)、全息通信、智能网络等功能, 同时追求超高速率、超低时延、超高可靠性以及全球无缝覆盖。在人工智能理论及相关技术的驱动下, 6G 有望在通信性能、智能化水平和应用场景上取得新突破, 甚至构建全新的数字化世界^[1]。

移动通信网络经过长期发展已有完整体系, 用一个完全基于 AI 的算法取代现有的移动通信网络代价太大也不现实, 也不符合移动通信网络作为异构网络需要兼容各个制造商的产品^[2]的要求。AI 可以为现有应用程序、数据库和环境添加知识和推理, 使它们更友好、更智能, 对环境的变化

更敏感^[3]。因此, 目前大多数 AI 技术在移动通信网络中的应用都是对网络的某一个技术或者模块运用的改进, 或者通过 AI 技术对整体的网络进行参数或者系统优化。

对于移动通信网络中的 AI 而言, AI 技术主要分为核心网 AI、网管 AI 和无线空口 AI。其中, 以网络数据分析功能 (network data analytics function, NWDAF) 为代表的核心网 AI, 可用于对各类网络数据的采集、分析推理; 网管 AI 通常面向全网公共类的应用场景和问题, 例如, 智能化网络切片管理、无线覆盖优化、用户流量预测等; 无线空口 AI 有望在空口的某些处理算法上, 突破传统的模块化系统建模和知识模型近似方式所导致的性能瓶颈, 例如, 无线信道估计、导频检测、信号均衡以及多用户资源调度等, 或者以隐式的学习方式, 解决空口小区部署优化问题, 其典型应用包括小区流量模式识别、空口自动化配置和波束优化^[4]。

1977 年, 国际标准化组织 (International Organization for Standardization, ISO) 认识到对不同制造商的互连系统的普遍需求迅速增加, 启动了开放系统互连 (open systems interconnection, OSI) 标准的编制工作。选择 “open” 一词是为了强调如果一个系统符合这些国际标准, 它将向全世界遵守相同标准的所有其他系统开放^[2]。经过多次专家讨论、草案修订和评审, 开

放系统互连参考模型（open systems interconnection reference model, OSI-RM）于1984年正式发布。OSI-RM被定义为七层结构，自上而下分别为应用层、表示层、会话层、传输层、网络层、数据链路层、物理层。每一层都为其上一层提供对应的服务。尽管OSI-RM没有对每一层的具体实现或者层之间的交互做出具体的规范，但是该模型被广泛地作为设计或者学习网络的标准模型，并且对现代移动通信网络产生了重大的影响。

目前的网络架构普遍基于OSI-RM的分层体系构建，在每一层的模块中引入AI技术，不仅可以最大限度保证与现有网络的兼容性，还能确保技术演进的平滑过渡。然而，现有关于AI技术与移动通信的综述研究，多以特定领域或功能作为分类标准，如移动通信中的安全、低时延、低功耗等^[5]，或聚焦于其他通信领域（如光通信^[3]或软件定义网络^[6]）进行综述归纳。这类综述往往以功能为主线，而较少从网络分层的视角出发对AI技术在移动通信网络中各层的应用现状进行系统梳理。此外，依据OSI-RM的分层结构对AI技术进行分类，不仅有助于对同一层中的不同人工智能优化方案进行横向比较，还能帮助研究人员快速定位具体问题，并查阅相关研究成果。这种基于分层体系的综述方法能够弥补现有研究在层次性分析中的不足，同时为移动通信网络中AI技术的深入应用和优化提供理论指导与实践依据。

本文试着从OSI-RM视角，分析已有或者未来可能的下一代移动通信系统中的AI技术应用情况。具体而言，将从如下3个方面进行介绍。

（1）AI技术在OSI-RM各层中的应用，其中某些技术可能跨越了2~3个层或者可以被应用于多个层中。

（2）对每一层中现已使用的AI技术进行总结，分析使用这些技术的共同点和大致思路。

（3）对未来OSI-RM中每层AI技术应用的发展进行总结与展望。

1 AI技术概述

AI是一门研究如何使机器具备模拟人类智能的学科，其核心目标是通过算法和计算实现感知、学习、推理与决策等功能。目前，AI技术的实现主要有传统机器学习、深度学习（deep learning, DL）、强化学习（reinforcement learning, RL）以及深度强化学习（deep reinforcement learning, DRL）等方法。

1.1 传统机器学习

传统机器学习是人工智能的基础，主要通过构建数学模型从数据中提取规律，进行预测或分类。其核心原理包括监督学习（如线性回归、支持向量机）、无监督学习（如聚类分析）和半监督学习等方法。传统机器学习的特点在于对特征工程的高度依赖，需要人为设计数据特征以实现模型性能的优化。在移动通信网络中，传统机器学习往往被应用于优化一些复杂度较低的参数，以及一些易于提取数据特征的场景。

1.2 DL

DL是机器学习的一个分支，基于人工神经网络的多层结构，通过大量数据训练实现从原始数据到特征提取和分类的端到端学习。DL算法，如卷积神经网络（convolutional neural network, CNN）和循环神经网络（recurrent neural network, RNN）广泛应用于图像识别、自然语言处理、语音识别等领域。DL的优势在于能够自动学习复杂的高维特征，但对数据量和计算资源要求较高。DL在移动通信中被用于从复杂数据中提取特征来优化参数或者发现复杂参数之间的复杂关系。

1.3 RL

RL是一种通过与环境交互获得奖励信号来学习决策策略的技术，其目标是通过最大化累计



奖励实现任务优化。不同于监督学习依赖标注数据, RL注重动态场景中的连续决策问题, 应用场景包括机器人控制、自动驾驶和游戏AI等。在移动通信中, 有大量的动态场景需要进行连续的决策优化, 而RL往往被应用在这样的场景。

1.4 DRL

DRL结合了DL的感知能力和RL的决策能力, 将深度神经网络引入RL框架, 使其能够处理高维、复杂的状态空间。这一技术在复杂任务中展现出强大的性能, 例如, 在围棋对弈 (AlphaGo)、自动化交易以及复杂系统优化等领域取得了显著成果。在移动通信的场景中, 传统RL方法由于无法从复杂的输入数据中提取高维特征, 或者在制定策略时面临计算复杂度高、适应性差等挑战, 往往难以应对复杂的网络环境。而DRL凭借其强大的特征提取能力和自适应学习机制, 能够有效处理这些传统方法难以解决的复杂问题, 如网络资源分配、动态频谱管理以及智能路由优化等场景。

2 AI技术在OSI-RM各层中的应用

本文对技术的分层归类基于该技术所优化或控制的对象所在的OSI-RM层, 而非依据该技术的控制信令传输层或网络状态检测层。

2.1 AI技术在物理层中的应用

移动通信网络中的物理层以无线传输为核心。为了提升网络性能, 物理层涉及诸多优化内容, 包括频谱分配、信号覆盖、波束成形、天线控制等方面。AI技术在这些领域已展现出巨大潜力, 通过智能化手段提升无线资源的利用效率、增强网络可靠性和优化信号传输效果。

2.1.1 物理层编解码

信道编解码可以有效提高信息在物理层中的传输效率, AI算法为物理层的信道编解码提供了新的思路。

在文献[7]通过在Tanner图中为传递的消息

分配适当的权重, 与传统的置信传播 (belief propagation, BP) 解码器相比, 在更少的迭代次数下实现了相当的解码性能。这些权重是通过在DL中的训练获得的, 这在一定程度上改善了Tanner图中短循环的影响。考虑BP解码包含许多乘法运算, 文献[8]提出了一种轻量级的神经偏移最小和解码算法, 该算法不需要乘法运算且硬件实现简单。文献[9]发现结构化代码比随机代码更容易学习, 并解决了基于DL的解码器难以训练长编码的挑战。因此, 文献[10]提出将极化编码图划分为子块, 并分别对每个子码字的解码器进行训练。文献[11]研究了深度神经网络解码器使用不同的神经网络的性能, 结果表明RNN的性能最好, 并且每个神经网络都有一个饱和长度。文献[12]介绍了一种更为通用的信息传输模型, 在不了解统计信道模型的情况下该模型通过机器学习生成一种编解码方式来实现最大的传输速率和可靠性。同时, 开发了一种名为LFIT (learn for information transmission) 的算法来完成上述学习任务, 通过数值实验验证了该算法的有效性。

约束序列码是一种特殊类型的编码方法, 它限制或控制在数字信号传输或存储过程中产生的码元序列的特征。简单地说, 约束序列码被设计用来避免在数据传输或存储时出现一些不想要的模式或特征, 如长串的相同数字 (如太多的0或1), 这可能会导致同步问题或错误检测问题。文献[13]介绍了一种基于DL的约束序列解码方法。其利用多层感知机 (multilayer perceptron, MLP) 和CNN, 降低了解码的复杂度, 实现了接近最大后验 (maximum a posteriori, MAP) 概率解码的低误码率, 并提高了系统吞吐量。同时, 该算法也实现了在固定长度达到理论最大传输容量的约束序列编码的设计和实施。

在物理层编解码领域, AI技术的应用主要集中在DL优化传统编解码流程和设计新型自适应

编解码算法两方面。这些应用的共同点在于通过学习算法补充传统方法的不足,并通过神经网络提取传输数据中的空域特征和时域特征来提升解码效率、降低计算复杂度以及提高传输可靠性。

2.1.2 信道调制和编码联合优化

当信号在不同的电磁环境中传输时, AI 算法可以动态地根据信道的变化来选择合适的调制方式和编码方式,以获得尽可能大的传输容量。

文献[14]研究了动态信道及速率的选择和调度,并且提出了基于多臂老虎机 (multi-armed bandit, MAB) 的自适应学习方案。该方案即使在信道条件变化非平稳的情景中,也能够实现高效追踪最佳传输信道和速率。然而,文献[14]提出的算法为启发式算法。文献[15]将 IEEE802.11 系统中的速率适配 (rate adaptation, RA) 机制形式化为在线随机优化问题,并提出了一种可证明最优的 (模式, 速率) 组合适配算法族——G-ORS (graphical optimal rate sampling)。该算法通过动态调整编码和调制方案,以及大规模多输入多输出 (multiple-input multiple-output, MIMO) 传输模式,实现了动态选择最优的传输速率与模式,以最大化网络吞吐量。

自适应调制和编码 (adaptive modulation and coding, AMC) 技术旨在根据信道条件动态调整传输参数,以最大化吞吐量或在给定误码率 (bit error rate, BER) 约束下优化传输速率。然而,实现这一目标通常需要准确的信道状态信息 (channel state information, CSI),而获取精确的 CSI 往往依赖于大量的信道测量数据和复杂的计算过程,这在系统实际运行中可能带来显著的开销和延迟。在 CSI 已知的情况下,文献[16]提出了一种基于深度 Q 网络 (deep Q network, DQN) 的适应性调制方案,通过使用马尔可夫决策过程 (Markov decision process, MDP) 模型来提高无线通信通道的数据速率。该算法使 RL 代理选择速率区域边界作为状态,将信噪比 (signal-to-

noise ratio, SNR) 范围划分为不同的速率区域。然而,文献[16]中 CSI 的统计分布是已知的,而在实际场景中,CSI 往往并不能即时得到。文献[17]设计了一种新的 AMC 方案,利用 RL 算法在运行时动态调整调制编码方案 (modulation-coding scheme, MCS) 的选择规则。基于先前 AMC 决策的效果知识,即使在信道质量指示 (channel quality indicator, CQI) 反馈提供较差信道性能预测的情况下,该方案也能发现最佳 MCS,表现出强大的性能。文献[17]仍然需要当前的 CSI,文献[18]则针对 CSI 过时情况下的自适应调制问题,提出了一种基于 DRL 的自适应调制 (deep reinforcement learning based adaptive modulation, DRL-AM) 方法。与传统的 (非) 线性自回归滑动平均 (auto-regressive moving average, ARMA) 模型相比, DRL-AM 虽然更复杂,但通过实际信道测量数据的数值结果显示其性能更优,并且将复杂性从接收端转移到发送端,使其特别适合资源有限的 IoT 设备。为了彻底解决 AMC 对 CSI 的依赖,文献[19]提出了一种名为 DeepRM (deep reinforcement learning with stable matching) 的联合 MCS 适配与资源块 (resource block, RB) 分配的在线学习技术,用于 5G 动态网络环境下的服务质量 (quality of service, QoS) 保障。DeepRM 结合了 DRL 和稳定匹配,通过在没有实时 CQI 反馈的情况下进行 MCS 适配与 RB 分配决策,以最小化总 RB 消耗保证每个用户设备 (user equipment, UE) 的 QoS 要求。

在动态改变调制和编码优化领域, AI 技术主要采用 RL 和 DRL 框架,以克服传统方法在 CSI 获取、复杂性控制和实时性优化等方面的局限性。这些方法的共同点在于利用 DL 算法提取环境信息,这是因为 RL 算法能动态适应信道条件,以优化传输速率和资源分配,同时减少对准确 CSI 的依赖。

近年来,基于 AI 技术的编码器和调制方式重构研究取得了显著进展。研究表明,完全由神经



网络构建的编码器模块展现出巨大潜力。文献[20]提出了一种基于DL的无监督自动编码器算法,该算法能够在干扰信道中动态优化编码和调制策略,展现出优异的并行计算性能,但其局限性在于缺乏在线学习的能力,需针对特定场景进行训练。文献[21]将基于DL的自动编码器算法扩展到了MIMO场景,同时引入无线电变换网络(radio transformer network, RTN)融合专家知识。并与单CNN的性能对比,CNN的性能可以接近RTN的性能,证明了使用完全的DL架构的潜力。文献[22]将基于DL的自动编码器算法扩展到了MIMO的场景,并且讨论了如何轻松适应开环和闭环操作,以及仅使用紧凑的二进制CSI作为反馈,使得该算法不局限于某一特定的信道。文献[23]提出了一种新型的神经网络结构,通过构建一个卷积自编码器来同时执行调制、均衡和解调的功能。该结构更加专注于调制部分,并且能够与现有编码技术连接使用。该系统能够根据信道环境动态调整比特序列到星座符号的映射方案。该方案通过摒弃全连接层结构,有效解决了计算复杂度随输入序列长度增长的问题,也突破了传统方案对序列长度的限制。

基于AI完全重新设计的编码器为传统通信系统带来了全新的优化思路。自动编码器利用DL的无监督特性,在干扰信道中优化调制与编码性能。CNN和Transformer算法可以有效提取信源和信道中的特征,以实现更高效、鲁棒性更高的编码。

2.1.3 频谱资源分配和规划

传统的频谱选择和规划需要估计所有信道的信道信息,即使有了完备的信道信息,也需要进行复杂的计算才能准确找到最优解。在密集型无线网络中,文献[24]提出了一种新的空间DL方法来解决上述问题。该文认为网络中的干扰模式在很大程度上取决于发射机和接收机的相对位置,于是提出了一种基于受干扰的相邻发射机/接收机

位置的地理空间卷积的神经网络架构,并通过多个反馈阶段学习获得最优调度方案。

为了提升室内移动网络的覆盖质量和传输速率,中立主机系统被部署于室内场景。该系统通过向多个运营商开放基础设施共享,为室内用户提供统一的移动网络接入服务。文献[25]设计了一种中立主机系统,采用集中无线电接入网(centralized radio access network, C-RAN)和无线电接入网(radio access network, RAN)切片的设计原则,并结合动态定价机制,以调节频谱资源在不同租户之间的分配。将定价决策问题建模为一个MDP,并使用DRL来解决。

在5G车联网(vehicle-to-everything, V2X)的场景下,需要进行合理的频谱分配来保障大量的V2X连接。文献[26]研究了基于D2D(device-to-device)的安全关键型V2X通信的无线资源管理问题,通过将V2X需求转化为可使用缓慢变化的信道状态信息计算的约束条件,并考虑了车辆用户(vehicular user, V-UE)和蜂窝用户(cellular user, C-UE)之间的资源共享,提出了一种名为CROWN的启发式算法来解决这一NP难问题。文献[27]利用RL算法优化了高移动性车辆网络中多V2V(vehicle-to-vehicle)链路试图共享V2I(vehicle-to-infrastructure)链路占用的频谱共享问题。将多个V2V链路的频谱接入建模为一个多智能体问题,并利用多智能体RL来设计分布式频谱和功率分配算法,同时提高V2I和V2V链路的性能,并且为V2V链路的周期性安全消息共享提供了直接的可靠性保证。V2V发射机还可以从与通信环境的交互中学习,并找出基于局部信息的分布式协作策略,以优化系统性能。

随着移动网络对传输速度需求的不断提高,探索频谱共享模式,允许用户在许可、共享和非许可频谱中进行通信成了潜在的可利用频谱资源。

文献[28]提出了一种名为NOBEL的非参数贝叶斯信道聚类方案,用于在无线多媒体认知无线网络中优化多媒体传输和稀缺无线频谱的利用。NOBEL使用基于人工智能无线高斯混合模型的折叠吉布斯采样器来识别可用授权信道上的可实现QoS级别。

随着移动通信的传输速率不断增加,为了更好地利用稀缺的无线频谱资源,移动通信开始使用较高频段,这些频段会跟雷达的频段产生一些重合。文献[29]提出了一种创新的基于相干相位编码MIMO雷达平台的波束形成方法,首次实现了在主瓣和旁瓣方向上同时消除无线干扰,和相干MIMO雷达在频谱共享期间能够有效消除来自基站和移动设备的无线干扰。然而,文献[29]中提出的算法需要准确的CSI,计算复杂度较高。文献[30]综合考虑协同设计算法的复杂度和可行性,提出了一种低复杂度的基于RL的通信与雷达系统之间频谱共享方法。该方法通过制定部分可观察马尔可夫决策过程(partially observable Markov decision process, POMDP)辅助网络关联方案来规避这一问题,其中雷达用户作为主要用户(primary user, PU),而认知通信用户作为次要用户(secondary user, SU),最大限度地提高网络吞吐量,且最大限度地减少对雷达用户的干扰。

在没有基站的自组织和D2D网络中,设备需要在不明了通道状态信息的情况下学习信道信息并进行频谱分配。文献[31]提出了一种基于MAB的算法,实现了在自组织网络中为了避免频道选择冲突导致的数据传输失败问题而进行稳定的频谱分配。然而,它要求所有用户同时感知所有信道,这种方式计算复杂且昂贵,因此可能不适合低成本、低功耗的用户终端。文献[32]中提出一种通用的MAB算法,该算法不需要用户之间的沟通和期望奖励矩阵。文献[33]对文献[32]进行了改进,提出了一种分布式信道分

配算法,该算法基于载波侦听多路访问(carrier sensing multiple access, CSMA)实现了分布式拍卖算法,无须用户间交换信息,仅通过观测单一信道是否有传输来进行操作。而文献[34]在同时满足了用户独立选择信道和信道质量不确定这2个条件的前提下,提出了一种基于MAB的静态网络分布式算法,并将其推广到动态网络中,实现了对未授权和共享频谱的充分利用。针对未授权和共享频谱的场景,文献[35]在CRN中的多用户多信道场景下,提出了一种基于MAB的低复杂度算法(UCB-PAC),用以解决信道选择的探索与利用之间的平衡问题,并通过模拟实验展示了该算法在动态频谱接入技术中提升频谱利用率的有效性。此外,该研究还扩展了该算法处理组合多臂老虎机问题(UCB-PAC-GO),并设计了分布式实现方式(UCB-PAC-dGO),以适应CRN的特点。

2.1.4 天线分配、控制和波束成形

为了满足VR、电视和教育中对多视角视频(multi-view video, MVV)日益增长的带宽需求,文献[36]首次提出了利用视频合成方案(如基于深度图像的渲染和大规模MIMO技术),设计了一种名为基于效用的多视角合成(utility-based multi-view synthesis, UMVS)的近似算法,动态调整天线的分配,并结合DRL实现在动态场景下有效传输MVV的目的。

网络天线调谐方案指的是在无线通信网络中,为了优化信号质量和提高QoS,对天线参数进行调整的一系列方法和策略。这些方案通常涉及调整天线的方向、功率、频率等参数,良好的调谐方案往往可以确保无线信号能够有效地覆盖目标区域,减少干扰,并提高数据传输的效率和可靠性。文献[37]提出了一种DRL方法,用于在具有强用户移动性的动态环境中,自动联合调整3D MIMO系统中宏基站的3个关键天线参数(下倾角、垂直和水平半功率波束宽度),通过使用



网格化的用户位置信息和一种新颖的混合Q学习算法,显著提高了异构网络中的平均加权和速率。文献[38]则提出了一种基于安全强化学习框架的SPIBB (safe policy improvement through baseline bootstrapping)方法,解决了远程电倾角优化中的安全问题。然而,文献[37-38]中的集中式解决方案存在分布式部署困难、次优性差、计算复杂度高、动作空间呈指数级增长等缺点。对此,文献[39]提出了一种两步妥协算法,首先在离线阶段使用多智能体均值场强化学习(multi-agent mean field RL, MFRL)算法提取关键信息并将其作为特征表示传递,然后在在线阶段采用单智能体RL算法结合深度神经网络学习用户位置,以联合优化异构蜂窝网络中宏小区的天线倾角、垂直和水平半功率波束宽度,实现了在保持算法紧凑和可实施性的同时,接近多智能体强化学习(multi-agent RL, MARL)性能的效果,且在环境动态性较低的情况下,仅需数百次在线试验即可达到目标。文献[40]构建了一个多天线调谐模拟平台,应用基于MARL技术的多智能体深度确定性策略梯度(multi-agent deep deterministic policy gradient, MADDPG)算法,训练代理在场景中自动调整多个天线参数,最终学习到一组最优参数。将这些参数迁移到实际天线场景中,节省了天线调整的成本,并在模拟场景中取得了良好的效果。文献[39-40]使用了MARL的方案,并且以QoS为优化目标。尽管在大部分场景中QoS与用户体验(quality of experience, QoE)为正相关,但是高QoS并不能保证高QoE。在文献[39-40]中并没有考虑小区故障的情况,文献[41]提出了一种基于QoE的天线调谐方法,该方法通过使用多目标MARL结合随机森林分类器和DNN的QoE/QoS映射模型,能够在不同小区内协同解决特定故障,并显著提高整个无线网络的平均QoE,同时降低了QoE预测的时间开销,实现了

更快且更稳定的收敛速度。

波束成形是无线通信中的一种信号处理技术,它利用多个天线发射和/或接收信号,通过控制每个天线信号的相位和幅度,使信号在特定方向上增强,在其他方向上减弱。这样,波束成形技术能够在期望的方向上传输或接收信号,同时避免信号在其他方向的干扰和噪声,提高通信系统的整体性能。毫米波通信由于使用高频率载波并且有大量的频谱资源,有潜力将移动通信的速率提高几个数量级。由于其高频率的特性,需要使用波束成形技术使得信号对准正确的方向发射。文献[42]提出了一种基于压缩感知(compressive sensing, CS)理论的新型波束对准方法,它将信道探测次数减少到与天线阵列尺寸成对数比例,相比传统的穷举法大大减少了计算量。文献[42]在该对准方法的基础上,提出一种机器学习方法来解决阵列硬件损坏导致的非平凡CS字典不匹配问题。文献[43]提出了一种基于RL的MAB学习模型来跟踪位于美国新泽西州罗格斯大学的COSMOS室内平台中的毫米波波束,实验的吞吐量达到了完全实时对准情况下的92%。在无人机网络部署的毫米波网络中,无人机会因不稳定的环境因素而产生移动并且位置有不确定性。文献[44]提出了一种新的波束控制方案LeBeam,该算法利用回声状态网络学习捕捉无人机动态机动性的不确定性,结合网络运行时的通信距离和无人机机动性的一阶和二阶统计信息,动态确定最优波束宽度,实现了毫米波无线链路性能的最大化。在无人机军事监视和车辆跟踪中,由于无人机通常使用相机进行车辆检测和监控,文献[45]提出了一种利用无人机对车辆通信系统的视觉辅助进行波束成形的框架,该框架利用计算机视觉来处理相机感知的视觉图像,解决了波束跟踪问题。为了进一步提高波束的对准能力,文献[46]和文献[47]使用了视觉和多种雷达的传感方式,通过多个数据来源对波束进行更加精准的预

测。其中,文献[46]运用了一种基于三维卷积Transformer的多模态DL框架,可以有效地整合和利用不同模态的传感数据。该算法可以感知现实环境和通信模型,从而进行波束预测。文献[47]采用3D卷积(3D-Conv)模型对多镜头编码后的多模态特征进行提取,利用GPT(generative pre-trained transformer)框架增强了该波束成形模型的自适应能力和泛化能力。文献[48]提出了一种名为MAMBA的MBA框架,用于在定向毫米波蜂窝系统中跟踪波束。MAMBA利用UE发回基站的ACK/NACK包(作为混合自动重复请求程序的一部分)来评估当前下行波束的质量,并选择新的下行波束以及合适的MCS用于未来的传输。MAMBA的特点是只需单个设备和波束,以及传输时本身所需要的信息即可实现波束对准。

2.1.5 链路估计

在无线网络的环境中,链路质量会受到各种环境因素的干扰,准确地预测某一链路的链路质量可以为链路选择和编码方式等提供指导。

文献[49]提出了一种基于长短期记忆(long short-term memory, LSTM)网络的方法,用于预测毫米波系统中多方向的链路质量,并在模拟环境和真实室内环境中进行了验证,实现了对多小区链路跟踪和波束预测的功能。然而,该算法需要根据时间的推进不断预测下一个时刻的链路质量。文献[50]通过从路由器提取CSI,设计了一个高精度的毫米波定位系统,名为LEAP,实现了结合位置信息对毫米波无线局域网中接入点选择、波束训练的优化,显著减少了控制开销,并提高了网络性能和链路稳定性。该系统的缺点是必须对某个场景的全部位置进行遍历,但现实情况往往难以做到。文献[51]使用DL技术,提出了2种模型:一种是自编码器模型,用于从有限数据中生成新数据;另一种是深度卷积神经网络(DCNN)模型,用于预测毫米波通道的路径功

率损耗,实现了在数据有限的情况下准确预测毫米波MIMO通信系统的通道特性。然而,这项工作仅根据估计的参数从距离上预测链路质量,没有考虑给定位置的特定障碍物环境。文献[52]提出了一种基于环境知识的链路质量预测方案,用于解决毫米波通信中遮挡和用户位置微小变化导致的链路质量快速变化的问题。该论文使用几何分析来识别分隔LoS和NLoS场景的阴影区域,并分别基于分析模型和回归方法构建LoS和NLoS的链路质量预测器。对于更具挑战性的NLoS情形,使用了一个合成数据集生成器和精确的光线追踪分析来训练深度神经网络,学习环境特征和链路质量之间的映射。然后,该论文使用深度神经网络高效地构建给定环境内的链路质量预测图。

2.2 AI技术在数据链路层中的应用

移动网络中的数据链路层主要包括介质访问控制(media access control, MAC)层、无线链路控制(radio link control, RLC)层、分组数据汇聚协议(packet data convergence protocol, PDCP)层和服务数据适配协议(service data adaptation protocol, SDAP)层。这些子层共同协作,保障了移动网络中数据链路层的链路速度、链路状态和可靠性,避免了与物理层传输中的冲突,检测并可能纠正物理层中发生的错误。为了进一步提升网络性能,许多AI技术被应用于数据链路层。

2.2.1 MAC层

MAC层在移动通信网络中负责控制UE如何接入共享的无线信道。它位于数据链路层的第二层,主要功能是协调多个UE对无线频谱的使用,确保有效的数据传输。MAC层通过调度机制分配物理资源,如时隙、频率资源等,还负责流量的优先级处理、数据的分组与重组、错误检测与报告等功能。此外,MAC层在上层协议(如RLC层)与物理层之间起到桥梁作用,确保数据能够



按照调度策略进行高效传输,优化资源利用并减少无线干扰。

在MAC中的频率资源分配方面,文献[53]提出了一种基于深度多用户RL的新型分布式动态频谱接入算法,用于多个用户在多信道无线网络中通信,实现网络效用最大化的同时无须用户之间在线协调或信息交换。文献[54]利用DQN来解决动态多频道接入问题,实现在未知联合马尔可夫模型下最大化长期成功传输次数,接近最优性能。然而,该方案所建模的环境模型是一个固定的模型,不会因为算法对终端设备的调节而改变。在有PU和SU的场景下,文献[55]利用DRL和储备计算技术,帮助SU在分布式动态频谱接入(dynamic spectrum access, DSA)网络中学习适当的频谱接入策略,以有效避免与PU和其他SU的冲突。为了应对异构无线网络环境,文献[56]研究了一种名为DLMA(deep-reinforcement learning multiple access)的基于DRL的MAC协议。DLMA能够在不了解其他网络MAC协议操作原理的情况下,学习最优的信道接入策略,并实现诸如最大化总吞吐量或者 α -公平性等预设的全局目标。同时,还展示了DRL相对于传统RL框架在学习速度和鲁棒性上的优势。文献[57]在文献[56]的基础上进行了改进,考虑了信道不完美导致控制类包丢失的可能性。为了解决这一挑战,文献[57]提出了一种反馈恢复机制来找回丢失的反馈信息,以及一个两阶段动作选择机制来帮助实现协同决策,减少代理间的传输冲突。文献[58]使用没有预先网络模型知识的DRL技术,研究了一种适应性较高的基于载波侦听的深度强化学习多址接入(carrier-sense deep-reinforcement learning multiple access, CS-DLMA)协议。CS-DLMA的目标是在同样优先级的异构无线网络间,实现一组设备高效公平的频谱共享。值得一提的是,该论文提出了一种非均匀时间步长的DQN算法来适应CSMA协议中的时步非均匀性。

在MAC中的时隙资源分配方面,不规则重复时隙ALOHA(irregular repetition slotted ALOHA, IRSA)是一种改进的随机接入协议,用于提高通信网络中的数据传输效率。IRSA对于时隙ALOHA的改进之处在于引入了不规则重复机制。文献[59]提出了一个新的学习框架,用于优化IRSA MAC协议的传输策略。通过将MAC协议设计的在线优化构建为一个MAB问题,并利用该学习框架中的IRSA结构,快速学习最优传输策略。然而,MAB的决策不依赖于历史信息或者系统的先前状态。对于去中心化的场景,边缘设备可能需要考虑其电池和缓冲状态,对此,文献[60]提出了一种用于优化传感器网络中IRSA协议的传输策略,采用基于RL算法的去中心化部分POMDP。该方法允许每个传感器节点独立决定数据包复制的数量和发送时间,以提升网络吞吐量并减少数据包碰撞,特别在网络流量较大时效果显著。由于该方案的节点之间没有信息交互,因此可能会陷入局部最优。针对类似的去中心化传感器网络场景,文献[61]提出了一种MAC方案,通过将MAC资源分配问题映射到因子图上,然后转换为协调图,并使用最大和(max-sum)算法来寻找传感器的最优传输行为。该方法通过将协调表示为多背包问题来降低复杂性,并提供了系统收敛的理论保证。

2.2.2 RLC层、PDCP层、SDAP层

RLC层介于MAC层和PDCP层之间,负责无线链路上的数据传输控制。它的核心功能如下。

(1)分段与重组。RLC层会根据需要将较大的数据包分段为较小的数据块,以适应无线链路的传输能力。在接收端,RLC层会将分段的数据重新组合成原始数据包。

(2)差错控制。通过自动重传请求机制,RLC层可以检测到丢失或错误的较小数据块,并请求重新传输,以确保数据的可靠传输。

(3) 流量控制。RLC层对数据流进行流量控制,防止数据拥塞。

目前针对RLC层的研究几乎都使用传统方法对该层中的参数进行优化,比如分段和重组的缓存区大小。

PDCP层位于RLC层和网络层之间,负责对互联网协议(Internet protocol, IP)层(或其他上层协议)提供数据传输服务。它的主要功能如下。

(1) 头压缩。PDCP层通过压缩IP包头和传输控制协议/用户数据报协议(transmission control protocol/user datagram protocol, TCP/UDP)头,减少包头长度,从而提高无线资源利用率。

(2) 加密和完整性保护。PDCP层负责对用户数据进行加密,确保数据的保密性。此外,它还负责对控制信令进行完整性保护,以防止数据被篡改。

(3) 序列号管理。PDCP层给每个传输的数据包分配一个序列号,确保接收端能够正确地按顺序重组数据。

(4) 数据重排序和去重。在有重传的场景下(如切换过程中的数据重复传输),PDCP层负责对接收到的数据进行重排序,确保数据按正确顺序传递到上层。同时,它可以识别并删除重复的包。

(5) 分割与合并。在不同的承载上,PDCP可以根据数据包的大小进行分割,或者在接收端重新合并。

PDCP层的吞吐量数据反映的是更高层次的用户数据吞吐量,而RLC层的吞吐量则反映了无线链路上传输数据的具体效率,包括链路的物理传输质量和重传的影响。文献[62]提出了一种结合统计方法和机器学习的联合算法,通过分析长期演进(long term evolution, LTE)微蜂窝网络中用户吞吐量与无线电频率参数的关系,评估网络性能。该研究使用自组织映射(self-organizing maps, SOM)技术和TEMS测量工具,

采集了PDCP、RLC和PDSCH层的数据流量,找出了影响吞吐量的关键无线电频率参数。

SDAP层位于PDCP层之上,专门针对用户面的数据处理QoS需求。由于SDAP的优化对象是单个用户的流量QoS,因此5G网络中的会话管理功能(session management function, SMF)还不能很准确地识别用户流量的类型,尤其是加密流量。目前已有的单个用户的QoS管理大多仅限于用户的网络流量和运营商业务(比如基于IP的语音传输)之间的QoS。当前这方面的研究较少,已有的一些研究是关于QoS的细颗粒度优化框架^[63],当前几乎没有AI技术在该层,并且其主要的难点在网络层中的流量分类任务,该部分会在后面的网络层中提到。

2.3 AI技术在数据链路层和网络层中的跨层应用

数据链路层关注的是“点对点”的通信,而网络层关注的是“端到端”的通信。通过集中控制平面,软件定义网络(software defined network, SDN)使网络运营商能够动态调整网络拓扑和流量路径,适应用户移动性和需求变化。数据链路层确保数据在同一网络内的节点间正确传输,而网络层则确保数据能够跨越不同的网络,从源网络传输到目的网络。因此,有一些AI技术将这两层放在一起进行优化,以实现对网络流量更精确的优化。由于接入网部分在网络层的结构较为简单,该部分技术大多与核心网相关。

SDN将控制平面与数据平面解耦,为数据中心提供了更好的网络管理。在SDN中,flow(流)是核心概念,决定了网络设备如何处理数据包。flow表是一组规则,用于匹配特定数据流并指定相应的转发或处理操作。控制平面通过控制器动态管理这些flow表,灵活控制流量的路径和行为,从而实现网络的集中控制和智能化管理。当前的OpenFlow控制器安装的流规则有一个固定的超时,在此之后,交换机会自动从其flow表中



删除这些规则。然而,这种固定超时策略有许多缺点,对于包间隔较短的flow,超时时间可能过大,导致flow规则在flow表中停留时间过长,使flow表被不必要地占用;对于包间隔较长的flow或周期flow,超时时间可能过短,从而产生过多的入包事件,导致控制器过载。文献[64]在控制器中引入了一个缓存模块,根据每个流的数据包到达间隔计算每个流的空闲超时时间。缓存记录过期flow规则的历史记录,以使用flow过期时间戳与对应flow的下一个到达时间之间的间隙来调整超时。文献[65]提出了一种自适应超时机制,该机制将流量特征考虑为流量持续时间和类型,以及流量表当前占用情况。先前关于超时优化的大多数工作都使用启发式算法,这种算法依赖于特定的网络分布来找到局部最优解,灵活性较差。此外,频繁和活跃的流量统计请求被现有的工作用来获取当前流量模式的全网知识,这给交换机带来了额外的计算负荷和更多的消息交换。文献[66]提出了一种名为DRL-FTO的方法,用于优化SDN中flow规则超时设置,以减少SDN控制器与交换机之间的消息交换频率,并通过这种方式降低控制器负载。

网络流量工程(traffic engineering, TE)通过动态调整流量路径,避免网络拥塞,实现负载均衡,确保网络资源的高效利用。虽然TE系统使用的线性规划(linear programming, LP)求解器可以找到最佳解决方案,但它们难以随着网络规模的增长而扩展。LP算法的计算并行性较差,同时某些近似算法^[67]因其仍然通过迭代不断分配更多的flow以达到目标,所以并不能显著优化计算性能。由于神经网络的并行性较好,文献[68]介绍了一种名为Teal的基于学习的TE算法,应用于SDN系统中,它使用以flow为中心的图神经网络(graph neural network, GNN)、MARL和交替方向乘子法(alternating direction method of multipliers, ADMM)的优化算

法,利用图形处理器(graphics processing unit, GPU)并行处理能力,快速高效地处理大规模广域网的流量分配问题,显著提高了流量分配的效率和性能。为了增强流量优化的实时性,文献[69]设计了一个名为AuTO的双层DRL系统,用于自动进行数据中心的流量优化,通过端系统快速处理短流,而中央系统负责处理全局流量信息和长流的单独决策。

大多数移动网络优化的DL模型都需要大量的真实数据集,然而由于隐私保护问题,大部分网络运营商并不会公开数据。文献[70]提供了一个包含来自多个基站的大规模移动通信流量数据集,并对数据集中的用户流量进行了深入分析,研究了在短期尺度上广泛采用的概率分布算法在移动流量中的适用性。分析表明,移动数据流量具有自相似性,且与无线资源控制(radio resource control, RRC)连接的用户数量呈现双峰分布。

在LTE-Wi-Fi的异构网络中,需要平衡语音通话流量和数据流量,并且在异构网络的切换过程中保证语音流量的连贯性。文献[71]采用基于相对值迭代算法(relative value iteration algorithm, RVIA)为核心的Q-learning方法,提出了一种在线的最优无线接入技术(radio access technologie, RAT)选择算法,旨在最大化系统总吞吐量的同时满足语音用户阻塞概率的约束,且无须预知语音和数据用户的到达过程。为了进一步降低优化算法的复杂度,文献[72]提出了2种在线学习算法,在不了解系统动态统计信息的情况下,优化RAT选择来最大化系统总吞吐量,同时满足语音用户的阻塞概率约束。一个算法利用了后决策状态学习算法,另一个考虑了最优策略的阈值结构来提高算法的收敛速度和减少计算及存储复杂性。

在数据链路层和网络层的跨层应用中,主要使用了RL和DRL算法。跨层应用的核心目的是将网络层和链路层打通,对网络中的流量进行精

确的控制。而RL可以根据环境变化和其反馈来制定合适的网络流量控制策略。

2.4 AI技术在网络层中的应用

在移动通信网络中,网络层的主要职责是确保数据包能够高效地在复杂的无线环境中跨越不同网络节点进行传输。这不仅包括路径选择和流量控制,还涉及设备的移动性管理。在接入网,由于移动终端频繁地在不同小区之间切换,网络层的优化重点之一是确保在移动过程中实现无缝的切换和连接管理,以避免包的丢失或延迟。在核心网,网络层优化的重点将是路由的优化。AI技术可以在网络层的路径选择、流量管理和切换优化中发挥重要作用,通过实时分析网络状态、预测流量变化及终端移动模式,提升网络的整体性能和QoE。

2.4.1 网络层流量估计和分类

对网络流量进行估计和分类,可以将不同类型的流量以不同的优先级发送,从而保证QoE,并且最大化网络资源利用率。

准确的蜂窝流量预测在5G时代,通过SDN/NFV技术,使蜂窝塔能够动态适应流量负载变化,从而帮助运营商优化资源调度,保证业务质量和网络性能,并降低运营成本。对于预测问题,主流解决方案是将信号塔的数据流量视为时间序列,采用时域数据分析和建模,如自回归综合移动平均、MDP^[73]和Holt-Winters^[74]、随机过程模型、卡尔曼滤波等。文献[75]提出了一种结合时空相关性的机器学习模型,利用多种RNN结构和多任务学习方法,以提高蜂窝网络用户流量预测的准确性。然而实验结果中,多任务学习的方法并没有获得显著的性能提升。文献[76]提出了一种DL方法,利用密集连接的CNN和参数矩阵融合方案,模型化蜂窝网络流量的时空依赖性。文献[77]提出了一种新颖的空间-时间精细颗粒度用户流量预测机制,通过将蜂窝流量分解为站内和站间流量,并应用基于GNN的DL方法进行准

确的蜂窝流量预测。实验结果表明,该方法在预测精度上超越了基于时间序列的方法。文献[78]提出了一种基于图的时空卷积网络(graph-based temporal convolutional network, GTCN)模型, GTCN通过节点聚合和时间卷积层学习网络小区间的空间关联和流量趋势的时间动态,用于预测无线网络单元的移动数据流量。此外,该研究还收集并公开了真实的大规模移动数据流量数据集。虽然RNN在学习时域特征方面表现较好,但在探索空间依赖性方面却无能为力。不仅如此, CNN和GNN最初是为计算机视觉或图形任务而设计的,在序列数据预测方面可能表现不佳^[79]。而针对细颗粒度的单个用户流量预测,文献[79]提出了一个基于空间-时间的精细颗粒度用户流量预测机制(spatio-temporal fine-granular user traffic prediction, STEP)。他们构建了一个深度图卷积网络,这是图卷积网络(graph convolutional network, GCN)和门控循环单元(gated recurrent units, GRU)的新颖组合,用于从用户的大数据集中学习有效的空间-时间模型进行流量预测。为了进一步深度挖掘数据间的信息,文献[80]提出了一种新型多视角时空图网络(multi-view spatial-temporal graph network, MVSTGN),该网络结合了注意力机制和卷积手段,以全面挖掘蜂窝网络流量的时空特性。该模型从全局空间、全局时间和局部时空3个角度分析流量模式,可以捕捉到不同区域和不同时间点之间的全局时空关联及局部时空依赖,显著提高了蜂窝网络流量的预测准确性。针对实际的应用场景,文献[81]提出了一种基于边缘控制器的蜂窝网络架构。该架构可以部署在实际的基站中收集数据,并且运用机器学习算法根据这些数据预测每个基站的用户数量,以及利用这些预测结果来指导高层应用根据网络关键性能指标进行基站和RAN之间的优化。

在移动网络中应用流量分类技术能够精确区



分不同类型的流量,优化资源分配和QoS,从而提升网络效率和QoE。借助流量分类,网络可以根据应用需求进行智能调度,减少拥塞,保障关键业务的低时延和高带宽需求。目前加密协议的广泛使用,使得DL成为流量分类的重要方法。FS-Net (flow sequence network) 是一个端到端分类模型,它使用RNN从由加密流量数据包大小信息组成的序列中学习代表性特征^[82]。与文献[82]不同,文献[83]通过CNN从原始有效载荷中提取抽象空间特征,然后引入堆栈双向LSTM学习时间特征。文献[84]提出了基于流的关系网络(flow-based relation network, RBRN),使用解决加密流量分类问题的元学习方法,解决网络数据不平衡、模型泛化和过度依赖数据大小的问题。然而,上述这些基于DL的方法通常缺乏可解释性,不能进行增量学习。互联网中会不断出现新的应用程序,进而产生新的流量,并且要对具体类型的流量进行管理,因此增量学习和一定的可解释性是必要的。文献[85]提出了一种用于加密流量分类的增量、可解释的递归神经网络(IPRNN)模型,该模型能够从具有局部鲁棒性的会话中提取序列指纹,并提供了模块级包括时间序列特征归因和类间相似性描绘图的可解释性。文献[86]通过类增量学习和可解释人工智能等方法,提升DL模型在流量分类领域中性能和模型整体的可解释性。同时,使用Deep SHAP等技术,对DL模型进行全局解释,且对抓取到的网络层数据进行分类。

最近,大语言模型 (large language model, LLM) 技术已经显示出其在自然语言和计算机视觉领域有效处理多模态和异构数据的能力,这些功能使它们成为解决电信网络中分类问题的一个有前途的研究方向^[87]。为了应对流量分类中加密流量分类的难点,文献[88]提出了一种基于BERT (bidirectional encoder representations from transformers) 和CNN的新型加密流量分类方法

(BERT-based byte-level feature convolutional network, BFCN)。该方法通过结合BERT模型捕获的全局流量特征和CNN提取的字节级局部特征,解决了现有加密流量分类方法中对特征提取不足的问题。网络中的流量量大且种类丰富,难以找到完整的有标签的数据集,文献[89]提出了一种新的加密流量表示模型ET-BERT (encrypted traffic bidirectional encoder representations from transformer),旨在通过大规模无标签加密流量进行预训练,生成通用的流量表示,并在小规模特定任务标注数据上进行微调,以实现多种加密流量的高效分类。

2.4.2 路由控制和优化

路由信息控制了网络中流量的传输路径。对路由的优化可以让网络中的包以合适的路径到达目的地,增强网络的整体转发性能,避免网络拥堵,并且充分利用每个网络节点的性能。

由于实际的网络环境是高度动态和复杂的,因此很难准确地建模或预测。DRL可以以无模型的方式工作,因而被广泛应用于网络流量控制领域。文献[90]提出了一种基于DRL的经验驱动的网络流量工程控制框架DRL-TE,首次将新兴的DRL技术应用于通信网络中的模型无关控制。该框架通过学习网络环境和动态,以及在大深度神经网络的指导下做出决策来最大化常用的效用函数。为了适应水下环境中剧烈的动态变化,文献[91]提出了一种名为CARMA (channel-aware reinforcement learning-based multi-path adaptive) 的路由协议,使用分布式RL框架自适应地在单路径和多路径路由之间切换,以优化设备功耗和数据包交付率。在CRN的场景中,由于信道的变化较快,文献[92]介绍了一种用于CRN的基于集群和RL的路由方案SMART。其主要内容是利用集群机制来解决CRN中的多跳路由问题,通过集群合并和分裂来适应动态的频道可用性。此外,还引入了RL来进一步优化网络

性能。由于智能城市不同区域人群的动态分布,设计满足严格且不断变化网络需求的路由策略变得越来越复杂。文献[93]提出了一种基于DRL的智能路由算法,以有效管理智能城市中不同区域人群分布产生的多种服务请求。该算法能够显著提高网络基础设施的利用率,避免智能城市中人群活动变化时出现网络拥塞。文献[94]则通过在DRL中加入GNN结构,提出了一种名为消息传递深度强化学习(message passing deep reinforcement learning, MPDRL)的路由优化方案。MPDRL利用GNN的特性与网络拓扑环境交互,通过拓扑中链路间的信息传递过程提取知识,以达到网络流量的均衡和性能提升。以上这些DRL算法均使用单一智能体的方式,但是这样的算法面对超大规模的网络是力不从心的,路由本质上需要以分布式和并行的方式实现。文献[95]提出了一种名为RTHop(real-time hop-by-hop)的实时分布式学习方法,用于移动边缘网络中的逐跳路由。该方法利用多智能体深度强化学习和实时马尔可夫决策过程,使用自我注意力机制优化网络拥堵和资源利用,提高数据包传输率和有效吞吐量。

路由表的初始配置往往需要具备丰富经验的技术人员完成,尤其是搭建大型网络,手动配置路由条目是一件非常耗时的工作。在最近的研究中,正在尝试将LLM应用于网络路由配置,降低使用门槛和编写效率。文献[96]将LLM(如GPT-4)结合验证器生成正确的路由器配置,提出了一种名为“Verified Prompt Programming”(验证提示编程)的方法,通过验证器提供局部反馈,自动修正GPT-4生成路由配置中的错误,解决了单靠GPT-4生成的配置存在语法、语义和拓扑错误的问题。

2.4.3 小区分配和切换

移动设备在连接移动网络时会不停地移动,其地理位置的改变会不可避免地切换接入的小

区。与此同时,将不同的移动设备分配到合适的小区中,也能有效提高QoE和网络容量。

对用户的移动行为进行预测可以对无线电资源管理、主动RRC、改进的主动UE之间的负载平衡、用户应用程序的QoS预测以及边缘云的服务迁移机制提供有效的帮助。文献[97]使用支持向量机嵌入高效的预处理结构中,基于CSI和切换历史,构建了一个机器学习预测系统,用于准确预测用户将切换到的下一个小区。而在预测切换时间方面,文献[98]基于模拟的数据,使用LSTM和梯度提升回归结合分类模型,设计并评估了智能切换时间预测模型。而文献[99]使用真实移动网络的数据集训练ML来预测时域切换,该论文提出了一种两步机器学习方法,包括分类器和回归器,用以预测移动用户何时将进行网络切换。在真实蜂窝网络数据集上进行验证,该方法能够以超过90%的回调率检测即将发生的切换,并将切换时机的预测误差控制在1s以内。

随着对移动网络带宽需求的不断增大,移动性负载管理成了一个重要的优化方面,有效的负载均衡策略可以给UE提供更大的带宽。文献[100]提出了一种基于DRL的移动负载均衡算法,解决了超密集网络中的大规模负载均衡问题。研究提出了自组织集群和异步并行学习框架的双层架构,该架构能够动态适应全局和局部的流量变化,提高系统的通用性、适应性和扩展性,且在不规则网络拓扑和随机用户运动的场景中表现出较好的性能。针对含有飞蜂窝的异构LTE网络,文献[101]提出了一种基于统计学习方法的自优化小区范围扩展方案,通过动态调整小区覆盖范围以平衡流量负载、减少小区拥塞和降低数据包丢失率。为了更好地满足运营商多样化的需求,文献[102]提出了一个DRL框架,选取关键性能指标作为网络状态的代表,并设计了多样化的奖励函数,用以优化蜂窝网络中小区个体偏移量,从而实现移动



性负载管理。文献[103]加入了对公共导频信道(common pilot channel, CPICH)的调节,提出了一种基于监督学习的模型来预测蜂窝网络的容量极限,并利用这个模型来预测在特定用户访问尝试下各蜂窝扇区的断点。然后,该论文提出了一种称为块协调下降模拟退火(block coordinated descent simulated annealing, BCDSA)的算法,调节CPICH和CIO,使部分用户被分配到相邻小区,从而最大化小区容量。

对于中心化的切换优化,文献[104]使用RL技术,根据UE提供的包含波束参考信号接收功率测量值的无线电测量报告,中央RL智能体优化5G蜂窝网络中的切换机制,实现了更好的移动性和吞吐量性能。而文献[105]专注于5G移动性管理切换执行过程中TTT(time-to-trigger)和迟滞的动态调整,提出了一种基于在线学习的智能移动管理机制(learning-based intelligent mobility management, LIM2),LIM2利用卡尔曼滤波器预测当前和邻区的未来信号质量,采用基于SARSA(state-action-reward-state-action)的RL选择切换目标小区,并通过 ϵ -贪婪策略调整TTT和滞后值,实现无缝的高速用户切换,保证了与现有架构的良好兼容性。

2.5 AI技术在OSI-RM下三层的跨层应用

OSI-RM下三层中的物理层会对链路的容量和可靠性产生很大的影响,因此目前流行的网络切片技术和一些流量分配技术需要根据物理层的参数和状态对上层的网络资源进行同步调整,以避免资源的浪费并保证网络性能。同时,也可以根据切片的需要来分配物理层的无线资源和转发资源。

网络切片技术允许运营商将物理网络划分为多个虚拟网络,每个切片可根据不同应用场景(如自动驾驶、IoT、高清视频等)提供定制化的QoS和资源分配。通过网络切片,移动网络能够实现资源的按需分配和隔离,满足不同

业务对带宽、时延、可靠性等方面的特定需求,从而提升网络的灵活性、效率和服务质量,特别是在5G网络中支持多样化的应用场景。文献[106]使用微服务架构、TICK Stack和机器学习技术实现了5G网络切片的自动化配置与资源分配,具体包括通过自动时隙配置无线资源和使用Docker Swarm实现自愈和高可用性。其优势在于能够动态调整网络切片,提高网络吞吐量和管理效率。文献[107]则结合物理信道的条件进一步优化网络切片,使用LSTM网络预测无线网络的信道条件,从而辅助资源分配和实现网络切片。其优势在于显著减少了错误的资源分配,提高了分配效率和准确性。文献[108]研究了将DQN应用于片间资源分配的可行性和效率,并考虑了基于优先级的核心网切片和无线资源切片这2个不同的应用场景。而文献[109]将DL和RL分层使用,提出了一种5G RAN切片的智能资源调度策略。其中,DL用于执行大时间尺度的资源分配,而RL用于执行在线资源调度,以解决小时间尺度的网络动态,包括不准确的预测和意外的网络状态。当突发流量较大时,人工智能算法会产生大量的计算性能需求,可能导致切片分配的延迟,文献[110]研究了在5G系统中通过机器学习技术加速RAN核心网切片和无线资源协同分配过程。首先提出了一种基于优先级的机制来保障不同网络切片间的性能隔离,当高精度算法需要过多的计算资源时,切换为近似算法;然后比较了几种监督学习算法以优化这一过程,并将其嵌入国际电信联盟电信标准化部门标准化的机器学习架构中。

随着NFV和SDN在移动通信中被提出,传统网络功能作为软件应用程序在虚拟机(virtual machine, VM)中运行。这样的虚拟化部署能够加快网络部署速度,简化管理和运维流程,降低硬件成本,同时支持按需动态扩展网络功能,满足移动网络中用户流量和服务需求的变化。其

中,文献[111]中提出的垂直导向监测系统(5G-VoMS),通过中心化的方式对虚拟机进行监控。但是中心化的方式会造成通信资源的占用、计算和传输的延迟。文献[112]提出了一个基于联邦学习的三层分布式VM异常检测框架,用于虚拟网络切片中的异常检测,允许分布式网络切片管理器协作训练全局VM异常检测模型,同时保证本地度量数据的私密性。

2.6 AI技术在传输层中的应用

传输层提供端到端的数据传输服务,将上层应用数据划分为适合网络传输的分段(segments),通过网络从源主机传输到目标主机,从一个应用程序传输到另一个应用程序,并保证服务质量。传输协议可以是面向连接的(如TCP),也可以是无连接的(如UDP)。TCP是面向连接的传输层协议,其核心功能(包括连接建立/关闭、可靠性机制、流量控制等)均属于OSI传输层的范畴。TCP由于其复杂机制(如拥塞控制、重传策略),在特定网络环境中存在进一步优化的可能性。

2.6.1 拥塞控制

在移动网络中,传输层的拥塞控制(congestion control, CC)机制通过调节数据传输速率,防止网络过载,确保稳定的数据传输性能。它能够有效应对移动用户动态变化的网络条件,减少拥塞引发的延迟和数据丢失,提升网络的整体效率和QoE。文献[113]提出了一种生成式的算法Remy,该算法使用策略优化的RL算法,通过迭代方式搜索最佳的状态-动作映射表,针对特定的场景生成对应的固定CC算法。然而,当场景发生变化时,该算法的性能会出现明显下降。文献[114]提出了Pantheon,该框架可以收集现实数据并模拟出网络环境,同时作者还提出了一种名为Indigo的拥塞控制方案,该方案通过提取Pantheon收集的数据,并使用LSTM神经网络进行训练,以实现数据驱动的拥塞控制。具体来说,In-

diggo利用Pantheon提供的校准模拟器进行离线训练和测试,然后在真实网络中进行评估。但是该算法也难以应对复杂的场景变化。随着DRL应用的深入,文献[115]使用DRL算法,完全通过数据对CC的参数进行学习,但是该算法缺少公平性策略。为了充分利用传统CC算法的成果,文献[116]提出了一种名为Orca的混合型拥塞控制方案,它结合了传统的CC策略和先进的DRL技术。通过广泛实验,证明了Orca能够适应不同网络条件并保持一致的高性能,同时显著减轻其纯学习型方案的问题和困难。文献[117]采用了相同的传统算法与DRL混合的设计理念,但它不是设计一个新的CC方案,而是引入了一个DRL驱动的CC插件,该插件可以在高度可变的蜂窝场景中自动提高给定CC方案的性能,而无须更改底层CC方案。由于先前的DRL算法只能够在单一场景下取得良好的性能,文献[118]提出了一种名为MOCC(multi-objective congestion control)的多目标CC算法,利用多目标强化学习框架自动学习不同应用需求与相应控制策略之间的关系,并通过迁移学习快速适应新目标。MOCC同时支持多种性能目标,且能够快速适应新应用需求。文献[119]提出了一个名为Sage的纯数据驱动的CC设计。这是第一个纯数据驱动的CC设计,通过利用现有的解决方案学习更好的方案。在互联网和受控环境中对Sage的性能进行广泛评估,并与最先进的CC方案进行比较。为了同时优化初始窗口(initial window, IW),文献[120]提出了一种名为TCP-RL的方法,它使用RL技术动态地配置TCP流传输的IW和CC,以改善TCP的性能。而对于毫米波场景,文献[121]研究了毫米波通信环境下传统的CC机制表现不佳的问题,并提出了一种依据端到端测量数据来学习早期拥塞信号的新方法。该论文通过对60 GHz毫米波链路上的周期性探针数据包进行无监督学习,成功地学习到了每个数据包的显式拥塞通知,并取得了高达



97%的F1值。

2.6.2 多路径传输控制协议

多路径传输控制协议 (multipath TCP, MPTCP) 是一种扩展了标准 TCP 功能的协议, 允许数据通过多个路径进行传输, 可以在移动网络中提高性能和可靠性。文献[122]介绍了一种名为 SmartCC 的基于学习的 MPTCP CC 方法, 旨在解决异构网络中多通信路径带来的问题。SmartCC 运用一种异步 RL 框架来学习 CC 规则, 使得发送者能够观察网络环境并相应地调整子流的拥塞窗口, 以适应不同的网络状况。文章还提出了一种用于状态聚合的层级瓦片编码算法和一种用于 Q 学习的函数估计方法, 能够高效地导出最优策略。而文献[123]使用了中心化的策略, 控制一个主机上的全部 MPTCP。该论文提出了一种基于 DRL 的 CC 框架 DRL-CC, 专门用于解决 MPTCP 的拥塞控制。该框架采用了 LSTM 网络, 结合演员-评论家 (actor-critic) 架构, 以连续控制模式动态调整所有活跃的 MPTCP 流量, 目的是最大化总体效用。由于 MPTCP 还需要考虑数据包的调度机制, 文献[124]提出了一种基于 DQL 的框架, 用于 MPTCP 的拥塞控制和数据包调度。该框架中的智能代理使用 DQL 技术和策略梯度从经验中学习最优的拥塞控制和调度机制。此外, 该框架利用 RNN 并将其与 LSTM 结合, 以持续地学习子流的动态行为, 同时使用优先级经验及时响应它们的行为。对于移动网络的特殊场景, 文献[125]提出了一种名为 RL-PSD 的增强学习基础上的移动 AR/VR 多路径传输技术, 该技术通过分析 AR/VR 输入流的功率谱密度 (power spectral density, PSD) 来提取特征, 并将输入流和网络特征结合起来, 以增强学习方式建模 MPTCP 的拥塞控制过程, 最后使用一种双阶段增强算法优化传输性能。

2.7 AI 技术在会话层中的应用

在现代网络协议栈中, OSI 会话层的一部分

功能由套接字 (Socket) 实现, 它的作用是将收到的网络层包发给不同的进程, 基本方式是每个进程对应一个端口号。这种端口映射机制属于相对固定的传输关联, 在通用场景下没有太多可以优化的地方。会话层的另一部分功能是控制进程间会话的建立和释放, 这部分并没有严格按照 OSI 模型来实现, 而是由传输层 (如 TCP) 和应用层协议 (如超文本传输协议、文件传输协议等) 来分担和实现, 例如 TCP 中的三次握手和四次挥手, 以及 HTTP/1.1 中的持久连接等。

2.8 AI 技术在表示层和应用层中的应用

在现代网络中, 与用户直接交互的大多是软件客户端, 且这些客户端大多也只与特定的服务器进行数据传输, 因此, 表示层和应用层大多直接集成于应用中, 并且会因应用的不同而使用不同的技术, 公开的标准较少。

目前使用公开协议的应用程序主要是基于 Web 的应用。该类应用主要使用 HTTP 和传输层安全性 (transport layer security, TLS)。由于 TLS 也有一定的传输层特性, 因此本节内容仅讨论其加密功能, 也就是表示层的功能。

2.8.1 TLS

TLS 并不严格对应 OSI 或 TCP/IP 模型的单一层级。它运行在“某些可靠的传输协议 (如 TCP) 之上”, 因此位于传输层之上。在 OSI 参考模型中, TLS 的功能横跨会话层和表示层, 但其加密服务更接近表示层的核心职责。然而, 从应用程序开发的角度看, TLS 通常被抽象为传输层的一部分, 因为开发者通过应用程序接口 (application program interface, API) 直接在其上构建应用协议^[126]。

SSL/TLS 证书是 TLS 加密中的一个重要组成部分, 验证 SSL/TLS 证书的有效性是一个复杂的过程, 需要检查证书链中的每个证书、有效期、公钥、扩展等多个方面, 并且 X.509 证书的语义

和语法在多个 IETF 的 RFC 文档中半正式地描述, 这些文档繁多且复杂, 使得开发者难以准确理解和实现证书验证逻辑。现有的开源 SSL/TLS 证书实现虽然可以用于证书验证, 但不能保证其验证逻辑的正确性, 这可能导致安全问题。在之前的证书自动化测试中, 往往采用随机组合种子证书的部分来生成大量证书作为测试用例, 如文献[127]提出的 SSL/TLS 实现中大规模测试证书验证逻辑的几种方法, 或者通过比较多种证书验证代码对相同证书的验证结果进行差分测试, 发现可能存在的设计缺陷。文献[128]提出了 DRLGENCERT 框架, 这是首个应用 DRL 于 SSL/TLS 证书验证自动化测试的框架, 通过接受普通证书作为输入并高效生成能触发差异的新证书, 相比随机组合生成证书的传统方法, 显著提高了测试效率和有效性。

随着 TLS 加密算法的流行, 对恶意流量的检测难度也随之加大, 而由于 TLS 会产生用于握手的明文字段, 文献[129]在深入研究 TLS 协议的基础上, 发现恶意软件与良性应用在 TLS 密钥协商过程中存在诸多差异, 并设计了一套新的 TLS 握手特性。实验结果表明, 加入 TLS 握手特征后, 分类器识别率达到 99.6%。文献[130]提出了一种新的方法来检测恶意的 TLS 流量, 该方法使用通信通道特征作为检测输入, 并设计了一套新的通信通道建模特征, 包括分布特征、一致性特征和 TLS 通信通道的统计特征。实验结果显示, 与其他 2 种特征相比, 一致性特征的贡献最大, 将这 3 种特征结合在一起可以训练出一个更好的分类器, 精度可达到 92.57%。

2.8.2 HTTP

慢速 HTTP 拒绝服务 (denial of service, DoS) 攻击是指应用层漏洞导致 HTTP 服务性能下降或达到拒绝状态的攻击。慢速 HTTP DoS 攻击由于其攻击流量小但持续时间长, 可以避开一般的 DoS 攻击检测技术^[131]。传统的静态算法 (如

针对分布式慢速 HTTP DoS 攻击的防御方法^[132]) 检测计算成本较高。对于有监督的算法, 文献[133]提出了一种使用深度前馈神经网络的监督学习方法, 用于检测和分类慢速 DoS 攻击。该研究使用公开数据集 CICIDS2017 中的网络流数据进行训练, 在测试中实现了 99.61% 的分类准确率, 并且能够有效区分正常流量与多种慢速攻击工具生成的恶意流量, 包括 Slowloris、SlowHTTPTest、HULK 和 GoldenEye。实验结果表明, 该方法对慢速 HTTP DoS 攻击的检测具有高精度和泛化能力。而有监督的算法需要大量的数据集, 文献[131]提出了一种名为 capsAEUL 的方法, 该方法利用多个自编码器作为无监督学习技术, 用于检测慢速 HTTP DoS 攻击中的 Slowloris、Slowread 和 Slow POST, 并实现了高准确性和相当的 AUC (area under curve) 评分。

随着当前在线直播等低时延视频传输的需求增加, 自适应比特率技术被广泛地应用在应用程序中。传统自适应比特率技术主要分为 2 类, 主要是估计信道速率^[134]和使用缓冲的自适应比特率系统^[135]。文献[136]提出了一种名为 L2A-LL (learn2 adapt-low latency) 的基于在线凸优化 (online convex optimization, OCO) 算法, 用于 HTTP 自适应流媒体 (HTTP adaptive streaming, HAS) 中的比特率适应, 旨在实现低时延和高流媒体比特率, 并提供良好的 QoE。该算法不需要参数调整、信道模型假设、吞吐量估计或特定应用调整, 适用于通道特性快速变化的用户。

3 文献汇总

基于前文对 OSI-RM 各层级及其子分类的逐层剖析, 本节从分层研究和技术演进的双重视角, 对 2011—2024 年 AI 技术在移动通信网络中的创新应用进行系统性文献汇总, 系统性地叙述每层中 AI 技术的更新和发展过程, 同时以跨层的视角, 发现其中的共同点。



在物理层的应用中, DL 技术占据主导地位。编解码领域^[7-13]自 2016 年起主要采用 MLP^[7,9,11]、CNN 和 RNN 等基础网络架构, 2017 年出现分区神经网络^[10]等创新结构, 2019 年进一步发展到 CNN 与 MLP 的混合模型^[13]。信道调制与编码联合优化方向^[14-23]呈现算法融合趋势, 既有 2011 年起的传统强化学习 (如 MAB)^[14-15], 也有 2016 年引入的 MLP+Transformer 跨模态架构^[20], 2020 年后 DRL (如 DQN)^[16,18-19]成了主流。频谱资源分配^[24-25,27-28,30-31,33-35]方面, 2016—2024 年间 RL 与 DRL 并进, MAB^[31,33-35]、actor-critic^[25]、POMDP^[30]等策略与 CNN 混合架构^[24]并存。天线控制领域^[36-48]则展现出算法多样性, 2020 年后出现了许多先进的 DL 技术的应用, 包括 YOLOv5 目标检测^[45]、GPT 大语言模型^[46-47]等计算机视觉与 NLP 技术。链路估计领域^[49-52]则以各种 DL 为主, 包括 CNN、DNN、LSTM。

数据链路层的 MAC 子层研究^[53-61]集中在 DRL 领域, 2018—2022 年间 DQN^[53-58]成为标准解决方案, 同时存在 Q-learning^[61]等传统 RL 变体。而在 RLC/PDCP 层中的研究文章较少, 2021 年出现了自组织映射^[62]无监督学习在 RLC/PDCP 层的应用。在跨层研究中 (数据链路+网络层)^[66,68-72], 2017—2023 年间主要采用 DQN^[66,69]、GNN 与 RL 的混合架构^[68], 其中 GNN 与 RL 的结合^[68]标志着拓扑感知智能的发展。

网络层呈现两大研究方向: 流量分析领域从基础 CNN/RNN^[75-76,78,82,84-85]演进至 GNN^[77,79]、注意力机制^[80,89]与 LLM^[88]的融合架构, 其中, 在 2023 年出现了开创性的 CNN+LLM 模型^[88], 实现了协议特征与语义理解的结合; 路由优化方面, RL^[91-92]和 DRL^[90,93-95]占据主导, 2023 年出现了 LLM^[95]直接应用于路由决策的创新尝试。小区管理研究^[97-105]则保持算法多样性, 涵盖梯度提升回归^[98]、actor-critic^[100]、SARSA^[105]等多

种方法。

传输层的拥塞控制研究^[113-121]呈现明显的 DRL 演进轨迹, 2013 年从策略优化起步, 2018 年引入 LSTM 时序建模^[114], 2019 年后近端策略优化 (proximal policy optimization, PPO)^[115]和 actor-critic^[116-118]成为主流框架, 2023 年 PPO^[119]的持续应用验证了其稳定性。而 MPTCP 优化研究^[122-125]则始终围绕 RL 展开, 其中 LSTM 与 actor-critic 的混合架构^[123]展现出对复杂网络状态的适应能力。

高层协议栈中, 表示层的 TLS 识别主要采用传统机器学习^[129-130], 也有 DRL 的应用^[128]。应用层的 HTTP 优化研究则呈现多元化, 既包含 OCO^[136]等经典方法, 也尝试了 MLP^[133]和编解码器^[131]DL 模型。

跨多层的应用方面, 网络切片研究^[106-112]在下三层整合中展现出算法融合特征, LSTM 与 actor-critic 的混合架构^[109]、联邦学习与 GAN 的组合^[112]等创新方案不断涌现, 其中在 2020 年更出现机器学习、RL、DL 的全景式方法集成, 体现了复杂网络环境下的协同优化需求。

从算法的角度看, 可以发现类似的算法在不同层间也互相借鉴应用。随着 DRL 算法的改进和性能的提升, 其应用领域从动态资源分配向复杂决策场景横向扩展; 而 DL 则随着神经网络架构的发展, 其性能不断提高, 被广泛应用于各层中高维信息的提取。

其中, 部分 AI 算法被用在某些特定领域, 例如多模态感知技术 (如视觉+毫米波波束预测) 对物理层-应用层数据融合的推动^[45-46]; LLM (如用 LLM 生成网络配置) 对网络部署和配置^[96]的变革。

为了表现 AI 技术在移动通信网络中的整体应用趋势, 对文献中所使用的技术进行了统计, 并形成了相关表格。不同技术在不同年份中的占比如图 1 所示, 不同技术总数如图 2 所示。




图1 不同技术在不同年份中的占比




图2 不同技术总数

根据图1和图2的统计，机器学习的方法比较多样化；DL的主要使用的网络类型为CNN、MLP、RNN和RNN的一些变体（比如LSTM），以及对抗性DL；RL主要使用了Q-learning和其他的一些MAB场景下的算法；DRL最多的算法为DQN，也有一些文章使用了actor-critic和PPO。

其中，DL算法在2018年以前以简单的MLP为主，从2018年到2021年则以CNN、RNN及RNN的变体为主，在2021年以后Transformer和LLM在技术中的应用明显增加，这与DL的发展状况相关，而对抗性DL主要被用于安全领域。

4 结束语

本文从OSI-RM视角，对当前应用于移动通信网络的AI技术进行了分类和归纳，并且对每一层中使用AI技术的思路 and 共同点进行了梳理。大部分的AI技术在原有分层网络技术的基础上，对某一技术加入了AI模块，提高了原有技术对输入信息的特征信息提取能力和应对环境变化时的鲁棒性。由于一些网络应用需求（比如网络切片）

需要跨越多层对网络实现联合的优化，本文对这些跨层应用中的AI技术也进行了总结，体现出AI技术在网络跨层应用中的巨大潜力。

在AI算法层面，仍然有很多在其他应用场景下表现出优异性能的AI算法并没有或者较少地在移动通信网络中应用。比如，在DL中，Transformer是一种基于自注意力机制的DL模型，通过捕捉输入序列中任意位置之间的依赖关系来实现高效建模，避免了传统序列模型的逐步处理限制。其特点是并行化能力强，适用于长序列数据，广泛用于自然语言处理和序列建模任务。然而，目前该算法在移动通信网络中的应用仍然较少。在RL中，Q-learning和DQN被广泛应用到移动通信网络中，然而存在一些缺点，比如都依赖大量的数据，并且探索效率低，也不支持连续的动作空间。而PPO是当前主流的RL算法之一，通过限制策略更新的幅度（引入信任域约束）来平衡探索和稳定性，避免策略更新过快导致的不稳定。其特点是简单高效、易于实现，同时在各种复杂任务中表现出色，但是其在移动通信网络中的研究和应用目前还较少。

在应用层面，AI技术尽管在移动通信网络中展现出了其强大的性能和巨大的潜力，但是仍然面临很多问题和挑战。首先，AI算法的运行需要大量的数据作支撑，尤其是DL和RL算法。其次，AI算法往往需要强大的算力作为支撑，这可能会提高设备的成本。最后，也是最重要的一点，很多AI算法所需要的数据并不只来源于其所在的层，比如小区切换预测中就需要物理层的链路信息和用户位置信息，基于QoE的天线参数优化需要应用层返回的用户QoE信息。然而，获取其他层的信息对很多运行在OSI-RM某一层的技术或者设备来说并不是一件容易的事，数据交换需要制定完整的信息交互行业规范才能实现。就AI的跨层应用而言，或许它们能够实现多层充分协同的效果，然而这样的技术往往与现有的网络



架构不匹配,难以应用推广。应用难点也是本文基于 OSI-RM 的分层视角进行综述的原因之一,从 OSI-RM 的分层视角,可以看到不同层的 AI 技术需要哪些数据,以及哪些技术存在跨层优化的潜力,为 AI 技术在移动通信网络的实际应用提供参考。

AI 技术在移动通信网络中的应用,不仅是对传统网络模型 OSI-RM 的挑战,更是对其潜力的挖掘和扩展。随着 AI 技术和移动通信相关技术的不断发展,有理由相信, AI 将引领移动通信网络进入一个更加智能、高效、自适应的新时代。

参考文献:

- [1] 张平,牛凯,田辉,等. 6G 移动通信技术展望[J]. 通信学报, 2019, 40(1): 141-148.
ZHANG P, NIU K, TIAN H, et al. Technology prospect of 6G mobile communications[J]. Journal on Communications, 2019, 40(1): 141-148.
- [2] ZIMMERMANN H. OSI reference model - the ISO model of architecture for open systems interconnection[J]. IEEE Transactions on Communications, 1980, 28(4): 425-432.
- [3] MATA J, DE MIGUEL I, DURÁN R J, et al. Artificial intelligence (AI) methods in optical networks: a comprehensive survey[J]. Optical Switching and Networking, 2018, 28: 43-57.
- [4] 6GANA.6G 网络原生 AI 技术需求白皮书[R].2023.
6GANA.6G network native AI technical requirements white paper[R].2023.
- [5] YAZICI İ, SHAYEA I, DIN J. A survey of applications of artificial intelligence and machine learning in future mobile networks-enabled systems[J]. Engineering Science and Technology, an International Journal, 2023, 44: 101455.
- [6] OSPINA CIFUENTES B J, SUÁREZ Á, GARCÍA PINEDA V, et al. Analysis of the use of artificial intelligence in software-defined intelligent networks: a survey[J]. Technologies, 2024, 12(7): 99.
- [7] NACHMANI E, BE'ERY Y, BURSHTEIN D. Learning to decode linear codes using deep learning[C]//Proceedings of the 2016 54th Annual Allerton Conference on Communication, Control, and Computing (Allerton). Piscataway: IEEE Press, 2016: 341-346.
- [8] LUGOSCH L, GROSS W J. Neural offset min-sum decoding[C]//Proceedings of the 2017 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE Press, 2017: 1361-1365.
- [9] GRUBER T, CAMMERER S, HOYDIS J, et al. On deep learning-based channel decoding[C]//Proceedings of the 2017 51st Annual Conference on Information Sciences and Systems (CISS). Piscataway: IEEE Press, 2017: 1-6.
- [10] CAMMERER S, GRUBER T, HOYDIS J, et al. Scaling deep learning-based decoding of polar codes via partitioning[C]//Proceedings of the GLOBECOM 2017 - 2017 IEEE Global Communications Conference. Piscataway: IEEE Press, 2017: 1-6.
- [11] LYU W, ZHANG Z Y, JIAO C X, et al. Performance evaluation of channel decoding with deep neural networks[C]//Proceedings of the 2018 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2018: 1-6.
- [12] ZHANG W Y, WANG Y Z, SHEN C, et al. A regression approach to certain information transmission problems[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(11): 2517-2531.
- [13] CAO C Z, LI D S, FAIR I. Deep learning-based decoding of constrained sequence codes[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(11): 2532-2543.
- [14] RADUNOVIC B, PROUTIERE A, GUNAWARDENA D, et al. Dynamic channel, rate selection and scheduling for white spaces[C]//Proceedings of the Seventh Conference on Emerging Networking Experiments and Technologies. New York: ACM Press, 2011: 1-12.
- [15] COMBES R, OK J, PROUTIERE A, et al. Optimal rate sampling in 802.11 systems: theory, design, and implementation[J]. IEEE Transactions on Mobile Computing, 2019, 18(5): 1145-1158.
- [16] LEE D G, SUN Y G, KIM S H, et al. DQN-based adaptive modulation scheme over wireless communication channels[J]. IEEE Communications Letters, 2020, 24(6): 1289-1293.
- [17] BRUNO R, MASARACCHIA A, PASSARELLA A. Robust adaptive modulation and coding (AMC) selection in LTE systems using reinforcement learning[C]//Proceedings of the 2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall). Piscataway: IEEE Press, 2014: 1-6.
- [18] MASHHADI S, GHIASI N, FARAHMAND S, et al. Deep reinforcement learning based adaptive modulation with outdated CSI[J]. IEEE Communications Letters, 2021, 25(10): 3291-3295.
- [19] YE X W, FU L Q. Joint MCS adaptation and RB allocation in cellular networks based on deep reinforcement learning with stable matching[J]. IEEE Transactions on Mobile Computing,

- 2024, 23(1): 549-565.
- [20] O'SHEA T J, KARRA K, CLANCY T C. Learning to communicate: channel auto-encoders, domain specific regularizers, and attention[C]//Proceedings of the 2016 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). Piscataway: IEEE Press, 2016: 223-228.
- [21] O'SHEA T, HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3(4): 563-575.
- [22] O'SHEA T J, ERPEK T, CLANCY T C. Deep learning based MIMO communications[J]. ArXiv Preprints, 2017: arXiv: 1707.07980.
- [23] ZHU B H, WANG J T, HE L Z, et al. Joint transceiver optimization for wireless communication PHY using neural network[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1364-1373.
- [24] CUI W, SHEN K M, YU W. Spatial deep learning for wireless scheduling[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1248-1261.
- [25] FOUKAS X, MARINA M K, KONTOVASILIS K. Iris: deep reinforcement learning driven shared spectrum access architecture for indoor neutral-host small cells[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(8): 1820-1837.
- [26] SUN W L, YUAN D, STRÖM E G, et al. Cluster-based radio resource management for D2D-supported safety-critical V2X communications[J]. IEEE Transactions on Wireless Communications, 2016, 15(4): 2756-2769.
- [27] LIANG L, YE H, LI G Y. Spectrum sharing in vehicular networks based on multi-agent reinforcement learning[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2282-2292.
- [28] ALI A, AHMED M E, ALI F, et al. Non-parametric Bayesian channels clustering (NOBEL) scheme for wireless multimedia cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2293-2305.
- [29] GENG Z, DENG H, HIMED B. Adaptive radar beamforming for interference mitigation in radar-wireless spectrum sharing[J]. IEEE Signal Processing Letters, 2015, 22(4): 484-488.
- [30] WANG J J, GUAN S H, JIANG C X, et al. Network association in machine-learning aided cognitive radar and communication co-design[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2322-2336.
- [31] AVNER O, MANNOR S. Multi-user lax communications: a multi-armed bandit approach[C]//Proceedings of the IEEE INFOCOM 2016 - The 35th Annual IEEE International Conference on Computer Communications. Piscataway: IEEE Press, 2016: 1-9.
- [32] BISTRITZ I, LESHEM A. Game of thrones: fully distributed learning for multiplayer bandits[J]. Mathematics of Operations Research, 2021, 46(1): 159-178.
- [33] ZAFARUDDIN S M, BISTRITZ I, LESHEM A, et al. Distributed learning for channel allocation over a shared spectrum[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2337-2349.
- [34] DARAK S J, HANAWAL M K. Multi-player multi-armed bandits for stable allocation in heterogeneous ad-hoc networks[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2350-2363.
- [35] KANG S, JOO C. Low-complexity learning for dynamic spectrum access in multi-user multi-channel networks[J]. IEEE Transactions on Mobile Computing, 2020, 20(11): 3267-3281.
- [36] SHI Y S, KUO W H, HUANG C W, et al. Cross-layer video synthesizing and antenna allocation scheme for multi-view video provisioning under massive MIMO networks[J]. IEEE Transactions on Mobile Computing, 2024, 23(1): 327-340.
- [37] LIN Y J, GAO H, XU W J, et al. Dynamic antenna configuration for 3D massive MIMO system via deep reinforcement learning[C]//Proceedings of the 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2020: 1-6.
- [38] VANNELLA F, IAKOVIDIS G, AI HAKIM E, et al. Remote electrical tilt optimization via safe reinforcement learning[C]//Proceedings of the 2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2021: 1-7.
- [39] BALEVI E, ANDREWS J G. Online antenna tuning in heterogeneous cellular networks with deep reinforcement learning[J]. IEEE Transactions on Cognitive Communications and Networking, 2019, 5(4): 1113-1124.
- [40] ZHAO Y, ZHANG K Q, HAN R. Multi-antenna tuning simulation platform by deep reinforcement learning[C]//Proceedings of the 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP). Piscataway: IEEE Press, 2019: 1-6.
- [41] LIU X W, CHUAI G, WANG X, et al. QoE-driven antenna tuning in cellular networks with cooperative multi-agent reinforcement learning[J]. IEEE Transactions on Mobile Computing, 2022, 23(2): 1186-1199.
- [42] YAN H, DOMAE B W, CABRIC D. mmRAPID: machine learning assisted noncoherent compressive millimeter-wave



- beam alignment[C]//Proceedings of the 4th ACM Press Workshop on Millimeter-Wave Networks and Sensing Systems. New York: ACM Press, 2020: 1-6.
- [43] NASIM I, SKRIMPONIS P, IBRAHIM A S, et al. Reinforcement learning of millimeter wave beamforming tracking over COSMOS platform[C]//Proceedings of the 16th ACM Press Workshop on Wireless Network Testbeds, Experimental evaluation & Characterization. New York: ACM Press, 2022: 40-44.
- [44] MOORTHY S K, GUAN Z Y. Beam learning in mmWave/THz-band drone networks under in-flight mobility uncertainties[J]. IEEE Transactions on Mobile Computing, 2022, 21(6): 1945-1957.
- [45] ZOU J Q, CUI Y H, ZOU Z X, et al. Computer vision assisted mmWave beamforming for UAV-to-vehicle links[C]//Proceedings of the 1st ACM Press MobiCom Workshop on Integrated Sensing and Communications Systems. New York: ACM Press, 2022: 7-11.
- [46] NIE J L, ZHOU Q, MU J S, et al. Vision and radar multimodal aided beam prediction: facilitating metaverse development[C]//Proceedings of the 2nd Workshop on Integrated Sensing and Communications for Metaverse. New York: ACM Press, 2023: 13-18.
- [47] CUI Y H, NIE J L, YU T K, et al. Sensing-assisted communication beamforming based on multi-modal feature extraction for high-reliable IoV[C]//Proceedings of the 3rd ACM Press MobiCom Workshop on Integrated Sensing and Communications Systems. New York: ACM Press, 2023: 19-24.
- [48] KRUNZ M, AYKIN I, SARKAR S, et al. Online reinforcement learning for beam tracking and rate adaptation in millimeter-wave systems[J]. IEEE Transactions on Mobile Computing, 2024, 23(2): 1830-1845.
- [49] ALI SHAH S H, SHARMA M, RANGAN S. LSTM-based multi-link prediction for mmWave and Sub-THz wireless systems[C]//Proceedings of the ICC 2020 - 2020 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2020: 1-6.
- [50] PALACIOS J, CASARI P, ASSASA H, et al. LEAP: location estimation and predictive handover with consumer-grade mmWave devices[C]//Proceedings of the IEEE INFOCOM 2019 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2019: 2377-2385.
- [51] NEEMA M, GOPI E S. Data driven approach for mmWave channel characteristics prediction using deep neural network[J]. Wireless Personal Communications, 2021, 120(3): 2161-2177.
- [52] LIU Y C, BLOUGH D M. Environment-aware link quality prediction for millimeter-wave wireless LANs[C]//Proceedings of the 20th ACM Press International Symposium on Mobility Management and Wireless Access. New York: ACM Press, 2022: 1-10.
- [53] NAPARSTEK O, COHEN K. Deep multi-user reinforcement learning for distributed dynamic spectrum access[J]. IEEE Transactions on Wireless Communications, 2019, 18(1): 310-323.
- [54] WANG S X, LIU H P, GOMES P H, et al. Deep reinforcement learning for dynamic multichannel access in wireless networks[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(2): 257-265.
- [55] CHANG H H, SONG H, YI Y, et al. Distributive dynamic spectrum access through deep reinforcement learning: a reservoir computing-based approach[J]. IEEE Internet of Things Journal, 2019, 6(2): 1938-1948.
- [56] YU Y D, WANG T T, LIEW S C. Deep-reinforcement learning multiple access for heterogeneous wireless networks[C]//Proceedings of the 2018 IEEE International Conference on Communications (ICC). Piscataway: IEEE Press, 2018: 1-7.
- [57] YU Y D, LIEW S C, WANG T T. Multi-agent deep reinforcement learning multiple access for heterogeneous wireless networks with imperfect channels[J]. IEEE Transactions on Mobile Computing, 2022, 21(10): 3718-3730.
- [58] YU Y D, LIEW S C, WANG T T. Non-uniform time-step deep Q-network for carrier-sense multiple access in heterogeneous wireless networks[J]. IEEE Transactions on Mobile Computing, 2021, 20(9): 2848-2861.
- [59] TONI L, FROSSARD P. IRSA transmission optimization via online learning[J]. ArXiv Preprints, 2018: arXiv:1801.09060.
- [60] NISIOTI E, THOMOS N. Decentralized reinforcement learning based MAC optimization[C]//Proceedings of the 2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2018: 1-5.
- [61] NISIOTI E, THOMOS N. Robust coordinated reinforcement learning for MAC design in sensor networks[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2211-2224.
- [62] JOSEPH I. Joint statistical and machine learning approach for practical data-driven assessment of user throughput quality in microcellular radio networks[J]. Wireless Personal Communications, 2021, 119(2): 1661-1680.
- [63] LIU X, ZHANG Y W. Application-aware fine-grained QoS framework for 5G and beyond[C]//Proceedings of the 18th In-

- ternational Conference, BIC-TA 2023. Singapore: Springer, 2024: 342-356.
- [64] ZHU H K, FAN H B, LUO X, et al. Intelligent timeout master: dynamic timeout for SDN-based data centers[C]//Proceedings of the 2015 IFIP/IEEE International Symposium on Integrated Network Management (IM). Piscataway: IEEE Press, 2015: 734-737.
- [65] ZHANG L L, WANG S, XU S Z, et al. TimeoutX: an adaptive flow table management method in software defined networks[C]//Proceedings of the 2015 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2015: 1-6.
- [66] HAQ F, NAAZ A, BANTUPALLI T V P K, et al. DRL-FTO: dynamic flow rule timeout optimization in SDN using deep reinforcement learning[C]//Proceedings of the 16th Asian Internet Engineering Conference. New York: ACM Press, 2021: 41-48.
- [67] FLEISCHER L K. Approximating fractional multicommodity flow independent of the number of commodities[C]//Proceedings of the 40th Annual Symposium on Foundations of Computer Science. Piscataway: IEEE Press, 2002: 24-31.
- [68] XU Z Y, YAN F Y, SINGH R, et al. Teal: learning-accelerated optimization of WAN traffic engineering[C]//Proceedings of the ACM Press SIGCOMM 2023 Conference. New York: ACM Press, 2023: 378-393.
- [69] CHEN L, LINGYS J, CHEN K, et al. AuTO: scaling deep reinforcement learning for datacenter-scale automatic traffic optimization[C]//Proceedings of the 2018 Conference of the ACM Press Special Interest Group on Data Communication. New York: ACM Press, 2018: 191-205.
- [70] PÉREZ P F, FIANDRINO C, WIDMER J. Characterizing and modeling mobile networks user traffic at millisecond level[C]//Proceedings of the 17th ACM Press Workshop on Wireless Network Testbeds, Experimental evaluation & Characterization. New York: ACM Press, 2023: 64-71.
- [71] ROYA, CHAPORKAR P, KARANDIKARA. An on-line radio access technology selection algorithm in an LTE-WiFi network[C]//Proceedings of the 2017 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2017: 1-6.
- [72] ROY A, BORKAR V, CHAPORKAR P, et al. Low complexity online radio access technology selection algorithm in LTE-WiFi HetNet[J]. IEEE Transactions on Mobile Computing, 2020, 19(2): 376-389.
- [73] CHINCHALI S, HU P, CHU T S, et al. Cellular network traffic scheduling with deep reinforcement learning[J]. Thirty-Second AAAI Conference on Artificial Intelligence, 2018, 32(1): 766-774.
- [74] SCIANCALEPORE V, SAMDANIS K, COSTA-PEREZ X, et al. Mobile traffic forecasting for maximizing 5G network slicing resource utilization[C]//Proceedings of the IEEE INFOCOM 2017 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2017: 1-9.
- [75] QIU C, ZHANG Y Y, FENG Z Y, et al. Spatio-temporal wireless traffic prediction with recurrent neural network[J]. IEEE Wireless Communications Letters, 2018, 7(4): 554-557.
- [76] ZHANG C T, ZHANG H X, YUAN D F, et al. Citywide cellular traffic prediction based on densely connected convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(8): 1656-1659.
- [77] WANG X, ZHOU Z M, XIAO F, et al. Spatio-temporal analysis and prediction of cellular traffic in metropolis[J]. IEEE Transactions on Mobile Computing, 2019, 18(9): 2190-2202.
- [78] SUN F Y, WANG P H, ZHAO J Z, et al. Mobile data traffic prediction by exploiting time-evolving user mobility patterns[J]. IEEE Transactions on Mobile Computing, 2022, 21(12): 4456-4470.
- [79] YU L X, LI M, JIN W Q, et al. STEP: a spatio-temporal fine-granular user traffic prediction system for cellular networks[J]. IEEE Transactions on Mobile Computing, 2021, 20(12): 3453-3466.
- [80] YAO Y, GU B, SU Z, et al. MVSTGN: a multi-view spatial-temporal graph network for cellular traffic prediction[J]. IEEE Transactions on Mobile Computing, 2023, 22(5): 2837-2849.
- [81] POLESE M, JANA R, KOUNEV V, et al. Machine learning at the edge: a data-driven architecture with applications to 5G cellular networks[J]. IEEE Transactions on Mobile Computing, 2021, 20(12): 3367-3382.
- [82] LIU C, HE L T, XIONG G, et al. FS-Net: a flow sequence network for encrypted traffic classification[C]//Proceedings of the IEEE INFOCOM 2019 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2019: 1171-1179.
- [83] LIN K D, XU X L, GAO H H. TSCRNN: a novel classification scheme of encrypted traffic based on flow spatiotemporal features for efficient management of IIoT[J]. Computer Networks, 2021, 190: 107974.
- [84] ZHENG W B, GOU C, YAN L, et al. Learning to classify: a flow-based relation network for encrypted traffic classification[C]//Proceedings of The Web Conference 2020. New York: ACM Press, 2020: 13-22.



- [85] SONG Z X, ZHAO Z M, ZHANG F, et al. I^2 RNN: an incremental and interpretable recurrent neural network for encrypted traffic classification[J]. *IEEE Transactions on Dependable and Secure Computing* (Early Access), 2023 (99): 1-14.
- [86] NASCITAA, CERASUOLO F, ACETO G, et al. Explainable mobile traffic classification: the case of incremental learning[C]// *Proceedings of the 2023 on Explainable and Safety Bounded, Fidelitous, Machine Learning for Networking*. New York: ACM Press, 2023: 25-31.
- [87] ZHOU H, HU C M, YUAN Y, et al. Large language model (LLM) for telecommunications: a comprehensive survey on principles, key techniques, and opportunities[J]. *IEEE Communications Surveys & Tutorials* (Early Access), 2024 (99): 1.
- [88] SHI Z L, LUKTARHAN N, SONG Y Y, et al. BFCN: a novel classification method of encrypted traffic based on BERT and CNN[J]. *Electronics*, 2023, 12(3): 516.
- [89] LIN X J, XIONG G, GOU G P, et al. ET-BERT: a contextualized datagram representation with pre-training transformers for encrypted traffic classification[C]// *Proceedings of the ACM Press Web Conference 2022*. New York: ACM Press, 2022: 633-642.
- [90] XU Z Y, TANG J, MENG J S, et al. Experience-driven networking: a deep reinforcement learning based approach[C]// *Proceedings of the IEEE INFOCOM 2018 - IEEE Conference on Computer Communications*. Piscataway: IEEE Press, 2018: 1871-1879.
- [91] DI VALERIO V, LO PRESTI F, PETRIOLI C, et al. CARMA: channel-aware reinforcement learning-based multi-path adaptive routing for underwater wireless sensor networks[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(11): 2634-2647.
- [92] SALEEM Y, YAU K A, MOHAMAD H, et al. Clustering and reinforcement-learning-based routing for cognitive radio networks[J]. *IEEE Wireless Communications*, 2017, 24(4): 146-151.
- [93] ZHAO L, WANG J D, LIU J J, et al. Routing for crowd management in smart cities: a deep reinforcement learning perspective[J]. *IEEE Communications Magazine*, 2019, 57(4): 88-93.
- [94] HE Q, WANG Y, WANG X W, et al. Routing optimization with deep reinforcement learning in knowledge defined networking[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(2): 1444-1455.
- [95] HE B, WANG J Y, QI Q, et al. RTHop: real-time hop-by-hop mobile network routing by decentralized learning with semantic attention[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(3): 1731-1747.
- [96] MONDAL R, TANG A L, BECKETT R, et al. What do LLMs need to synthesize correct router configurations? [C]// *Proceedings of the 22nd ACM Press Workshop on Hot Topics in Networks*. New York: ACM Press, 2023: 189-195.
- [97] CHEN X, MÉRIAUX F, VALENTIN S. Predicting a user's next cell with supervised learning based on channel states[C]// *Proceedings of the 2013 IEEE 14th Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. Piscataway: IEEE Press, 2013: 36-40.
- [98] UNIYAL N, BRAVALHERI A, VASILAKOS X, et al. Intelligent mobile handover prediction for zero downtime edge application mobility[C]// *Proceedings of the 2021 IEEE Global Communications Conference (GLOBECOM)*. Piscataway: IEEE Press, 2021: 1-6.
- [99] VIELHAUS C L, BUSCH J V S, GEUER P, et al. Handover predictions as an enabler for anticipatory service adaptations in next-generation cellular networks[C]// *Proceedings of the 20th ACM Press International Symposium on Mobility Management and Wireless Access*. New York: ACM Press, 2022: 19-27.
- [100] XU Y, XU W J, WANG Z, et al. Load balancing for ultradense networks: a deep reinforcement learning-based approach[J]. *IEEE Internet of Things Journal*, 2019, 6(6): 9399-9412.
- [101] SIERRA FRANCO C A, DE MARCA J R B. Load balancing in self-organized heterogeneous LTE networks: a statistical learning approach[C]// *Proceedings of the 2015 7th IEEE Latin American Conference on Communications (LATINCOM)*. Piscataway: IEEE Press, 2015: 1-5.
- [102] ALSUHLI G, BANAWAN K, ATTIAH K, et al. Mobility load management in cellular networks: a deep reinforcement learning approach[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(3): 1581-1598.
- [103] ALBANNA A, YOUSEFI' ZADEH H. Learning-constrained enhancement of cellular networks capacity[J]. *IEEE Transactions on Mobile Computing*, 2019, 18(1): 153-164.
- [104] YAJNANARAYANA V, RYDÉN H, HÉVIZI L. 5G handover using reinforcement learning[C]// *Proceedings of the 2020 IEEE 3rd 5G World Forum (SGWF)*. Piscataway: IEEE Press, 2020: 349-354.
- [105] KARMAKAR R, KADDOUM G, CHATTOPADHYAY S. Mobility management in 5G and beyond: a novel smart handover with adaptive time-to-trigger and hysteresis margin[J]. *IEEE Transactions on Mobile Computing*, 2022, 22(10): 5995-6010.
- [106] SALHAB N, LANGAR R, RAHIM R, et al. Autonomous network slicing prototype using machine-learning-based forecast-

- ing for radio resources[J]. IEEE Communications Magazine, 2021, 59(6): 73-79.
- [107] TOSCANO M, GRUNWALD F, RICHART M, et al. Machine learning aided network slicing[C]//Proceedings of the 2019 21st International Conference on Transparent Optical Networks (ICTON). Piscataway: IEEE Press, 2019: 1-4.
- [108] LI R P, ZHAO Z F, SUN Q, et al. Deep reinforcement learning for resource management in network slicing[J]. IEEE Access, 2018, 6: 74429-74441.
- [109] YAN M, FENG G, ZHOU J H, et al. Intelligent resource scheduling for 5G radio access network slicing[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7691-7703.
- [110] YARKINA N, GAYDAMAKA A, MOLTCHANOV D, et al. Performance assessment of an ITU-T compliant machine learning enhancements for 5G RAN network slicing[J]. IEEE Transactions on Mobile Computing, 2024, 23(1): 719-736.
- [111] PAPAGIANNI C, MANGUES-BAFALLUY J, BERMUDEZ P, et al. 5Growth: AI-driven 5G for automation in vertical industries[C]//Proceedings of the 2020 European Conference on Networks and Communications (EuCNC). Piscataway: IEEE Press, 2020: 17-22.
- [112] WANG W L, LIANG C C, TANG L, et al. Federated multi-discriminator BiWGAN-GP based collaborative anomaly detection for virtualized network slicing[J]. IEEE Transactions on Mobile Computing, 2023, 22(11): 6445-6459.
- [113] WINSTEIN K, BALAKRISHNAN H. TCP ex machina: computer-generated congestion control[C]//Proceedings of the ACM Press SIGCOMM 2013 conference on SIGCOMM. New York: ACM Press, 2013: 123-134.
- [114] YAN F Y, MA J, HILL G D, et al. Pantheon: the training ground for Internet congestion-control research[C]//Proceedings of the 2018 USENIX Annual Technical Conference (USENIX ATC 18). Berkeley: USENIX Association, 2020: 731-743.
- [115] JAY N, ROTMAN N H, GODFREY B, et al. A deep reinforcement learning perspective on Internet congestion control[C]//Proceedings of the 36th International Conference on Machine Learning (ICML 2019). ICML, 2019: 5390-5399.
- [116] ABBASLOO S, YEN C Y, CHAO H J. Classic meets modern: a pragmatic learning-based congestion control for the Internet[C]//Proceedings of the Annual Conference of the ACM Press Special Interest Group on Data Communication on the Applications, Technologies, Architectures, and Protocols for Computer Communication. New York: ACM Press, 2020: 632-647.
- [117] ABBASLOO S, YEN C Y, CHAO H J. Wanna make your TCP scheme great for cellular networks? let machines do it for you![J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1): 265-279.
- [118] MA Y Q, TIAN H, LIAO X D, et al. Multi-objective congestion control[C]//Proceedings of the Seventeenth European Conference on Computer Systems. New York: ACM Press, 2022: 218-235.
- [119] YEN C Y, ABBASLOO S, CHAO H J. Computers can learn from the heuristic designs and master Internet congestion control[C]//Proceedings of the ACM Press SIGCOMM 2023 Conference. New York: ACM Press, 2023: 255-274.
- [120] NIE X H, ZHAO Y J, LI Z H, et al. Dynamic TCP initial windows and congestion control schemes through reinforcement learning[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1231-1247.
- [121] AHMAD T, IYER S R, DIEZ L, et al. Learning congestion state for mmWave channels[C]//Proceedings of the 3rd ACM Press Workshop on Millimeter-wave Networks and Sensing Systems. New York: ACM Press, 2019: 19-25.
- [122] LI W Z, ZHANG H, GAO S H, et al. SmartCC: a reinforcement learning approach for multipath TCP congestion control in heterogeneous networks[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(11): 2621-2633.
- [123] XU Z Y, TANG J, YIN C X, et al. Experience-driven congestion control: when multi-path TCP meets deep reinforcement learning[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1325-1336.
- [124] POKHREL S R, WALID A. Learning to harness bandwidth with multipath congestion control and scheduling[J]. IEEE Transactions on Mobile Computing, 2023, 22(2): 996-1009.
- [125] XU C Q, QIN J R, ZHANG P, et al. Reinforcement learning-based mobile AR/VR multipath transmission with streaming power spectrum density analysis[J]. IEEE Transactions on Mobile Computing, 2022, 21(12): 4529-4540.
- [126] HOOPER H. CCNP security VPN 642-648 official cert guide[M]. 2nd ed. Indianapolis, Ind.: Cisco Press, 2012.
- [127] BRUBAKER C, JANA S, RAY B, et al. Using frankencerts for automated adversarial testing of certificate validation in SSL/TLS implementations[C]//Proceedings of the 2014 IEEE Symposium on Security and Privacy. Piscataway: IEEE Press, 2014: 114-129.
- [128] CHEN C, DIAO W R, ZENG Y P, et al. DRLgencert: deep learning-based automated testing of certificate verification in SSL/TLS implementations[C]//Proceedings of the 2018 IEEE International Conference on Software Maintenance and Evolu-



- tion (ICSME). Piscataway: IEEE Press, 2018: 48-58.
- [129] ANDERSON B, PAUL S, MCGREW D. Deciphering malware's use of TLS (without decryption)[J]. Journal of Computer Virology and Hacking Techniques, 2018, 14(3): 195-211.
- [130] ZHENG R F, LIU J Y, LI K, et al. Detecting malicious TLS network traffic based on communication channel features[C]//Proceedings of the 2020 IEEE 8th International Conference on Information, Communication and Networks (ICICN). Piscataway: IEEE Press, 2020: 14-19.
- [131] SHAIK T A, KATAOKA K. capsAEUL: Slow HTTP DoS attack detection using autoencoders through unsupervised learning[C]//Proceedings of the Asian Internet Engineering Conference. New York: ACM Press, 2021: 49-55.
- [132] HIRAKAWA T, OGURA K, BISTA B B, et al. A defense method against distributed slow HTTP DoS attack[C]//Proceedings of the 2016 19th International Conference on Network-Based Information Systems (NBIS). Piscataway: IEEE Press, 2016: 152-158.
- [133] MURALEEDHARAN N, JANET B. A deep learning based HTTP slow DoS classification approach using flow data[J]. ICT Express, 2021, 7(2): 210-214.
- [134] BENTALEB A, TIMMERER C, BEGEN A C, et al. Bandwidth prediction in low-latency chunked streaming[C]//Proceedings of the 29th ACM Press Workshop on Network and Operating Systems Support for Digital Audio and Video. New York: ACM Press, 2019: 7-13.
- [135] HUANG T Y, JOHARI R, MCKEOWN N, et al. A buffer-based approach to rate adaptation: evidence from a large video streaming service[C]//Proceedings of the 2014 ACM Press conference on SIGCOMM. New York: ACM Press, 2014: 187-198.
- [136] KARAGKIOULES T, MEKURIA R, GRIFFIOEN D, et al. Online learning for low-latency adaptive streaming[C]//Proceedings of the 11th ACM Press Multimedia Systems Conference. New York: ACM Press, 2020: 315-320.

[作者简介]



章坚武 (1961-), 男, 博士, 杭州电子科技大学信息工程学院特聘教授、创新创业学院院长, 中国通信学会会士, 主要研究方向为移动通信与信息安全、移动通信与AI融合技术。

张天恒 (2000-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为移动通信与AI融合技术。

章谦骅 (1990-), 男, 浙江大学信息与电子工程学院博士生, 主要研究方向为天基计算、激光通信、计算卸载等。

郭春生 (1971-), 男, 博士, 杭州电子科技大学通信工程学院教授、博士生导师, 主要研究方向为图像处理、移动通信与AI融合技术。

傅剑峰 (1976-), 男, 浙江大学信息与电子工程学院硕士生, 中国电信股份有限公司义乌分公司副总经理、正高级工程师, 主要研究方向为智慧城市、智慧教育(校园)、智慧安防等。

詹明 (1975-), 男, 博士, 台州学院教授、博士生导师, 主要研究方向为信道编码理论与技术、工业无线传感器网络、高可靠低时延通信和安全通信技术。