

# 通信计算融合无线网络：从云化协同迈向感智协同

彭木根<sup>1,2</sup>, 姜宁<sup>1,2</sup>, 闫实<sup>1,2</sup>

(1. 北京邮电大学网络与交换技术国家重点实验室, 北京 100876; 2. 低轨星座融合通信与组网技术北京市重点实验室, 北京 100876)

**摘要:** 为了满足巨容量和极低时延性能需求, 通信计算融合无线网络通过分解传统基站功能、构建基带池云化集中协同机制, 并逐渐向云-边-端一体化的云化协同演进, 实现了资源高效复用、信息实时处理与干扰精准抑制。随着各种新兴应用涌现, 通信感知一体化和 AI 内生成成为 6G 的重要特征, 感知和智能计算 (简称感智) 协同进一步赋能通信计算融合无线网络云-边-端-业, 推动云化协同迈向感智协同。系统梳理了云化协同学术研究与产业化进展, 重点介绍了组网性能规律、体系架构设计及关键技术; 提出了感智协同理论体系和关键技术, 阐明了感智协同的性能增益, 为 6G 全域覆盖与极致性能需求提供了支撑。结合典型应用场景, 展望了感智协同在低空经济、低轨道地球卫星和空天地一体化等领域的应用。

**关键词:** 通信计算融合无线网络; 云化协同; 感智协同; 6G; 低空经济; 低轨道地球卫星; 空天地一体化

**中图分类号:** TN929.5

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-436x.TXXB260063

## Communication-computing integrated wireless networks: from cloud-based collaboration to integrated sensing and intelligent coordination

Peng Mugen<sup>1,2</sup>, Jiang Ning<sup>1,2</sup>, Yan Shi<sup>1,2</sup>

1. State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China

2. Beijing Key Laboratory of Convergent Communication and Networking Technologies in LEO Satellite Systems, Beijing 100876, China

**Abstract:** To meet the requirements for massive capacity and ultra-low latency in 6G, the evolution of communication-computing integrated wireless networks from cloud-based collaboration to integrated sensing and intelligent coordination was investigated. The academic research and industrial progress of cloud-based collaboration were systematically summarized, with an emphasis on networking performance, system architecture, and key technologies. Subsequently, a theoretical framework and key technologies for integrated sensing and intelligent coordination were proposed. The resulting performance gains were elaborated, and solid support for achieving global coverage and ultimate performance in 6G was provided. Finally, this paper envisions future applications of integrated sensing and intelligent coordination in typical scenarios, such as the low-altitude economy, low earth orbit satellite, and space-air-ground integration.

**Key words:** communication-computing integrated wireless network, cloud-based collaboration, integrated sensing and intelligent coordination, 6G, low-altitude economy, low earth orbit satellite, space-air-ground integration

收稿日期: 2026-01-26; 修回日期: 2026-04-14

通信作者: 闫实, yanshi01@bupt.edu.cn

基金项目: 国家科技重大专项基金资助项目 (No.GXB-2-2025-5); 国家自然科学基金资助项目 (No.62371067); 北京市自然科学基金资助项目 (No.L223007)

**Foundation Items:** The National Science and Technology Major Project of China (No.GXB-2-2025-5), The National Natural Science Foundation of China (No.62371067), The Natural Science Foundation of Beijing (No.L223007)

## 0 引言

移动通信系统具有显著的代际特征,其演进伴随着多址接入技术和无线组网理论的变革。移动网络架构演进如图1所示,第一代至第三代移动通信系统基于蜂窝组网理论与架构,在实现无缝覆盖的同时,一直在追求更高的网络频谱效率和小区平均容量。第四代移动通信系统(4G)为了满足热点区域高容量需求和业务流量的潮汐迁移,在无缝覆盖的小区基础上部署额外的异构小基站,颠覆了传统蜂窝组网理论,核心是无蜂窝异构协同组网理论和体系架构。第五代移动通信系统(5G)更是打破传统个人通信的束缚,实现人机物通信,在追求更高通信速率的同时,也追求更低通信时延和更多的连接数等。传统通信与计算分离的网络架构已难以满足这些极致性能需求,为此提出了通信和计算融合的超蜂窝组网理论与架构。作为超蜂窝组网机理的最早代表,云无线接入网(cloud-radio access network, C-RAN)的核心是把传统基站的信号处理等通信功能进行分解并集中到基站池,通过基站池处的无线通信资源云计算协同处理,实现云集中化协同<sup>[1]</sup>。为了适应低时延性能需求,充分利用边缘计算和终端计算的处理能力,后续陆续提出了云边缘化协同、云集中-云边缘-终端自适应的云化协同等<sup>[2]</sup>。基于云化协同的超蜂窝体系架构打破了传统宏基站和微基站的界限,强化了终端直通、边缘计算和微基站等的资源整合与协同处理能力,实现了基站间的深度通信计算融合。

随着产业发展和技术进步,新兴应用正不断涌现,如车联网(vehicle-to-everything, V2X)、远程医疗、工业互联网(industrial Internet of things, IIoT)、增强现实/虚拟现实(augmented reality/virtual reality, AR/VR)等,对无线网络提出了新的

性能需求。第六代移动通信系统(6G)提出了如下性能目标:传输速率需达到太比特每秒(Tbit/s)级别,端到端时延需降至毫秒(ms)级甚至微秒( $\mu\text{s}$ )级,除此以外还需要具备强大的计算能力、感知能力和智能决策能力。因此,在云化协同的基础上,基于基站可提供无线射频感知功能、超蜂窝网络架构和泛在算力引发的智能化处理广泛部署于云-边-端,且自适应协同适配不同应用场景和极致性能目标需求,由此迈向感智协同,实现通信、计算、感知和智能深度融合<sup>[3]</sup>。

云化协同通过打破传统网络中通信与计算资源相互独立的局面,构建了统一的资源池和协同调度框架,实现了资源的高效利用和服务的自适应提供,不仅能够显著提升网络性能,还能为垂直行业的数字化转型提供强有力的支撑。云化协同以超蜂窝理论为核心,包含3种主要模式:云集中化、云边缘化,以及集中-边缘-终端自适应的云雾化。

云集中化协同是对超蜂窝理论的基础性继承,其核心在于通过资源池化和集中管控实现通信与计算资源的一体化调度<sup>[3]</sup>。网络将分布式的通信基站基带资源、计算服务器资源和存储资源集中部署于统一的大型云数据中心,构建逻辑统一的通算资源池,通过虚拟化技术和云原生理念将物理资源抽象为虚拟资源单元,按需为各类业务提供通信与计算协同服务。集中式架构的前传与回传链路易出现容量压力,难以适配工业控制、远程医疗等业务对低时延的刚性要求,这一性能适配矛盾推动了协同模式向边缘侧优化,促进未来无线网络架构向服务化架构(service-based architecture, SBA)演进<sup>[4]</sup>。该模式仅实现了通信与计算的集中式融合,完全缺失边缘原生感知与实时智能决策能力,无法适配6G低时延、高动态的通感一体场景需求。

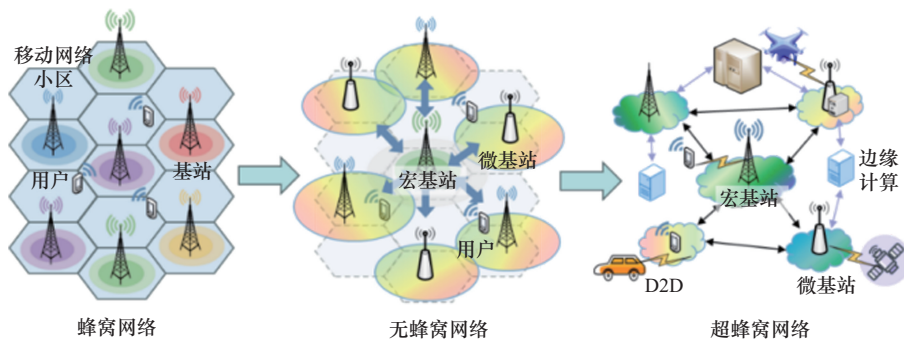


图1 移动网络架构演进

云边缘化协同作为对云集中化的优化形态,针对集中式架构在实时性业务处理方面的不足,提出了资源下沉和就近服务的设计思路,该模式继承了云集中化协同的资源虚拟化与软件定义核心思想,并改进了云集中化协同的全量资源集中部署的逻辑,转而将通算资源从核心网云中心下沉至基站侧、园区接入点、物联网网关等网络边缘节点<sup>[5]</sup>,构建分布式的边缘通算节点集群。云边缘化协同的资源调度边界相对固定,无法灵活适配业务流量的突发波动与终端高速移动带来的接入切换需求,自适应调度技术的成熟为突破这一静态局限提供了技术条件。该模式仅解决了时延的局部优化问题,未实现感知、通信、计算的跨域协同,智能化仍为外挂式,无法应对广域多节点的动态协同需求。

云雾化协同作为超蜂窝理论的进一步演进,核心创新在于打破云集中化协同与云边缘化协同的静态边界,在架构逻辑上,构建集中管控(云)、边缘(边)和终端(端)响应相结合的动态协同体系<sup>[6]</sup>,实现实时业务本地化和非实时业务云端化,从而在资源利用效率与实时性之间实现了初步平衡。云雾化协同深度继承了云集中化协同的全局资源调度能力及云边缘化和终端化协同的低时延特性<sup>[7]</sup>,通过自适应调度技术<sup>[8]</sup>,进一步实现通算资源在集中云与边缘节点间的动态部署、弹性调度与协同适配,本质上以适配协同实现全局性能的优化与均衡,使通信计算融合网络从单一目标优化转向多目标全局优化。云雾化协同的多层级协同架构会带来网络复杂度的提升,难以匹配 6G 时代对极致性能与低运维成本的双重需求,这一矛盾成为云化协同向更高阶形态演进的核心动力。该模式虽实现了云-边-端通信与计算资源的动态调度,但仍未突破“通信为主体、计算为辅助”的框架,感知能力未原生融入,智能化未形成闭环,无法支撑 6G 通信-计算-感知-智能四者深度融合的核心需求。

随着移动通信网络性能持续飞跃,其复杂度亦呈指数增长,云化协同显著提升了网络的性能和灵活性,但其多层级、多域协同的架构带来了高昂的运维成本与能耗。为从“万物互联”演进为“万物智联”,要求通算融合无线网络具备内生式的环境感知能力,而不仅是传递信息的管道,感知协同通信是实现“数字孪生”和“全域智能”的核心能力底座。此外,为破解“性能提升伴随复杂度剧增”

的顽疾,基于算力“云-边-端”泛在部署和人工智能内生设计,移动通信网络从“外挂式智能化”和“叠加式复杂化”转向“内生式智能化”与“架构级简约化”。总之,由于 6G 感知协同通信和通信智能一体化的迫切需求,云化协同将演进为感知协同<sup>[9]</sup>。感知协同的原理是依托云-边-端的泛在感知和算力体系,通过架构级简约化构建高效数据底座与执行环境,借助内生式感知和全域智能实现网络动态管理与优化,最终达成通信、计算、感知、智能深度融合的自主协同模式<sup>[10]</sup>。

架构级简约化以感知协同的核心需求为导向,针对云化协同体系多层级叠加、多域壁垒分明的固有设计进行系统性重构,通过轻量化协议栈、标准化接口与集成化功能模块,实现无线网络架构的扁平化极简重构,从根本上降低多层级交互带来的数据损耗、信令开销、运维复杂度与系统能耗,为全域感知数据高效流转、内生智能决策低时延执行构建高可靠的底层执行环境。其核心体现在 3 个维度:一是感知数据采集的“简”,通过控制与转发分离、全域接口标准化设计,消除多源感知数据的格式壁垒与交互障碍,使智能中枢可无歧义、全量、实时获取全网全域感知数据,为内生智能构建高保真、低时延的统一数据底座,支撑网络数字孪生体的构建与动态更新;二是感知驱动决策执行的“简”,依托网络功能虚拟化(network functions virtualization, NFV)与云原生架构,将网络功能元素转化为可编程、可弹性伸缩的标准化软件组件,内生智能中枢基于全域感知数据生成的决策,可通过统一编排器快速下发执行,无需人工逐台设备操作,实现从感知输入到策略执行的高效闭环,大幅降低决策时延与运维成本;三是效果评估验证的“简”,基于全域感知数据构建与物理网络实时同步的数字孪生体,可对感知协同策略进行离线仿真、验证与优化,同时基于实时感知数据持续校验策略执行效果,实现全流程轻量化验证与闭环优化。

内生式智能化以全域原生感知为输入基础,依托云-边-端泛在部署的算力体系完成内生 AI 设计,将智能算法原生嵌入网络通感一体信号处理、资源调度、故障自愈、协议适配等核心环节,通过机器学习、深度学习与自适应推理技术,构建全域感知输入、智能认知决策、通算资源优化和感知性能提升的内生闭环,实现网络状态实时感知、业务需求

预判与资源配置动态优化, 破解传统依赖人工干预的运维模式与固定规则的调度逻辑。架构级简约化对底层物理复杂性进行统一封装与抽象, 为内生智能屏蔽底层异构性; 内生智能化则基于全域感知数据, 对抽象后的通感算智4类资源进行动态协同管理。感智协同的核心目标是实现业务意图的端到端翻译与闭环保障, 当业务性能意图明确后, 智能中枢的意图引擎可自动将其拆解为可量化指标, 进而翻译为具体的网络配置策略, 通过简约化架构快速下发执行, 同时基于全域感知数据持续验证意图满足情况并自动修复性能偏差, 形成完整的意图保障闭环。此外, 基于全域感知数据与机器学习算法, 智能中枢可预测信道波动、网络故障、业务体验劣化与目标运动轨迹, 提前触发资源预配置、干扰规避等保护动作, 将网络运维从被动响应变为主动预判, 大幅提升高动态场景下网络的可靠性与服务连续性。

全域原生感知、内生式智能化与架构级简约化三者深度协同产生耦合增益, 共同构建起感智协同的核心能力体系, 使网络在传输速率、端到端时延、连接密度、感知精度等核心性能与运行效率之间实现最优均衡, 在不牺牲通信、感知、计算等核心性能指标的前提下, 最大化降低网络运行管理成本, 最小化系统全流程能源消耗。

通信计算融合无线网络从云化协同迈向感智协同, 为6G实现通信、计算、感知、智能四域深度融合, 适配车联网、AR/VR、低空经济、低轨道地球卫星 (low earth orbit satellite, LEO) 和空地一体化等新兴应用的极致性能需求提供了核心理论与架构支撑。感智协同为6G网络发展开辟了新路径, 但其全面实现仍面临一系列关键挑战: 理论层面, 需建立感知-智能-简约三者耦合的统一量化模型, 构建跨云-边-端的感智协同性能界限理论;

技术层面, 感知驱动的轻量化内生AI算法设计、通感一体极简协议栈优化、跨域意图理解、智能与安全一体化融合等问题亟待突破; 应用层面, 面向低空经济、空地一体化等高动态广覆盖场景, 感智协同能力的快速部署、高效运维与场景化适配, 仍需深入地探索与验证。如何应对这些挑战, 将是未来该领域研究的重点方向。

## 1 通信计算融合网络理论性能研究

传统无线网络以蜂窝理论为基础, 目的在于优化网络容量。然而, 随着通信与计算从分离走向深度融合, 网络性能指标扩展为容量、时延等多种维度, 影响性能的因素愈发繁杂且呈现非独立、非均匀的复杂分布。特别在引入协同处理与动态管控后, 如何按需实现容量与时延性能的最优均衡, 更缺乏系统性的理论指导。为此, 业界对通信计算融合网络理论性能的研究从云集中化切入, 首先提出了云集中化协同理论, 目的在于通过资源集中管控换取全局利用效率的最大化。为了适应网络需求的动态变化, 进一步聚焦于中心云与边缘节点和终端间资源的灵活部署、弹性调度与适配协同, 从云-边两者之间的层协同发展出云雾体协同; 雾的内涵是面向边-端-业的通感算一体化处理, 云边层协同演进为面向云与边-端-业的通感算一体协同, 从而进一步提升容量、时延和感知性能, 并实现这些极致性能的自适应优化。张平院士率先提出将AI与无线网络结合的“智简”理论<sup>[9]</sup>, 为通算融合网络的下一阶段演进指明了方向, 感智协同作为该理论的核心实践形态, 目标是借助智能化手段进一步突破传统性能边界, 为多维度性能优化与网络复杂度控制的平衡提供了关键理论支撑。

### 1.1 云集中化协同理论性能分析

云集中化协同如图2所示, 通过将多个基站的基带处理任务汇聚至统一的基带处理单元 (base-

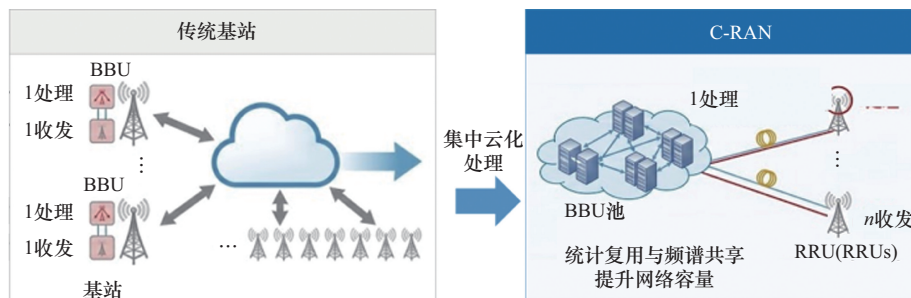


图2 云集中化协同

band unit, BBU) 资源池, 使计算需求在不同小区和不同时段之间实现统计复用, 从而实现频谱资源共享和统一管理, 能够极大地提升无线网络容量性能<sup>[11]</sup>。图2明确了基带处理功能集中化的核心逻辑, 展示了传统基站功能分解后, 通过BBU池实现RRH资源的统计复用与频谱共享, 体现了集中管控提升资源利用率的趋势。

云集中化协同理论聚焦于分析网络容量性能与协作规模、节点密度、天线数等关键参数间的尺度规律。文献[12]给出了 $N$ 个射频频拉远单元(remote radio unit, RRU)云集中化协同下的遍历容量上界为:

$$C_{\text{NRRH}}^{\text{Upper}} \approx \Gamma - \sum_{j=0}^{\infty} \frac{1}{(j+1)(2j+1)} + \ln \frac{L\rho\pi^3\lambda^4}{4} \quad (1)$$

其中,  $\Gamma$ 为欧拉常数,  $\rho = \frac{P}{\sigma^2}$ 为发送功率与噪声功率的比值,  $\lambda$ 为RRU的节点密度,  $L$ 为天线数量。可以看出云集中化协同下网络容量性能随着RRU节点密度及RRU天线数量增加而单调递增, 且容量的增长趋势逐渐减缓, 揭示了云集中化网络资源规模与网络容量之间的量化关系。

以最大化容量为目标的云集中化协同理论局限也十分显著, 由于边缘的原始数据全部需要回传至云端集中处理, 回传链路和前传链路容量会极大影响网络的时延性能。为此, 业界进一步基于有效带宽理论, 提出了有效容量指标, 用于衡量时延约束下的云集中化协同网络最大可达通信容量<sup>[13]</sup>。有效容量指标的导出基于假设存在一个无限大的队列, 在业务源具有恒定的到达率时, 有效容量可以表示为:

$$E(\theta) = -\lim_{t \rightarrow \infty} \frac{1}{\theta t} \ln \mathbb{E} \left\{ e^{-\theta S(t)} \right\} \quad (2)$$

其中,  $\mathbb{E} \{ \cdot \}$ 表示期望算子;  $S(t) = \sum_{\substack{0=t_0 < t_1 < \dots < t_n = t \\ \dots < t_{n-1} < t_n = t}} r(\tau) d\tau$

表示在时间间隔 $[0, t]$ 上通过无线信道以比特为单位传送的服务数据;  $r(\tau)$ 表示在时间 $\tau$ 处的信道容量; 参数 $\theta$ 为正的服务质量指数, 用于量化时延约束的严格程度。可以看出, 有效容量指标为网络服务质量和无线信道容量建立了联系。进一步地, 从排队论角度看,  $\theta$ 也可以被定义为具有随机队列长度 $Q$ 的尾部分布的衰减率, 表达式为:

$$\theta = \lim_{q \rightarrow \infty} \frac{\ln \Pr \{ Q > q \}}{q} \quad (3)$$

其中, 较小的 $\theta$ 意味着较宽松的时延要求, 基于式(2)和式(3), 有效容量可以进一步表示为<sup>[14]</sup>:

$$E(\theta) = -\frac{1}{\theta \bar{T}} \ln \mathbb{E} \left[ (1 + \gamma)^{-\mu \theta \bar{T}} \right] \quad (4)$$

其中,  $\bar{T} = \frac{T}{\ln 2}$ ,  $\gamma$ 表示信干噪比,  $W$ 为信道带宽,  $\mu$ 为信道衰落系数。进一步地, 由于回传链路和前传链路容量受限, 为了满足端到端时延约束, 无线接入链路所需要的服务质量指数可以进一步表示为:

$$\theta = \frac{1}{1 - \frac{2B}{D_{\max} C}} \theta_s \quad (5)$$

其中,  $\theta_s$ 表示如果不存在前传和回传时延的参考服务质量指数,  $D_{\max}$ 表示系统允许的最大端到端时延,  $C$ 表示前传或回传链路容量,  $B$ 表示数据包的大小,  $2B$ 指代通过前传和回传链路的双向开销导致的数据量。将式(5)代入式(4)中, 可以得到网络考虑前传和回传链路容量的有效容量, 可以看出, 前传容量越小, 留给空口的容错空间越小, 对空口的服务质量指数要求越高。

此外, 云集中化协同通过在低负载时段关闭部分处理单元, 在理论上能够进一步提升无线接入网的能量效率等性能, 为通信计算融合网络中引入计算密集型业务提供了能效保障。尽管云集中化协同在静态场景下提升了容量, 但在高动态场景中其局限性日益凸显。该架构依赖全量状态信息回传, 导致高昂的信令开销与时延。

## 1.2 云雾化协同理论性能分析

为了自适应满足差异化业务的不同极致性能需求, 通信计算融合网络进一步向增强资源灵活部署、弹性调度与适配协同方向演进, 相应的云雾化协同理论应运而生。其核心在于将原有的“云-边缘协同”集中式处理模式, 扩展为面向云计算与边缘、终端、业务的通感算一体化的“云-雾体协同”, 从而在系统层面针对巨容量、极低时延、精准和广域感知等极致性能自适应不同的网络体系架构和关键技术。图3展示了云边缘协同向云雾体协同的扩展逻辑, 相应的云雾化协同理论的研究推动通信计算融合网络理论从分析网络参数对单一目标的量化影响, 转向揭示多目标之间全局均衡的内在机理, 为构建动态的通信计算融合网络提供了重要理论基础。

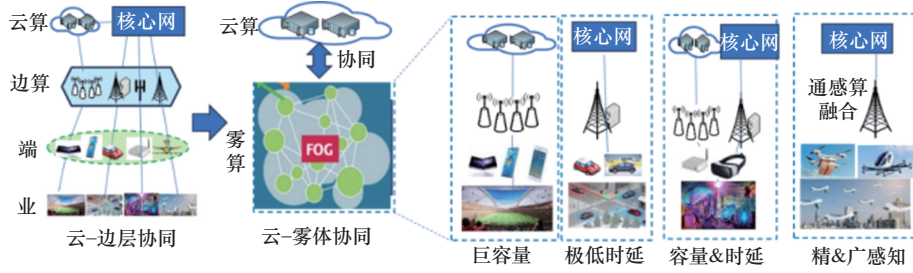


图3 云雾化协同(从云边层协同演进为云雾体协同)

云雾化协同理论可分为3个主要方向：(1) 性能均衡理论，分析采用不同接入模式下，网络容量、时延与回传链路容量之间的量化关系；(2) 资源置换理论，分析云雾化协同下不同网络性能间的折中表达式，从而揭示资源间的置换关系；(3) 联合优化理论，聚焦资源约束下为每个任务选择最优处理位置，从而实现通信-计算性能联合全局帕累托最优。

对于性能均衡，文献[15]给出了在最大参考信号接收功率 (reference signal receiving power, RSRP) 接入与最低时延接入两种模式下云雾化协同容量与时延性能的表达式。

对于最大 RSRP 接入模式，云雾化协同容量与时延性能的表达式分别为：

$$C_{\text{RSRP}} = P_F(\lambda_F, \lambda_R, k) \sum_{i=1}^L E(\theta_i^F) + [1 - P_F(\lambda_F, \lambda_R, k)] \sum_{i=1}^L E(\theta_i^C) \quad (6)$$

$$D_{\text{RSRP}} = P_F \left[ \frac{L}{E(\theta_i^F) - \rho_F} + (1 - p_{\text{hit}}) D_{\text{back}} \right] + (1 - P_F) \left[ \frac{L}{E(\theta_i^C) - \rho_R} + D_{\text{front}} \right] \quad (7)$$

其中， $P_F(\lambda_F, \lambda_R, k)$  表示进行边缘处理的概率， $1 - P_F$  表示采用云集中化处理的概率， $\lambda_F$  和  $\lambda_R$  分别表示雾节点和 RRU 的分布密度， $k$  与两种节点发送功率比值相关； $E(\theta_i^F)$  和  $E(\theta_i^C)$  分别表示边缘处理和云集中化处理的有效容量， $p_{\text{hit}}$  表示用户成功命中边缘缓存数据的概率， $D_{\text{back}}$  和  $D_{\text{front}}$  分别代表回传链路和前传链路的时延， $\rho_F$  和  $\rho_R$  分别代表边缘和云处理的流量密度， $L$  为传输数据包的大小。

对于最低时延接入模式，云雾化协同容量与时延性能的表达式分别为：

$$C_{\text{Delay}} = \sum_{i=1}^L E(\theta_i, \gamma_n = \max_{x \in \Phi} \gamma_x) \quad (8)$$

$$D_{\text{Delay}} = P_F \frac{L}{E(\theta_i^F) - \rho_F} + P_F \left[ \frac{L}{E(\theta_i^F) - \rho_{\bar{F}}} + D_{\text{back}} \right] + (1 - P_F - P_{\bar{F}}) \left[ \frac{L}{E(\theta_i^C) - \rho_R} + D_{\text{front}} \right] \quad (9)$$

其中， $\Phi$  为所有节点的集合。式(8)和式(9)分别揭示了云雾化协同容量  $C_{\text{Delay}}$ 、时延  $D_{\text{Delay}}$  与边缘缓存、节点密度、回传链路约束间的内在规律，阐明了对不同业务需求可采用不同的接入模式以换取容量和时延的均衡。

最大允许时延  $D$  与集中度  $r$  和速率  $\mu$  密切相关，相互间的制约关系可以表示为：

$$D = \begin{cases} \frac{1 - 2\mu}{r}, & \mu \in [0, \mu_1 = \frac{1 - r}{2 + r}] \\ \frac{2 - \mu}{1 + r}, & \mu \in [\mu_1, \mu_2 = 1 - r] \\ 1, & \mu \in [\mu_2, 1] \end{cases} \quad (10)$$

其中， $\mu_1$  和  $\mu_2$  为两个关键速率阈值，其定义分别为  $\mu_1 = \frac{1 - r}{2 + r}$  和  $\mu_2 = 1 - r$ 。这两个阈值将速率区间划分为3个部分，分别对应不同的时延变化规律：当速率较低时，即  $\mu \leq \mu_1$ ，时延随  $\mu$  增加而快速下降；当速率中等时，即  $\mu > \mu_1$  且  $\mu \leq \mu_2$ ，时延以另一线性关系下降；当速率较高时，即  $\mu > \mu_2$ ，时延保持为常数1，不再随速率变化。

式(10)精确地反映了容量-时延制约关系，并展示了不同云集中化  $r$  程度下的时延性能变化规律。随着  $\mu$  增加，最大允许时延  $D$  逐渐减小并最终趋于稳定值1， $\mu$  接近0时，最大允许时延对集中化程度  $r$  极为敏感。 $r$  越小，意味着云集中化程度越高，最大允许时延  $D$  初始值越大，例如  $r = 0.2$  时  $D = 5$ ， $r = 0.8$  时  $D = 1.25$ 。当  $\mu$  接近1时，所有曲

线汇聚于  $D = 1$ ，表明拖尾效应显著，最大允许时延性能与云集中化程度无关。

对于资源置换性能，在云雾化协同网络中通信和计算共用资源存在竞争和增强关系：一方面实时高效的计算能力可以帮助系统更好地处理数据，提高通信性能；另一方面会产生额外的时延、系统开销和能耗，从而降低系统的能效和增加网络平均时延。需要根据具体的场景和需求，合理调整和平衡通信容量、时延、能耗等关键参数，以实现系统的最优性能。为此，文献[16]给出了云雾化协同网络中能效与无线通算资源间的表达式，即：

$$\eta_{EE}(t) = \frac{\alpha}{K_R} \sum_{k=1}^{K_R} \omega_k R_k(t) - \frac{1-\alpha}{N} \sum_{n=1}^N \mu_n P_n(t) \quad (11)$$

其中， $\alpha$  表示权重因子，用于控制传输速率与功率消耗在优化目标中的相对重要性， $\alpha$  越大，系统越倾向于追求高吞吐量， $\alpha$  越小，系统越倾向于节能；等号右边第一部分代表加权平均和速率， $K_R$  表示服务区域内的用户总数， $\omega_k$  代表第  $k$  个用户的传输权重，通常代表用户的优先级或服务要求， $R_k(t)$  为第  $k$  个用户在  $t$  时刻的传输速率；等号右边第二部分代表加权平均总功耗， $N$  代表网络中基站的总数， $\mu_n$  为第  $n$  个基站的功耗权重， $P_n(t)$  为第  $n$  个基站在  $t$  时刻的总功率消耗。

为了解决非凸的长期平均能效最大化问题，引入李雅普诺夫优化框架，通过构造虚拟队列将长期约束转化为每个时隙的瞬时优化问题。首先定义虚拟队列  $Q_k(t)$  表示时延约束累积违背，即：

$$Q_k(t+1) = \max\{Q_k(t) - R_k(t) + A_k(t), 0\} \quad (12)$$

其中， $A_k(t)$  代表第  $k$  个用户在第  $t$  个时隙的业务到达量。同理，定义功率虚拟队列  $H_n(t)$ ，反映平均功率约束的累积违背情况，即：

$$H_n(t+1) = \max\{H_n(t) - P_n^{avg} + P_n(t), 0\} \quad (13)$$

基于式(6)的目标，每一时刻的优化目标不是简单的能耗与时延的加权，而是最大化能效收益与队列稳定收益之和，等价于最小化以下目标函数，即：

$$\min_{a_k(t), b_k(t), \dots} \left\{ \sum_{n=1}^N \left[ H_n(t) + \frac{V(1-\alpha)\mu_n}{N} \right] P_n(t) - \sum_{k=1}^{K_R} \left[ Q_k(t) + \frac{V\alpha\omega_k}{K_R} \right] R_k(t) \right\} \quad (14)$$

其中， $a_k(t), b_k(t), \dots$  代表网络通算资源的调配，系

统参数  $V$  控制着能效与时延之间的置换比例。系统性能满足以下理论界限，即：

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}[\eta_{EE}(t)] \geq \eta_{EE}^{opt} - \frac{B}{V} \quad (15)$$

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \sum_{k=1}^{K_R} \mathbb{E}[Q_k(t)] \leq \frac{B + C + V(\eta_{EE}^{max} - \eta_{EE}^{opt})}{\epsilon} \quad (16)$$

其中， $B$  是一个有限正常数，用于界定李雅普诺夫漂移的上界； $C$  代表加性近似常数； $\epsilon$  是一个正实数，代表业务到达率向量距离网络容量区域边界的距离。式(15)表示平均能效下界，指出了平均能效可以无限逼近理论最优值  $\eta_{EE}^{opt}$ ，差距为  $O(V^{-1})$ ，且  $V$  越大，能效越高。式(16)表示平均时延上界，指出了平均队列长度与  $V$  成线性正比关系  $O(V)$ ，且  $V$  越大，能效越高。理论表达式揭示了通算资源对性能的置换关系，从而为优化求解时延与能耗折中均衡点提供理论支撑。

对于联合优化性能，云雾化协同引入了管控处理，高效实时逼近最优决策。但无线网络的数据和算力时空高动态，导致云雾化协同决策时延长、能耗性能受损。为此，文献[17]给出了管控处理业务集中分布自适应下系统时延与通信、计算能耗的联合表达式，定义系统总代价  $C_{m,n}$  为任务处理时延与能耗的加权和，该代价函数可表示为：

$$C_{m,n} = \theta_D D_{m,n} + \theta_E E_{m,n} \quad (17)$$

其中， $m$  指示第  $m$  个用户； $n$  指示第  $n$  个任务； $\theta_D$  和  $\theta_E$  分别为时延和能耗的归一化权重系数，且  $\theta_D + \theta_E = 1$ ； $D_{m,n}$  和  $E_{m,n}$  分别表示任务在选定模式下的总时延与总能耗。定义卸载决策变量  $x_{m,n}^i \in 0, 1$ ，其中， $i \in L, F, C$  分别代表终端、边缘与云模式，总时延与总能耗的具体构成分别为：

$$\begin{aligned} D_{m,n} &= x_{m,n}^L D_{m,n}^L + x_{m,n}^F D_{m,n}^F + x_{m,n}^C D_{m,n}^C \\ E_{m,n} &= x_{m,n}^L E_{m,n}^L + x_{m,n}^F E_{m,n}^F + x_{m,n}^C E_{m,n}^C \end{aligned} \quad (18)$$

对于终端计算模式，任务完全在用户终端本地执行，总能耗和总时延分别为：

$$E_{m,n}^L = \eta_{L,m} B_{m,n} (f_{L,m})^2 \quad (19)$$

$$D_{m,n}^L = \frac{\mu_{L,m} B_{m,n}}{f_{L,m}} \quad (20)$$

其中，能耗和时延均来自本地计算， $B_{m,n}$  表示任务的数据量大小， $f_{L,m}$  表示终端算力， $\mu_{L,m}$  为处理单位数据量所需的终端算力， $\eta_{L,m}$  代表终端计算服务器

的有效开关电容系数。

对于边缘计算模式,任务通过接入链路卸载至边缘节点执行,包含传输与计算两个阶段,总能耗和总时延分别为:

$$E_{m,n}^F = P_m \frac{B_{m,n}}{R_m} + \eta_F B_{m,n} (f_F)^2 \quad (21)$$

$$D_{m,n}^F = \frac{B_{m,n}}{R_m} + \frac{\mu_F B_{m,n}}{f_F} \quad (22)$$

其中,  $f_F$  表示边缘节点算力,  $\eta_F$  代表边缘节点计算服务器的有效开关电容系数,  $\mu_F$  为处理单位数据量所需的边缘节点算力,  $P_m$  为用户的发送功率,  $R_m$  为用户的传输速率。

对于云计算模式,任务经由雾计算,然后通过回程链路卸载至云中心,包含接入传输、回程传输与云计算3个阶段,总能耗和总时延分别为:

$$E_{m,n}^C = P_m \frac{B_{m,n}}{R_m} + P_T \frac{B_{m,n}}{R_T} + \eta_C B_{m,n} (f_C)^2 \quad (23)$$

$$D_{m,n}^C = \frac{B_{m,n}}{R_m} + \frac{B_{m,n}}{R_T} + \frac{\mu_C B_{m,n}}{f_C} \quad (24)$$

其中,  $f_C$  表示云算力,  $\eta_C$  代表云中心计算服务器的有效开关电容系数,  $\mu_C$  为处理单位数据量所需的云算力,  $P_T$  为边缘节点的发送功率,  $R_T$  是边缘节点的传输速率。式(23)和式(24)可用于评估云雾化协同决策的有效性和能效增益,进而能够将复杂的联合优化问题转换为时延约束下最大化能效,以及在功耗约束下最小化时延等子问题,通过求解相应的优化问题找到云雾化协同最佳工作点。

总之,云雾化协同理论构建起了通信计算融合无线网络的动态协同理论体系,通过资源抽象实现了不同类型、不同位置资源的逻辑一体,从而实现资源的动态调度,解决供需错配问题,实现多性能目标全局与局部的性能均衡。但是,云雾化协同虽然引入了边缘计算以降低时延,但其本质仍是基于规则的资源重新规划,这种多层级架构导致了网元接口激增与协议栈冗余。在面对6G全域覆盖与极致性能需求时,这种协同方式会导致系统复杂度呈指数级上升,即边际效应递减。

### 1.3 感智协同理论性能分析

云化协同与云雾化协同理论为通算融合网络的性能分析奠定了重要基础,通感算融合理论则通过纳入感知维度,为网络从“云化协同”向“感智协同”演进提供了奠基性理论框架。随着网络向感智

协同的深度发展,理论分析范式需从固定式资源优化向意图保障与自主进化转变。感智协同对网络性能的影响体现在两个方面:一是决策机制从基于模型和规则的显式优化,转变为基于数据与学习的隐式适配;二是系统设计目标从追求单一或加权性能指标的极致,转向追求在满足业务多性能需求下的复杂度和能耗的全局最小化。

为量化评估感智协同中架构级简约化的实际效能,定义网络简捷度  $\mathbf{J}$  为多维度量向量,该指标是感智协同打破云化协同多层级壁垒、实现通感算智资源高效协同的核心量化依据。

$$\mathbf{J} = [J_{\text{layer}} J_{\text{signal}} J_{\text{interface}}]^T \quad (25)$$

其中,  $J_{\text{layer}} = \frac{N_{\text{ref}}}{N_{\text{proto}}}$  表示协议栈层级精简比,量化

协议栈层级裁剪的实际效果,  $N_{\text{proto}}$  为感智协同架构协议层数,  $N_{\text{ref}}$  为云化协同参考架构层数,其核心价值在于通过协议栈轻量化适配通感一体信号处理的端到端低时延需求,消除通信与感知数据跨层流转的协议壁垒;  $J_{\text{signal}} = 1 - \frac{O_{\text{sig}}}{O_{\text{ref}}}$  表示信令开销降

低率,  $O_{\text{sig}}$  为感智协同架构信令数,  $O_{\text{ref}}$  为云化协同参考信令数,反映感智协同架构对感知数据交互、智能决策下发流程中信令冗余的优化能力,数值越接近1表示信令开销压缩效果越显著;

$J_{\text{interface}} = 1 - \frac{N_{\text{if}}}{N_{\text{ref-if}}}$  表示网元间标准化接口数量精简比,表征网元接口的标准化与精简程度,数值越大说明接口冗余越少、通感算智资源跨域交互效率越高,  $N_{\text{if}}$  为感智协同架构标准化接口数量,  $N_{\text{ref-if}}$  为云化协同参考标准化接口数量。

$\mathbf{J}$  的各分量越趋近于1,架构越简约,越能为全域感知数据的高效流转与内生智能决策的低时延执行提供底层支撑。实际分析中可采用线性加权得到简捷度综合标量值,闭式表达为  $J_{\text{com}} = \omega_1 J_{\text{layer}} + \omega_2 J_{\text{signal}} + \omega_3 J_{\text{interface}}$ , 其中  $\omega_1$ 、 $\omega_2$ 、 $\omega_3$  为各分量权重,满足  $\omega_1 + \omega_2 + \omega_3 = 1$ , 权重根据场景对架构简约、信令优化、接口精简的需求优先级设定。综合标量  $J_{\text{com}} \in (0,1]$ , 值越接近1,代表网络整体的简约化水平越高,架构运行与运维的复杂度越低。

感智协同的本质数学目标,是通过感知赋能智能、智能驱动简构、简构反哺通感的内生闭环,实现系统全维度熵减<sup>[18]</sup>。

$$\min_{\Theta} H_{\text{total}} = H_{\text{info}} + H_{\text{complexity}} + H_{\text{energy}} \quad (26)$$

其中,  $H_{\text{total}}$  为系统总熵, 涵盖信息熵  $H_{\text{info}}$ 、复杂度熵  $H_{\text{complexity}}$  与能量熵  $H_{\text{energy}}$  3 个维度;  $\Theta$  为系统优化参数集合, 包含 AI 模型参数、网络架构参数、通感算智资源分配策略等。式(26)明确了以感育智和以智减熵的核心逻辑。其中, 信息熵不仅包含传统通信传输的信息不确定性, 还纳入了全域感知数据的信息熵, 通过内生智能实现感知数据的价值挖掘与无效信息过滤, 降低冗余数据传输带来的信息熵增量; 复杂度熵对应通感算智四域协同带来的系统求解复杂度与运维复杂度, 通过架构简约化消除云化协同多层级交互的复杂度, 通过内生智能将通感算智多维度联合优化问题转化为低复杂度的智能决策问题, 实现复杂度熵的持续降低; 能量熵涵盖感知发射、通信传输、信号处理、智能计算全流程的系统能耗, 通过感智协同实现资源的适配与按需调度, 最小化无效能耗带来的能量熵增量。

为避免感智协同设计中出现智能冗余或过度简化的极端情况, 同时保障感知、智能、简约三者的协同耦合增益, 提出感智协同的核心效能约束关系<sup>[19]</sup>, 即:

$$G_{\text{sensi-intelli}} \times \eta_{\text{concise}} \geq \text{Const} \quad (27)$$

其中,  $G_{\text{sensi-intelli}}$  为感知赋能的内生智能增益系数, 用于量化全域感知数据支撑下, AI 对系统通信、感知、计算综合性能的提升倍数, 核心反映感知与智能的闭环协同效能;  $\eta_{\text{concise}}$  为适配通感算智融合的系统简约度;  $\text{Const}$  为系统最低效能保障阈值, 确保感知、智能与架构简约三者相互促进而非相互制约。式(27)明确了感智协同的核心设计准则: 感知是内生智能的输入基础, 架构简约是智能能力落地的执行支撑, 三者必须形成耦合协同, 才能在不牺牲系统核心性能的前提下, 实现复杂度与能耗的全局优化。

式(25)和式(26)为感智协同的性能量化提供了底层支撑, 与后文定义的感智协同度共同构成感智协同理论的数学体系。为进一步量化评估感智协同的核心能力, 定义感智协同度  $I$ , 表征全域感知与内生智能的融合深度, 以及智能决策对通感算智资源的协同管控能力, 是衡量感智协同水平的核心量化指标, 即:

$$I = \alpha A_{\text{sensi-intelli}} + \beta R_{\text{auto-sche}} + \gamma C_{\text{adapt-conv}} \quad (28)$$

其中,  $A_{\text{sensi-intelli}}$  为感知-智能闭环匹配度, 量化全域感知数据对内生智能决策的支撑精度, 包括环

境、信道、目标、业务状态的感知准确率, 感知数据与智能模型输入的匹配度, 以及感知数据驱动的智能决策有效率;  $R_{\text{auto-sche}}$  为感智驱动的通感算智资源调度自动化率, 量化内生智能基于感知结果, 对通信、感知、计算、智能算力 4 类资源的协同调度、故障自愈与策略执行的自动化比例;  $C_{\text{adapt-conv}}$  为感智协同策略自适应收敛速度, 量化面对高动态场景时, 感智协同策略基于实时感知数据完成自适应优化的收敛效率;  $\alpha$ 、 $\beta$  和  $\gamma$  为权重系数, 采用场景化优先级标定与层次分析法相结合的方式确定, 取值需匹配具体应用场景的性能需求。感智协同度  $I$  的数值越高, 代表感知与智能的融合深度越深、智能决策对通感算智资源的管控能力越强, 网络自主协同与动态适配的水平越高。低时延、高可靠场景如车联网、应急通信, 需提升资源调度自动化率的权重占比; 高精度感知场景如 LEO 对地观测、低空安防, 需加大感知-智能闭环匹配度的权重; 高动态场景如低空无人机集群协同、卫星高速过境, 需提高策略自适应收敛速度的权重。

感智协同并非单纯追求传统通信容量或时延性能指标的提升, 而是重新定义了给定网络简捷度  $J$  和感智协同度  $I$  约束下的通感算智联合有效性能的上界。考虑一个包含感智协同增益与简约损耗的联合模型, 感智协同架构下的通感联合有效容量  $C_{\text{ISIC}}(J, I)$  可表示为:

$$C_{\text{ISIC}}(J, I) = C_{\text{ISAC}}^{\text{Upper}}(1 + f(I))g(J) \quad (29)$$

其中,  $C_{\text{ISAC}}^{\text{Upper}}$  为前文所定义的云化协同架构下感智一体场景遍历容量的上界; 函数  $f(I) \geq 0$  代表感智协同带来的通感联合性能增益, 其增益来源包括基于全域感知结果的精准信道预测与干扰避免带来的通信容量提升, 基于通信信道信息赋能的感知目标参数估计精度提升, 基于内生智能的通感算智资源动态调度实现的二者协同增益, 其具体形式取决于感智协同度与智能算法效能; 函数  $0 < g(J) \leq 1$  代表架构简约化可能引入的性能损耗因子, 例如协议功能合并、接口精简可能损失的部分编码增益或处理自由度。感智协同的通感联合有效容量由云化协同基础通感容量、感智协同内生增益、架构简约化损耗共同耦合决定, 将网络感智协同水平与架构简约程度同步纳入性能评估体系。模型实现了感智三者之间的量化耦合, 当  $(1 + f(I))g(J) \geq 1$  时, 感智协同带来的通感联合性能增益, 可完全补偿甚至超越架构

简约化的潜在损耗,此时感智协同在降低网络复杂度与运维成本的同时,能同步提升通信容量与感知精度,这也是感智协同架构设计的核心判定准则。

为进一步验证感智协同模型在高动态场景下的有效性,本文针对低空无人机集群典型应用场景开展数值仿真分析,对比云集中化协同、云雾化协同、无感知辅助感智协同、全域感知辅助感智协同 4 种架构模式,在归一化信令开销、端到端时延、系统算力能效 3 项核心指标上的性能差异,不同协同方式通算融合网络的信令开销、端到端时延和算力能效分析分别如图 4、图 5 和图 6 所示。本次仿真基于 1 000 m×1 000 m×300 m 低空三维区域构建场景,地面呈正三角形部署 3 个 64 天线宏基站,单天线无人机集群规模设置为  $N_{UAV} = 10$  至  $N_{UAV} = 100$ ,模拟不同网络负载下的系统性能表现。信道模型采用 3GPP TR 38.901 Urban Macro 低空场景标准模型,载波频率设置为 3.5 GHz,系统总带宽 100 MHz,前传/回传链路受到 10 Gbit/s 的带宽容量限制,基站最大发射功率 43 dBm,无人机终端发射功率 23 dBm,噪声功率谱密度为 -174 dBm/Hz。云端数据中心最大有效信息处理能力为 256 Tbit/s,单地面宏基站边缘节点最大有效信息处理能力为 32 Gbit/s,单无人机机载终端最大有效信息处理能力为 2 Gbit/s,单字节感知数据基础处理的能效损耗为 0.003 Mbit/J,边缘节点、终端设备的算力能效基准值分别为 15 Mbit/J、12 Mbit/J,云端通用处理节点的能效基准值为 5 Mbit/J。




图 4 信令开销分析




图 5 端到端时延分析




图 6 算力能效分析

4 类对比架构采用差异化计算任务调度模式:云集中化协同将全量任务卸载至云端处理,云雾化协同采用实时任务就近接入边缘处理、非实时任务云端处理,感智协同采用云-边-端的三级协同算力调度。业务模型采用泊松到达的上行感知数据回传、下行控制信令传输混合业务模式,数据包到达率为 10~100 数据包/s,其中控制信令和计算任务结果数据包固定为 128 B,感知数据包大小在 128~1 500 B 动态调整,并根据 30% 概率随机设置为实

时业务，其余为非实时业务。算法层面，感智协同架构采用 Dueling DQN (dueling deep Q-Network) 架构的深度强化学习算法，通过内生智能决策实现带宽资源分配和算力节点选择，算法设置 24 维状态空间，包括无人机位置、信道环境和业务类型，8 维动作空间对应梯度化带宽分配策略和算力节点选择。无人机轨迹预测模块采用隐藏层维度为 64 的 LSTM (long short-term memory) 时序预测模型，以连续时隙的无人机运动数据为输入，输出未来时隙的位置，为资源预配置提供先验信息；通感联合性能增益基于本文指数饱和模型量化，闭式表达式为  $f(I) = 1 + 0.6(1 - e^{-0.04N_{UAV}})$ ，以此表征多无人机协同感知的边际效用递减规律。仿真结果表明，在信令开销方面，云雾化协同随用户规模增加开销逐渐升至 0.95 左右；全域感知辅助的感智协同得益于架构简洁化与内生智能轨迹预测机制，实现零信令切换与先验式资源预留，将开销稳定收敛于 0.45~0.50，有效验证了以感育智和以智换简的增益。在端到端时延方面，不同于云集中化协同因回传链路拥塞导致的时延线性激增，全域感知辅助的感智协同基于实时感知状态实现通感算任务的主动预判与算力匹配，在重负载下仍将平均时延稳定控制在 15~20 ms，体现了高动态业务下的实时响应能力。在系统算力能效方面，全域感知辅助的感智协同通过精准识别有效业务需求，显著提升能效，成功实现了系统有效信息处理能力的最大化。

## 2 通信计算融合网络云化协同关键技术

通信计算融合云化协同理论打破了传统通信与计算理论的隔阂，指导了融合体系架构设计与关键技术的研究。云化协同理论的发展，催生并指导了一系列关键技术的突破，构成了通信计算融合无线网络的近期实践基础。然而，随着网络向感智协同阶段演进，这些技术也面临新的挑战与进化需求。本节围绕通信计算融合无线网络的云化协同体系架构、云化协同信号处理、云化协同通算资源调度、云化协同算力编排技术等进行系统描述，概述其演进脉络、核心原理与研究现状等，并分析其如何支撑未来感智协同，从而揭示技术体系从“云化”向“感智”演进的内在逻辑与必然趋势。这 4 项技术相互支撑形成闭环，架构提供部署基础，算力编排

整合异构资源，资源调度实现精准分配，信号处理完成核心执行并反馈优化需求。

### 2.1 云化协同体系架构

传统无线网络架构主要围绕通信业务需求展开，采用静态、固化的分层体系，难以适应人、机、物业务多样化及服务场景动态变化的挑战。然而，受早期算力与通信处理能力的限制，为满足大容量、高性能的网络需求，通常需要依赖大规模协作信号处理与集中式计算。因此，集中式云化协同成为最初推动通信与计算融合的重要思想，由此催生了云无线接入网络的设计理念。云集中化协同网络架构如图 7 所示，C-RAN 通过解耦传统基站的信号处理功能，在边缘 RRU 节点只保留射频及底层物理层功能，其他高层功能全部集中至基带处理池，并通过大规模信号处理抑制干扰，提升组网容量与资源利用效率，也有效降低了网络运营成本。




图 7 云集中化协同网络架构

为破解这一难题，业界进一步提出将控制平面与用户平面分离的异构云无线接入网 (heterogeneous cloud radio access network, H-CRAN) [20]，它以宏基站承载广覆盖的控制面功能，以密集部署的灵巧小基站承载高容量业务面功能，并通过资源协同调度，优先将高速移动用户卸载至宏基站。尽管 H-CRAN 通过将部分业务面和控制面功能下沉至网络边缘，在一定程度上平衡了网络负载，但其边缘节点（如灵巧基站与 RRU）与云中心之间仍主要依赖集中式协同交互，前传链路的容量与时延瓶颈并未得到根本解决[21]。

基于云雾化协同理论的雾无线接入网络 (fog radio access network, F-RAN) 架构，进一步突破了前两类架构的静态资源调度局限，核心是充分挖掘边缘-业的通信、计算与感知能力，构建通感算一体化的灵巧雾基站 (fog access point, F-AP)，推动雾基带功能全软件化与接入网功能全虚拟化，实现网络性能的全局优化[7]。F-RAN 将核心网网络切片技术延

伸至无线接入网,可柔性适配超大容量与极低时延的差异化业务场景。云雾化协同网络架构如图8所示,其硬件层深度融合NFV与软件定义网络(sdn)技术,解耦硬件与软件的紧耦合关系,构建“通用+异构”的云化通算资源池<sup>[22]</sup>,通过一体化编排器实现业务需求到底层资源的端到端映射,可依托“通用硬件+加速器”组合满足实时性业务的硬件加速需求<sup>[23]</sup>,并结合拉远天线技术,实现广域范围内的高容量信号覆盖。




图8 云雾化协同网络架构

面向未来感知协同体系架构演进的重点在于协同机制优化与异构资源整合,在协同机制方面,围绕资源动态迁移、任务分流与策略全局优化展开,比如实现vCU(virtual centralized unit)、vDU(virtual distributed unit)在云层与边缘层的弹性调度,依托RIC(RAN intelligent controller)完成业务在BBU池与边缘节点的分配,同时通过高速骨干链路实现BBU池与多RRU、云层与边缘层的资源弹性共享<sup>[24]</sup>;在异构资源整合方面,致力于通过新型前传接口等标准化接口,实现算力的统一抽象与调度,以此打破BBU、RRU及边缘硬件之间的资源孤岛问题。

## 2.2 云化协同信号处理技术

云化协同信号处理技术的演进与通信计算融合网络架构演进方向深度关联,可划分为以下3个典型阶段,每一阶段均致力于解决特定瓶颈并适配新的性能目标。

第一阶段为云集中化协同信号处理,以C-RAN架构为核心载体,依托云集中化协同的有效容量理论,通过跨小区、跨用户的信号联合处理实现网络

容量提升。该阶段的核心技术包括大规模协作多点传输(coordinated multiple point transmission and reception, CoMP)与干扰消除算法<sup>[25]</sup>,可利用全局信道状态信息实现近似最优的协同处理,将网络容量与频谱效率提升至传统分布式架构难以企及的高度。3GPP、O-RAN(Open Radio Access Network All-iance)联盟等组织定义的RAN功能切分方案,核心设计目标正是权衡此类集中化协同的增益与前传开销<sup>[26]</sup>。但该模式依赖全量数据回传至中心云处理,前传/回传链路带宽压力巨大,端到端时延难以保障。

第二阶段为云边协同信号处理,适配H-CRAN架构的分层设计,核心是通过更灵活的功能切分缩短传输路径,贴合时延约束下的有效容量优化理论。该阶段将对时延敏感<sup>[27]</sup>、计算量相对较小的信号处理功能下沉至边缘分布式单元DU(distributed unit)节点,将计算密集、非实时性的复杂处理保留在中心云<sup>[28]</sup>,形成“中心优化,边缘执行”的协同模式,在保持协同增益的同时,有效缓解了传输瓶颈,为实时性业务支撑奠定了基础。

第三阶段为云雾化协同信号处理,对应F-RAN架构的全场景适配需求,核心是实现通信、感知、计算三重异构任务的全局最优均衡,贴合云雾化协同的联合优化理论<sup>[29]</sup>。该阶段在信号设计上,采用通感一体的普适帧结构与波形,实现资源的动态共享<sup>[30-31]</sup>;在处理架构上,采用“云端全局策略生成、边缘实时预处理执行”的混合式流程,集中式云资源池负责全局策略生成、通感数据融合与大模型推理<sup>[32]</sup>,边缘节点承担实时信号预处理、分布式干扰协调、本地感知特征提取与AI推理等任务<sup>[33]</sup>,可灵活支撑复杂场景的通感算一体化处理<sup>[34]</sup>。例如,在Massive MIMO系统中,云端可通过全局信道估计与用户调度,设计接近最优的多用户波束赋形矩阵,将网络频谱效率提升一个数量级<sup>[35]</sup>;基于博弈论的干扰协调技术<sup>[36]</sup>,通过在限制层间干扰的约束,利用斯塔克尔伯格博弈联合优化宏小区和毫微微小区,实现有效的干扰协调,通信计算融合无线网络干扰协调算法性能<sup>[36]</sup>如图9所示。本文基于合同理论的干扰协调技术,相比传统联合频率复用和功率控制技术,以及时域干扰消除技术,取得了更优的和速率性能。




图9 通信计算融合无线网络干扰协调算法性能<sup>[36]</sup>

### 2.3 云化协同通算资源调度技术

云化协同通算资源调度技术始终围绕资源利用效率、业务适配性与响应实时性三者之间的动态平衡展开，可归纳为从静态配置到协同优化，最终实现完全可重构的最优调度。

第一阶段，集中式资源分配：C-RAN网络以集中式的资源预配置为主导，基于固定策略为通信与计算资源进行分配。该模式基于云集中化协同的资源一体化理论，通过固定策略实现资源统计复用，难以适配动态需求。这种方式缺乏对业务动态性与资源状态变化的适应能力，难以适配差异化、突发性的业务需求。第二阶段，双层协同调度：随着H-CRAN架构的兴起，资源调度技术进入双层协同阶段。其协同机制依托云雾化协同的资源置换理论，通过分层调度验证通信与计算资源的折中优化关系。该阶段通过云层全局调度与边缘层局部调度相结合，初步提升了资源调配的灵活性与业务适配能力。其核心是在宏观粗调配与微观细调配之间建立协同机制，并依托无线网络切片与多目标优化算法，初步实现了资源在时间与空间维度上的动态平衡<sup>[37]</sup>。第三阶段，云雾化协同调度：实现资源与业务需求的精准、实时匹配，调度技术演进至以云雾化协同为核心的调度阶段。该调度模式深度契合云雾化协同的联合优化理论，通过集中编排与分布优化的结合，实现全局性能与局部实时性的帕累托最优。其中集中编排部署切片编排器，基于业务类型、流量预测与全局资源视图，对算力、带宽、频谱等资源进行宏观规划与粗粒度调配，致力于全局性能优化<sup>[38]</sup>。分布优化在边缘节点部署本地调

度器，依据实时业务请求与局部资源状态，进行资源的微秒/毫秒级细粒度调度，确保对业务变化的近实时响应。两层之间通过性能反馈机制形成闭环控制，从而实现全局最优与局部实时适配的统一。

通信计算融合无线网络云化协同通算资源调度如图10所示，切片化资源分配将通算资源按业务需求划分为逻辑独立的切片，实行“一片一策”的精准管理，切片间集中式编排与切片内分布式调度的双层架构，明确不同业务场景下资源优化的差异化目标，体现资源按需分配的核心逻辑。多目标优化算法则通过动态权重调整与迭代优化，在满足差异化业务服务质量（quality of service, QoS）需求的前提下，持续提升网络整体效能。

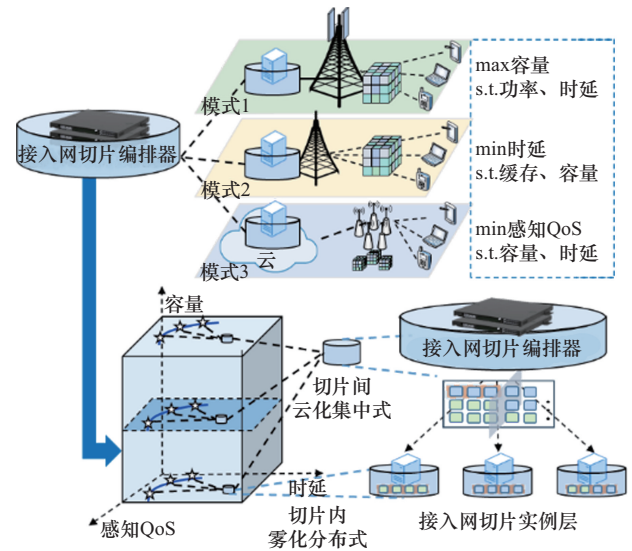


图10 通信计算融合无线网络云化协同通算资源调度

云化协同通算资源调度算法的研究重点集中在调度算法优化、切片管理与业务适配性提升方面。在优化算法方面，深度强化学习<sup>[39]</sup>、博弈论<sup>[40-41]</sup>等智能算法的融入，提升了调度决策的动态适配能力；在切片管理方面，切片的动态创建、调整与释放技术成为研究热点<sup>[42]</sup>，通过一体化编排器实现切片资源的弹性伸缩；在业务适配方面，针对AR/VR<sup>[43-44]</sup>、自动驾驶、工业控制和LEO<sup>[45-46]</sup>等差异化场景的调度策略研究逐步深入。对于空地一体化网络，采用无人机搭载轻型基站为地面用户提供接入服务<sup>[47]</sup>，为保证服务质量和均衡卫星资源利用，面向网络切片部署的服务功能链嵌入问题<sup>[48-49]</sup>，提出了一种启发式的多维加权服务功能链映射算法<sup>[50]</sup>，通过在频繁使用路径上引入额外的

代价,将服务功能链引导到资源丰富且代价较低的链路上,基于切片的服务请求拒绝率<sup>[50]</sup>如图11所示,通过不同用户数量下的拒绝率对比,揭示了多维加权服务功能链映射算法在资源均衡利用方面的优势,验证其应对高动态业务请求的稳定性。本文算法相比传统的服务功能链映射算法、最近请求和最短时延算法,可以实现最低的服务请求拒绝率,实现切片资源的高效调度。




图11 基于切片的服务请求拒绝率

面向未来感智协同的资源管控技术持续向与人工智能深度融合的方向演进,旨在实现更加自主、可信与高效的智能调度体系。例如意图驱动,网络管理者只需声明所需业务的QoS自然语言,而无需关心如何实现,调度系统会自动将这种高级意图翻译为具体的资源分配策略。此外,可解释AI<sup>[51]</sup>的应用能让管理者理解AI为什么会作出某个调度决策,增强对智能系统的信任和可维护性<sup>[52]</sup>;同时,将数字孪生与AI相结合<sup>[53]</sup>,通过构建与物理网络高保真同步的虚拟数字孪生,可对新型AI调度策略进行安全的沙箱测试、迭代优化与效果验证,再无缝部署至实际网络,形成“虚拟推演-真实部署”交互闭环,提升调度的可靠性与演进效率。面对未来网络极致的性能要求、极复杂的异构环境与极动态的业务意图,其调度策略的生成效率、跨域协同能力与长期演进潜力均面临瓶颈。

### 3 通信计算融合网络感智协同关键技术

云化协同关键技术体系通过架构云化、功能解耦、资源池化与弹性调度,实现了通信与计算双维

度的深度融合,为通算融合无线网络奠定了工程实践基础。但面对6G时代通信感知一体化、AI内生的核心需求,云化协同技术体系仍存在本质性瓶颈:架构层面多层次叠加的设计导致通感算资源跨域协同壁垒高;信号处理层面通信与感知功能割裂、难以实现联合优化;资源调度层面仅能实现通信与计算双维度的规则化分配,无法适配通感算多维度资源的动态耦合关系;智能化始终以外挂形式存在,未能形成“感知-决策-执行-验证”的内生闭环。感智协同关键技术是云化协同技术的演进,以全域原生感知为基础、内生全域智能为核心、架构级简约化为支撑,破解云化协同技术中通信、计算、感知、智能能力的相互割裂状态。

#### 3.1 感智协同的通算融合网络体系架构

云化协同体系架构(如C-RAN、H-CRAN和F-RAN)通过基站功能解耦与云-边-端三级资源池构建,实现了通信与计算的初步融合。然而,面向6G通信感知一体化与AI内生需求,传统多层次叠加、功能静态固化的云化架构难以满足资源跨域协同的要求。为此,感智协同的通算融合网络体系架构对现有架构进行了扁平化重构,核心理念涵盖架构级简约化、智能内生、通感算一体化和全域协同化。该架构旨在通过物理层与网络层的服务化设计削减协议栈冗余,并依托全链路闭环的内生智能体系,实现通信、计算、感知与智能能力的全局原生融合<sup>[31]</sup>。

架构级简约化以感智协同核心需求为导向,通过协议栈轻量化精准裁剪、网络功能服务化原子化重构、全域接口标准化三大核心路径实现无线网络架构扁平化重构,降低多层次交互带来的数据损耗、信令开销、运维复杂度与系统能耗,为感知数据高效流转、内生智能决策低时延执行筑牢底层支撑。其核心体现在3个维度。一是感知数据采集的“简”,通过控制与转发分离、全域接口标准化设计,消除多源感知数据的格式壁垒与交互障碍,为内生智能构建高保真、低时延的统一数据底座。二是感知驱动决策执行的“简”,将传统无线资源控制(radio resource control, RRC)、分组数据汇聚协议(packet data convergence protocol, PDCP)等协议层功能拆解为最小粒度的原子化服务,基于内生智能决策与业务需求按需编排,替代传统分层协议栈的固定流程。同时针对高动态场景完成协议

栈精准裁剪, 典型优化示例如下: RRC层依托轨迹预测先验信息, 简化周期测量上报与切换交互流程, 实现零信令预配置切换, 削减90%以上的冗余测量信令; PDCP层融合感知数据预处理功能, 设计通感一体轻量化封装格式, 裁剪互联网协议(Internet protocol, IP)/用户数据报协议(user datagram protocol, UDP)/PDCP冗余包头字段, 消除跨层交互开销。内生智能中枢生成的决策可通过统一编排器快速下发执行, 大幅降低决策时延与运维成本。三是效果评估验证的“简”, 基于全域感知数据构建与物理网络实时同步的数字孪生体, 可对感知协同策略进行离线仿真、验证与优化, 同时基于实时感知数据持续校验策略执行效果, 实现全流程验证与闭环优化。

在底层资源架构方面, 感知协同以资源全域一体化为基础, 利用虚拟化技术将天线、频谱、基带、算力、存储及感知载荷等物理实体, 抽象为标准化的可调度资源单元, 进而构建逻辑统一的全域通感算智资源池。通过资源归一化表征与接口调用机制, 为多维资源的联合调度与动态适配提供底层架构支撑。在功能模块化设计上, 架构采用基于服务化的标准化接口, 重构了原有分层的协议栈体系。其中, 全域原生感知模块负责汇聚基站射频、卫星遥感及终端等感知数据, 并在边缘侧进行分级预处理与特征提取, 以降低全量数据上传导致的时延与带宽开销; 内生智能管控模块以分布式协同架构替代集中式人工配置模式, 通过内置意图引擎将业务需求映射为网络配置策略, 构建“感知-训练-推理-执行”闭环; 通算融合转发模块融合信号处理、算力转发与路由功能, 支持基于可编程硬件的转发路径动态配置; 极简服务化接入模块则采用轻量化协议栈与无状态接入机制, 结合感知预测信息, 以优化高动态异构节点的接入信令开销与切换流程。

为支撑上述模块的协同运作, 感知协同架构在云雾化机制基础上, 部署了云-边-端三级动态协同机制, 其中云端核心网节点侧重于全局管控、非实时大模型训练与跨域资源统筹调度策略的生成; 区域边缘节点则负责区域内的实时智能推理、通感一体联合信号处理及本地资源闭环管控; 终端与接入节点主要承担轻量化感知数据采集、底层物理层信号处理与端侧模型协同推理任务。三

级节点通过标准化服务化接口交互, 支持vCU、vDU、通感处理及AI推理等网络微服务功能在不同层级间的弹性部署与动态迁移。此外, 该架构在接口规范上原生兼容空基、天基和海基节点, 支持扩展为空天地海一体化的全域协同形态, 从而适应LEO、低空经济等广域组网场景的动态接入与处理需求。

### 3.2 通感一体化物理层智能信号处理技术

云化协同架构下的信号处理技术以通信性能优化为核心, 通感一体设计多为通感叠加模式, 通信与感知处理流程相互割裂, 且依赖固定数学模型与算法, 难以适配6G高动态、强非平稳的通感一体场景, 无法实现感知精度与通信性能的协同最优。感知协同下的通感一体化物理层智能信号处理技术, 将轻量化AI模型原生嵌入物理层全信号处理流程, 实现全流程联合优化与高动态场景自适应适配, 在共享频谱、硬件与算力资源的前提下, 实现通信容量与感知精度的双向增益。

AI内生的通感一体波形自适应设计技术: 该技术以生成式AI为核心构建波形生成与优化模型, 以通信传输速率、误码率、感知测距/测角精度等多维度指标为优化目标, 实现通感一体波形端到端自适应生成<sup>[54]</sup>; 通过神经网络将信道编码、调制、帧结构设计等环节融合为统一可学习模块, 基于实时信道状态、目标运动状态与业务需求, 动态调整波形核心参数, 在资源受限条件下实现通信与感知性能联合最优<sup>[55]</sup>; 同时通过轻量化技术适配云-边-端不同节点的算力约束, 通过云端全局训练实现模型持续进化, 适配高动态场景下的极端信道环境。

通感智联合信道估计与目标检测技术: 该技术基于通信与感知信道的强相关性, 构建内生AI驱动联合处理框架, 打破传统信道估计与目标检测相互独立的流程壁垒, 实现通信信道信息与感知目标信息的双向赋能与联合估计; 通过统一深度学习神经网络同步完成两大任务, 以通信导频、数据信号与感知回波信号为联合输入, 挖掘信道状态信息与目标运动参数的内在关联, 实现通信数据辅助感知精度提升、感知参数辅助信道预测跟踪的双向增益; 针对多节点协同场景, 通过联邦学习实现多节点信息融合, 大幅提升低信噪比场景下的检测与估计性能<sup>[56]</sup>。

多节点协同的通感智联合波束成形技术: 该

技术以多智能体强化学习为核心构建云-边协同联合波束优化框架,同时兼顾通信速率、感知精度与干扰抑制需求,突破传统波束成形仅以通信信干噪比最大化为目标的局限<sup>[57]</sup>,将多节点通感波束成形问题建模为分布式马尔可夫决策过程;采用云端训练、边缘分布式执行的模式,通过边缘智能体实现本地波束成形矢量实时优化与节点间协同决策,解决大规模场景下集中式优化复杂度高、决策时延大的问题;同时通过深度强化学习算法优化波束零陷位置与深度,同步抑制通信用户间干扰与感知旁瓣干扰,实现通信与感知的并行高效传输<sup>[58]</sup>。

轻量化AI模型的物理层嵌入式部署技术:该技术通过神经架构搜索、模型量化等轻量化技术,针对物理层核心任务设计专用轻量化神经网络,将模型推理时延控制在微秒级,满足物理层实时处理需求;同时通过软硬件协同优化设计专用AI加速算子与硬件加速引擎,实现轻量化模型并行高速推理,替代传统固定算法硬件逻辑,实现物理层信号处理的可编程、可重构与自优化。

### 3.3 通感算深度融合的智能资源调度技术

资源调度是通算融合无线网络实现资源高效利用与业务需求精准适配的核心环节。传统云化协同架构仅实现了通信与计算双维度资源的协同调度,优化目标聚焦于容量与时延均衡,未将感知资源与智能算力纳入体系,且依赖固定优化模型与人工配置,难以应对6G超大规模与超高动态的调度需求。为此,感知协同架构提出了通感算深度融合的智能资源调度技术,将感知、通信、计算、智能4类资源纳入统一体系,基于全域感知数据通过内生智能实现多维资源的联合优化。感知协同功能编排流程如图12所示,该体系构建了端到端的自动化闭环机制:首先以业务意图翻译为起点,通过语义分析与意图识别生成结构化指令;随后进入算力感知阶段,依托多维资源感知构建全局算力图谱;进而通过极简链路构建模块完成智能链路优化与切片的快速连接;最终,系统进行性能闭环验证,通过实时服务等级保障(service level assurance, SLA)监测与比对生成智能反馈,并将动态调整指令作用于前端。这一闭环机制确保系统能够根据实时网络状态与业务波动,自适应地完成通感算智多维度资源的深度耦合与智能编排优化。

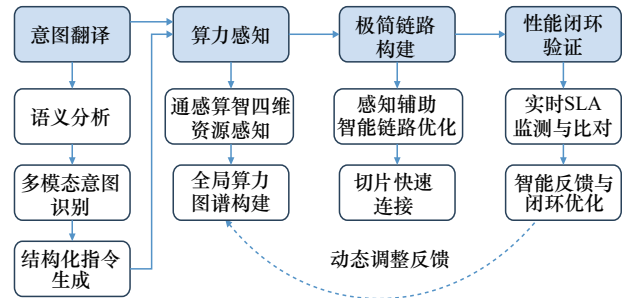


图12 感知协同功能编排流程

意图驱动的通感算智四维资源联合调度技术:该技术以自然语言语义理解与意图翻译引擎为核心,实现从高层业务意图到底层资源调度策略的端到端自动映射,替代传统人工配置的调度模式;通过内生意图引擎,将自然语言业务意图自动拆解为感知精度、通信速率、端到端时延等性能指标,再通过多目标优化算法映射为具体的资源调度策略,并通过统一编排器下发执行。通过构建四维资源联合优化目标函数,以系统资源利用效率最大化为目标、业务性能指标为约束,通过内生智能算法实现资源动态分配,针对差异化业务需求实现资源的适配与全局最优<sup>[59]</sup>。

多智能体强化学习的分布式协同调度技术:该技术通过构建云-边-端三级分布式智能体调度体系,实现大规模网络下的分布式协同决策,在保障全局性能最优的同时,大幅降低调度决策时延与信令交互开销,将全网调度问题拆解为多个区域级、节点级子问题,为各边缘与接入节点部署分布式智能体,负责本地资源状态感知与调度决策生成,通过有限信息交互实现多智能体协同优化;云端全局智能体负责全局调度模型的训练与迭代,通过联邦学习实现全局模型统一优化,下发全局调度约束保障分布式决策的协同性。通过协同奖励函数设计,该技术实现跨节点、跨域资源协同调度,解决高动态场景下节点快速切换、资源供需时空错配的问题。

数字孪生驱动的闭环智能调度技术:该技术通过构建与物理网络高保真同步的网络数字孪生体,实现“虚拟推演-真实部署-效果验证-策略优化”的完整闭环,将资源调度从被动响应升级为主动预判;基于全域感知全量状态数据,在云端构建与物理网络实时同步的数字孪生体,复刻网络拓扑、资源状态、业务规律与环境特征。基于数字孪生体,

一方面通过深度学习算法实现网络状态与业务需求的长时序精准预测，提前生成资源预配置策略，避免业务性能劣化；另一方面构建网络沙箱环境，对新型调度策略进行离线仿真验证与迭代优化，确保策略安全稳定后再部署至物理网络。同时通过数字孪生体与物理网络的实时数据交互，实现模型在线增量学习，实现业务负载动态调整资源配比<sup>[60]</sup>，提升资源整体利用效率。

#### 4 通信计算融合网络感智协同应用

通信计算融合无线网络的感智协同，本质是构建一个智能元素在空间、时间、形态上无处不在，并与网络、计算、感知、控制能力深度耦合的原生网络体系，它将通感算一体化能力与空天地海一体化覆盖深度融合，通过内生智能保障智能处理的实时性与高效性，通过架构简约拓展智能服务的覆盖边界，从地基拓展为空基-天基-地基一体化<sup>[61]</sup>。

空天地一体化感智协同无线网络示意如图 13 所示，通过 AI 赋能通信和组网，使无线信号处理、无线接入和无线组网技术简约化；通过协议栈轻量化裁剪冗余字段、合并功能相近的协议模块<sup>[62]</sup>，降低协议处理时延与资源开销；通过功能模块集成化设计，将分散在不同层级的通信、计算、管理功能进行整合，减少跨模块交互节点；通过跨域接口

标准化统一云、边、端各域，消除域间数据传输的兼容性障碍，实现网络中不同类型的节点在通信计算功能上的高效简化结合<sup>[63]</sup>，在提高网络效率的同时，控制运维流程的复杂度和网络运行的能耗。通信计算融合无线网络的感智协同将在 LEO、低空经济、应急通信、智能交通、空天一体化等领域具有广阔的应用前景<sup>[64]</sup>，下面围绕这些典型应用，探索其具体实施方式与未来发展。

#### 4.1 LEO 应用

全球通信覆盖场景中，LEO 通信计算融合网络实现偏远地区、海洋、空中的通信接入，面向 LEO 的感智协同组网如图 14 所示，展示了 LEO 与地面、星间的协同连接关系。在偏远山区、沙漠等地面通信基础设施缺失区域，用户通过便携终端接入 LEO 网络，获得语音通话、数据传输服务。在海洋航行场景中，LEO 为船舶提供持续通信与导航服务，支持船舶与岸基、船舶间的协同调度，同时实现海洋环境数据的实时采集与分析。在航空通信场景中，卫星与飞机机载通信系统对接，为乘客提供高空互联网服务，为机组提供实时气象、航行数据，提升飞行安全性与舒适性。在应急通信场景中，LEO 通信计算融合网络成为最后一道通信保障；当地面通信网络中断时，LEO 可快速构建应急通信链路，为灾区提供生命通道，支撑救援指挥与灾情上报。在

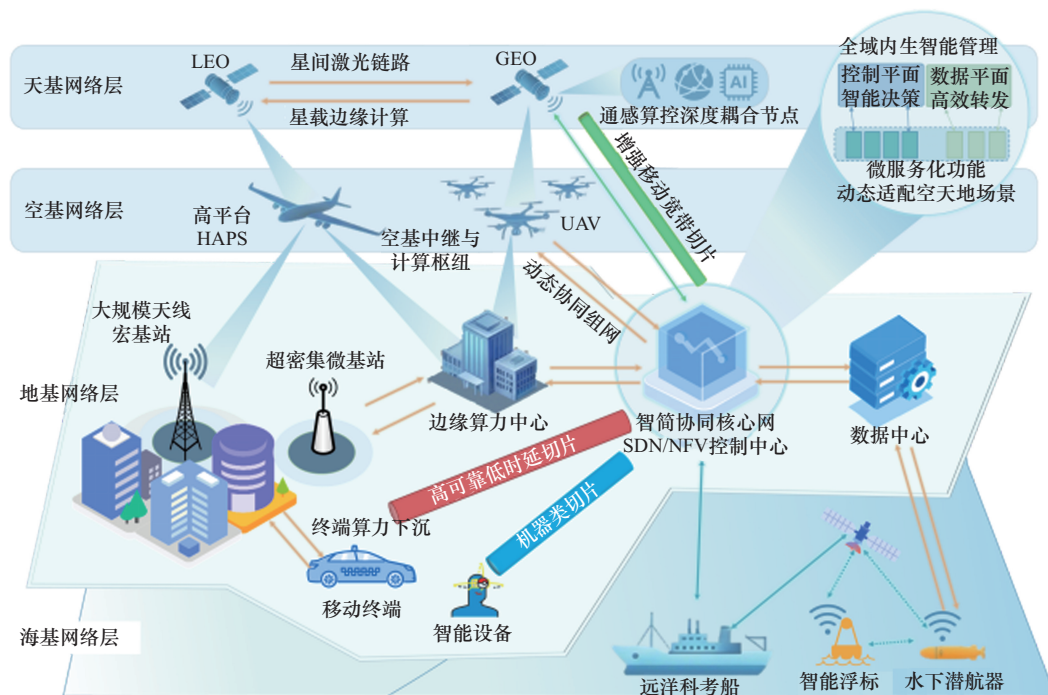


图 13 空天地一体化感智协同无线网络示意

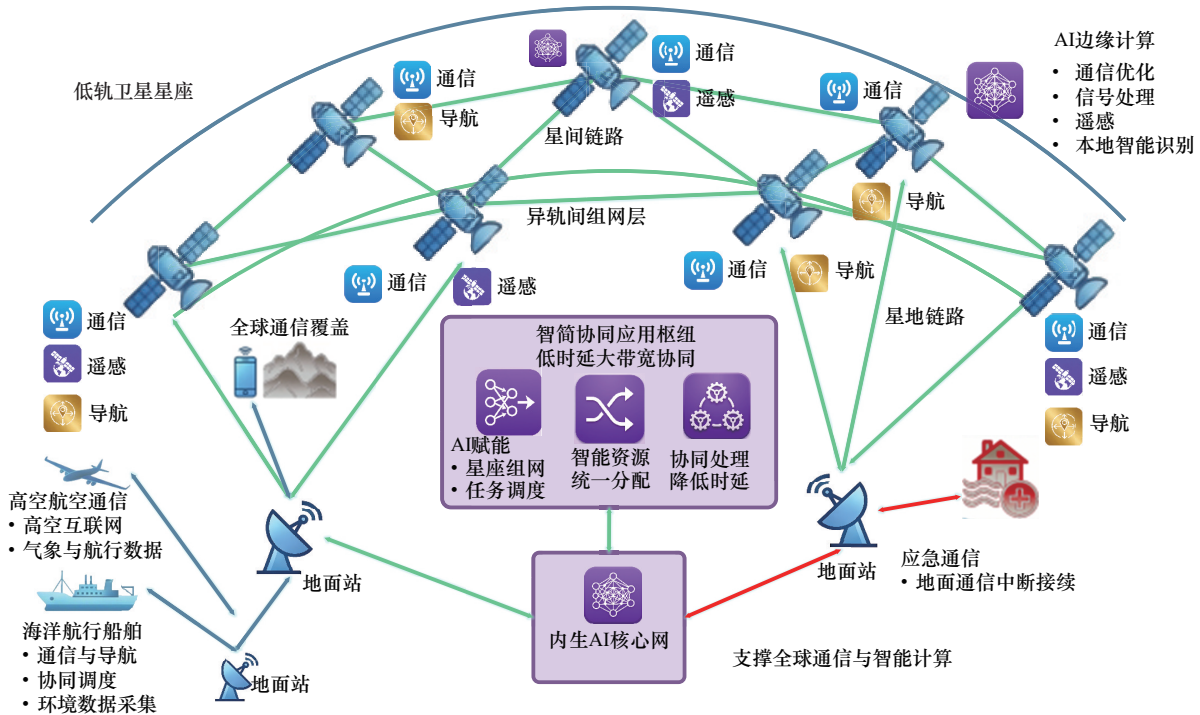


图 14 面向LEO的感智协同组网

物联网应用中，LEO支持全球物联网设备的接入与管理，为智能农业、环境监测、野生动物保护等场景提供数据传输服务，边缘计算节点本地处理物联网数据，降低卫星链路传输压力，实现通感算的端到端协同。

为了高效支撑上述应用，LEO感智协同应用通过LEO搭载轻量化通信载荷与边缘智能算力，实现卫星与地面、卫星与卫星间的高速通信与数据处理；地面站通过云化协同体系架构接入核心网，实现卫星资源与地面资源的统一调度；依托感智协同技术，卫星不仅承担通信中继功能，还可实现对地观测、环境感知数据的本地智能识别处理，大幅降低数据回传时延。解决传统卫星通信时延高、带宽有限、地面依赖强的痛点，支撑全球范围内的通信与智能计算服务。LEO星地链路存在高动态性与长传播时延的特征，传统云化协同难以适配该场景需求。云集中化协同要求全量数据回传至地面云中心处理，会进一步放大传输时延，且星地链路的动态变化易导致回传链路拥塞；云边缘化协同的资源调度边界相对固定，无法实时适配星地信道的动态波动；云雾化协同的多层级协同架构会占用星载有限的算力与功耗资源，难以在卫星平台部署，感智协同则可针对性解决这些问题，成为LEO场景的未

来技术演进方向。

#### 4.2 低空产业应用

面向低空产业应用的感智协同组网如图 15 所示。由图 15 可以看出，低空无人机集群、地面无线网络与云端决策平台构成三级架构，其中无人机为前端执行单元组成空中网络，地面智能无线网络（包括通感一体基站、接入点等）构成通信连接与边缘计算处理层，云端数据中心与调度平台为后端决策与资源管控核心。通过资源与功能的跨层协同，实现感知泛在、算力泛在、智能泛在的低空产业服务能力。在具体应用中，借助通感一体波形与智能无线网络设备，系统能够实现低空目标的精准、连续感知与实时通信；通过云雾化协同通算资源调度，算力得以在云端、边缘与机载端灵活分配，使识别、定位、预测等智能能力遍布全网。同时，通过对架构与协议进行简化，无人机集群可以依托统一数据共享与协同机制，自主完成探测、识别、定位、导航等任务，同时与地面网络协同，实现空域规划、路径优化、拦截调度的智能决策。

在低空物流等集群作业中，多无人机可以通过感智协同实现航路规划与碰撞规避，提升整体效率。在低空安防场景中，通过部署通感一体基站和监控设备等对低空飞行器进行广域监控，感知数据

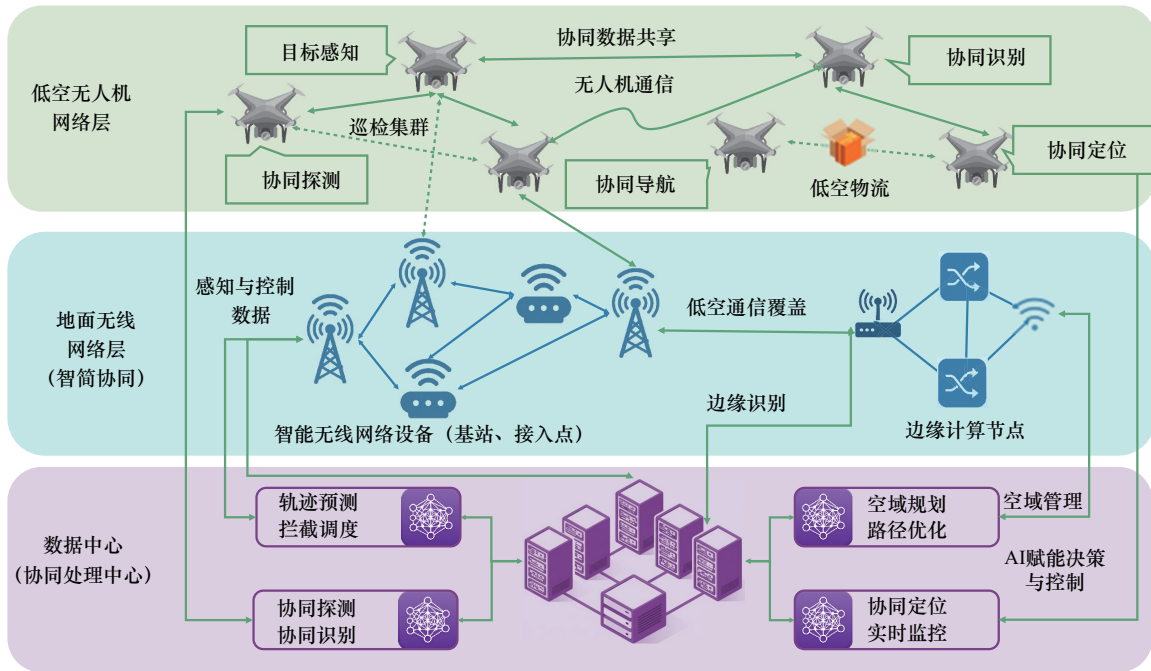


图 15 面向低空产业应用的感知协同组网

在边缘节点的即时处理，实现违规目标的本地识别与告警。云端数据中心则可以融合多源感知信息，进行非法无人机轨迹预测并下发拦截调度指令，为重要设施提供立体防护。在空域管理方面，系统构建动态管理平台，整合飞行计划、实时监控与路径优化功能，通过智能调度确保空域资源的高效、有序利用，为低空经济的安全健康发展奠定基础。

### 4.3 车联网应用

面向车联网应用的感知协同组网如图 16 所示，展示了车辆、路侧通感算一体基站与云端平台的协同架构。在网络中包括智能车辆与普通非智能车辆组成的执行单元，路侧部署的通感算一体基站可持续采集交通流量、车辆轨迹、事件信息等多维数据，并通过算力灵活调度，实现数据就近处理与实时反馈，提供路况分析、风险预警、决策规划等智能服务，同时通过 V2X 直连通信实现对车辆的低时延数据交换与边缘决策数据下发。协同决策层的云端平台进行宏观协调，形成全局最优的交通管控与车辆调度方案。

在城市交通管理中，路侧通感算一体基站实时采集交通参数，边缘节点快速生成区域状态评估与信号灯优化方案，同时云端平台融合多区域信息，实施动态配时与拥堵疏导，并通过车路协同 V2X 通信向驾驶员提供绕行引导。在自动驾驶协同场景

中，感知协同网络可为差异化车辆类型赋能。针对智能网联车辆，通过车-路 V2X 数据共享与边缘侧计算，实现高精度融合定位、协同轨迹规划与实时决策辅助，显著提升自动驾驶的安全性及通行效率。针对非智能车辆，则依托多基站协同探测与协同识别技术，实现对车辆身份的识别、轨迹预测与行为分析。同时，云端综合全网车辆动态向相关智能车辆或路侧设备下发碰撞预警、盲区提醒等安全信息，从而实现对非智能车辆提供网络赋能型的自动驾驶，全面增强道路系统的整体安全与协同效率。

### 4.4 应急场景应用

面向应急场景应用的感知协同组网如图 17 所示，在应急场景中可以依托“空-天-地”多层级的各类基础设施节点，快速构建起融合通信、感知与智能计算的应急响应感知协同网络。其中，LEO 卫星能够提供广域覆盖的通信、遥感、导航能力，支持灾害区域的遥感数据处理、引导救援人员与应急指挥通信。无人机作为灵活的空基平台，可快速部署成为能够连接 LEO 与地面的空中基站与边缘计算节点。地面协作处理层依托灵活快速部署的云/雾小站汇聚来自 LEO 卫星、无人机、应急响应专网，以及灾害感知基础设施的各层数据，通过协调分布式算力实现灾情智能分析研判，并通过跨层

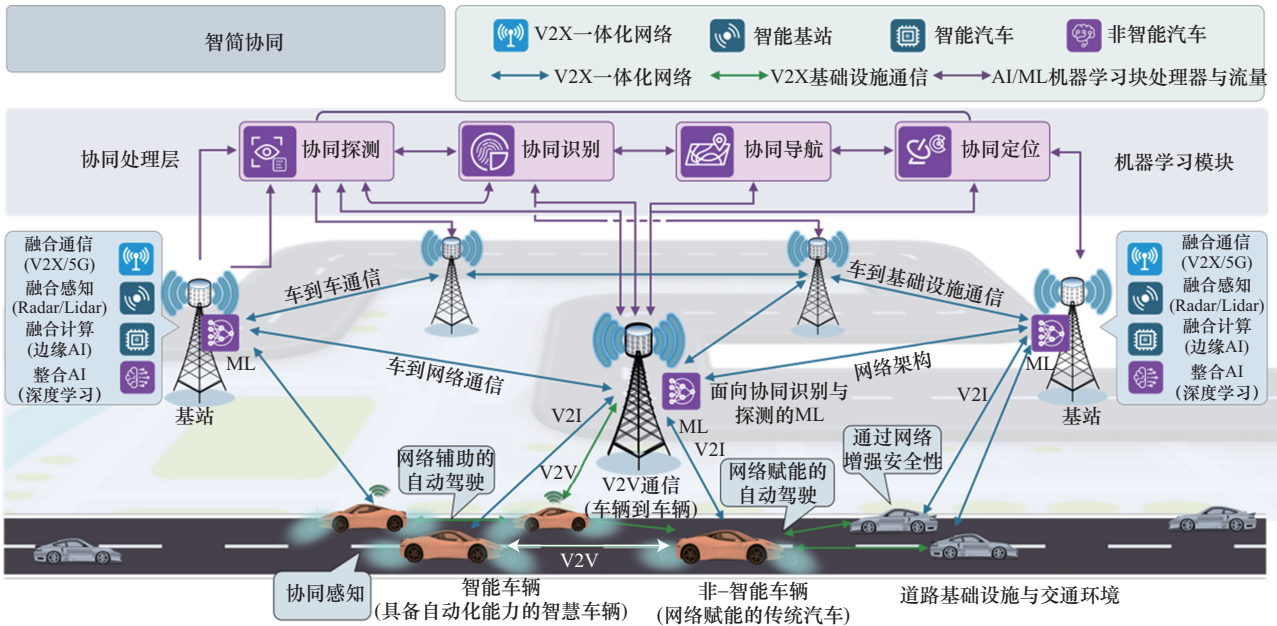


图 16 面向车联网应用的感智协同组网

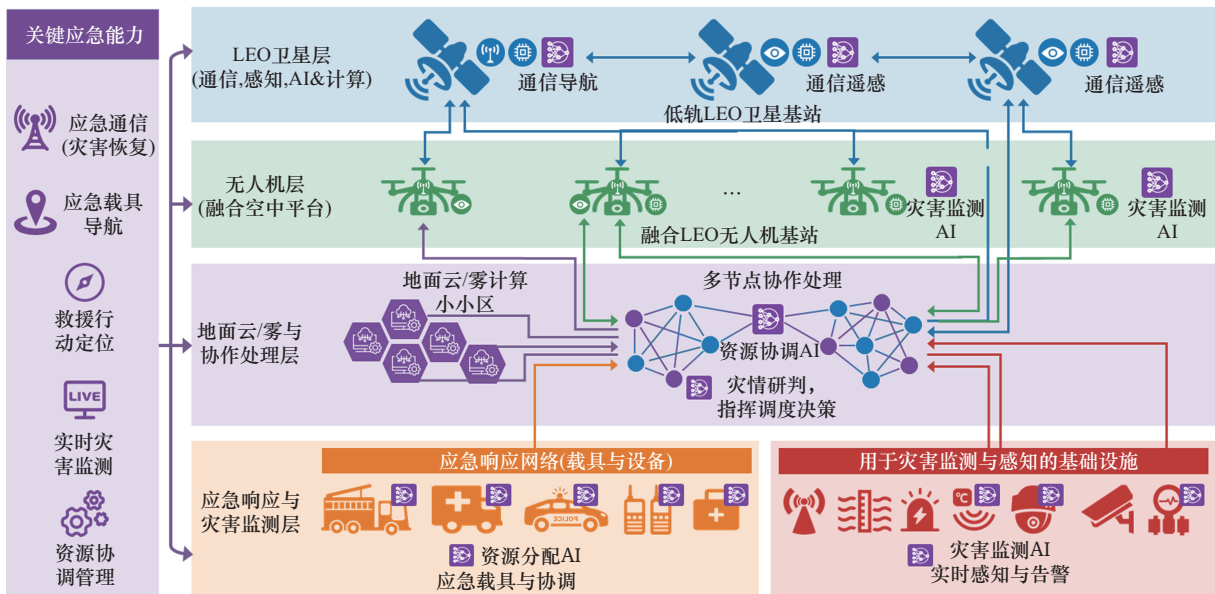


图 17 面向应急场景应用的感智协同组网

资源调配选择应急通信链路协调指挥调度、开展救援等，实现从灾情感知到救援调度的快速闭环。

在灾害救援中，可以通过部署便携式的通感算一体小站（如车载、背负）快速搭建临时网络，并与LEO卫星链路及无人机空中平台协同组网，实现灾区通信快速补盲、实时影像回传与本地AI识别。同时借助多节点协同AI模型，系统能够联合处理来自不同平台的感知、通信、计算信息，支撑灾情综合研判与指挥调度决策，同时动态优化通信带宽、计算任务及无人机空中平台位置等资源。在

大型活动或公共安全事件中，借助多无人机协同组网与地面节点，实现高密度用户接入与全景监控覆盖，实时识别异常事件并告警，提升现场响应速度。在公共安全事件发生时，通过融合卫星、无人机与地面感知、导航数据，为救援车辆与人员提供高精度导引与实时态势共享，从而全面提升应急救援的协同效率与智能化水平。

### 5 未来发展与挑战

感智协同作为6G通信计算融合无线网络的核

心演进范式,当前相关研究仍处于原理验证与体系完善初期,在基础理论、工程技术、安全防护、产业落地方面仍存在亟待突破的核心挑战,未来重点研究方向如下。

### 5.1 基础理论体系深化研究

现有研究虽建立了感智协同的量化分析框架与性能模型,但尚未形成全场景普适的完备理论体系,未能完全厘清全域原生感知、内生式智能化、架构级简约化三者的非线性耦合机理,也未明确多维度极致性能需求下的系统理论性能边界。未来需基于信息论、随机几何与人工智能理论,构建感-智-简耦合的统一量化理论模型,明确三者内在约束关系与性能增益边界;推导容量、时延、感知精度、能耗多维度约束下的系统联合性能上界,建立统一的理论优化准则;完善高动态异构场景下的理论模型自适应适配机制,建立场景特征与模型参数的精准映射关系,从底层破解性能提升与系统复杂度增长的核心矛盾,为技术优化提供底层理论支撑。

### 5.2 核心技术工程化适配研究

现有技术方案多聚焦地面蜂窝网络场景的实验室原理验证,尚未形成适配 6G 空天地海一体化异构组网需求的工程化实现路径。未来需构建兼容地面蜂窝网、LEO、高空平台等多制式网络的统一服务化架构与极简协议栈,实现跨域网络能力的原子化封装、按需调用与无缝协同;研发面向通感一体信号处理的专用轻量化神经网络,通过神经架构搜索、模型量化与软硬件协同优化,解决微秒级实时性约束下的 AI 模型嵌入式部署与硬件加速难题,实现 AI 能力与通感一体信号处理的深度原生融合;构建意图驱动的通感算智四维资源联合调度框架,基于深度强化学习实现从高层业务意图到底层资源配置的端到端闭环优化,完成通信、感知、计算、智能多域资源的全局动态最优调配。

### 5.3 内生安全与隐私保护技术研究

感智协同全域原生感知机制涉及用户位置、终端身份、运动轨迹等敏感隐私数据的全生命周期流转,架构简约化与智能内生也催生了新型安全攻击面,传统外挂式安全防护方案难以适配其低时延、高动态的核心特征。未来需构建与感智协同原生融合的全链路安全防护体系,在协议栈轻量化与服务化的接口标准化设计中,同步内置轻量化安全检

测、全链路身份认证与细粒度访问控制机制,实现安全能力与网络架构的原生共生;在内生智能算法设计中融入对抗训练与鲁棒性增强机制,结合模型驱动的 AI 技术实现决策过程可追溯,完成 AI 模型全生命周期的安全管控;重点突破联邦学习在感智协同场景的轻量化落地方法,针对多节点协同感知场景,研究横向联邦学习分布式训练机制,实现感知数据本地处理、模型参数全局聚合,解决非独立同分布数据下的模型收敛与低开销更新问题;针对云边端跨域协同决策场景,研究纵向联邦学习安全联合建模方法,在原始数据不出域的前提下,实现隐私保护与感智协同性能的全局最优平衡。

### 5.4 标准化与场景化验证体系构建

当前感智协同仍缺乏统一的技术规范、跨厂商互通规则与性能评估体系,现有场景化验证多为小规模、单一场景的原理性测试,难以支撑技术的规模化产业落地。未来需加快推进感智协同核心技术的国际化体系建设,重点推动系统架构、协议规范、接口定义、安全防护等方向在 3GPP、ITU (International Telecommunication Union)、O-RAN 联盟等国际标准组织的立项与技术规范制定,建立统一的技术测试方法、性能评估指标与认证体系;联合产学研用各方构建协同创新生态,针对低空经济、LEO、车联网等核心场景开展规模化试点示范,完善场景化适配方案,推动感智协同技术从学术研究向产业化落地的全面转化。

## 6 结束语

通信计算融合无线网络在发展前期通过云集中化协同、集中边缘自适应的云雾化协同等模式,推动了通信计算融合网络从追求资源效率最大化、服务实时性优化,到实现全局资源与性能动态均衡的理论跨越。本文从研究背景与基本原理出发,系统阐述了通信计算融合网络的性能理论、关键技术、演进趋势、典型场景及面临挑战。展望未来,通信计算融合网络的关键技术将朝着协同更深入、调度更智能、适配更广泛的方向持续演进,最终实现从“云化协同”到“感智协同”的跨越。与此同时,仍需持续攻克技术标准化、异构网络兼容、运维高效化等关键挑战,以推动通信计算融合网络走向规模化部署与产业化应用,为未来智能社会奠定坚实的信息网络基石。

## 参考文献:

- [1] 尹博南, 艾元, 彭木根. 雾无线接入网: 架构、原理和挑战[J]. 电信科学, 2016, 32(6): 20-27.  
Yin B N, Ai Y, Peng M G. Fog computing based radio access networks: architecture, principles and challenges[J]. Telecommunications Science, 2016, 32(6): 20-27.
- [2] Sun Y H, Peng M G. Recent advances of heterogenous radio access networks: a survey[J]. Journal of Mobile Multimedia, 2018, 14(4): 345-366.
- [3] 闫实, 彭木根, 王文博. 通信-感知-计算融合: 6G 愿景与关键技术[J]. 北京邮电大学学报, 2021, 44(4): 1-11.  
Yan S, Peng M G, Wang W B. Integration of communication, sensing and computing: the vision and key technologies of 6G[J]. Journal of Beijing University of Posts and Telecommunications, 2021, 44(4): 1-11.
- [4] Baldoni G, Quevedo J, Guimarães C, et al. Data-centric service-based architecture for edge-native 6G network[J]. IEEE Communications Magazine, 2023, 62(4): 32-38.
- [5] 李子姝, 谢人超, 孙礼, 等. 移动边缘计算综述[J]. 电信科学, 2024, 34(1): 87-101.  
Li Z S, Xie R C, Sun L, et al. A survey of mobile edge computing[J]. Telecommunications science, 2018, 34(1): 87-101.
- [6] 董裕民, 张静, 谢昌佐, 等. 云边端架构下边缘智能计算关键问题综述: 计算优化与计算卸载[J]. 电子与信息学报, 2024, 46(3): 765-776.  
Dong Y M, Zhang J, Xie C Z, et al. A survey of key issues in edge intelligent computing under cloud-edge-terminal architecture: computing optimization and computing offloading[J]. Journal of Electronics & Information Technology, 2024, 46(3): 765-776.
- [7] Peng M G, Yan S, Zhang K C, et al. Fog-computing-based radio access networks: issues and challenges[J]. IEEE Network, 2016, 30(4): 46-53.
- [8] Xiang H Y, Yan S, Peng M G. A realization of fog-RAN slicing via deep reinforcement learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2515-2527.
- [9] 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.
- [10] 彭木根, 孙耀华, 王文博. 智简 6G 无线接入网: 架构、技术和展望[J]. 北京邮电大学学报, 2020, 43(3): 1-12.  
Peng M G, Sun Y H, Wang W B. Intelligent-concise radio access networks in 6G: architecture, techniques and insight[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(3): 1-10.
- [11] Peng M G, Sun Y H, Li X L, et al. Recent advances in cloud radio access networks: system architectures, key techniques, and open issues[J]. IEEE Communications Surveys & Tutorials, 2016, 18(3): 2282-2308.
- [12] Peng M G, Yan S, Poor H V. Ergodic capacity analysis of remote radio head associations in cloud radio access networks[J]. IEEE Wireless Communications Letters, 2014, 3(4): 365-368.
- [13] Wu D P, Negi R. Effective capacity: a wireless link model for support of quality of service[J]. IEEE Transactions on Wireless Communications, 2003, 2(4): 630-643.
- [14] Zhao Z Y, Peng M G, Ding Z G, et al. Cluster content caching: an energy-efficient approach to improve quality of service in cloud radio access networks[J]. IEEE Journal on Selected Areas in Communications, 2016, 34(5): 1207-1221.
- [15] Yin B N, Peng M G, Yan S, et al. Tradeoff between ergodic rate and delivery latency in fog radio access networks[J]. IEEE Transactions on Wireless Communications, 2020, 19(4): 2240-2251.
- [16] Peng M G, Yu Y L, Xiang H Y, et al. Energy-efficient resource allocation optimization for multimedia heterogeneous cloud radio access networks[J]. IEEE Transactions on Multimedia, 2016, 18(5): 879-892.
- [17] Zhao Z Y, Bu S Q, Zhao T Z, et al. On the design of computation offloading in fog radio access networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(7): 7136-7149.
- [18] 张平, 许晓东, 韩书君, 等. 智简无线网络赋能行业应用[J]. 北京邮电大学学报, 2020, 43(6): 1-9.  
Zhang P, Xu X D, Han S J, et al. Entropy reduced mobile networks empowering industrial applications[J]. Journal of Beijing University of Posts and Telecommunications, 2020, 43(6): 1-9.
- [19] Zhang P, Xu W J, Liu Y M, et al. Intellicise wireless networks from semantic communications: a survey, research issues, and challenges[J]. IEEE Communications Surveys & Tutorials, 2025, 27(3): 2051-2084.
- [20] Li J, Peng M G, Yu Y L, et al. Energy-efficient joint congestion control and resource optimization in heterogeneous cloud radio access networks[J]. IEEE Transactions on Vehicular Technology, 2016, 65(12): 9873-9887.
- [21] Peng M G, Zhang K C, Jiang J M, et al. Energy-efficient resource assignment and power allocation in heterogeneous cloud radio access networks[J]. IEEE Transactions on Vehicular Technology, 2015, 64(11): 5275-5287.
- [22] Ai Y, Peng M G, Zhang K C. Edge computing technologies for Internet of Things: a primer[J]. Digital Communications and Networks, 2018, 4(2): 77-86.
- [23] Mao Y Y, You C S, Zhang J, et al. A survey on mobile edge computing: the communication perspective[J]. IEEE Communications Surveys & Tutorials, 2017, 19(4): 2322-2358.
- [24] Mach P, Becvar Z. Mobile edge computing: a survey on architecture and computation offloading[J]. IEEE Communications Surveys & Tutorials, 2017, 19(3): 1628-1656.
- [25] Lin P, Song Q Y, Jamalipour A. Multidimensional cooperative caching in CoMP-integrated ultra-dense cellular networks[J]. IEEE Transactions on Wireless Communications, 2020, 19(3): 1977-1989.
- [26] 项弘禹, 肖扬文, 张贤, 等. 5G 边缘计算和网络切片技术[J]. 电信科学, 2017, 33(6): 54-63.  
Xiang H Y, Xiao Y W, Zhang X, et al. Edge computing and network slicing technology in 5G[J]. Telecommunications Science, 2017, 33(6): 54-63.
- [27] Shafiqur Rahman G M, Peng M G, Zhang K C, et al. Radio resource allocation for achieving ultra-low latency in fog radio access networks[J]. IEEE Access, 2018, 6: 17442-17454.
- [28] Xiang H Y, Zhou W A, Daneshmand M, et al. Network slicing in fog radio access networks: issues and challenges[J]. IEEE Communications Magazine, 2017, 55(12): 110-116.

- [29] Zhang J P, Yan S, Peng M G. Joint beam alignment and resource allocation for multi-user mmwave integrated sensing and communication systems[J]. *IEEE Transactions on Vehicular Technology*, 2023, 73(4): 5288-5303.
- [30] Dong F W, Liu F, Cui Y H, et al. Sensing as a service in 6G perceptive networks: a unified framework for ISAC resource allocation[J]. *IEEE Transactions on Wireless Communications*, 2022, 22(5): 3522-3536.
- [31] Peng M G, Zhang J P, Yan S, et al. Integrated communication, sensing and computing enabled fog radio access networks: issues and challenges[J]. *IEEE Network*, 2026, 40(2): 327-335.
- [32] Peng M G, Quek T Q S, Mao G Q, et al. Artificial-intelligence-driven fog radio access networks: recent advances and future trends[J]. *IEEE Wireless Communications*, 2020, 27(2): 12-13.
- [33] Zhang X, Peng M G. Testbed design and performance emulation in fog radio access networks[J]. *IEEE Network*, 2019, 33(3): 49-57.
- [34] Liu A, Huang Z, Li M, et al. A survey on fundamental limits of integrated sensing and communication[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(2): 994-1034.
- [35] Wubben D, Rost P, Bartelt J S, et al. Benefits and impact of cloud computing on 5G signal processing: flexible centralization through cloud-RAN[J]. *IEEE Signal Processing Magazine*, 2014, 31(6): 35-44.
- [36] Peng M G, Zhao Z Y, Sun Y H. Fog radio access networks (F-RAN): architectures, technologies, and applications[M]. Berlin: Springer International Publishing, 2020.
- [37] Lien S Y, Hung S C, Chen K C, et al. Ultra-low-latency ubiquitous connections in heterogeneous cloud radio access networks[J]. *IEEE Wireless Communications*, 2015, 22(3): 22-31.
- [38] Shi Y M, Zhang J, Letaief K B, et al. Large-scale convex optimization for ultra-dense cloud-RAN[J]. *IEEE Wireless Communications*, 2015, 22(3): 84-91.
- [39] Jiang N, Yan S, Liu H R, et al. Computation offloading for distributed learning in vehicular networks: a service scheduling and resource allocation method[J]. *IEEE Transactions on Vehicular Technology*, 2026, 75(2): 3222-3237.
- [40] Yan S, Peng M, Cao X Y. A game theory approach for joint access selection and resource allocation in UAV assisted IoT communication networks[J]. *IEEE Internet of Things Journal*, 2018, 6(2): 1663-1674.
- [41] Yan S, Jiao M H, Zhou Y C, et al. Machine-learning approach for user association and content placement in fog radio access networks[J]. *IEEE Internet of Things Journal*, 2020, 7(10): 9413-9425.
- [42] Yan S, Qi L, Zhou Y C, et al. Joint user access mode selection and content popularity prediction in non-orthogonal multiple access-based F-RANs[J]. *IEEE Transactions on Communications*, 2019, 68(1): 654-666.
- [43] Sun Y H, Chen J M, Wang Z Y, et al. Enabling mobile virtual reality with open 5G, fog computing and reinforcement learning[J]. *IEEE Network*, 2022, 36(6): 142-149.
- [44] Dang T, Peng M G. Joint radio communication, caching, and computing design for mobile virtual reality delivery in fog radio access networks[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(7): 1594-1607.
- [45] Yuan S, Peng M G, Sun Y H. Satellite-terrestrial integrated fog networks: architecture, technologies, and challenges[J]. *IEEE Wireless Communications*, 2025, 32(4): 208-215.
- [46] 彭木根, 袁硕. 面向星地融合的 6G 云雾化自组网[J]. *电信科学*, 2024, 40(3): 1-14.  
Peng M G, Yuan S. Toward satellite-terrestrial integration: 6G cloud-fog collaborative self-organizing network[J]. *Telecommunications Science*, 2024, 40(3): 1-14.
- [47] Liu B H, Liu C X, Peng M G. Dynamic cache placement and trajectory design for UAV-assisted networks: a two-timescale deep reinforcement learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2023, 73(4): 5516-5530.
- [48] Sun Y H, Peng M G, Mao S W, et al. Hierarchical radio resource allocation for network slicing in fog radio access networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(4): 3866-3881.
- [49] Xiang H Y, Peng M G, Sun Y H, et al. Mode selection and resource allocation in sliced fog radio access networks: a reinforcement learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(4): 4271-4284.
- [50] Zhang Y M, Zhou J E, Zhu M, et al. Resource balance optimization of network slicing based on MDW-SFCM in space-air-ground integrated networks[C]//*Proceedings of the 2025 IEEE/CIC International Conference on Communications in China (ICCC Workshops)*. Piscataway: IEEE Press, 2025: 1-6.
- [51] 张彤, 任奕璟, 闫实, 等. 人工智能驱动的 6G 网络: 智慧内生[J]. *电信科学*, 2020, 36(9): 14-22.  
Zhang T, Ren Y J, Yan S, et al. Artificial intelligence driven 6G networks: endogenous intelligence[J]. *Telecommunications Science*, 2020, 36(9): 14-22.
- [52] Liatsas L, Kibalya G M, Antonopoulos A. XAI-driven model design for resource utilization forecasting in cloud-native 6G networks[C]//*Proceedings of the 2024 IEEE International Mediterranean Conference on Communications and Networking (MeditCom)*. Piscataway: IEEE Press, 2024: 566-571.
- [53] Zhao M K, Li X, Huang Y S, et al. IC2S-swarm: when digital twin meets collaborative ISR[J]. *IEEE Communications Magazine*, 2025, 63(4): 221-227.
- [54] Zhang J F, Guo S Y, Gong S Q, et al. Intelligent waveform design for integrated sensing and communication[J]. *IEEE Wireless Communications*, 2024, 32(1): 166-173.
- [55] Jiang P, Li M, Liu R, et al. SLP-based dual-functional waveform design for ISAC systems: a deep learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(7): 11105-11119.
- [56] Zhou Y, An Q C, Wang Z B, et al. Integrated sensing, computation, and communication enabled federated edge learning[J]. *IEEE Transactions on Wireless Communications*, 2026, 25: 7117-7131.
- [57] Zhang J P, Yan S, Peng M G, et al. Coordinated multi-point enabled ISAC under asynchronous errors: performance analysis and waveform-beamforming optimization[J]. *IEEE Transactions on Vehicular Tech-*

nology, 2025, 74(8): 12189-12205.

- [58] Zhang J X, Xu S, Li C G, et al. Efficient beam selection for ISAC in cell-free massive MIMO via digital twin-assisted deep reinforcement learning[J]. IEEE Transactions on Wireless Communications, 2026, 25: 9875-9890.
- [59] Qi Q, Chen X M, Khalili A, et al. Integrating sensing, computing, and communication in 6G wireless networks: design and optimization[J]. IEEE Transactions on Communications, 2022, 70(9): 6212-6227.
- [60] Wei Y M, Peng M G, Liu Y Q. Intent-based networks for 6G: insights and challenges[J]. Digital Communications and Networks, 2020, 6(3): 270-280.
- [61] Liu B H, Peng M G, Li J J, et al. Integrated communication and navigation enabled low earth orbit satellite systems[J]. IEEE Network, 2025, 39(5): 254-262.
- [62] Zhang S H, Yan S, Tang Z L, et al. Joint multiservice resource optimization for integrated sensing, communication, and computing networks[J]. IEEE Internet of Things Journal, 2025, 12(16): 32765-32779.
- [63] Ren Y J, Sun Y H, Peng M G. Deep reinforcement learning based computation offloading in fog enabled industrial Internet of things[J]. IEEE Transactions on Industrial Informatics, 2020, 17(7): 4978-4987.
- [64] Sun Y H, Peng M G, Mao S W. Deep reinforcement learning-based mode selection and resource management for green fog radio access networks[J]. IEEE Internet of Things Journal, 2018, 6(2): 1960-1971.

#### [作者简介]



彭木根 (1978-), 男, 博士, 北京邮电大学教授、博士生导师, 主要研究方向为6G、空间信息通信、通感算一体化、通算融合无线电接入网络等。



姜宁 (1998-), 男, 北京邮电大学博士生, 主要研究方向为通信感知一体化和智能无线网络。



闫实 (1988-), 男, 博士, 北京邮电大学教授、博士生导师, 主要研究方向为分布式智能计算方法和无线通信组网方法。