中国科学:信息科学 2026 年 第 56 卷 第 11 期: 2843–2859
SCIENTIA SINICA Informationis
Agentic AI 赋能的 6G 融合通信专题 • 论文

意图驱动的智能体通感算控一体化融合网络: 架构、协议设计与实现

周伟杰[1,2], 张朝阳[1,2,3*], 秦天怡[1,2], 程旋[1,2], 陈子瑞[1,2], 孙令潇[1,2], Tony Q. S. QUEK[4]

1. 浙江大学信息与电子工程学院, 杭州 310027, 中国
2. 浙江省信息处理与通信网络重点实验室, 杭州 310027, 中国
3. 浙江大学基础交叉研究院, 杭州 310058, 中国
4. Information System Technology and Design Pillar, Singapore University of Technology and Design, Singapore 487372, Singapore
* 通信作者. E-mail: ning_ming@zju.edu.cn

收稿日期: 2026–03–30; 修回日期: 2026–08–07; 接受日期: 2026–09–15; 网络出版日期: 2026–11–10

具身智能体网络通感算融合基础理论与关键技术 (批准号: 62631025) 和国家自然科学基金 (批准号: 62394292) 资助项目

摘要 本文针对未来 6G 网络中海量异构终端接入、多样化动态化业务需求以及复杂网络环境带来的挑战, 提出了一种基于意图驱动的智能体通感算控一体化融合网络架构. 该架构以自主人工智能 (Agentic artificial intelligence, Agentic AI) 为核心, 旨在实现通信、感知、计算与控制的深度协同与自主化智能管理. 通过在网络各层级部署具备多模态理解、自主决策、持续学习与协同交互能力的智能体, 该架构能够将用户或应用层的高层意图自动解析并转化为底层的跨域网络控制策略, 从而动态、精准地分配无线、计算与感知资源. 本文进一步结合开放式无线接入网 (open radio access network, O-RAN) 标准, 设计了具体的 Agentic AI-RAN 实现方案, 并通过基于真实硬件平台的原型实验验证了所提架构的可行性与有效性. 实验结果表明, 通过智能体闭环控制, 能够将高层业务意图有效转化为底层资源调度参数, 并按需调整终端的资源分配, 为构建自主化、智能化的下一代 6G 网络提供了创新的架构思路与可行的技术路径.

关键词 自主人工智能, 6G, 意图驱动, 融合网络, 通感算控一体化, 无线接入网

1 引言

未来 6G 网络将迎来接入设备类型和数量的爆发式增长, 日益增多的个人和家用设备、各种城市传感器、无人驾驶车辆、智能机器人等都将成为新型智能终端, 这些新型终端不仅需高速数据传输, 还需要实现不同类型智能设备间的协作与学习. 海量异构终端的广泛接入, 叠加其在不同应用场景下所呈现出的多样化、动态化服务质量需求, 为无线网络的运作带来了前所未有的复杂性与严峻挑战 [1,2]. 6G 相比于 5G 进一步扩展了典型应用场景, 包括沉浸式通信、超大规模连接、极高可靠低时延通信、人工智能 (artificial intelligence, AI) 与通信融合、通感一体和泛在连接, 这意味着 6G 网络将不再仅仅是通信的载体, 而是同时具备通信、感知、计算和控制的信息

引用格式: 周伟杰, 张朝阳, 秦天怡, 等. 意图驱动的智能体通感算控一体化融合网络: 架构、协议设计与实现. 中国科学: 信息科学, 2026, 56: 2843–2859, doi: 10.1360/SSI-2026-0115
Zhou W J, Zhang Z Y, Qin T Y, et al. Intent-driven integrated communication, sensing, computing, and control network: architecture and protocol design and implementation. Sci Sin Inform, 2026, 56: 2843–2859, doi: 10.1360/SSI-2026-0115

© 2026《中国科学》杂志社

服务平台. 多样的智能终端和业务需求以及复杂的网络环境要求未来 6G 网络拥有自主化和智能化的网络资源优化和调度的能力, 同时需要具备更强的面对用户与环境的交互能力 [3].

无线接入网络 (radio access network, RAN) 的架构正在向解耦、软件化的方向演进, 将网络的控制从嵌入式节点独立到软件平台, 由软件驱动控制节点对网络架构进行控制, 这为将 AI 引入无线网络系统提供了契机 [4]. 然而, 尽管深度学习方法在资源分配、网络优化和信号处理等无线任务中已展现出潜力, 但通常是适用于特定场景和问题的小模型 [5~8]. 面对 6G 环境中动态变化、高度复杂的无线条件, 此类模型往往缺乏足够的迁移和泛化能力. 无线网络依然没有达到预期的自主性、智能化、可交互的水平. 因此, 我们需要考虑未来 AI 赋能的 6G 网络架构的设计. 该架构需具备持续理解、整合并满足多样化需求以及动态演进的能力, 对环境和异构终端具有极强的适应性. 更重要的是, 未来的 6G 网络将面对更加复杂多样的服务场景, 要求能够权衡并联合求解更多相互关联甚至冲突的目标, 诸如吞吐量、能耗、时延与可靠性. 这些目标的优先级和约束条件会随用户规模、需求偏好及环境状态实时变化, 远非针对固定场景的局部优化模型所能胜任.

近期在生成式 AI 领域的研究突破, 为构建基于意图的 6G 融合网络提供了极具前景的创新思路与强大工具. 诸如 ChatGPT 这样的大语言模型 (large language models, LLMs) 能够很好地理解用户的需求 [9~11], 实现图像生成、专业问题解答等任务. 相关的研究也已经探索了如何将 LLMs 引入到无线通信领域中, 例如解决符号检测、功率控制和切片等问题 [12~14], 说明了 LLMs 在无线领域中同样具备实现意图驱动的任务求解能力. 然而, 仅仅使用独立的大模型无法满足无线领域任务需求, 因为 LLMs 面临语言数据与无线数据不匹配、推理时延过长以及部署成本过高等问题. LLMs 主要针对语言相关任务进行训练, 这就导致了其在面对无线领域抽象的、大规模的收发数据时存在数据形式、推理模式等方面的局限性. 此外, LLMs 只能被动地回答问题, 而不具备主动解决问题以及系统交互与控制的能力. 自主人工智能 (Agentic AI) 为解决上述 LLMs 面临的问题提供了解决思路. Agentic AI 通过赋予 LLMs 工具调用、实时信息获取、多步推理与规划以及基于反馈的迭代优化等关键能力, 显著提升了智能体处理目标导向型任务的效能. 这些智能体能够理解指令、分解任务、利用工具执行操作, 并根据反馈动态调整, 展现出应对动态变化的初步适应能力. 此外, Agentic AI 可以通过构建多智能体协同系统 (collaborative multi-agent system, MAS), 在复杂工作流中进行通信、协调与动态任务分配, 以达成更高级别的目标 [15]. 同时, 为避免概念混淆, 我们定义 Agentic AI 指以意图理解、任务规划、工具调用、协同交互和反馈优化为核心的技术范式与能力体系, 智能体则指基于该范式部署在基站、终端等具体网络节点中的决策与执行实体.

研究者已从自主决策、资源调度、多智能体协作和意图驱动控制等角度探索 Agentic AI 在无线通信网络中的应用. 文献 [16] 提出了包含感知、记忆、规划和行动模块的智能体网络架构, 通过工具调用和反思式工作流支持复杂任务的自主执行; 文献 [17] 面向 RAN 切片场景设计了基于强化学习的意图感知调度方法, 通过意图奖励函数动态分配无线资源, 以满足差异化服务质量需求; 文献 [18] 提出 AgentNet, 通过智能体控制器及标准化交互机制支持异构智能体之间的信息交换、知识迁移和任务协同; ALLSTaR [19] 利用 LLM 从文献中提取、生成并测试调度算法, 构建调度器知识库, 并根据用户意图选择或生成相应的调度策略. 此外, 文献 [20] 提出面向低空无线网络的 Agentic AI-RAN, 将感知、通信、计算和控制组织为统一的 SC3 任务闭环; AgentRAN 则构建分层智能体体系, 将自然语言意图沿时间尺度、空间范围和协议层级逐步分解, 并由资源分配、功率控制、调度和波束赋形等功能智能体执行 [21].

现有工作主要面向特定网络功能、具体应用任务或智能体协作基础设施, 通常由预设的专用模型、优化算法或任务型智能体完成资源调度、功率控制、无人机导航等任务; 现有意图驱动方法也多将高层意图映射为特定策略、算法或控制行为. 与之不同, 本文面向更高层的复合意图, 将 Agentic AI 作为异构网络智能能力之上的任务级编排核心, 根据任务目标、网络状态和资源约束, 对通信、感知、计算和控制相关的模型、算法、网络功能及智能体进行统一选择与协同. 因此, 现有调度、功率控制、流量预测和异常检测等模型均可作为本文框架中的底层能力组件, 而本文重点解决这些能力如何在高层任务驱动下实现跨域组织与闭环管理.

针对上述问题, 本文提出一种意图驱动的智能体通感算控一体化融合网络架构, 利用 Agentic AI 实现高层意图理解、跨域任务编排与网络闭环控制. 本文将 Agentic AI 作为位于专用网络智能能力之上的任务级编排核心, 使其能够理解用户和业务系统提出的高层意图, 并将其转化为相互关联的通信、感知、计算和控制任务. 此

外, 本文设计了一个基于 Agentic AI 的跨域智能编排与闭环协同机制. Agentic AI 可根据任务需求、网络状态和资源约束, 对无线基础大模型、专用 AI 模型、传统优化算法、网络功能及任务型智能体进行选择与协同, 并结合执行反馈动态调整任务流程和资源配置. 最后, 本文结合 O-RAN 架构设计 Agentic AI 的部署与交互流程, 并搭建小规模真实网络原型, 初步验证了从自然语言意图理解到无线资源调控的闭环可行性, 为后续开展更大规模的通感算控跨域协同研究提供实现基础.

2　基于意图的 6G 融合网络架构设计

Agentic AI 的核心价值在于塑造高度自主的智能体, 使其具备理解并追求预设目标、持续感知与理解复杂动态环境、自主分析推理与做出最优决策、从经验中学习并适应变化以及高效协同合作的能力. 这种能力架构契合了 6G 智能化、自主化的资源管理的核心诉求. 用户或网络管理者仅需提供高层次的意图描述或简单配置 (如设定关键性能指标阈值、选择业务场景模板), Agentic AI 便能自动解析需求、填充必要细节、自主执行复杂的资源调度逻辑、并在运行中持续动态优化策略. 智能体在无线系统中扮演了决策者的角色, 基于已有的知识库和功能库, 下发指令以及调用工具执行特定的任务, 也可以与其他智能体交换信息. 因此, 探索和设计基于 Agentic AI 的下一代无线通信系统框架, 是应对 6G 复杂挑战的关键方向 [22, 23].

2.1　基于 Agentic AI 的融合网络的特点

相比于传统的无线网络架构, Agentic AI 将使得未来的 6G 网络具备自主化、智能化与个性化的特点, 具体可以总结为如下几个方面.

- 多模态理解与交互能力. 5G 网络受限于预设数据接口, 依赖于结构化的输入输出. 而智能体天然地或通过调用工具的方式就能够理解诸如语言、图片、声音、点云等多模态的数据, 由此也就提供了与用户和环境交互的接口. 用户的意图、环境以及网络负载等信息可以不再强制转化为特定的格式化数据, 而是可以用更加灵活的形式让智能体对这些数据进行理解, 借助智能体来提取服务需求信息, 监控环境变化情况等. 更重要的是, 不同于 5G 被动接收的模式, Agentic AI 将会根据系统实际的运行情况和用户的反馈, 主动地调用各类传感器、智能终端获取环境、负载等信息, 自主地对调度策略、资源分配、模型参数进行更新.
- 数字孪生. 通过在数字世界挖掘丰富的历史和实时数据, 智能网络中的 AI 模型能够获取充足的训练数据, 缓解实际系统中真值获取难度高的问题 [24, 25]. 数字孪生使得网络能够在孪生世界对物理实体或者过程实现模拟、验证、预测、控制, 再将推演的结果反馈给物理世界, 降低网络的试错与部署成本.
- 持续学习能力. 要让 6G 网络中各类 AI 模型能够在动态的无线环境中持续稳定地工作, 网络就必须具备持续学习的能力. 强化学习是让智能体通过与环境互动来学习最佳行为的重要方法, 而强化学习也将成为未来 6G 网络具备持续学习能力的关键. 大量的终端设备和交互行为将会带来海量的反馈信息, 然而我们通常难以将这些信息建模为严格的数学公式、损失函数或者标签用于监督学习的梯度下降更新, 而诸如人类反馈强化学习 (reinforcement learning from human feedback, RLHF) 等强化学习方法则可以通过值函数估计、蒙特卡洛方法或策略梯度等方式利用终端反馈进行学习, 对模型进行持续优化, 使得系统从动态数据分布中学习, 适应任务的动态扩展, 在实际运行的过程中不断优化决策策略.
- 个性化与可扩展性. 传统的 5G 网络在应对涌现出的新场景和新业务, 存在着开放度以及灵活度的限制. 5G 网络仍需要根据专家经验进行人工干预和静态配置, 无法根据业务需求实现灵活、智能的配置. 此外, 用户只能在有限的可对外开放的网络能力和业务场景选择对应的服务, 5G 网络并不支持用户根据自身业务需求设计调用定制化的网络. 而智能体间的通信对于数据结构化的要求降低, 通过在物理层、数据链路层、网络层等不同的无线网络层级间部署智能体, 降低指令结构化要求, 业务场景也无需再提前预设, 或只需设定少量的模板, 智能体根据模板和用户实际需求设定新的网络参数, 大大扩展了业务场景, 满足用户的个性化需求. 此外, 通过训练专门用于组网与部署的智能体, 当用户发起组网请求时, 结合用户的需求, 快速部署个性化的网络, 有效降低人工干预和专家依赖.

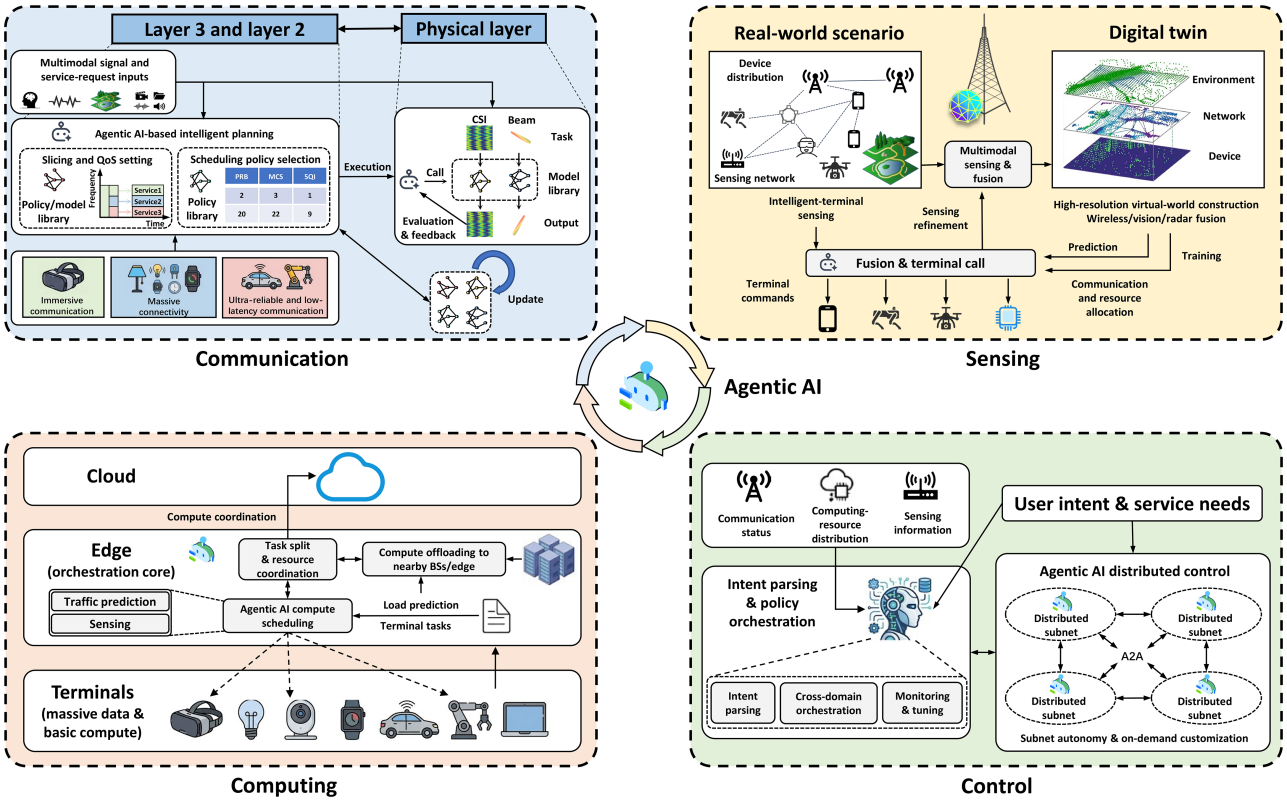

图 1　(网络版彩图) 基于 Agentic AI 的 6G 通感算控融合网络架构图.

Figure 1　(Color online) Schematic diagram of Agentic AI-based 6G integrated communication, sensing, computing, and control network architecture.

2.2　基于 Agentic AI 的通感算控一体化网络架构

为了应对 6G 网络高度异构与任务多样化的挑战, 结合前文所总结的网络特点, 我们提出了基于 Agentic AI 的融合网络架构, 如图 1 所示. 该架构通过在网络各层部署具备自主决策与跨域协作能力的智能体, 将 Agentic AI 作为核心控制体, 实现通信、感知、计算与控制的深度一体化融合. 具体而言, 在通信维度, Agentic AI 凭借强大的多模态理解与语义交互能力, 实现网络资源的动态分配与自适应调度; 在计算维度, 智能体作为全局算力编排大脑, 统筹云、边、端侧的泛在算力, 进行任务的智能拆解与主动式的负载均衡; 在感知维度, Agentic AI 深度融合海量节点的多模态数据, 结合各类 AI 小模型大幅提升环境感知精度, 并辅助数字孪生的构建; 在控制维度, 该架构确立了 “意图驱动” 的分布式自治机制, 将宏观非结构化需求转化为底层跨域协同策略. 通过这四个维度的闭环交互, 从而实现网络整体效能的全局最优协同.

在通信维度, Agentic AI 主要负责将业务意图转化为无线资源配置与协议参数, 并根据网络状态进行动态调度. Agentic AI 运用于 6G 系统后, 智能体的学习、预测和决策能力使通信系统能够根据流量和用户行为主动调整无线传输格式和通信动作. 以往的通信系统中信息和指令传递必须要求使用严格定义的格式, 有限的参数集意味着用户往往是在预定义的业务场景中选择服务. 而智能体强大的多模态交互能力和理解能力带来的是通信系统灵活度的提升. 在网络层与数据链路层, Agentic AI 承担着全局智能规划的核心角色. 面对沉浸式通信、超大规模连接以及极高可靠低时延等异构业务需求, 智能体能够结合内置的策略库与模型库, 动态进行智能切片规划与 QoS 设定等控制层任务, 并自主完成调度策略选择与关键物理参数的设定, 例如物理资源块 (physical resource block, PRB) 分配、调制与编码方案 (modulation and coding scheme, MCS) 等. 在诸如 MAC (medium access control) 层、RLC (radio link control) 层等主要的控制层, 除了协议规定的指令格式, 分布式智能体之间还

能够借助诸如现有的智能体间交互 (agent-to-agent, A2A) 开放协议[1)]进行协同, 以更加灵活的语义格式在层与层之间传递信息. 结合先验知识库和实时需求, Agentic AI 可以构建自定义的调度策略, 由此扩展了核心网和无线接入网中模块部署与决策的途径, 显著提高通信参与模块间的协调性. 在物理层中, 对于部署的 AI 接收机、信道状态信息 (channel state information, CSI) 预测以及波束管理等各类 AI 小模型, 根据控制层的指令, 直接调用模型库执行具体任务, 避免在物理层中进行复杂的推理过程, 降低系统时延. Agentic AI 基于执行结果的评估反馈, 结合环境变化、数字孪生和用户意图等交互信息持续推动模型、策略和算法的更新与微调, 不断提高底层 AI 小模型的实用性与系统整体的鲁棒性.

在计算维度, Agentic AI 主要负责云、边、端计算资源的监控、任务分割与协同调度. 未来 6G 网络的发展将从集中式向着集中和分布协同、分布式自治的方式进行转变, 大量的应用也在向着边缘侧聚集. 然而, 海量的数据将从终端产生, 而主要的算力则位于云边端. Agentic AI 将负责监控和感知系统中的负载、各类应用的算力需求以及算力资源等, 进行智能的编排和调度, 根据业务意图、网络状态和算力分布进行选择与调用诸如通感算一体化 (integrated sensing, communication, and computation, ISCC) 相关的任务级的优化算法, 在推理精度和时延约束下优化边缘设备能耗 [26]. 我们将以基站作为计算资源编排的起点. 基站中部署的智能体会监控基站、接入到这个基站的终端以及基站所连接的云端的算力资源, 基于算力资源的分布, 智能体会将任务进行分割, 规划云、边、端侧的任务. 任务通常是终端发起, 但是终端的算力往往有限. 未来 6G 网络内将集成大量预训练模型, Agentic AI 根据终端需求, 调用网络内的模型, 直接将处理结果反馈给算力受限的终端设备. 更重要的是, 基站智能体还需要进行主动负载平衡, 在负载激增之前, 需要通过感知环境趋势, 例如预测将出现人群聚集事件时, 提前向邻近基站或边缘数据中心调动算力, 避免临时调度引发的拥塞. 网络中的闲置终端算力也可以被 Agentic AI 调度, 为其他任务提供补充, 实现全网能效最大化.

在感知维度, Agentic AI 主要负责组织多模态感知数据的采集、融合与反馈, 并协调感知设备和相关模型. 未来将会有大量的智能终端接入到 6G 网络中, 这些智能终端通常也具备了环境感知、信号分析的能力. 随着超大规模多输入多输出 (multiple-input multiple-output, MIMO) 阵列、可重构智能表面 (reconfigurable intelligent surface, RIS) 等技术的发展, 6G 网络进行感知的手段和精度都有了显著提升. RIS 等智能反射技术可通过重构无线传播环境, 为面向万物互联场景的低能耗、可持续网络设计 (Internet of Everything, IoE) 提供重要支持 [27]. Agentic AI 可结合终端分布、信道状态与业务需求, 对 RIS 等底层网络能力进行统一调用和配置, 实现智能波束控制. 而基站除了根据无线信号感知环境以外, 还能够通过接收智能终端的多模态的感知内容并进行理解, 用于感知结果的补充、矫正, 感知的视角和范围也将会大大提升. 在诸如物联网的应用场景中, Agentic AI 能够很容易地通过中心基站向边缘设备或者终端发送指令, 调用对应的终端进行环境的感知, 感知的结果向上层层融合, 在中心端汇聚. 而随着感知数据的模式、数量大大增加, 以及当前诸如三维重建算法、无线感知算法的发展, 通过中心端的强大算力, 智能体能够基于各类成熟的算法、AI 模型, 利用无线、视觉、雷达等感知数据构建高分辨率的、完整的虚拟世界. 构建的虚拟世界也将能够用于环境预测, 为模型训练提供大量的样本, 反馈通信和辅助资源的分配和使用.

在控制维度, Agentic AI 主要负责全局意图解析、跨域策略编排以及分布式子网之间的协调. 随着 6G 网络规模增大、服务多样性增加, 6G 网络将不再仅仅提供通信服务, 还将作为 AI、数据等信息服务的平台, 并且分布式子网的大量出现, 也将显著提高控制的难度, 因此传统无线网络主要针对通信的控制方案以及基于集中式配置和固定参数映射的控制方案需要进一步完善. Agentic AI 对于构建基于用户意图驱动、跨域协同以及分布式自治的智能化控制机制提供了重要的思路. 首先, Agentic AI 改变了传统的指令下发模式. 在控制层, 智能体能够利用大语言模型或多模态理解能力, 直接解析用户或应用层的非结构化意图. 根据通信、计算、感知的实时数据, Agentic AI 能够自动将宏观意图翻译为底层的网络控制策略, 并根据网络状态的变化进行动态优化. 针对 6G 海量节点带来的控制信令开销和延迟问题, 控制架构将向 “分布式智能控制” 演进. Agentic AI 被部署至各个分布式子网或边缘节点中, 赋予局部网络高度的自治能力. 子网内的智能体可以基于本地环境独立做出快速

1) A2A 协议的项目代码位于: https://a2a-protocol.org/latest/.

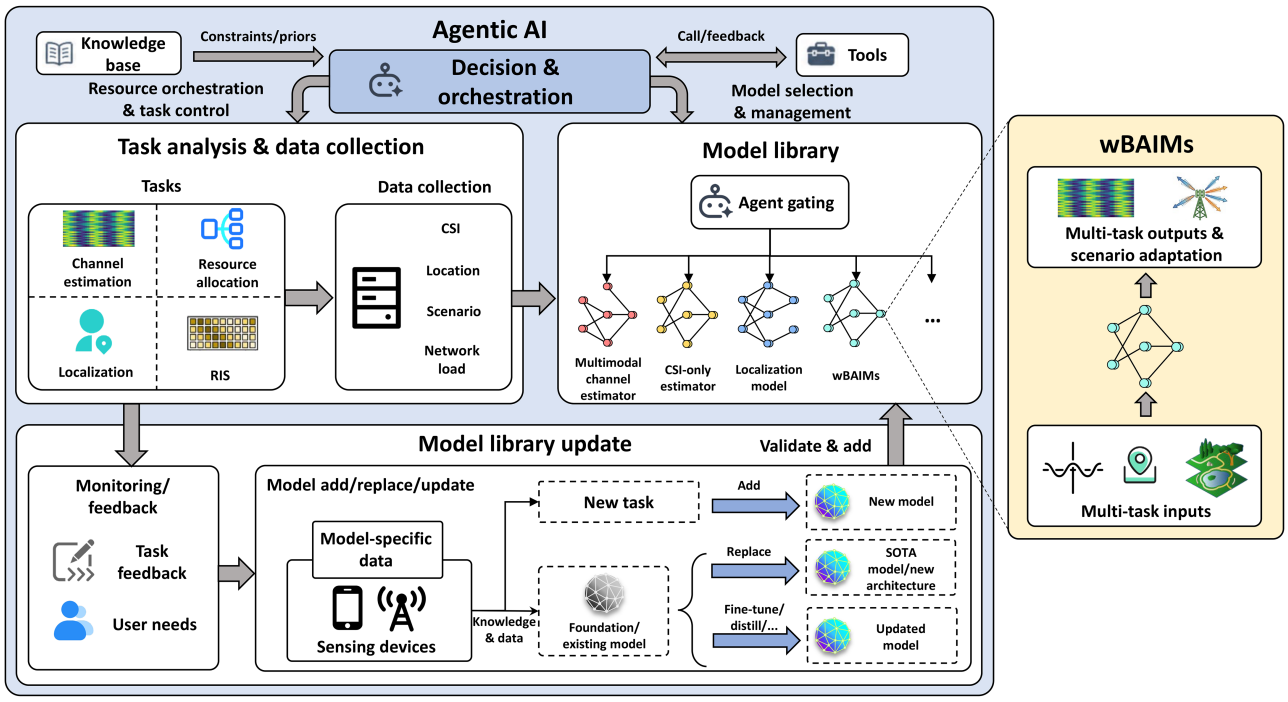

图 2　(网络版彩图) Agentic AI、wBAIMs 及知识库、模型库和工具库之间的功能关系与调用流程. 其中, Agentic AI 负责决策与编排, wBAIMs 是模型库中的一类可调用模型.

Figure 2　(Color online) Functional relationships and invocation process among Agentic AI, wBAIMs, and the knowledge, model, and tool repositories. Here, Agentic AI is responsible for decision-making and orchestration, while wBAIMs represent a class of invocable models in the model repository.

的控制决策. 同时, 子网之间通过 A2A 协议进行交互与协商, 解决跨子网的资源冲突和干扰问题. 以往的控制平面主要针对通信资源进行调度, 而 Agentic AI 具备强大的跨域多目标优化能力. 在统一的控制框架下, 同时控制和调度通信链路、云边端算力分配以及感知任务的启停. 例如, 在算力不足时主动降低通信编码复杂度, 或在感知任务繁重时定向为其分配额外的算力和频谱资源.

3　Agentic AI 与无线大模型

在文献 [28, 29] 中, 作者提出了无线大模型 (wireless big artificial intelligence models, wBAIMs), 旨在通过统一的基础模型架构适配多样化的通信任务. 然而, 无线领域数据的异构性, 涉及多维模态、复杂的物理语义及非结构化特征, 使得基础模型的构建与微调面临严峻挑战. 此外, 关于数据获取时机、基础模型的选择、样本规模以及任务与输入输出匹配等关键问题, 依然是应用 wBAIMs 前尚待解决的.

Agentic AI 相比于 wBAIMs 的主要优势在于交互、协作与反馈能力, 如图 2 所示, 这为解决 wBAIMs 在数据获取、模型选择和任务适配等方面的问题提供了新的途径. 我们将 Agentic AI 定位为任务构建与编排核心, 将 wBAIMs 及其他专用无线模型作为模型库中的可调用执行单元. Agentic AI 接收用户需求、网络状态、可用数据和任务反馈, 并从知识库中获取协议规则、场景知识与历史经验, 在此基础上完成任务分解和模型选择, 其输出包括面向模型库的模型调用与参数配置指令, 以及面向工具库的数据采集、预处理、模型训练更新和网络控制指令. 被选中的 wBAIMs 接收 CSI、用户位置、场景信息等任务数据, 输出信道估计、用户定位或资源分配等结果; 工具库则返回采集数据、工具执行状态和网络反馈. Agentic AI 对上述输出进行综合评估, 并根据反馈触发模型重新调用、替换或参数更新, 从而形成完整的闭环. 借鉴 OpenClaw[2)] 等智能体的成功实践, 该机制能够减少复杂无线任务链条中的人工干预. 因此, 在 Agentic AI 的控制下, 可以不再依赖单一的通用大模型, 而是针

2) OpenClaw 的源代码位于:https://github.com/openclaw/openclaw.

对不同场景构建可持续扩展的模型库. 模型库中各模型的输入数量和数据模态可根据具体任务进行设计, 并由 Agentic AI 完成应用需求、可用数据与模型能力之间的匹配. 例如, 我们可以构建一个能够同时融合 CSI、用户位置、场景信息等多模态数据的模型, 也可以仅仅针对 CSI 数据设计模型, 即使前者因为融合了更多的信息而能够获得更加准确的信道估计或预测结果, 但是在数据获取受限或者信道状态足够良好的情况下, 我们可以选择使用后者得到输出结果. 智能体将根据实际可使用的输入、应用需求对模型库中的模型进行调用. 类似于构建了一个混合专家模型 (mixture of experts, MoE) [30], 而不同于 MoE 的是, 智能体将作为其中的门控网络, 负责根据输入智能地选择最合适的专家进行处理, 并将选定专家的输出作为最终输出. 这种模式也将具备更加显著的灵活性, 因为随着应用的增加, 我们可以不断向模型库中增加模型, 而不需要再通过修改基础模型使其适应不断增加的输入数量和任务输出. 而随着 AI 技术的发展, 势必会有越来越高效的网络架构被提出, 例如从简单的全连接网络、卷积网络, 到更加复杂的 diffusion [31]、flow matching [32] 架构, 特定任务的新的 SOTA 模型也会不断出现, 我们只需要不断地更新模型库中的模型. 此外, 我们还需要让智能体学会新的模型参数更新的方式, Agentic AI 将持续监控任务反馈, 根据反馈结果, 结合场景信息、用户需求, 对模型实现持续更新, 这也是其区别于 MoE 的一个重要特点. 不同小区之间还能够互相协作, 对彼此的模型库、知识库进行补充. 在数据获取方面, Agentic AI 能够控制 6G 融合网络的大量终端和基站等感知设备获取特定任务下的数据, 根据模型设定的训练方式进行训练或参数更新.

4　基于 O-RAN 的 Agentic AI-RAN 架构设计

本节将基于开放式无线接入网 (open RAN, O-RAN) 标准分析 Agentic AI-RAN 的架构设计. O-RAN 将传统 gNodeB 按功能剖分为 O-RAN 射频单元 (O-RAN radio unit, O-RU)、分布单元 (O-RAN distributed unit, O-DU) 与集中单元 (O-RAN centralized unit, O-CU), 推动无线接入网实现功能开放化、部署虚拟化与原生智能化 [33, 34]. 相比传统 RAN 的一体化集中式基带架构, 解耦拆分后的网元、开放标准化的接口与软件化重构的功能, 为端到端实时数据采集、智能策略下发与闭环自动化优化提供了基础支撑, 也为 AI 原生的自主决策创造了必要的接入入口与执行环境. O-RAN 标准定义了服务管理与编排 (service management and orchestration, SMO) 架构, 通过 O1、O2 等接口沟通 CU、DU 等网元, 负责网络功能运维管理等功能, 同时还提供了意图驱动管理的管理模式, 用以实现不指定具体实现方式、仅描述期望目标. 此外, O-RAN 还定义了 RAN 智能控制器 (RAN intelligent controller, RIC), 其核心设计目标就是为 RAN 注入原生智能化能力, 实现网络功能的自动化编排、性能优化与差异化服务保障 [35, 36]. RIC 本身天然具备部署感知 – 决策 – 执行闭环智能体的理想环境, 其原生支持的近实时应用 (xApps)、非实时应用 (rApps)、实时应用 (dApps) 等模块化应用部署, 可在近实时、实时等不同时间尺度上, 完成数据分析、模型推理、策略生成与无线资源动态管理等任务, 为智能体的运行提供了标准化载体 [37].

如图 3 所示, 本文基于 O-RAN 标准提出一种结合智能体的 Agentic AI-RAN 网络架构, 可响应用户提出的个性化任务请求, 基于多智能体协同实现网络的自适应智能化调整. 我们在 RIC 与 CU/DU 中都内置了自主智能体, 分别承担不同粒度的决策与执行功能. 其中部署在 RIC 侧的智能体是整个网络智能化的核心, 具备四大核心能力.

- 理解能力. 作为多智能体闭环的输入入口, 该模块需要处理异构输入信息, 包括用户侧下发的任务意图、CU/DU 运行状态, 也包括监听模块采集的网络实时数据与性能测试的反馈结果, 这些输入通常涵盖文本描述、结构化信令、实时测量报告等多模态形态. 负责理解的智能体需要完成多模态信息的统一解析与对齐, 将非结构化/半结构化输入转化为面向决策的统一特征表示, 输出给决策模块作为推理基础.
- 决策能力. 智能体基于知识库的规则约束, 保证所有决策满足协议规范, 再结合任务需求和监听模块上报的实时网络负载、信道状态、业务 QoS 诉求, 生成端到端适配的决策输出, 包括用户优先级映射、QoS 流配置、MCS 选择、PRB 分配在内的完整参数集合, 同时可基于诸如比例公平 (proportional fair, PF) [38] 等经典调度准则与现有研究的优化框架, 针对当前网络的业务分布自适应调整调度逻辑, 在满足不同任务的个性化需求的前提下最大化无线资源利用率.

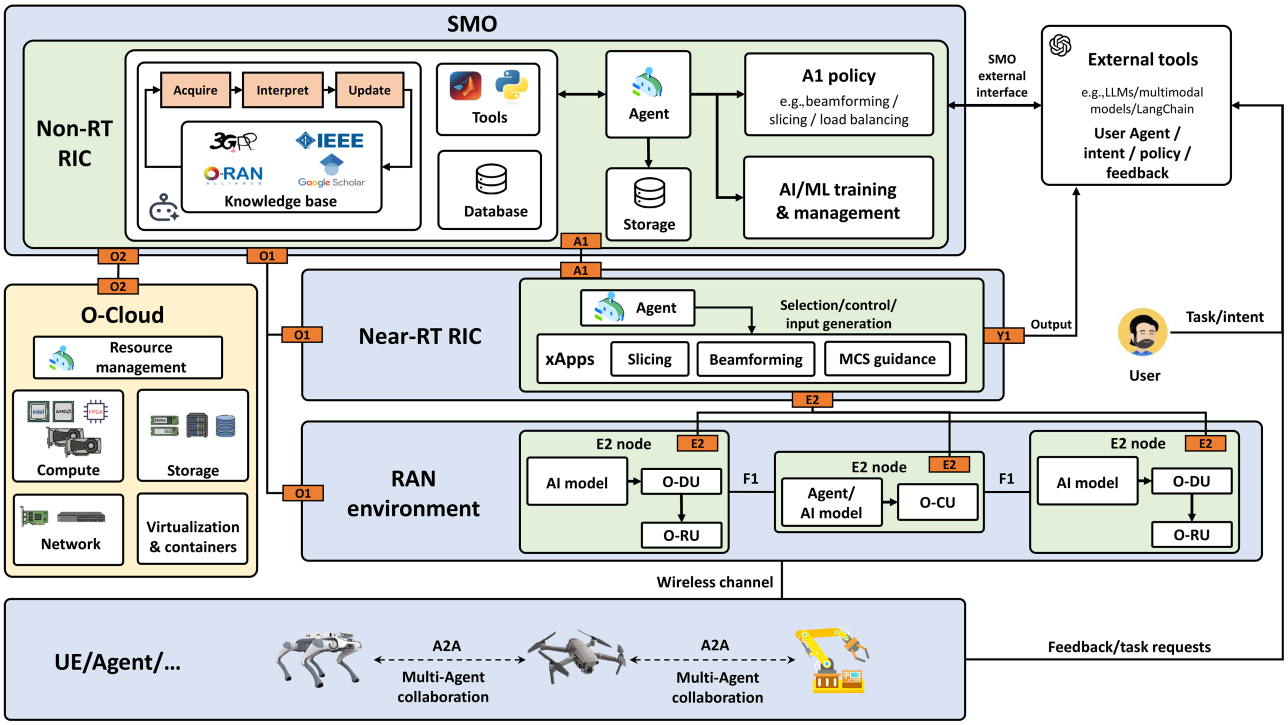

图 3　(网络版彩图) Agentic AI-RAN 与 O-RAN 功能实体及协议接口的映射关系图.

Figure 3　(Color online) Mapping between Agentic AI-RAN and O-RAN functional entities and protocol interfaces.

- 监听能力. 智能体需要监听核心网与基站的运行状态、用户接入情况、环境反馈等信息, 并将这些信息传递给理解、决策和测试智能体, 为全流程决策提供实时状态输入.
- 测试验证能力. 接收决策模块生成的调度策略与参数配置, 校验其是否符合通信协议与系统规范, 确保参数配置与接口调用的合法性, 保障网络在策略更新后可稳定运行.

Agentic AI-RAN 的首要特征是实现了网络管理的意图化与高度自主化. 当终端智能体或者用户产生个性化的任务需求或出现环境反馈时, 这些非标准通信信令的应用层数据会被传递给右上角的诸如基于 LLMs 的多模态控制中心等外部工具. 该外部模块扮演着两个关键角色: 首先, 它通过标准的 Y1 接口从准实时 RIC (near-real time RIC, near-RT RIC) 持续监督 RAN 并分析信息服务, 从而掌握底层的网络状态; 其次, 它结合用户意图、终端反馈与 Y1 分析数据进行综合推理, 将复杂的业务需求进行初步的处理, 并通过 SMO 外部接口注入到 SMO 框架中. 考虑到通信对低时延的要求, 但是智能体推理通常存在较高时延, 我们选择将具备领域专家能力的智能体嵌入到 SMO 中负责长期网络优化的非实时 RIC (non-real time RIC, non-RT RIC).

Non-RT RIC 模块通过引入由 3GPP 协议、O-RAN 标准以及研究成果与文献构建的专业知识库, 并配备了专用的工具库, 使 Agentic AI-RAN 具备领域专家级的知识推理能力, 为任务理解、资源分配、参数配置等核心流程提供专业依据. 同时, 该智能体将定期完成知识梳理与增量更新, 持续吸纳最新的协议标准与研究成果, 保障知识的时效性与推理输出的准确性. 当接收到外部注入的意图后, non-RT RIC 中的智能体利用其强大的理解与推理能力, 结合知识库的规则约束进行任务分解与参数规划. 随后, 它通过 A1 接口将生成的高级引导策略 (A1 policy, 如特定的切片保障策略和负载均衡目标) 和训练好的 AI/ML 模型下发给 near-RT RIC、O-CU 和 O-DU 等下层模块. 同时, SMO 依然保留了通过 O1 接口对 O-RAN 节点进行统一操作维护管理, 以及通过 O2 接口调度 O-Cloud 底层计算与存储资源的标准能力.

当 non-RT RIC 中的智能体同时接收到多个用户或业务意图时, 需要将自然语言描述转换为可计算的性能目标与资源约束. 其中, 时延、可靠性和最低服务保障等要求可设为刚性约束, 吞吐量、业务质量和任务完成时间等则作为可根据资源状态调整的弹性目标. 知识库用于提供业务优先级和网络约束, 帮助智能体判断不同意

图之间是否存在冲突. 在此基础上, 智能体结合实时网络状态确定各目标的重要程度, 构造资源优化问题, 并调用专用模型或传统优化算法完成具体求解. 智能体主要负责意图理解、约束设置、工具选择和结果校验, 具体的无线资源、算力及任务参数仍由相应算法计算. 当资源不足以满足全部期望目标时, 系统优先保证刚性约束, 再对其余需求进行协调; 若仅调整单一资源无法获得可行方案, 则进一步联合调整无线资源、计算位置和业务参数. 例如, 当低时延控制业务与高清视频业务同时竞争有限无线资源时, 智能体可将控制业务的时延和可靠性要求设为刚性约束, 将视频业务的期望吞吐量及最低可接受速率设为弹性目标. 资源优化算法首先保证控制业务的基本需求, 再将剩余资源分配给视频业务; 若视频吞吐量仍无法达到期望值, 智能体可在允许范围内降低视频编码速率, 或将部分数据处理迁移至边缘节点. 随后, non-RT RIC 通过 A1 接口向 near-RT RIC 下发资源保障比例和业务优先级等高级策略, 由相应 xApp 结合实时信道与负载状态完成细粒度调度, 并依据执行结果进一步调整资源配置.

在准实时控制层面, 内置了智能体的 near-RT RIC 作为网络智能化的核心枢纽. 它一方面解析来自 A1 接口的宏观策略以及访问 SMO 中的知识库, 另一方面持续监听底层网络状态. 基于这些多模态输入, near-RT RIC 智能体会自主调度和协同各类 xApps (如切片控制、波束成形、MCS 策略指导), 生成满足严苛时延和 QoS 要求的细粒度无线资源调度指令. 这些控制指令通过 E2 接口被精准下发至 RAN 环境中的 E2 节点.

我们在 CU/DU 侧同样部署了轻量级的端侧 AI 模型与执行智能体. 它们不承担复杂的推理任务, 而是专注于严格、快速地执行 RIC 下发的参数配置, 保障接口调用的合法性. 同时, E2 节点也会将底层的执行结果与基站级指标通过 E2 或 O1 接口逆向反馈, 为上层智能体提供状态更新.

在无线网络的边缘与终端侧, 我们进一步延展了智能化的边界. 完成 RAN 侧的资源调度后, 网络为终端设备提供了可靠的通信保障. 终端侧智能体通过 A2A 协议开展信息交换、任务协商和状态同步, 其自身也可以通过诸如模型上下文协议 (model context protocol, MCP) 调用各类工具和函数来辅助任务执行, 在动态场景或突发工况下进行本地的分布式协同与实时状态同步. 物理终端在执行协同避障、精密编队等联合任务时产生的环境信息和任务反馈, 可进一步上传至上层智能体, 为后续网络资源调整提供依据. 不同层级智能体之间可能存在任务语义和描述粒度不一致的问题. Non-RT RIC 中的智能体面向较长时间尺度理解业务意图并生成高级策略, near-RT RIC 中的智能体需要将其转换为具体的控制目标, 终端侧智能体则主要依据本地任务状态执行相应操作. 因此, 同一意图在不同层级需要逐步细化. 例如, 上层提出 “保障低时延业务” 时, 应在向下传递过程中进一步明确作用对象、时延要求、资源范围和生效时间, 否则下层智能体可能对任务范围或完成条件产生不同理解, 导致最终控制结果偏离原始意图. 为此, A2A 交互除传递任务目标外, 还应包含必要的上下文和约束信息; 接收方在执行前需要结合本地状态和能力检查任务是否能够被准确映射, 信息不足时则请求补充说明. 不同厂商智能体采用的知识表示和能力接口也可能存在差异, 可通过统一外部任务描述和本地适配方式进行协调. 未来可结合 O-RAN 开放接口, 逐步规范智能体的任务描述、能力声明和结果反馈, 为跨层级、跨厂商的 A2A 协同提供基本的语义一致性保障. 这些数据再次上传至 “外部工具” 模块中, 从而触发新一轮的 O-RAN 网络资源自适应调优, 实现了从物理世界感知、大模型意图解析到无线网络弹性重构的端到端完全自治.

此外, 分布式部署的多基站依托核心云平台实现跨站信息交互与智能协同, 地理分散的多个基站通过云端完成信息交换, 各基站会将自身的实时运行状态、局部覆盖区域的业务负载与环境感知结果同步上云, 同时也可从云端获取其他基站共享的信息与决策经验. 这种机制是 Agentic AI-RAN 智能化的重要支撑, 多基站信息共享打破了单基站的局部信息局限, 能够帮助 RIC 侧智能体更精准地预判跨区负载变化、干扰分布等网络动态, 提升了全局决策的鲁棒性, 便于跨站负载均衡和移动性管理等智能优化.

在 O-RAN 中引入 Agentic AI 后, 自然语言意图可以参与网络策略的生成, 这在提高网络自主性的同时, 也可能带来新的安全问题, 因此需要避免异常输入被直接转化为控制行为. 外部请求进入智能体前, 系统应确认请求来源及其可操作范围, 并判断其是否符合既定的网络管理规则. 对于试图改变系统指令、超出权限或缺少必要约束的请求, 智能体不应继续生成控制策略, 而应拒绝执行或要求补充信息. 智能体生成的策略同样不能直接作用于底层网络. 测试验证模块需要检查策略是否符合通信协议、网络资源条件及参数取值范围, 只有通过验证的结果才能经由 A1 或 E2 接口下发. 对于可能影响较大范围用户或关键网络配置的操作, 还应增加人工确认或预

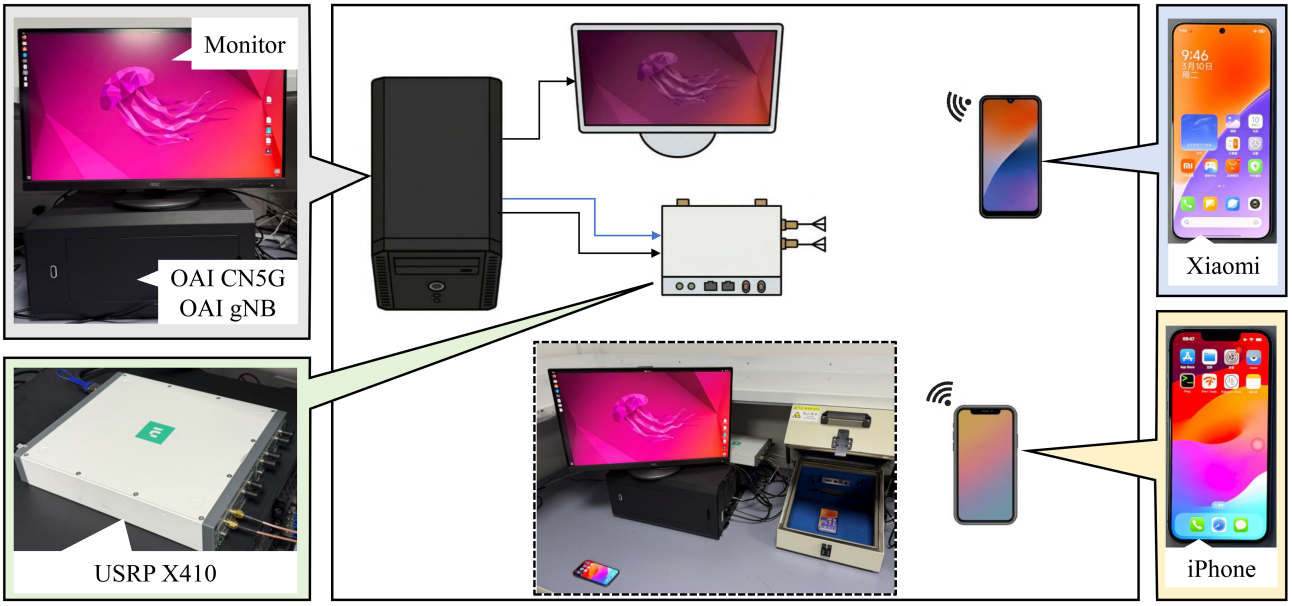

图 4　(网络版彩图) 实验环境图. 实验设备包括 OAI CN5G、OAI gNB、USRP X410 射频前端以及两台商用终端. 其中, OAI CN5G 和 OAI gNB 通过容器化的方式部署在同一台主机上.

Figure 4　(Color online) Diagram of the experimental environment. The experimental setup includes an OAI CN5G, an OAI gNB, a USRP X410 RF front-end, and two commercial UEs. The OAI CN5G and OAI gNB are containerized and deployed on the same host machine.

表 1　实验室平台设备详细清单.

Table 1　Detailed list of laboratory platform equipment.

Device name	Model/specifications
Host computer (OAI CN5G + gNB)	CPU: Intel Core i9-14900K; GPU: NVIDIA GeForce RTX 4090
RF front-end	USRP X410
Smartphone (commercial UE)	iPhone 14, Xiaomi 15

先测试环节. 与此同时, 部署在 RIC 中的模型应运行在受控环境中, 外部应用仅能调用模型服务, 不能直接访问模型参数.

5　实验平台与原型验证

5.1　实验平台与实现方法

为验证本文所提出的基于意图驱动的智能体通感算控一体化融合网络架构在真实无线系统中的可行性, 我们开展了原型实验, 旨在探究如何通过智能体解析自然语言意图并形成闭环决策, 最终在真实 5G 系统中实现面向目标业务的按需资源分配. 实验基于 OpenAirInterface (OAI) 构建了端到端 5G 原型系统, 在真实射频环境与商用终端参与下, 完成了感知、决策与执行的闭环验证 [39, 40]. 实验平台如图 4 所示, 由 OAI 5G 核心网 (OAI CN5G) 、OAI 5G 基站 (OAI gNB) 、USRP X410 射频前端、两台商用终端组成, 所使用的设备与硬件配置如表 1 所示. 其中, OAI CN5G 负责接入管理、会话建立与用户面转发; OAI gNB 运行经修改的 OAI 基站协议栈, 实现无线接入与调度控制; USRP X410 提供真实空口射频收发能力; 两台商用终端分别作为业务竞争用户接入同一小区, 以构造受限无线资源下的共享场景.

表 2 进一步给出了实验采用的主要无线参数、业务配置及控制时间尺度. 人工调权实验和智能体动态调控实验均采用相同的无线配置与终端部署环境. 实验中, iPhone 14 和 Xiaomi 15 同时接入同一 OAI 5G 小区, 并

表 2　原型系统关键实验配置. 在时隙配置中, D、S 和 U 分别表示下行时隙、特殊时隙和上行时隙; 在特殊时隙配置中, D、G 和 U 分别表示下行 OFDM 符号、保护符号和上行 OFDM 符号.

Table 2 Key experimental configuration of the prototype system. In the slot configuration, D, S, and U denote downlink, special, and uplink slots, respectively. In the special-slot configuration, D, G, and U denote downlink OFDM symbols, guard symbols, and uplink OFDM symbols, respectively.

Parameter	Configuration	Parameter	Configuration
Operating band	NR n78	Carrier center frequency	Approx. 3609.12 MHz
System bandwidth	20 MHz (51 PRBs)	Subcarrier spacing	30 kHz
TDD frame structure	5 ms, 7D/1S/2U	Special-slot configuration	6D/4G/4U
gNB antenna configuration	1T1R	Traffic generation tool	iperf3 (downlink)
Data reporting interval	10 ms	Run duration/repetitions	300 s/run, 5 runs
Agent model	Qwen3-8B	Agent control interval	Approx. 1.8 s

在每组实验过程中保持固定位置. 其中, 一台终端放置于射频屏蔽箱内, 另一台终端放置于实验台面, 以形成具有差异的无线信道条件. 两台终端与射频前端设备的物理距离约为 0.4 ∼ 0.6 m. 实际无线传播条件主要取决于终端与收发天线或屏蔽箱内耦合天线之间的相对位置. 为构造持续的无线资源竞争场景, 两台终端均采用 iperf3 生成全速下行业务. 数据监控 xApp 以 10 ms 为周期通过 E2SM-MAC 采集各 UE 的 MAC 层传输指标, 并据此计算瞬时下行吞吐量.

为使我们的控制目标能够作用于真实基站调度器, 本文对 OAI gNB 的调度算法进行了修改, 在原有算法中引入用户级动态权重参数. 具体而言, OAI gNB 默认使用 PF 调度算法, 该算法旨在平衡系统总吞吐量与用户间的公平性 [38]. 设系统中同时参与调度的用户设备 (user equipment, UE) 数量为 M, 可分配的 PRB 数量为 N, 则 UE 索引记为 $i \in \{1, 2, \ldots, M\}$, PRB 索引记为 $k \in \{1, 2, \ldots, N\}$. 本实验中, $M = 2$, $N = 51$. 对于第 i 个 UE 和第 k 个 PRB, 调度器计算权重系数 $C_{i,k}$ 如下:

$$C_{i,k}(t) = \frac{R_{i,k}(t)}{T_i(t)}, \tag{1}$$

其中, $R_{i,k}(t)$ 表示时刻 t 下第 i 个 UE 在第 k 个 PRB 上的瞬时可达速率, 该值与信道质量指示 (channel quality indicator, CQI) 、调制与编码方式等因素有关; $T_i(t)$ 表示第 i 个 UE 的历史平均吞吐量. 调度器依据 $C_{i,k}(t)$ 的大小为各 UE 分配无线资源, 通常优先选择度量值更大的 UE 占用相应资源. 对于第 i 个 UE, 我们引入了乘法权重因子 W_i 以控制不同 UE 的资源权重

$$C'_{i,k}(t) = \frac{R_{i,k}(t)}{T_i(t)} \times W_i, \tag{2}$$

其中, W_i 是我们可以实时动态控制的权重参数. 每个 UE 的初始值 $W_i = 1.0$, 即标准 PF 调度.

FlexRIC 是一种符合 O-RAN 标准的 RIC 框架, 它通过 E2 接口与 gNB 相连, 使研究人员能够在网络运行过程中灵活地监测和控制无线网络 [41]. 在 RAN 侧, gNB 内部的 RAN function 通过 E2 Agent 与 RIC 建立通信, E2 Agent 的职责是把基站能够被监测或控制的功能暴露出来, 并按照 E2 服务模型 (E2 service model, E2SM) 的形式传递给 FlexRIC. 由此, RAN 与 FlexRIC 之间就形成了基于 E2 应用层协议 (E2 application protocol, E2AP) 和 E2SM 的交互关系, 使网络运行状态能够被实时采集和控制指令能够下发 [42, 43]. 本文基于 FlexRIC 框架扩展实现了定制化 xApp, 建立面向 gNB 调度参数的近实时读写控制链路. 我们复用了 RAN 控制 (RAN control, RC) 服务模型的 Action ID 2 (QoS flow mapping configuration), 并扩展了其参数定义, 新增参数 scheduling priority weight 和 scheduling direction. xApp 负责构建 E2SM-RC 控制消息, 当 gNB 收到 Action ID 2 的控制消息时, 会解析消息并根据方向更新目标 UE 的上行和下行权重.

在上述真实硬件平台基础上, 我们构建了面向无线资源动态调控的智能体控制闭环. 如图 5 所示, 整体架构划分为用户意图层、决策编排层、感知与执行层、无线接入网层四个部分. 其中, 用户意图层用于接收用户以自

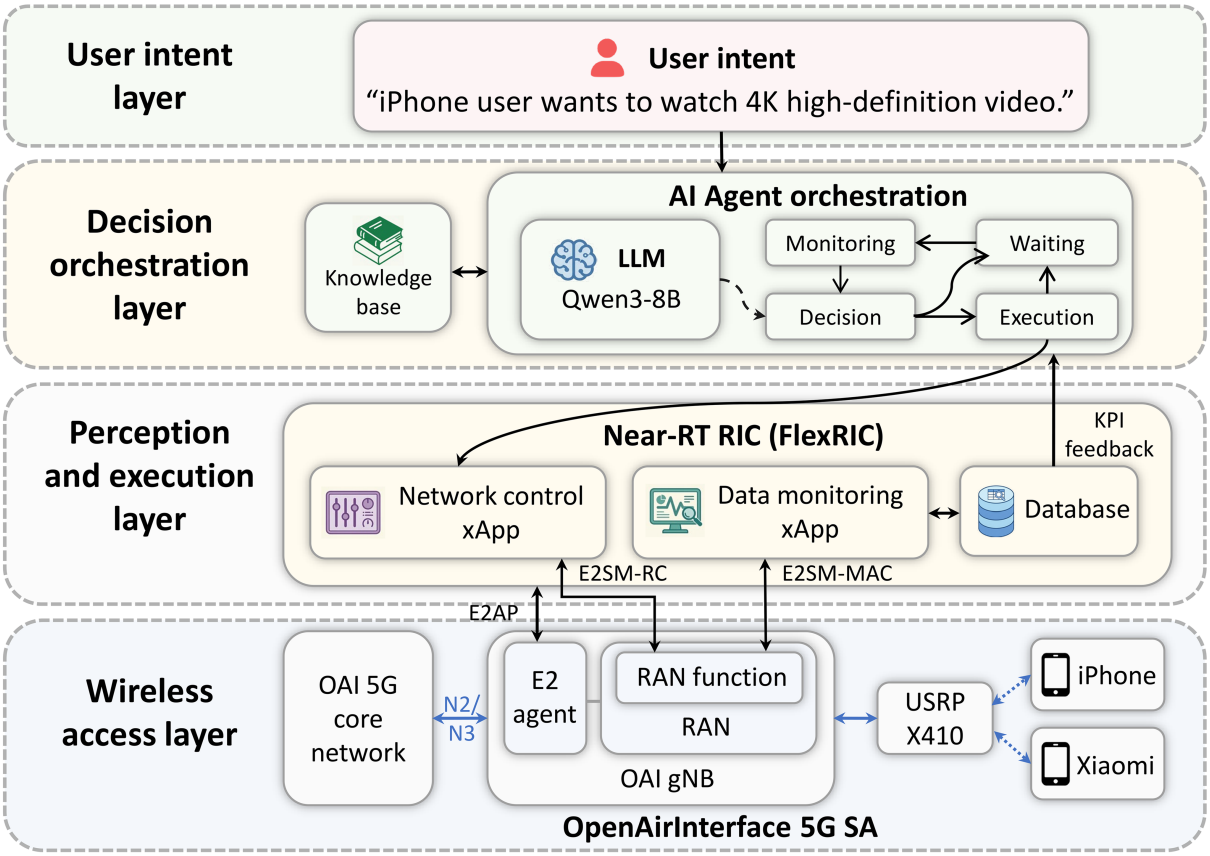

图 5　(网络版彩图) 实验原型系统的模块组成与意图驱动闭环控制流程. 在实验中, 用户只需要提供上层需求, 经过智能体理解, 通过 FlexRIC 进行网络的监控与策略的实际下发.

Figure 5　(Color online)　Module composition of the experimental prototype system and intent-driven closed-loop control process. During the experiment, users only need to provide high-level requirements, which are interpreted by the agent, and FlexRIC is then utilized for network monitoring and actual policy enforcement.

然语言形式表达的高层业务需求, 例如 “iPhone 用户要看 4K 高清视频”. 决策编排层以大语言模型驱动的智能体为核心, 本文采用基于 vLLM 本地部署的 Qwen3-8B 模型, 负责对用户意图进行语义理解与任务编排.

具体而言, 系统在每轮闭环中将用户意图、知识库检索结果和动态网络状态组织为智能体的决策上下文. 其中, 用户意图和知识库检索结果用于确定目标 UE、业务类型及其性能目标; 在本文原型实验中, “4K 高清视频”业务对应的目标下行吞吐量配置为 40 Mbps. 网络状态除各 UE 当前上下行吞吐量及调度权重外, 还包括目标 UE 近 5 轮吞吐量与权重观测序列、平均下行吞吐量、相对目标的性能偏差、吞吐量变化趋势与波动程度, 以及其他竞争 UE 的当前吞吐量、调度权重和短时变化趋势.

本文设计的提示模板包括智能体角色、业务性能目标、实时与短时历史网络状态、最近一次控制动作、动作边界及输出规范. Qwen3-8B 基于上述上下文完成网络状态分析和控制动作生成, 综合目标性能偏差、短时变化趋势、吞吐量波动程度、当前调度权重以及其他 UE 的资源竞争状态, 判断是否需要调整目标 UE 权重, 并在需要调节时生成结构化候选动作. 该动作包括目标 UE、目标权重和控制方向; 当无需调整时, 智能体输出保持动作. 由此实现从自然语言业务需求、性能目标到无线资源调度参数的闭环映射.

为保证智能体生成动作的稳定性和可执行性, 系统在大模型上下文推理的基础上进一步设置目标容差范围和动作边界. 设知识库解析得到的目标下行吞吐量为 R_{tar}, 目标 UE 当前下行吞吐量为 $R_i(t)$, 本文将 $[R_{\mathrm{tar}}-2, R_{\mathrm{tar}}+2]$ Mbps 作为目标性能是否得到满足的参考区间. 当 $R_i(t)$ 低于该区间时, 智能体根据当前性能偏差、短时变化趋势及吞吐量波动程度生成提高目标 UE 调度权重的动作; 当吞吐量达到目标附近后, 系统停止继续增权并保持当前配置, 结合后续状态反馈判断业务性能是否得到持续保障. 对于持续高于业务需求且对其他 UE

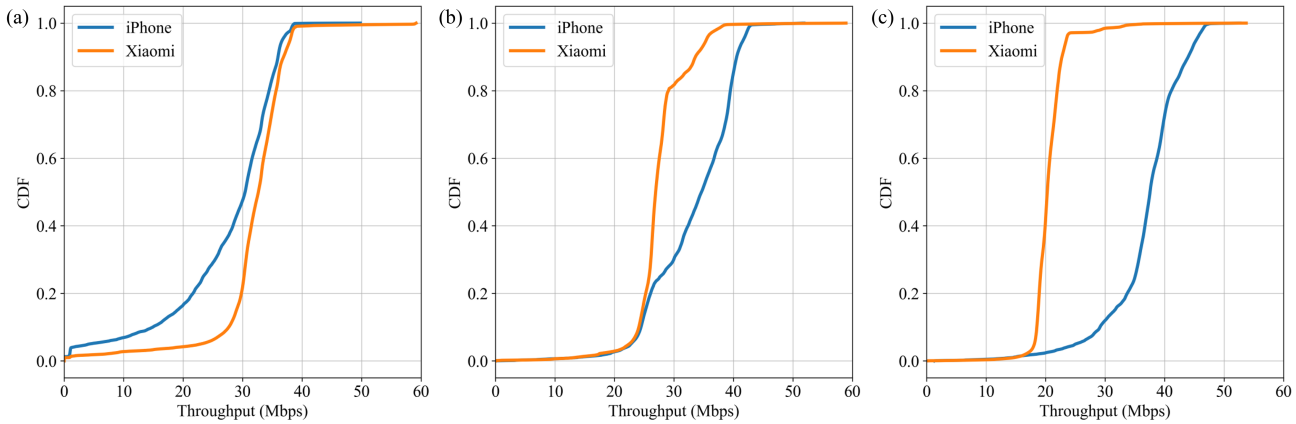

图 6　(网络版彩图) 不同权重下 UE 吞吐量的 CDF 结果: (a) 1:1; (b) 1:1.5; (c) 1:2.

Figure 6　(Color online) CDF results of UE throughput under different weights: (a) 1:1; (b) 1:1.5; (c) 1:2.

资源造成明显影响的情况, 智能体可进一步生成降低权重的控制动作. 在每轮控制中, Qwen3-8B 综合当前吞吐量、近 5 轮吞吐量统计结果及当前调度权重, 在 0.1 ∼ 0.3 范围内动态确定单轮权重调整步长. 系统同时利用近 5 轮平均下行吞吐量辅助判断目标性能是否稳定达到业务需求, 以减少瞬时信道波动引起的频繁调节.

感知与执行层依托 near-RT RIC (FlexRIC) 实现控制与监测功能, 其中网络控制 xApp 负责接收智能体生成的控制策略, 并通过 E2SM-RC 服务模型将控制参数下发至基站侧; 数据监控 xApp 则通过 E2SM-MAC 服务模型负责采集终端吞吐量等关键性能指标, 并将相关监测结果写入数据库, 供上层智能体读取与分析. 无线接入网层由 OAI CN5G、集成 E2 Agent 和 RAN Function 的 OAI gNB、USRP X410 以及商用终端组成, 负责完成实际的无线接入、基站调度与业务承载. 其中, OAI gNB 通过 E2AP 与 near-RT RIC 交互, 在接收到控制指令后, 对无线资源参数进行动态调整; 终端在资源调控后的业务性能变化, 则通过监控链路反馈至上层, 作为评估控制效果的依据. 因此, 整个实验平台实现了从意图解析、状态采集、策略生成、参数下发到结果反馈的完整闭环控制流程.

5.2　实验结果

为验证底层资源调度链路是否具备可控性, 首先开展基础控制能力实验. 在不引入智能体自主决策的条件下, 通过人工配置不同的用户权重组合, 观察两台终端吞吐量随权重变化的响应规律. 实验中, 两台商用终端 iPhone 与 Xiaomi 同时接入所搭建的 5G OAI 真实系统, 并使用 iperf3 产生全速下行业务, 使系统处于持续资源竞争状态. 每组实验持续 300 s, 重复运行 5 次; xApp 以 10 ms 周期上报统计数据. 本文汇总两个 UE 在全部采样时刻的瞬时吞吐量样本, 并绘制累积分布函数 (cumulative distribution function, CDF) 曲线. 图 6(a)∼(c) 展示了三种不同权重设置下两个用户吞吐量分布的对比结果. 将 Xiaomi 与 iPhone 的权重分别记为 W_1 和 W_2, 三组权重比 $W_1 : W_2$ 分别为 1:1、1:1.5 和 1:2, 即从图 6(a) 到 (c), iPhone 的相对调度权重逐步提高.

结果表明, 加权 PF 调度器对权重变化呈现出清晰的响应趋势. 如图 6(a) 所示, 在默认 PF 调度条件下, 两用户权重均为 1:1, 此时 iPhone 与 Xiaomi 的吞吐量 CDF 曲线整体较为接近, 主要集中于 25 ∼ 35 Mbps 区间. 受终端位置和无线信道条件差异影响, iPhone 曲线相较 Xiaomi 略向左偏移.

当提高 iPhone 的调度权重后, 如图 6(b) 所示, iPhone 的吞吐量分布整体向高吞吐区间右移, 其中位吞吐量提升至约 35 Mbps; 与此同时, Xiaomi 的吞吐量分布相应向低吞吐区间偏移. 进一步地, 当权重差距增大至 1:2 时, 如图 6(c) 所示, 两条 CDF 曲线出现更明显的分离, Xiaomi 的吞吐量主要集中于 20 ∼ 25 Mbps 区间, 而 iPhone 的吞吐量分布进一步向右扩展, 较高吞吐量样本占比明显增加.

综合图 6(a)∼(c) 可以看出, 随着 iPhone 相对调度权重的提高, 其吞吐量分布持续向高吞吐量区间移动, 而 Xiaomi 的吞吐量相应下降, 说明所引入的用户级权重参数能够改变加权 PF 调度器对无线资源的分配倾向. 该结果验证了从 xApp 控制消息、gNB 调度参数更新到终端吞吐量变化的底层控制链路具有实际可控性. 本组实

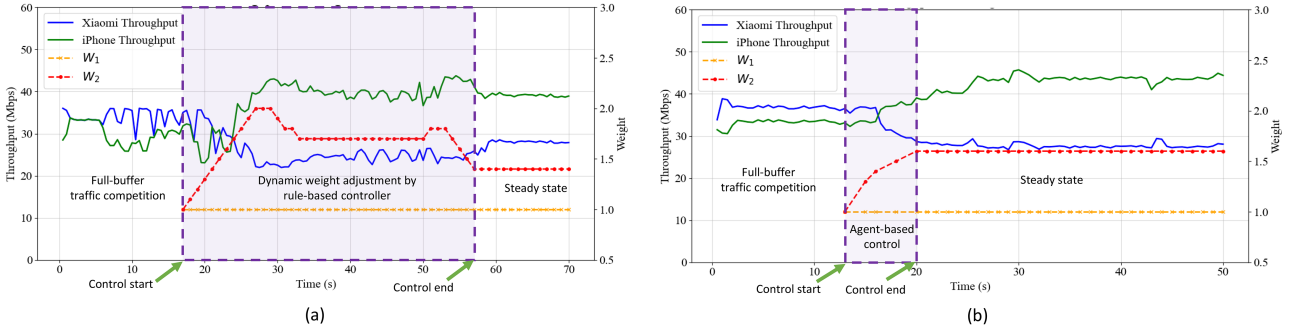

图 7　(网络版彩图) 不同闭环控制方法下 UE 吞吐量与调度权重的动态变化情况: (a) 固定步长规则控制器; (b) 智能体动态调控.

Figure 7　(Color online) Dynamic changes in UE throughput and scheduling weights under different closed-loop control methods: (a) fixed-step rule-based controller; (b) agent-based controller.

验中的权重由人工预先配置, 其作用主要是验证智能体后续执行资源调控所依赖的控制接口和调度机制, 而非验证智能体的自主决策能力.

在前述人工调权实验所采用的实验环境与持续资源竞争条件保持不变的基础上, 进一步开展智能体动态调控实验, 以验证所设计系统是否能够依据高层业务意图, 自主完成目标 UE 吞吐量的闭环调节. 与前述实验中人工预设固定权重不同, 本实验由智能体根据用户输入意图、实时网络状态以及业务知识库中预定义的业务需求自主生成控制动作. 实验中输入意图为 “iPhone 用户要看 4K 高清视频”, 系统结合业务知识库将该业务映射为目标下行吞吐量 40 Mbps, 并由基于 vLLM 本地部署的大模型 Qwen3-8B 驱动智能体完成调控决策.

为分析智能体动作生成机制的作用, 本文设置固定步长规则控制器作为对照方法. 规则控制器与智能体控制器采用相同的加权 PF 调度器、状态监测周期和底层控制链路. 为保证控制过程具有可比性, 规则控制器直接接收目标 UE 和目标吞吐量. 当目标 UE 当前吞吐量低于目标区间时, 规则控制器将其调度权重提高 0.1; 当吞吐量高于目标区间时, 将权重降低 0.1; 当吞吐量位于目标区间内时, 则保持当前权重. 该控制器不使用历史吞吐量、变化趋势和波动程度等状态信息.

图 7 给出了固定步长规则控制器和智能体控制器下两个 UE 吞吐量与调度权重的动态变化过程. 在闭环控制启动前, 也就是灌包竞争阶段, 两个 UE 均采用默认 PF 调度, 调度权重保持为 1. 此时 iPhone 吞吐量低于 40 Mbps 的业务性能需求, 说明默认 PF 调度虽然能够兼顾系统吞吐量与用户公平性, 但不具备面向高层业务意图主动调整用户资源份额的能力.

如图 7(a) 所示, 固定步长规则控制器启动后, 由于 iPhone 吞吐量低于目标区间, 控制器以 0.1 的固定步长逐轮提高其调度权重. iPhone 权重首先由 1.0 提高至约 2.0, 其吞吐量随之上升并超过目标区间, 控制器随后反向降低权重. 由于该方法仅根据当前吞吐量进行判断, 瞬时无线信道波动多次触发增权和减权操作. 在本次实验的观测过程中, 固定步长调权阶段持续约 40 s. 完成末次调权后, iPhone 权重保持在约 1.4, iPhone 和 Xiaomi 的吞吐量分别维持在约 39 和 28 Mbps.

图 7(b) 展示了智能体动态调控 UE 权重的实验过程. 当输入 “iPhone 用户要看 4K 高清视频” 的业务意图后, 系统进入智能体决策阶段. 智能体首先识别目标 UE 及其业务类型, 并依据业务知识库获得 40 Mbps 的目标下行吞吐量. 与直接给定固定权重不同, 智能体根据目标 UE 当前吞吐量、近 5 轮吞吐量统计结果以及当前调度权重逐轮生成控制动作. 在约 4 轮闭环决策过程中, iPhone 的调度权重由 1.0 逐步提高至 1.6, 对应的下行吞吐量也由约 33 Mbps 逐渐上升至目标附近. 与此同时, Xiaomi 吞吐量随无线资源向目标 UE 倾斜而相应下降.

当 iPhone 当前吞吐量及近 5 轮吞吐量统计结果达到业务满足条件后, 智能体不再继续提高其调度权重, 并将权重保持为 1.6. 受调度参数生效过程及吞吐量统计响应的影响, iPhone 吞吐量在停止调权后继续上升, 随后稳定在约 43 Mbps, 满足 4K 高清视频业务对应的吞吐量需求; Xiaomi 吞吐量则稳定在约 28 Mbps. 该过程表明, 智能体能够结合业务目标和动态网络状态逐步调整用户间的资源分配关系.

从闭环控制时序来看, 本文将业务意图输入后智能体首次生成控制动作的时刻作为调节起点, 并将智能体不再生成新的权重调整动作作为动态调权完成判据. 图 7(b) 中, 智能体经过 4 轮闭环决策完成权重调整, 对应时间约为 8 s. 在当前实验平台下, Qwen3-8B 单次决策耗时约为 0.8 s; 控制动作下发后, 系统预留约 1 s 用于调度参数生效及吞吐量反馈. 计入状态读取、动作下发和状态更新等过程后, 单轮状态观测, 策略生成, 参数下发以及结果反馈的闭环周期约为 1.8 ∼ 2.0 s. 该时间尺度表明, 本文系统主要承担秒级业务意图驱动的外环资源调控, 基站内部的毫秒级无线资源分配仍由加权 PF 调度器完成.

与固定步长规则控制器相比, 智能体方案能够在较少控制轮次内使目标 UE 吞吐量达到业务需求, 并减少固定步长控制器中由瞬时吞吐量波动引起的重复增权和减权操作. 若以首次调权至末次调权之间的时间作为动态调权持续时间, 两种方法分别约为 40 和 8 s, 智能体方案缩短约 80%. 该结果表明, 在本实验场景下, 智能体动作生成机制能够以更少的控制轮次完成面向业务意图的资源配置调整, 提高外环控制的意图响应效率.

综合图 6 和 7 的结果, 图 6 首先验证了底层加权 PF 调度器能够依据用户权重改变两个 UE 之间的无线资源分配; 在此基础上, 图 7 则进一步验证了智能体将自然语言业务意图转化为吞吐量目标并实施闭环资源调控的能力. 由此, 原型系统实现了从业务意图解析, 性能目标生成, 调度参数调整, 无线资源重新分配到最后执行结果反馈构成的闭环过程, 验证了意图驱动智能体架构在真实 5G OAI 无线资源控制场景中的实现可行性.

需要指出的是, 当前原型实验仅设置了两个商用 UE, 主要用于验证自然语言业务意图、智能体决策、xApp 控制、gNB 调度与性能反馈之间的端到端闭环可行性, 尚未对大规模用户接入场景下的智能体性能进行实验评估. 因此, 本文结果不能直接视为对大规模用户场景可扩展性的完整验证.

在当前实现中, 数据监控 xApp 能够按照 UE 标识采集多个 UE 的网络状态, 网络控制 xApp 也能够面向不同目标 UE 分别下发调度权重, 式 (2) 中的权重参数 W_i 同样适用于一般的 M 用户场景. 因此, 底层状态监测、参数下发与加权 PF 调度机制在功能上并不局限于两个 UE. 随着接入 UE 数量增加, 影响系统可扩展性的主要因素来自智能体侧: 一方面, 输入智能体的网络状态数量及上下文长度随 UE 规模增长, 可能增加模型的推理时延; 另一方面, 当多个 UE 具有不同业务需求时, 智能体需要同时处理更多目标、约束及潜在冲突, 可能影响策略生成的效率和一致性.

6　总结

本文面向 6G 网络中高层业务意图理解与跨域网络能力协同问题, 提出了一种意图驱动的 Agentic AI 通感算控一体化融合网络架构, 将 Agentic AI 作为任务级编排核心, 实现高层意图向通信、感知、计算和控制任务的转化; 此外, 明确 Agentic AI 与 wBAIMs、知识库、模型库和工具库之间的功能关系, 构建知识辅助、模型推理、工具执行和反馈调整相结合的闭环协同机制; 最后, 结合 O-RAN 设计 Agentic AI-RAN 的部署与交互流程, 并基于 OAI、FlexRIC、USRP X410 及商用终端搭建真实网络原型. 实验结果表明, 所构建控制链路能够有效调节终端无线资源, 智能体可将自然语言业务意图转化为具体调度参数, 并结合网络状态反馈完成闭环调整, 验证了所提架构在意图驱动无线资源调控场景中的可行性.

当前原型选取无线资源调控作为代表性应用, 对意图理解、策略生成、网络执行和结果反馈之间的关键链路进行了验证. 未来将在此基础上进一步扩展网络切片、波束管理、感知任务组织及云边端算力调度等能力, 研究通信、感知、计算与控制之间的联合编排, 并面向多小区、多用户及异构智能终端开展更大规模的系统验证. 同时, 将进一步完善智能体的可信与实时运行机制, 重点研究意图合法性检查、模型与工具访问控制、策略执行校验、推理时延和闭环稳定性等问题.

参考文献

1　Xu M, Niyato D, Kang J, et al. When large language model agents meet 6G networks: perception, grounding, and alignment. IEEE Wireless Commun, 2024, 31: 63–71

2　Chen J, Liang X, Xue J, et al. Evolution of RAN architectures toward 6G: motivation, development, and enabling technologies. IEEE Commun Surv Tutorials, 2024, 26: 1950–1988

3 Wang Y, Yang C, Li T, et al. A survey on intent-driven end-to-end 6G mobile communication system. IEEE Commun Surv Tutorials, 2025, 28: 882–915
4 Agarwal B, Irmer R, Lister D, et al. Open RAN for 6G networks: architecture, use cases and open issues. IEEE Commun Surv Tutorials, 2025, 28: 2881–2924
5 Chen Z, Zhang Z, Yang Z, et al. Channel mapping based on interleaved learning with complex-domain MLP-mixer. IEEE Wireless Commun Lett, 2024, 13: 1369–1373
6 Yang Y, Zhang Z, Chen Z, et al. A hybrid inference architecture incorporating neural network with belief propagation for AI receivers. IEEE Trans Wireless Commun, 2025, 24: 6365–6381
7 Yang Y, Yan S, Zhou W, et al. Diffusion models for wireless transceivers: from pilot-efficient channel estimation to AI-native 6G receivers. ArXiv:2510.24495
8 Zhou X, Liang L, Zhang J, et al. Generative diffusion models for high dimensional channel estimation. IEEE Trans Wireless Commun, 2025, 24: 5840–5854
9 Brown T, Mann B, Ryder N, et al. Language models are few-shot learners. ArXiv:2005.14165
10 Liu A, Feng B, Xue B, et al. DeepSeek-V3 technical report. ArXiv:2412.19437
11 Bai J, Bai S, Chu Y, et al. Qwen technical report. ArXiv:2309.16609
12 Liu B, Tong J, Zhang J. LLM-slice: dedicated wireless network slicing for large language models. In: Proceedings of the 22nd ACM Conference on Embedded Networked Sensor Systems, 2024. 853–854
13 Cui Y, Guo J, Wen C K, et al. Exploring the potential of large language models for massive MIMO CSI feedback. ArXiv:2501.10630
14 Guo W, Liang K, Zheng G, et al. An LLM-based framework for beamforming optimization. IEEE Commun Mag, 2026, 64: 99–104
15 Sapkota R, Roumeliotis K I, Karkee M. AI agents vs. Agentic AI: a conceptual taxonomy, applications and challenges. ArXiv:2505.10468
16 Tong J, Guo W, Shao J, et al. Wirelessagent: large language model agents for intelligent wireless networks. ArXiv:2505.01074
17 Nahum C V, Lopes V H L, Dreifuerst R M, et al. Intent-aware radio resource scheduling in a RAN slicing scenario using reinforcement learning. IEEE Trans Wireless Commun, 2023, 23: 2253–2267
18 Xiao Y, Shi G, Zhang P. Towards Agentic AI networking in 6G: a generative foundation model-as-agent approach. ArXiv:2503.15764
19 Elkael M, Polese M, Prasad R, et al. ALLSTaR: automated LLM-driven scheduler generation and testing for intent-based RAN. ArXiv:2505.18389
20 Sun L, Zhang Z, Lin Z, et al. Agentic AI-RAN empowering synergetic sensing, communication, computing, and control. ArXiv:2601.16565
21 Elkael M, D'Oro S, Bonati L, et al. Agentran: an Agentic AI architecture for autonomous control of open 6G networks. ArXiv:2508.17778
22 Chen Z, Sun Q, Li N, et al. Enabling mobile AI agent in 6G era: architecture and key technologies. IEEE Netw, 2024, 38: 66–75
23 Xiao Y, Shi G, Zhang P. Toward Agentic AI networking in 6G: a generative foundation model-as-agent approach. IEEE Commun Mag, 2025, 63: 68–74
24 Zhang H, Zhang Z, Liu X, et al. Integrated sensing and communication for 6G holographic digital twins. IEEE Wireless Commun, 2025, 32: 104–112
25 Wang J, Zhang J, Zhang Y, et al. Radio environment knowledge pool for 6G digital twin channel. IEEE Commun Mag, 2025, 63: 158–164
26 Yao J, Xu W, Zhu G, et al. Energy-efficient edge inference in integrated sensing, communication, and computation networks. IEEE J Sel Areas Commun, 2025, 43: 3580–3595
27 Shi W, Xu W, You X, et al. Intelligent reflection enabling technologies for integrated and green internet-of-everything beyond 5G: communication, sensing, and security. IEEE Wireless Commun, 2023, 30: 147–154
28 Chen Z R, Zhang Z Y, Liu C Y, et al. Towards wireless native big AI model: the mission and approach differ from large language model. Sci China Inf Sci, 2025, 68: 170303
29 Chen Z, Zhang Z, Yang Z. Big AI models for 6G wireless networks: opportunities, challenges, and research directions. IEEE Wireless Commun, 2024, 31: 164–172
30 Du N, Huang Y, Dai A M, et al. GLaM: efficient scaling of language models with mixture-of-experts. In: Proceedings of International Conference on Machine Learning, 2022. 5547–5569
31 Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models. In: Proceedings of the 34th Conference on Neural Information Processing Systems, 2020. 6840–6851
32 Lipman Y, Chen R T, Ben-Hamu H, et al. Flow matching for generative modeling. ArXiv:2210.02747
33 Polese M, Bonati L, D'Oro S, et al. Understanding O-RAN: architecture, interfaces, algorithms, security, and research challenges.

IEEE Commun Surv Tutorials, 2023, 25: 1376–1411
34 Abdalla A S, Upadhyaya P S, Shah V K, et al. Toward next generation open radio access networks: what O-RAN can and cannot do! IEEE Network, 2022, 36: 206–213
35 Almeida G M, Bruno G Z, Huff A, et al. RIC-O: efficient placement of a disaggregated and distributed RAN intelligent controller with dynamic clustering of radio nodes. IEEE J Sel Areas Commun, 2023, 42: 446–459
36 Prananto B H, Iskandar, Hendrawan, et al. LSTM neural network algorithm for handover improvement in a non-ideal network using O-RAN near-RT RIC. IEICE Trans Commun, 2024, E107-B: 458–469
37 D'Oro S, Polese M, Bonati L, et al. dApps: distributed applications for real-time inference and control in O-RAN. IEEE Commun Mag, 2022, 60: 52–58
38 Kwan R, Leung C, Zhang J. Proportional fair multiuser scheduling in LTE. IEEE Signal Process Lett, 2009, 16: 461–464
39 Kaltenberger F, Melodia T, Ghauri I, et al. Driving innovation in 6G wireless technologies: the openairinterface approach. Comput Netws, 2025, 269: 111410
40 Kaltenberger F, Silva A P, Gosain A, et al. OpenAirInterface: democratizing innovation in the 5G era. Comput Netws, 2020, 176: 107284
41 Schmidt R, Irazabal M, Nikaein N. FlexRIC: an SDK for next-generation SD-RANs. In: Proceedings of the 17th International Conference on Emerging Networking Experiments and Technologies, 2021. 411–425
42 Moro E, Polese M, Capone A, et al. An open RAN framework for the dynamic control of 5G service level agreements. In: Proceedings of the 2023 IEEE Conference on Network Function Virtualization and Software Defined Networks (NFV-SDN), 2023. 141–146
43 Ngo M V, Tran N B L, Yoo H M, et al. RAN intelligent controller (RIC): from open-source implementation to real-world validation. ICT Express, 2024, 10: 680–691

Intent-driven integrated communication, sensing, computing, and control network: architecture and protocol design and implementation

Weijie ZHOU[1,2], Zhaoyang ZHANG[1,2,3*], Tianyi QIN[1,2], Xuan CHENG[1,2], Zirui CHEN[1,2], Lingxiao SUN[1,2] & Tony Q. S. QUEK[4]

1. *College of Information Science and Electronic Engineering, Zhejiang University, Hangzhou 310027, China*
2. *Zhejiang Provincial Key Laboratory of Multi-Modal Communication Networks and Intelligent Information Processing, Hangzhou 310027, China*
3. *Institute of Fundamental and Transdisciplinary Research, Zhejiang University, Hangzhou 310058, China*
4. *Information System Technology and Design Pillar, Singapore University of Technology and Design, Singapore 487372, Singapore*
* Corresponding author. E-mail: ning_ming@zju.edu.cn

Abstract To address the challenges posed by massive access by heterogeneous user equipment, diverse and dynamic service demands, and complex network environments in future 6G networks, we propose an intent-driven integrated communication, sensing, computing, and control (SC3) network architecture based on Agentic artificial intelligence (Agentic AI). Centered on Agentic AI, this architecture aims to achieve deep coordination and autonomous intelligent management of SC3. By deploying agents with multi-modal understanding, autonomous decision-making, continuous learning, and collaborative interaction capabilities across network layers, the architecture can automatically parse high-level intents from users or applications and translate them into underlying cross-domain network control policies. This enables dynamic and precise allocation of wireless, computing, and sensing resources. Based on the open radio access network (O-RAN) standard, we further detail a concrete Agentic AI-RAN implementation scheme and validate the feasibility and effectiveness of the proposed architecture through prototype experiments on a real hardware platform. Experimental results demonstrate that the closed-loop control via agents can effectively transform high-level intents into low-level resource scheduling parameters and adjust resource allocation on demand. This work provides an innovative architectural vision and a feasible technical pathway for building the next-generation autonomous and intelligent 6G network.

Keywords Agentic AI, 6G, intent-driven, integrated network, integrated SC3, RAN