

## 面向6G的知识驱动“自智”网络架构

林佳琦<sup>1,2</sup>, 钱琪杰<sup>2,3</sup>, 钟旭东<sup>2</sup>, 冯涛<sup>2</sup>, 高先明<sup>2</sup>, 葛嘉鑫<sup>2</sup>, 彭木根<sup>1</sup>, 任保全<sup>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.军事科学院系统工程研究院, 北京 100141;  
3.南京邮电大学通信与信息工程学院, 江苏 南京 210003)

**摘要:** 面向6G网络的知识驱动“自智”网络架构, 通过将网络视为认知主体, 引入“智能大脑”——网络元智能, 实现从感知、学习到决策、演进的闭环自治运维。基于此, 分析了现有自治网络框架的局限, 设计了知识驱动“自智”网络的体系结构和控制机制, 并提出了实现该架构的关键技术方案, 重点探讨了其在6G低空交通管控中的应用。实验比较了3种策略生成系统(KDSN、KDN、IBN)的性能差异, 结果表明, KDSN在知识复用效率、长期稳定性和策略生成时延等方面表现最优, 尤其在高动态环境下展现了优越的抗干扰能力。最后, 提出了针对实时性、可扩展性和异构网络协同等挑战的技术解决方案, 并展望了未来研究方向, 为自治6G网络发展提供参考。

**关键词:** 网络知识; 知识驱动网络; 网络元智能; 智能网络; 自治网络

**中图分类号:** TN915.5

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2025159

## Knowledge-driven “self-intelligent” network architecture for 6G

LIN Jiaqi<sup>1,2</sup>, QIAN Qijie<sup>2,3</sup>, ZHONG Xudong<sup>2</sup>, FENG Tao<sup>2</sup>, GAO Xianming<sup>2</sup>, GE Jiaxin<sup>2</sup>,  
PENG Mugen<sup>1</sup>, REN Baoquan<sup>2</sup>

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

2. System Engineering Institute, AMS PLA, Beijing 100141, China

3. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract:** A knowledge-driven “self-intelligent” network architecture for 6G was presented, integrating a cognitive framework with network meta-intelligence to enable autonomous operation. Limitations of existing frameworks were analyzed, control mechanisms were designed, and technical solutions were proposed, particularly targeting 6G low-altitude traffic management. Experimental comparisons among KDSN, KDN, and IBN demonstrate that KDSN achieves superior performance in knowledge reuse efficiency, long-term stability, and strategy generation delay, especially under dynamic environments. Challenges in real-time performance, scalability, and network collaboration are also addressed, and corresponding solutions and future research directions are outlined to advance 6G autonomy.

**Keywords:** network knowledge, knowledge-driven network, network meta-intelligence, intelligent network, autonomous network

收稿日期: 2025-06-10; 修回日期: 2025-09-02

通信作者: 任保全, renbq88@126.com

基金项目: 国防重点实验室基金资助项目(No.6142006240401)

**Foundation Item:** The Key Laboratory Fund of National Defense (No.6142006240401)

## 0 引言

随着云计算、大数据、物联网与人工智能的深度融合<sup>[1]</sup>,网络流量与设备接入量呈指数级增长,传统通信架构在海量数据实时处理与灵活资源调度方面面临严峻挑战<sup>[2]</sup>。6G 不仅要求更高峰值速率与容量,还需支持亚毫秒级端到端时延、厘米级定位精度,并在安全、隐私与能效方面达到更高标准<sup>[3]</sup>。典型应用场景包括车路协同的实时切片与智能频谱调度、无人机蜂群的高机动性与能效平衡,以及全息视频的千兆级吞吐与抖动抑制<sup>[4]</sup>。

在这些复杂环境中,集中软件定义网络(SDN, software defined network)通过全局可编程控制平面提升了网络的灵活性和可管理性<sup>[5-6]</sup>,但其对大规模异构环境下的实时智能决策仍依赖人工阈值调优<sup>[7-8]</sup>,且在网络时延、可靠性和容错性方面存在瓶颈。海量监测数据的在线分析、跨场景的自主协同与多目标权衡,使基于规则或阈值的传统优化方法难以适应<sup>[9]</sup>。由此,网络需要一种能够实现自感知、自学习、自优化的内生智能机制,以在不断变换的运行环境中自主调整和演进<sup>[10]</sup>。

自 2003 年 Clark 等<sup>[11]</sup>提出知识平面(KP, knowledge plane)概念以来, KP 已从最初的“识别-解释”循环演进为“识别-解释-建议-执行”连接的闭环系统<sup>[12]</sup>,通过分布式推理与学习为网络提供智能推荐与自动化运维能力。基于此理念,知识定义网络(KDN, knowledge defined network)将数据驱动的决策模型与 SDN 控制平面深度整合,实现对单一域流量、拓扑及安全策略的闭环优化与自适应调整<sup>[13]</sup>。在流量工程、故障诊断和动态配置等领域, KDN 已取得了初步成效<sup>[14-16]</sup>。然而,要在 6G 环境中构建真正的自治网络<sup>[17]</sup>,仍面临以下挑战。

1) 异构场景与跨域融合: 6G 涵盖车路协同、无人机蜂群与全息通信等多种应用场景<sup>[18-19]</sup>,网络环境、业务需求和性能指标各不相同<sup>[20]</sup>,亟须一种统一的知识表示方法,将业务涵盖的多域知识在动态运行中实现增量式融合。

2) 认知模型与代理设计: 要将上述原理落地为自动化网络,需要构建能够学习和模仿人类操作员决策流程的认知模型<sup>[21]</sup>。网络中的智能体不仅要能够从零开始掌握网络配置、流量调度等任务<sup>[22-23]</sup>,还应能够迁移已有经验,借助“意图”和

“约束”机制调节自身行为,确保其决策符合人类价值观。

3) 自动化闭环与网络智能的持续演进: 6G 自动化管理须在多域融合和大规模网络中实现高效、稳定的在线更新和快速调优<sup>[24-25]</sup>,必须设计端到端的闭环流程,包括感知、推理、执行、验证与反馈,以系统化地协调各环节,保障网络智能持续自我校准与优化<sup>[26]</sup>。

本文提出了知识驱动“自智”网络(KDSN, knowledge-driven “self-intelligent” network)架构,知识驱动是本架构的核心机制,通过对物理网络和业务运行状态的主动认知建模,支撑网络“大脑”的构建<sup>[27]</sup>。即以网络为认知主体,通过感知、学习、分析、加工等手段,获取并处理电磁环境、自身状态和用户行为等多域信息,生成并更新网络知识。感知、学习、分析、加工各环节按既定逻辑协同运作,构成完整的网络认知功能体系<sup>[28]</sup>。

首先,回顾了自治网络的定义,梳理并评述了现有自主网络综合模型与方案(ANIMA, autonomous networking integrated model and approach)、KDN 和意图驱动网络(IBN, intent-driven network)等主流标准框架及其局限,总结出智能化自治网络设计的准则。在此基础上,提出了知识驱动的“自智”网络架构,旨在构建一个能够自感知、自学习、自优化并持续自演进的端到端自治网络架构,将传统规则化与单域优化运维升级为真正意义上的全场景智能运维。接着,阐明了所需关键技术与代表性应用场景,实验部分重点探讨了系统的三大核心能力,即动态环境适应性、跨域协同效能和自演进可靠性。通过对比 3 种典型网络策略生成系统,验证了知识复用在提升系统稳定性、降低时延和增强鲁棒性方面的重要作用。最后,深入分析了实现该架构的关键挑战,并提出若干开放性研究问题,展望了面向 6G 自治与智能运维的未来发展方向。

## 1 主流自治标准框架对比及设计准则

### 1.1 主流自治标准框架比较

网络管理贯穿服务设计、资源调配、性能监控与故障恢复等全生命周期,需要持续分析来自各组件的大量控制数据<sup>[29]</sup>。为应对这一挑战,网络自动化管理应用智能算法和自动化工具,覆盖配置、

调度、监控和故障处理各环节<sup>[30]</sup>；自治网络则是在此基础上的进一步演进，旨在构建覆盖全网络生命周期的智能化运维能力，实现敏捷运营和全场景服务<sup>[31]</sup>。在自治网络框架下，“意图”用以描述用户在特定时刻对网络的期望目标，“策略”则是在给定事件或条件下，为达成意图所采取的具体行动。意图驱动策略，策略保障意图兑现；二者必须随环境与需求的变化动态调整、持续优化<sup>[32]</sup>。业界通常将自治网络划分为6个成熟度级别<sup>[33]</sup>。

L0-L1（手动→辅助）：从纯人工运维过渡到对重复性任务的脚本化自动执行。

L2-L3（初级自治→条件自治）：引入单一或多模型在受控场景下对特定域进行闭环优化，并具备环境感知能力。

L4-L5（高度自治→全面自治）：跨域融合多源数据，面向服务预测与主动决策，最终实现全生命周期的端到端自演进与完全自治。

自治网络的发展历程从纯人工运维、脚本化辅助，到单域与条件闭环，再到跨域预测性管理，直至端到端多域在线自演进，恰好对应了架构在智能层级、跨域融合、闭环完整度、自演进能力及应用场景这五大维度上的逐级升级。现有主流自治标准框架归纳与关键属性对比如表1所示，本节将基于上述维度，对现有主流自治标准框架进行系统归纳与对比。

1) IETF 自主网络（ANIMA）框架

IETF 于2017年成立 ANIMA 工作组，将 IBM 在2001年提出的“自我管理”计算理念引入网络领域，旨在构建不需要人工干预的“自我管理”网络<sup>[34]</sup>。ANIMA 框架以监测-分析-规划-执行-知识共享（monitoring, analysis, planning, execution-knowledge, MAPE-K）闭环模型为核心，将网络节点划分为自治节点和被管理节点，并通过独立的自主控制平面为它们之间提供安全、轻量级的通信通道

（通常在 IPv6 网段中实现）<sup>[36]</sup>。在此基础上，ANIMA 定义了若干关键功能实体和协议。

①自治服务代理：运行在每个节点上，负责本地环境监测与事件上报。

②自主网络引导：通过零接触配置（ZTP），机制，实现设备的自动引导与可信加入。

③自治中继与自主信任防火墙：构建分层信任模型，保证跨域自治节点之间的安全信息交换。

④注册与发现：基于自主控制平面实现服务与节点的自发现与动态注册。

ANIMA 将网络管理中的配置、监控、故障发现与修复等任务模块化到各节点的自治服务代理，依托自主控制平面的全网广播与汇聚能力，实现了 L2-L3 级的单域闭环运维与部分跨域协同。在 ANIMA 框架奠定了基础自治理念之后，业界和标准组织陆续提出了多种面向更高层次智能化的扩展方案。欧洲电信标准组织（ETSI）体验网络智能（ETSI ENI, experiential networked intelligence）在 MAPE-K 循环中引入“用户体验感知”模块，通过多维数据分析驱动策略自适应调整，使网络优化更加贴合业务和用户诉求<sup>[37-39]</sup>；3GPP 在蜂窝网络中推广了自组织网络（SON, self-organizing network）<sup>[40-41]</sup>，包括自动邻区配置、功率控制、负载均衡与故障自愈等功能，将自治能力落地于无线接入网<sup>[42-43]</sup>；TM Forum 的 IBN<sup>[44]</sup>则以上层业务意图为核心，通过意图解析、策略生成与验证环节，实现端到端的意图闭环管理<sup>[45]</sup>；Linux 基金会主导的开放网络自动化平台（ONAP, open network automation platform）<sup>[46]</sup>整合 NFV/SDN 编排、策略引擎与闭环监控，为运营高级大规模网络提供微服务化的自动化与 DevOps 化运维<sup>[47]</sup>；城域以太网联盟（MEF）的全生命周期服务编排（LSO, lifecycle service orchestration）则在多域多供应商环境中统一编排服务设计、交付与保障，推动了跨运营商、

表1 现有主流自治标准框架归纳与关键属性对比

框架	智能层级	跨域融合	闭环完整度	自演进能力	应用场景
ANIMA <sup>[34]</sup>	L2-L3: 基础自我管理	—	部分: 监测→执行→恢复	低: 需人工或集中协调	基础设施层面自动发现与自愈
KDN <sup>[12]</sup>	L3-L4: 知识驱动	单域: 流量/故障领域	中等: 感知→推理→执行→验证	低: 离线模型重训练	SDN 网络中的流量工程与故障自愈
IBN <sup>[35]</sup>	L4-L5: 意图驱动	松散: 意图在多域中传递	高: 意图→策略→执行→校验→调整	中: 基于模板的自动调优	企业/运营商网络的业务意图管理

跨技术域的端到端自动化运维<sup>[48]</sup>。

在国内, 3GPP 自 R16 起在 SA5 工作组中引入了自主网络等级 (ANL, autonomous network level)<sup>[49]</sup>、闭环服务等级保障 (COSLA, closed-loop service level assurance)<sup>[48]</sup>、意图驱动管理服务 (IDMS, intent-driven management service)<sup>[50]</sup>、增强型管理数据分析 (eMDA, enhanced management data analytics)<sup>[51]</sup>等项目, 华为、中兴通讯、中国移动等机构均参与了相关提案与规范制定。同时, CCSA TC7 (网络管理与运营支撑委员会)<sup>[52]</sup>自 2021 年以来将“自智网络”纳入标准体系, 通过制定《网络运营管理智能化水平分级技术要求》等团体标准<sup>[53]</sup>, 推动 ANIMA 式闭环架构在国内设备与运营商网络中的落地<sup>[54]</sup>。这些框架或在 ANIMA 基础上加强业务体验和意图驱动, 或引入微服务与多域协同, 共同促进了自治网络从基础设施层面向全业务、全场景的智能化演进。

## 2) KDN 框架

知识作为一种动态信息结构, 包含结构化经验、价值观、关联信息与专家见解等要素, 能够将观察、决策与行动紧密关联, 从而快速生成正确的网络运维决策。受人类认知理论启发, KDN 最早于 2017 年在 ACM SIGCOMM《计算机通信评论》中被提出<sup>[12]</sup>, 旨在将 2003 年提出的“知识平面”<sup>[11]</sup>理念落地于 SDN 控制平面, 实现基于数据驱动推理与决策的网络闭环优化。其核心架构由 3 个部分组成。

①知识平面: 从网络元素与业务日志中提取特征, 利用监督、无监督或强化学习模型生成针对流量工程、故障诊断与安全策略的优化建议。

②控制平面: 以 SDN 控制器为基础, 接收知识平面下发的策略并将其转化为具体的转发表项或配置命令。

③管理平面: 监控策略执行效果, 并将反馈数据持续回流至知识平面, 形成“感知-推理-执行-验证”的闭环。

随着机器学习技术的发展, KDN 逐渐从最初的“识别-解释”循环发展为“识别-解释-建议-执行”的闭环控制, 一定具备学习与推理能力。学习能力是通过多种方式不断积累和更新知识, 使系统在动态复杂的网络环境中不断提升性能; 推理能力是将现有知识转化为对观测结果的解释

和行动决策, 并通过规则引擎对新观测进行推断。同时为了实现对网络环境的感知与干预, 知识平面需管理所谓的“传感器”和“执行器”, 前者用于采集观测数据, 后者负责执行决策指令。最终, 知识平面通过构建松散耦合的分布式系统, 实现自动化运维与智能推荐, 并为网络的自适应演进提供支持。

近年来, 业界涌现出多种以“知识平面”为核心的自治实践: ETSI ENI 在架构中引入知识库组件, 通过本体与知识图谱对关键性能指标 (KPI, key performance indicator)、事件与用户反馈进行语义化建模, 并依托推理引擎驱动策略规划<sup>[55]</sup>; TM Forum KDN 定义统一的 KP API, 利用图数据库与 SPARQL 查询对多域拓扑、策略与性能行为进行实时增量更新与推理, 实现跨域闭环优化<sup>[56]</sup>; ONAP 在 DCAE<sup>[57]</sup>模块之上开发了 Context & Knowledge 子系统, 将数字孪生、拓扑与元数据存入知识库, 再结合规则与机器学习模型进行决策推理<sup>[58]</sup>; O-RAN Near-RT RIC 的 AI Policy 接口则支持下载场景定义与优化知识包, 供 xApp 在线推理与动态调整无线资源管理策略<sup>[59-60]</sup>。上述实践通过统一的多源知识表示层、实时更新机制与推理引擎, 将“知识驱动”深度融入网络自治全流程, 显著提升了跨域协同与智能运维能力。

国内在知识驱动网络方面, CCSA 设立了 SDN/NFV/AI 标准与产业推进委员会 (TC610) 自智网络工作组, 参照 TM Forum 和 IETF 的相关框架, 制定了多源信息建模、知识平面接口与能力分级评估的技术规范; 这些标准为将 KP 与 SDN 控制器深度融合, 并在云边协同环境中实现动态策略下发提供了基础规范。

## 3) IBN 框架

IBN 最早由业界厂商在 2016 年左右提出, 用以解决传统网络从业务需求到设备配置之间的“语义鸿沟”<sup>[35,61]</sup>。这一理念以“声明式意图”为核心<sup>[62]</sup>, 借鉴了软件工程中的声明式编程, 用户仅需指定“做什么”, 而不需要关注“怎么做”, 由系统自动完成底层网络配置。意图驱动网络将“用户意图”作为网络管理的核心, 将高层业务和服务需求转化为可执行的网络策略, 实现端到端的意图闭环<sup>[63]</sup>。其典型流程如下。

①意图定义: 通过图形化界面或声明式语言捕

获业务意图，例如“为视频会议流量保证低时延”或“在故障发生时优先恢复关键链路”。

②意图解析：将自然语言或声明式意图转换为中间表示，并进行语义验证与冲突检测。

③策略生成：基于意图模型自动生成或推荐具体策略（如流表规则、服务质量（QoS, quality of service）配置、安全访问控制策略等）。

④执行与下发：通过南向接口将策略下发给 SDN 控制器、路由器或防火墙等设备，并进行实时应用。

⑤保证与校验：持续监测网络状态，将运行数据反馈至意图解析模块，验证策略执行效果并在意图偏离时自动调整。

IBN 的优势在于能够将业务需求与网络运营直接解耦，提高策略下发速度与一致性<sup>[64]</sup>。TM Forum 发布的泛化意图模型（GIM, generic intent model）<sup>[45]</sup>与 Google<sup>[35]</sup>、Cisco<sup>[65]</sup>等厂商的 IBN 实践平台均遵循上述五阶段流程。在 IBN 概念得到广泛认可后，开源社区和厂商均推出了多种落地方案：OpenDaylight<sup>[66]</sup>和 ONOS<sup>[67]</sup>在其 SDN 控制平台中分别引入了 Intent Manager 和分布式意图层，用于意图编译、冲突检测与增量部署；Cisco DNA Center<sup>[68]</sup>和 HPE Infosight<sup>[69]</sup>等商用系统则在基础意图编排之外，集成了仿真验证、可视化风险评估与 AI 异常检测，以提升意图执行的可靠性和自适应性；同时，TM Forum 发布的 Intent Open API<sup>[70]</sup>支持意图在接入网、传输网与云网的跨域传递<sup>[71]</sup>，而学术界的 Intent++ 原型进一步通过强化学习动态生成和优化意图模型<sup>[72]</sup>，增强了对复杂与异常场景的在线自演进能力<sup>[73]</sup>。

针对意图驱动网络，CCSA TC7 启动了电信运营商智能化体系白皮书等标准化项目<sup>[74]</sup>，形成了端到端意图模型、策略翻译与验证流程等系列文档。中兴、华为等设备商则联合开展多域场景下的互操作性测试与白盒评估，验证了意图闭环在业务意图下发、网络状态在线学习与反馈机制中的可行性和性能<sup>[75]</sup>。

## 1.2 现有架构存在不足

尽管 ANIMA、KDN 和 IBN 在自治网络领域各有所长，但仍存在明显不足：ANIMA 在基础设施层面通过 MAPE-K 循环实现自动发现与故障自愈，却仅限于单一域的配置与恢复，难以跨域协同；

KDN 将 KP 与 SDN 控制深度融合，完成了基于离线训练的数据驱动优化，却缺乏对环境、网络与用户行为等多域信息的统一实时建模与增量更新；IBN 则以业务意图为核心构建了端到端的意图闭环管理，但未对底层网络状态进行在线学习，也难以在多域场景中共享或复用知识。由此可见，现有框架在以下方面存在不足。

1) 全链路覆盖不足：只能在某一层或某一域内形成闭环，难以实现从物理基础设施到业务意图的无缝衔接。

2) 跨域协同欠缺：现有跨域往往是业务跨域、区域跨域，缺少统一的多域知识表示与动态更新机制，难以支撑环境、网络与业务需求的实时协同。

3) 持续自演进乏力：在线学习与策略自优化能力不足，网络在面对突发变化或全新场景时难以快速自适应与持续演进。

## 1.3 自治网络引入知识驱动的动机

随着 6G 网络对亚毫秒级时延、大容量吞吐和海量终端接入的要求不断攀升，实时决策与跨域协同面临前所未有的挑战。系统既需保证极低响应时延，又要动态融合多源信息并持续自演进；现有框架难以在实时性、可扩展性与持续演进之间取得平衡，因而亟须一种兼顾多域融合与闭环自治的新型网络架构。

### 1) 全局与局部感知能力提升

6G 网络需同时处理物理层（链路质量、无线干扰）、网络层（路由拓扑、切片状态）和业务层（用户行为、服务质量）的海量异构数据<sup>[4]</sup>。知识驱动架构可将这些分散信息映射至统一的知识空间，实现跨层次、跨域的全局视图。借助知识图谱建立故障因果关系模型，不仅能够迅速还原事件序列，还可基于历史经验自动推断潜在根因，大幅提升故障诊断的速度与准确率。

### 2) 知识跨域协同与策略自适应

图神经网络与知识蒸馏技术已在多领域证明了对大规模异构数据的在线融合与模型更新能力<sup>[76]</sup>。通过此类模型统一编码环境域、网络域与用户行为域的关键特征，并实时融合新观测，知识库始终与真实网络保持同步。基于此最新知识，系统可自动生成或调整策略，不需要事先设置大规模阈值，即可实现跨域流量调度、切片管理与资源协同的精准自适应。

### 3) 持续自演进与高可用性保障

元学习、自监督与强化学习算法使智能体能在新场景下快速适应并迁移策略;全局知识库定期蒸馏各领域最新信息,更新底层模型参数,确保策略推理模块具备经验迁移能力<sup>[77]</sup>。各智能体基于本地知识与全局策略生成闭环反馈,当环境或需求发生变化时,可在线微调并迅速恢复,保证自治系统在高动态或部分故障场景中的稳定运行。

综上,引入知识驱动机制不仅打破了单域、离线与静态框架的限制,而且构建了实时、跨域与自演进的端到端自治闭环,为 6G 网络提供了兼顾全局协调与局部精细化的智能运维能力,以满足日益严苛的多场景服务需求。

## 2 面向 6G 的知识驱动“自智”网络架构

### 2.1 架构设计准则

知识驱动“自智”网络(以下简称“系统”)旨在构建一个能够自感知、自学习、自优化并持续自演进的端到端自治网络架构,将传统规则化与单域优化运维升级为真正意义上的全场景智能运维。实现从物理基础设施到业务意图的闭环管理,真正做到“感知-决策-执行-验证-反馈”全流程自动化<sup>[78]</sup>。将“环境、网络与用户行为”三大信息域无缝融合,以知识为纽带协调多域资源与策略,将网络变为认知主体。网络能够在运行中实时学习并迭代优化策略,应对突发变化与新场景需求。

为满足 6G 多场景下的自治需求,网络架构在基础闭环、知识驱动与意图治理三者基础上,设计应遵循以下 5 项关键准则。

1) 多层元智能:将网络视为多层次的认知主体,发展“关于网络智能的智能”<sup>[27]</sup>,分级部署感知、推理和决策模块,既保证局部快速响应,也支持全局协同优化。

2) 统一知识表示:采用可扩展的知识模型,规范环境域、网络域与行为域的特征编码,并支持在线增量更新,确保知识库始终与真实网络状态保持同步。

3) 模块化与可插拔:各功能组件(图神经推理、知识蒸馏、在线代理等)应遵循统一接口规范,可根据场景灵活组合或扩展。

4) 自监督与自适应:在智能体中引入自监督与强化学习机制,使系统能基于运行反馈自动调整

策略,不需要人工阈值调优。

5) 高可用与容错:设计冗余的知识存储与决策路径,支持智能体在线微调与快速恢复,确保在部分故障或网络动态剧变时仍能稳定运行。

本文“认知平面+网络元智能”架构在多个方面突破了传统的 KDN 架构。首先, KDN 的知识表示过于单一,主要集中在网络状态数据(如拓扑矩阵、流量特征),未能考虑环境动态(如电磁干扰、节点位移)和用户行为意图(如业务优先级、QoS 需求)。这种单维度的表示无法有效应对复杂、多变的网络环境,限制了 KDN 在高动态环境中的应用。相比之下,本文通过引入跨域知识融合,构建了“环境-网络-行为”三元知识图谱,使网络能够同时处理网络状态、环境因素和用户需求,从而在决策过程中提升适应性和决策质量。

其次, KDN 仅关注单一域的优化(如流量工程调度),缺乏跨环境、网络和行为域的协同决策能力,难以处理跨域的复杂决策问题。本文的认知平面通过全局协同自治机制,整合网络元智能,使不同领域和层次智能体能够协同工作,进行跨域决策优化,确保多维度的优化。最后, KDN 的决策过程依赖预定义的规则库,无法实时调整策略,缺乏足够的自适应能力。相比之下,本文的认知平面通过引入自监督学习和在线强化学习,形成闭环认知引擎,能够根据环境反馈实时优化决策,持续自我改进。

在 IBN 框架中,意图引擎作为核心组件,负责解析用户意图并生成策略。然而, IBN 依赖离线训练的模型,策略生成缺乏对实时变化的网络环境的适应性,无法快速响应突发事件(如链路中断或干扰)。这种适应能力缺失限制了 IBN 在高度动态环境中的应用。与之不同,本文网络元智能体通过引入在线强化学习和自适应决策机制,能够实时响应环境扰动,实施动态策略调优,确保网络在突发事件中能快速调整决策,显著提升系统的适应性。

此外, IBN 的知识沉淀机制存在断层,历史经验无法转化为可复用的知识,从而降低了系统的学习和优化效率。相比之下,本文网络元智能体能够将历史经验转化为可复用的知识,并通过自监督学习和强化学习不断优化决策策略,提升决策效率和准确性。最后, IBN 架构的决策层级较为扁平,集

中式的决策处理无法满足 6G 超可靠、低时延通信等业务对时延的严格要求。本文通过分布式部署和层级决策, 可将决策处理下放到边缘节点, 减少了决策时延, 提高了响应速度, 满足了高时效需求。

## 2.2 跨域知识的表示与组织

以 6G 空天地一体化的低空交通管控场景为例, 知识驱动“自智”网络所需的核心能力是将物理环境、网络运营和无人机行为这三大域的异构信息, 统一到一个“知识空间”里进行感知与决策, 其业务域进行如下拆分。

1) 环境域: 采集飞行区域的物理与电磁环境信息, 包括风速、温度、湿度、地形起伏, 以及电磁干扰源、信道状态信息 (CSI)、信号覆盖强度、噪声水平、路径损耗、NLoS/LoS 状态。

2) 网络域: 实时监测无人机编队与地面基站的拓扑关系、空地切换事件、网络切片分配与链路利用率, 也包括节点连接性、带宽分配、链路质量 (如 SNR、BER)、路由策略、拓扑变化, 确保路由控制、切片管理和拥塞缓解策略的精准执行。

3) 用户行为域: 聚焦无人机群承载的业务类型 (如货物投递、巡检巡航或应急救援)、任务类型分布、流量特征、飞行轨迹与服务等级需求 (时延敏感度、带宽要求), 为资源调度与 QoS 保证提供优先级指引。

这种拆分不仅是通过物理层、链路层、网络层、应用层对网络拆解进行感知后认知, 分域处理也使故障、性能瓶颈或异常行为能迅速定位到具体域, 便于精细化排查与决策回溯, 同时提升了系统透明度。知识表示与组织的流程可分为以下 5 个阶段。

1) 跨域信息预处理与分段: 系统首先对物理层 (风速、温度、地形起伏、电磁参数)、网络层 (拓扑关系、切片状态、链路质量) 和业务层 (飞行任务类型、轨迹、服务等级) 等多源时序数据进行分段和预处理, 包括去噪、归一化与窗口分割, 从而形成一个结构化的特征矩阵。

不同任务和场景往往具有共性特征, 这些特征可以迁移至新任务中, 从而提升系统的泛化能力, 并且是整合异构信息的关键。通过知识化过程, 将多源数据转化为结构化的知识图, 可以实现不同域信息在多层次上的融合。与直接依赖原始数据的模型相比, 知识驱动模型也更具弹性。

2) 环境知识建模: 接下来实现跨域知识的统一编码, 需要设计一个匹配机制, 将不同域的知识映射到统一的空间中。每个信息域 (环境、网络、行为) 都会生成自己的特征向量。我们借助“注意力机制”来自动判断在当前时刻、针对某个网络节点, 哪些域的信息更重要, 并以此为权重将它们融合成一个综合描述。这样, 当链路质量或无人机行为发生突变时, 系统能迅速捕捉到最关键的变化。

3) 全局信息传播: 把物理世界的实体 (基站、无人机、干扰源等) 和它们之间的关系 (“覆盖” “干扰” “触发” 等) 组织成一个知识图谱, 然后用轻量级的嵌入方法 (比如 TransE) 把它们转化为可以在神经网络里运算的向量。这一步让系统能够在知识层面重演故障场景或分析干扰源, 以便更准确地诊断与预防问题。

4) 全局信息传播: 在全局控制层面, 把所有无人机上报的行为数据看作图上的节点, 用图卷积网络来进行信息扩散, 也就是把一个节点的状态和它邻居节点的状态相互传递融合, 从而让每架无人机都能获得整个蜂群的协同信息。

5) 视觉感知多模态融合: 如果无人机配备了摄像头, 还能将图像帧通过卷积神经网络提取成视觉特征, 然后与上述跨域特征一起投入决策模型中, 使路径规划不仅依赖网络和环境数据, 还能结合实际视觉中的障碍物信息。

通过这套流程, 知识驱动“自智”网络能够在复杂的低空交通场景中, 实现对异构信息的统一感知、快速决策和高效执行。

## 2.3 架构及工作流程

在对 ANIMA、KDN 与 IBN 框架进行比较并深入剖析架构设计原则与认知模型后, 本文在 SDN 集中控制之上新增了一层“认知平面”, 构建了知识驱动的自智网络架构, 如图 1 所示, 该架构在传统的应用平面、管理与控制平面以及基础设施平面 3 层结构之间, 插入了认知平面。用户和业务意图自应用平面下发, 底层采集的多源数据和状态信息则沿管理与控制平面汇聚至认知平面, 经过智能分析与推理后, 再通过应用平面下发策略, 实现了真正的端到端自治闭环。

应用平面: 部署高层次的网络服务, 允许用户通过文本、语音或影像表达意图, 利用北向接口管理网元开发高级网络服务和应用, 如流量工程、安

全管理和 QoS 等。

认知平面：作为系统的智能中枢，整合“网络元智能”机制，在多变环境中协同调度各类模型与智能体，实现自我认知、自我管理 with 自我优化。其部署具备计算与通信能力的设备和知识库，支持感知、推理学习、知识生成、验证优化与记忆检索等功能。具体流程如下。

①输入获取：从应用平面接收用户意图与经验知识，然后从管理与控制平面、基础设施平面收集并预处理网络监控数据。

②智能处理：运用机器学习算法，分析与推理跨域信息，生成或优化模型参数，并结合知识图谱完成知识发现、存储与传播。

③策略下发：通过南向接口将优化后的决策与策略下发至管理与控制平面，通过北向接口将反馈与调整结果回传至应用平面，形成端到端的自演进闭环<sup>[79]</sup>。

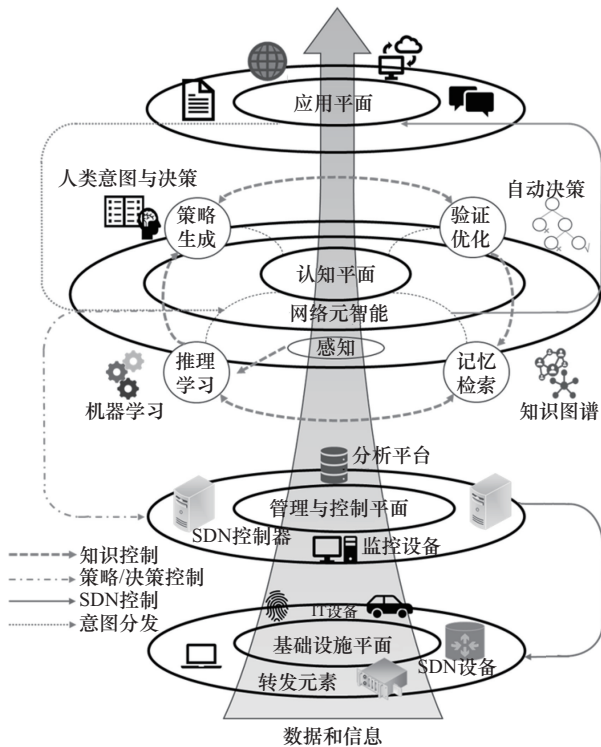


图 1 知识驱动的智能网络架构

管理与控制平面：结合了管理平面和控制平面的功能，部署监控设备、控制器与分析平台，监控设备收集网络状态和性能数据，控制器处理网络设备的配置和管理，从而定义网络拓扑，分析平台将决策和具体配置相互转化。

认知平面通过收集“观察-约束-断言”数据，并基于预定义规则生成响应，需访问监控设备（传感器）和网络设备（执行器）。监控设备从基础设施平面采集状态与性能数据并记录历史，控制器则通过南向接口下发配置并交换执行状态，动态更新数据平面规则。分析平台对原始数据进行清洗和预处理，将结构化结果传递给认知平面，为其高级推理与决策提供基础。

基础设施平面：由主机、可编程转发硬件及其物理链路组成，负责数据包的存储、转发与处理，并依赖管理与控制平面实时更新转发表与配置，确保数据在网络中的高效、准确传递。在 6G 场景下，基础设施平面还扩展至高频毫米波小基站、可重构智能表面、空天地一体化的无人机基站与卫星链路，以及分布式边缘计算节点等多样化设备，从而支撑超宽带、超低时延和广覆盖的网络需求。

### 2.4 网络元智能模块设计及工作流程

人类认知的过程涉及记忆系统、感知和情况评估、推理学习机制以及知识的获取和改进。学习是通过多种方式积累知识，并在动态和复杂的环境中改进自身性能；而推理可以将现有知识转化为对观察结果和行动决策的解释<sup>[80]</sup>。网络元智能模块是认知平面功能实现的核心单元，其在认知流程中承担感知、推理、决策与反馈等关键职责。

“元智能”一词源自对智能系统自身进行认知与控制的再度智能化，即对多种学习、推理与决策方法之间的协调与自治能力的自我管理<sup>[81]</sup>。在网络领域，“网络元智能”即“网络智能的智能”，它构成了认知平面的核心：每个元智能体在其局部环境中感知多域信息、学习并优化决策策略，然后主动调整自身行为。

令网络元智能体定义为

$$MA = \langle S, \mathcal{A}, \mathcal{K}, \mathcal{F}, \mathcal{R}, \mathcal{L} \rangle \quad (1)$$

其中， $S$  是状态空间，表示环境域、网络域和行为域的乘积，即环境域  $\otimes$  网络域  $\otimes$  行为域。例如，一个状态  $s_t$  可以由信噪比、拓扑结构和 QoS 需求等信息组成  $\{ \text{e.g., } s_t = [\text{SNR}]_t, \text{Topo}_t, \text{QoS}_t \in \mathbb{R}^d \}$ 。

动作空间  $\mathcal{A}$  包括路由策略、切片配置和资源分配等组成部分，即路由策略  $\times$  切片配置  $\times$  资源分配，例如一个动作  $a_t$  可以表示为路径选择和切片配置的组合，形式为  $\{ \text{e.g., } a_t = \{ \text{Path}_k, \text{Slice}_m \} \}$ 。

知识库  $\mathcal{K}$  包含三元组存储和模型参数的组合，

即  $\{(e_i, r_{ij}, e_j)\} \cup \Theta_{\text{model}}$ ，其中三元组存储包含环境元素、网络状态以及行为之间的关系， $\Theta_{\text{model}}$  表示模型参数。

状态转移函数描述了给定当前状态和动作后，如何转移到下一个状态，即  $\mathcal{F}: \mathcal{S} \times \mathcal{A} \rightarrow \mathcal{S}$ ，该函数用于模拟系统状态随时间的变化。

奖励函数  $\mathcal{R}: \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$  定义了每个状态-动作对所获得的奖励，可以通过式(2)计算奖励，即

$$\mathcal{R}(s, a) = w_1 \text{Latency}^{-1} + w_2 \text{Throughput} - w_3 \text{Risk} \quad (2)$$

其中， $w_1, w_2, w_3$  是权重系数，用于平衡时延、吞吐量和风险之间的关系。

为使网络能够有效地学习状态表示，本文引入自监督学习损失  $\mathcal{L}_{\text{ssl}}$ ，即

$$\mathcal{L}_{\text{ssl}} = \min_{\theta} \| \text{GNN}(s_t; \theta) - \text{GNN}(s_{t+\Delta}; \theta) \|_2 \quad (3)$$

该损失函数通过优化图神经网络模型参数  $\theta$  来最小化当前状态和下一状态之间的表示差异。

为了训练强化学习模型，本文使用期望的奖励来优化价值函数，即

$$\mathcal{L}_v = \mathbb{E}_{s,a} [ \mathcal{R}(s,a) + \gamma V(s') - V(s) ] \quad (4)$$

网络元智能的工作流程如图2所示，作为最小的逻辑单元，网络元智能体集成了多域感知、知识推理、策略生成与在线优化等功能，是实现网络端到端自适应与持续演进的基本功能实体<sup>[28]</sup>，本文给出网络元智能运行的一般流程。

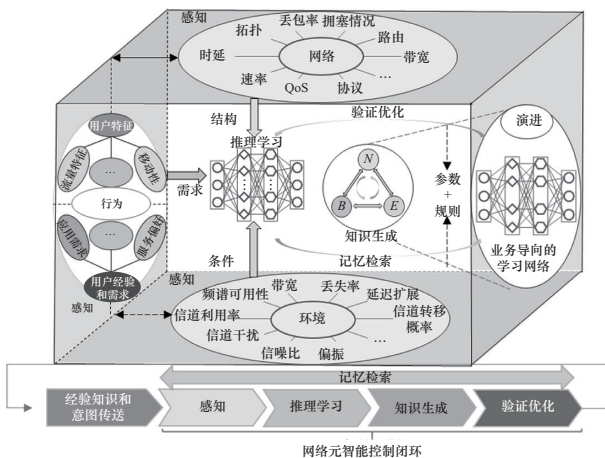


图2 网络元智能的工作流程

用户意图是指用户对网络服务、资源配置与性能优化等方面的高级需求与期望，是实现以用户为中心网络管理的关键要素<sup>[32]</sup>。意图通常以自然语言或声明式格式表达，不仅反映当前的管理目标，

还可能包含对未来场景的预期约束或特殊需求，以可操作的任务或优化目标形式呈现。有时意图隐含于用户行为和上下文中，需通过元智能体生成的知识进行反馈确认。与此同时，经验知识则依赖记忆检索，来源于网络管理过程中的历史数据、成功案例、策略模板以及专家系统的积累，为系统在遇到类似问题时提供快速参考和决策支持。在实际应用中，ANIMA 偏重经验知识的积累与复用，KDN 强调用户域或业务域知识的结构化表达，而 IBN 则将用户意图置于核心位置<sup>[82]</sup>。

**步骤1 经验知识与意图传达。**系统首先自应用层捕获用户或业务的高层意图（如“30 s内完成交付”或“优先保证低时延”），并通过轻量级语义解析将自然语言指令转化为具体的性能约束与优先级设置<sup>[83]</sup>。与此同时，系统从历史运行日志、专家知识库与物理模型中抽取经验规则，诸如典型故障恢复流程、链路性能规律等，并将其载入全局知识库，为后续决策提供上下文支持。

**步骤2 多域同步感知。**网络元智能并行采集三大域的实时数据。环境域：链路质量、电磁干扰、气象条件与地形起伏等物理环境信息。网络域：路由拓扑、网络切片分配、节点可达性与拥塞水平。行为域：终端的任务类型及服务等级需求。所有原始数据经过去噪、归一化与窗口分段处理后，形成统一的多域特征表达，为后续的推理与学习提供准确而全面的输入。

**步骤3 推理学习。**在这一阶段，网络元智能运用多种模型对当前状态进行分析和预测，借助知识图谱，系统可快速重演故障场景并推断根因；利用图神经网络等在线模型，在智能体群体或网络节点之间传播状态信息，预测未来负载与拓扑变化；通过自监督与机器学习算法，智能体在运行中不断微调自身策略，快速适应新环境；借助元学习框架，当遭遇未见场景时，系统可仅凭少量样本实现模型的快速迁移。

**步骤4 知识生成。**“网络一切信息皆知识”，基于推理与学习结果，网络元智能将高层意图、实时感知和历史经验融合，生成一系列候选参数或策略，包括新的路由、切片调整或无人机航线。随后，这些策略在虚拟孪生环境中进行快速仿真，剔除明显违背性能目标或风险过高的方案。最终，经验证的最优策略通过标准接口下发到 SDN 控制器

或智能体, 加速落地执行。

**步骤 5 验证优化。**策略执行后, 系统持续监测关键指标 (如时延、吞吐、碰撞风险等), 将现实反馈与预期结果进行对比。在必要时, 触发局部或全局的在线微调, 确保策略迅速收敛至最佳状态。与此同时, 成功的策略和推理路径被自动存入知识库, 丰富经验知识; 失败的案例也会作为负例保留, 支持后续故障根因分析与模型改进。

**步骤 6 记忆检索。**在验证优化后, 网络元智能会定期检索全局知识库: 通过索引与相似度匹配, 找到与当前场景 (如相似拓扑或干扰模式) 最贴合的历史策略, 将其作为调优起点, 缩短决策时间。回溯少见故障或极端链路环境下的应对方案, 确保在罕见事件发生时也有可借鉴的经验。自动剔除过时或低效策略, 根据业务与网络演变动态更新经验条目, 保持知识库的精简与时效。在联邦或多控制区部署中, 各智能体可互换成功案例, 加速全网自演进。同时, 系统持续监测关键指标 (时延、吞吐、碰撞风险等), 将实际反馈与预期结果对比, 如有偏差立即触发在线微调。所有成功策略与推理路径被存入知识库丰富经验; 失败案例则作为负例保留, 用于后续根因分析与模型优化。

系统将包括用户意图在内的所有网络信息以知识化形式回传至全局视图, 由此完成一次闭环控制, 并为后续优化与演进提供依据。网络元智能的行为可抽象成一个状态机, 通过注意力机制在多源特征间动态分配权重, 从而聚焦当前任务最关键的信息并生成最优策略。例如, 系统能够输出语义状态: “在区域 A 中, 节点 28 在马尔可夫干扰环境下若要实现设备间的最快数据传输, 应选用路径 1”。此时网络便成为认知的主体, 即使环境域、网络域或行为域信息不全, 状态机也能基于语义状态和既有知识, 推断出近似最优解。

在网络管理与调度中, 自适应机制是保证系统能够在不断变化的环境中动态调整的核心部分。为了实现这一目标, 本文采用了在线强化学习策略优化和知识演化动力学 2 种机制。

首先, 本文定义一个马尔可夫决策过程, 用以描述在当前状态下, 如何选择最佳动作来最大化长期回报。具体地, MDP 包含以下 5 个元素。

**状态空间  $\mathcal{S}$ :** 表示系统可能的所有状态。

**动作空间  $\mathcal{A}$ :** 在每个状态下, 系统可以采取的

所有可能动作。

**状态转移概率  $\mathcal{P}$ :** 描述从一个状态到另一个状态的概率。

**奖励函数  $\mathcal{R}$ :** 定义每个状态-动作对的即时奖励。

**折扣因子  $\gamma$ :** 用于计算长期奖励的折扣, 控制当前奖励与未来奖励之间的权衡。

通过优化策略  $\pi^*(a|s)$  来最大化期望的总回报。期望回报被表示为未来所有时间步的奖励的加权和, 计算式为

$$\pi^*(a|s) = \arg \max_{\pi} \mathbb{E} \left[ \sum_{t=0}^T \gamma^t \mathcal{R}(s_t, a_t) \right] \quad (5)$$

其中,  $\pi^*(a|s)$  表示在状态  $s$  下选择动作  $a$  的最优策略, 目标是使总回报最大化。为了在强化学习过程中调整策略, 使用策略梯度更新机制, 通过式(6)来优化模型参数为

$$\Delta \theta = \alpha \nabla_{\theta} (\ln \pi_{\theta}(a_t|s_t) A(s_t, a_t)) \quad (6)$$

其中,  $\theta$  表示策略的参数;  $\alpha$  是学习率;  $A(s_t, a_t)$  是优势函数, 定义为当前策略在状态  $s_t$  和动作  $a_t$  下的优势, 即

$$A(s, a) = \mathcal{R}(s, a) + \gamma V(s') - V(s) \quad (7)$$

其中,  $\mathcal{R}(s, a)$  是即时奖励,  $V(s')$  是下一个状态的价值,  $V(s)$  是当前状态的价值。优势函数衡量了当前动作相对于状态的价值偏差, 帮助优化策略, 使其逐步改进以获得更好的长期回报。

除了在线强化学习策略优化, 本文还引入了知识演化动力学, 用于描述知识库在训练过程中如何随着策略和环境的变化不断演化。知识库  $\mathcal{K}$  包含了从环境中获得的知识与策略经验, 它会随时间动态变化。其演化动力学可描述为

$$\frac{d\mathcal{K}}{dt} = \underbrace{\lambda \text{RL}_{\text{exp}}(\pi^*)}_{\text{策略经验}} + \underbrace{\mu \text{GNN}_{\text{emb}}(s_t)}_{\text{感知知识}} - \underbrace{\delta \text{Entropy}(\mathcal{K})}_{\text{知识衰减}} \quad (8)$$

其中,  $\lambda$ 、 $\mu$  和  $\delta$  是权重/速率系数, 控制贡献强度和衰减速率;  $\pi^*$  是 (近) 最优策略, 来自 RL 训练或当前最优近似;  $s_t$  是环境/网络状态;  $\mathcal{K}$  是知识库状态 (知识向量或主题分布)。知识库的演化受到 3 个主要因素的影响。

**策略经验 ( $\text{RL}_{\text{exp}}(\pi^*)$ ):** 策略经验是通过强化学习算法获得的, 它帮助知识库在新的策略下进行

知识更新。这部分的贡献由 $\lambda$ 权重控制，反映了策略经验对知识演化的影响。

感知知识 ( $\text{GNN}_{\text{emb}}(s_t)$ ): 感知知识是由图神经网络 (GNN) 从状态  $s_t$  中提取的特征。GNN 通过从网络状态中提取信息来增强知识库的表示能力，这部分的贡献由 $\mu$ 权重控制。

知识衰减 ( $\text{Entropy}(\mathcal{K})$ ): 随着时间的推移，知识库中的某些知识可能变得过时或无效，因此引入了知识衰减机制，通过熵来衡量知识的不确定性，并进行适当的衰减。是控制衰减速率的参数。

通过合理的风险控制、策略优化与历史经验回溯，本文“认知平面+网络元智能”架构能够不断提升系统的智能化水平和自适应能力。从决策的角度来看，网络元智能的核心不仅在于持续优化单一模态策略的生成，更在于提升其面向多样化场景的自适应解决能力。

## 2.5 面向 6G 的知识驱动“自智”网络所需关键技术

为实现认知平面的核心功能，本文的关键技术分别支撑感知建模、推理学习、策略生成与知识演进等关键环节，与 2.3 节所构建的认知平面架构以及 2.4 节中的网络元智能体运行流程紧密对应，构成系统闭环自治能力的底层技术支撑体系。针对当前系统在实时融合、大规模扩展、策略可解释性及多终端协同等方面所面临的核心挑战，本文进一步凝练出 3 类关键技术模块：跨域知识融合基础设施、AI 驱动的控制与编排引擎，以及在线学习与全局自演进引擎。系统性构建知识驱动“自智”网络的技术实现路径，并结合已有研究基础展开深入分析与探讨。

### 2.5.1 跨域知识融合基础设施

为了打破环境域、网络域与用户行为域之间的信息孤岛，系统需要构建一个端到端的跨域知识表示管道。该技术构成认知平面中的感知输入与知识统一建模子模块，为网络元智能体的多域感知与特征表示提供底层支持。首先，系统可以通过轻量化的自然语言处理 (NLP, natural language processing) 模型<sup>[84]</sup>和定制化解析器，对用户业务意图和运行日志进行语义解析与关键词抽取，并借助特征存储 (feature store)<sup>[85]</sup>等技术完成结构化特征的预处理与在线更新；紧接着，通过在线特征工程提取链路质量、切片利用率及任务类型分布等多源指标，并利用 Apache Kafka<sup>[86]</sup>或消息队列遥测传输

(MQTT, message queuing telemetry transport)<sup>[87]</sup>数据总线将这些多域遥测信息实时汇聚。基于此，系统在 Neo4j 图数据库<sup>[88]</sup> (Neo4jGD, Neo4j graph database) 中构建起“环境-网络-行为”的三元知识图谱，使用 TransE<sup>[89]</sup>或 ComplEx<sup>[90]</sup>将实体与关系映射到向量空间；随后，借助深度图学习库 (DGL, deep graph library)<sup>[91]</sup>或 PyTorch 几何驱动的 GNN<sup>[76,92-93]</sup> (如图注意力网络 (GAT, graph attention network)<sup>[94]</sup>、图采样与聚合 (GraphSAGE, graph sample and aggregate))，在该异构图上执行消息传递，并通过多头注意力 (multi-head attention) 动态计算不同域特征的融合权重，从而将各域特征统一编码到同一潜在空间。最后，整个模型在教师-学生的知识蒸馏框架下定期更新，将最新的跨域表示下沉至边缘智能体，确保本地模型与全局知识库始终保持一致。该流程端到端可微，能够在分布式 GNN 推理引擎中实现多层次、在线增量的跨域知识融合与推理。

### 2.5.2 AI 驱动的控制与编排引擎

作为全网自治的“大脑”，系统需要内置一个 AI 驱动的控制与编排引擎，将跨域知识直接翻译为可执行的网络策略。该引擎对应于认知平面中的策略生成子模块，主要支撑元智能体在“感知-推理-策略”形成过程中的实时决策与策略下发。引擎可首先通过业务流程模型与标注<sup>[95]</sup> (BPMN, business process model and notation) 结合 Kubernetes Operator 定义策略工作流，支持多阶段并行执行与动态分支调整；然后借助因果机器学习 (CausalML, causal machine learning) 库<sup>[96]</sup>等，对每个候选方案进行因果推理与置信度评估，提前剔除高风险路径；接着，利用强化学习库 (RLlib, reinforcement learning library) 驱动的深度强化学习算法 (如近端策略优化<sup>[97]</sup> (PPO, proximal policy optimization)、软行动者-硬评论家<sup>[98]</sup> (SAC, soft actor-critic))，以及模型无关元学习<sup>[99]</sup> (MAML, model-agnostic meta-learning) /reptile 框架，在控制层对策略进行在线试验与快速微调，以加速收敛；最后，通过封装 ONAP、ONOS Intent、NETCONF/YANG 等主流 northbound / southbound 协议<sup>[100]</sup>，将经验证的最优策略无缝下发至 SDN 控制器或智能体各网络组件，确保端到端闭环的可靠执行。

### 2.5.3 在线学习与全局自演进引擎

为了满足 6G 网络对持续动态演进的需求,系统需要构建一个在线学习与全局自演进引擎,以不断优化模型与知识库。该引擎支撑认知平面中的知识演进模块,强化元智能体的策略适应性与模型更新能力,实现系统在复杂环境下的持续演进与自治。首先,在跨域控制域之间可以采用联邦平均<sup>[101]</sup>(FedAvg, federated averaging)或联邦近端优化<sup>[102]</sup>(FedProx, federated proximal)协议开展联邦学习,并结合差分隐私<sup>[103]</sup>(DP, differential privacy)与安全多方计算<sup>[104]</sup>(SMPC, secure multi-party computation)技术,确保本地数据不出域且敏感信息受保护。在模型部署环节,通过 8 位整数量化、结构化剪枝与神经架构搜索<sup>[105]</sup>(NAS, neural architecture search)将全局教师模型蒸馏为轻量学生模型,以满足边缘节点的毫秒级推理需求。最后,当监测系统触发在线微调需求时,结合在线微调流程和 Kubeflow 管道自动化编排重训练任务,使模型与策略在多变网络环境中持续自校准、自优化,保持最佳性能。

## 2.6 准则与架构的对应关系

多层元智能(体现准则 1)。图 1 中,认知平面作为“智能大脑”,其内部通过分层部署的网络元智能体实现智能的层级化。全局元智能体(部署于核心认知平面)负责跨域协同优化与意图管理;区域/域级元智能体(可部署于边缘或特定域控制器)则专注于本地环境的快速感知、推理与决策。这种分层结构确保了全局最优与局部快速响应的结合,满足准则 1“多层元智能”的要求。

统一知识表示(体现准则 2)。系统通过构建统一的“环境-网络-行为”三元知识图谱(如 2.2 节所述),并利用 GNN 进行特征编码与融合,将物理环境(如链路质量、干扰)、网络状态(如拓扑、切片负载)和用户行为(如任务类型、QoS 需求)等异构多源信息映射到同一语义空间。这种统一的、可扩展的知识表示模型是支撑跨域协同决策的基础,直接实现了准则 2“统一知识表示”的设计目标。

模块化与可插拔(体现准则 3)。架构设计遵循模块化原则。认知平面中的跨域知识融合基础设施、AI 驱动的控制与编排引擎、在线学习与全局自演进引擎(对应 2.5.1~2.5.3 节)均通过定义清晰的 API 接口(如基于 YANG 模型或 RESTful)进行

交互。例如,知识图谱模块可替换为不同的图数据库(Neo4j、JanusGraph),推理引擎可选用不同 GNN 变体(GAT、GraphSAGE)或因果推理模型,策略生成引擎可集成 PPO、SAC 等多种强化学习算法。这种模块化与可插拔特性使系统能根据特定 6G 场景需求灵活组合技术组件,符合准则 3 的要求。

自监督与自适应(体现准则 4)。网络元智能体的核心运行流程内嵌了自监督与自适应机制。在“推理学习”阶段,智能体利用自监督学习从无标签的时序数据(如链路状态、流量模式)中学习表征;在“验证优化”阶段,基于强化学习(如 PPO)的机制使智能体能够根据策略执行后的环境反馈(如实际时延、吞吐量变化)自动调整策略参数,实现策略的在线微调和快速收敛。这种基于反馈的闭环优化机制,避免了依赖固定阈值和人工调优,充分体现了准则 4“自监督与自适应”。

高可用与容错(体现准则 5)。为确保系统鲁棒性,架构设计了冗余机制和动态恢复策略。认知平面支持多副本部署关键模块(如全局知识库、策略引擎)。在网络元智能层面,当监测到本地智能体失效或网络分区时,相邻智能体可通过知识图谱检索或联邦知识共享临时接管其决策职责,或在全局智能体协调下进行策略重路由。同时,验证优化阶段的快速在线微调能力有助于系统在环境剧变或部分故障时快速恢复稳定运行。这些设计直接支撑了准则 5“高可用与容错”的目标。

## 2.7 面向 6G 的知识驱动“自智”网络典型应用

### 2.7.1 低空交通管控

随着无人机等低空经济终端的广泛部署,低空空间迅速成为“空中拥堵”高发区。系统可以融合环境域(气象、地形、电磁干扰)、网络域(地面基站与 UAV 编队链路状态、切片资源)和用户行为域(飞行任务类型、优先级、服务等级需求)3 类知识,实时完成跨域流量调度、动态切片分配与路径重规划<sup>[106]</sup>。当突发风速变化或链路抖动时,认知平面瞬时更新全局知识图谱,调度多层元智能体生成新的航线与资源分配策略,保障蜂群安全、高效通行。

### 2.7.2 全息交互与工业互联网

对于远程医疗手术、工业远控维护等超低时延、高可靠场景,系统可在超密集切片和边缘计算节点间,基于跨域知识快速生成网络切片与算力调度策略<sup>[107]</sup>。环境域提供端到端链路时延与抖动信

息,网络域反馈切片负载与虚拟化资源使用,用户行为域映射触觉反馈与视觉渲染需求,认知代理以毫秒级决策下发超可靠切片和边缘算力配置,确保触觉回路与全息视频帧同步<sup>[108]</sup>。

### 2.7.3 工业数字孪生驱动的智能制造

在智能工厂中,来自物联网传感器的设备健康、能源消耗和生产节拍数据,与企业级系统的生产调度意图相结合,形成跨域的全生产线知识图谱。系统通过图神经网络进行在线推理,预测生产瓶颈与故障根因,并在机器人控制网络与工业以太网之间动态调度资源;同时,元智能体持续学习最佳维护与调度策略,驱动数字孪生平台执行“仿真-优化-部署”的闭环,实现生产效率与可靠性的持续提升。

## 3 仿真实验

本实验旨在系统地验证知识驱动“自智”网络架构的三方面能力,具体内容如下。

**动态环境适应性:**验证系统在6G典型高扰动场景下的实时决策能力,特别是在6G低空交通管控场景中,涉及无人机、无人车等设备的实时调度与管理,要求网络能够在高动态环境中快速响应,并满足低时延和高可靠性的要求。

**跨域协同效能:**评估环境、网络和行为三域知识的融合对优化决策过程的增益,考察跨领域协同对整体系统性能的提升作用,尤其是在低空交通管控中如何高效调度资源。

**自演进可靠性:**检验网络元智能闭环流程在不断变化的环境中如何实现持续优化,确保系统在长期运行中的自我修复和稳定性,特别是在复杂的低空交通场景下的可靠性与应急响应能力。

从网络元智能流程的步骤入手,实验设计框架如图3所示。

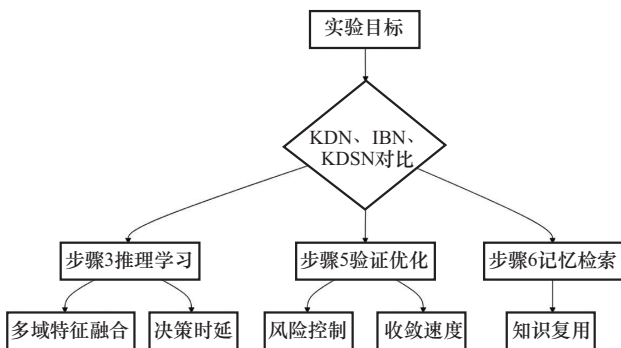


图3 实验设计框架

### 3.1 实验环境与量化指标设计

实验环境设置如表2所示,具体介绍如下。

组件	参数	仿真工具
环境域	现实扰动与电磁干扰	MATLAB 流体仿真
网络域	12个基站+3LEO卫星	NS-3网络仿真器
行为域	30架无人机(含10架高优先级)	Gazebo+ROS

**环境域:**考虑到低空交通中对飞行稳定性和通信质量的需求,模拟了风速和电磁干扰的影响。风速范围设定为8~15 m/s,电磁干扰影响5G毫米波信号的质量,模拟其对通信的波动。

**网络域:**网络结构由地面基站、低轨卫星和无人机组成,模拟多层次的网络拓扑。网络节点间的负载超过85%,且卫星节点在轨道上的运动引起约±20 ms的时延波动。

**行为域:**优化任务包括总载荷调度和资源分配,设置了不同任务的QoS标准。此外,还模拟了电池电量低于20%时的应急响应和任务中断等突发事件。

在过程中,系统需要衡量一系列核心功能与量化指标,确保在实时网络环境中实现高效的资源管理与决策制定。为了更好地评估和优化调度策略,本文引入关键性能指标体系,如表3所示。

### 3.2 实验结果

规则和意图匹配度分布如图4所示,系统对比了3种网络策略生成系统(KDSN、KDN<sup>[12]</sup>和IBN<sup>[73]</sup>)在核心性能维度上的差异。图4(a)聚焦于“模板规则匹配度”,设置了0.90的目标基准线;图4(b)针对“用户意图匹配度”设定了更严格的0.95目标基准线,反映了不同任务场景下的性能需求。在规则匹配分析中,3种系统表现出显著差异。KDSN的匹配度集中在0.45~0.92,且分布向更高匹配度延伸,显示出规则识别任务中的稳定性与高效性。KDN则主要集中在0.75~0.85,且尾部分布稀疏,表明其在复杂规则匹配中的波动性较大。IBN的分布呈双峰形态,在0.70和0.90附近有明显的聚集区,暗示其匹配机制存在不稳定因素。在用户意图匹配中,KDSN的匹配度接近完美,核心密度集中在0.93~0.98,尾部几乎消失,表现出对用户意图理解的极致能力。KDN则主要集中在0.80~0.86,表现出较大的不稳定性。IBN则在0.85~0.92

表3 关键性能指标体系

流程阶段	核心功能	量化指标	数学表达
步骤3推理学习	多域特征融合	模板规则、用户意图	$H(S) - H(GNN(S)) \geq \eta$
	策略生成	决策时延上界 动态扰动响应时间	$t_{\text{decision}} \leq t_{\text{max}}$ $t_{\text{response}} = t_{\text{detect}} + t_{\text{adjust}}$
步骤5验证优化	策略收敛性	策略优化收敛速度	$\ \nabla \mathcal{L}_t\ _2 \leq \epsilon$
	风险控制	失败策略检出率	$\text{Precision}_{\text{risk}} = \frac{\text{TP}}{\text{TP} + \text{FP}}$
步骤6记忆检索	知识复用效率	历史策略匹配度	$\text{sim}(s_t, s_{\text{hist}}) = \cos(\phi(s_t), \phi(s_{\text{hist}}))$
		长期稳定性	$\sigma_{\text{perf}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - \mu)^2}$

有 2 个密度峰值，表明其匹配度范围更广，且涉及高低匹配度两端。

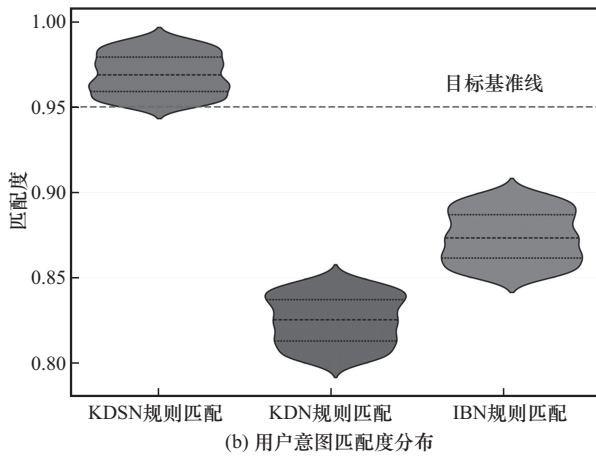



图4 规则和意图匹配度分布

多域特征融合权重差异如图 5 所示。从图 5 中可以看出，KDSN 系统在环境域表现出较高的权重分配，这表明它在处理物理环境因素方面具有优势；KDN 系统在网络域显示最强的权重表现，突

显其在网络特性优化方面的专注；而 IBN 系统则在行为域权重明显领先，强调它在用户行为和意图理解方面的优势。3 种策略系统形成了互补的特征关注模式，整体展示了不同系统架构在特征融合方面的差异化设计理念和技术侧重点。

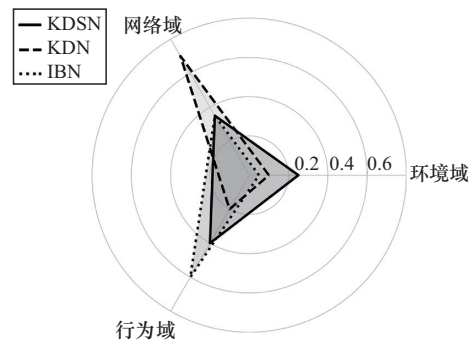
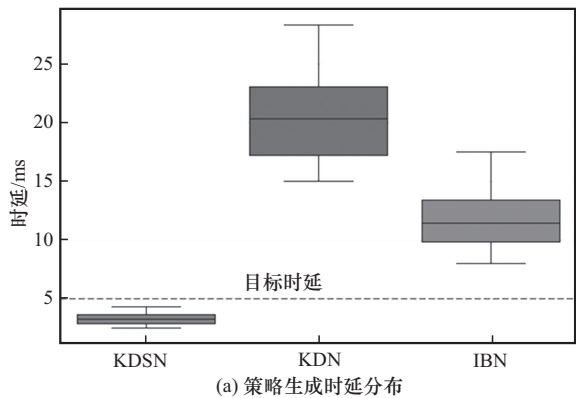


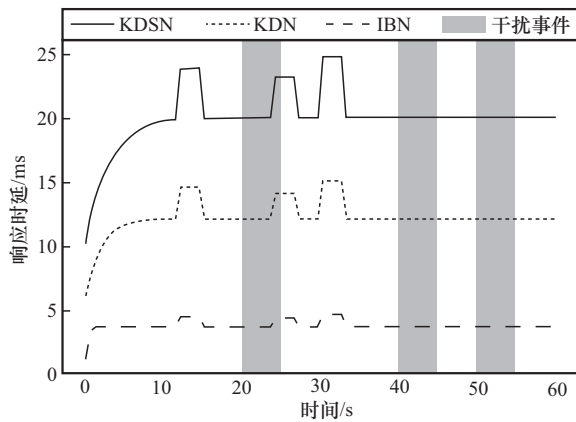
图5 多域特征融合权重差异

策略生成效率对比如图 6 所示，通过时间序列变化展示了 3 种系统在动态扰动下的响应表现。图 6(a)展示了 KDSN、KDN 和 IBN 这 3 种策略系统在处理任务时的时效性能差异。整体观察可见，KDSN 系统的表现最为卓越，其箱体结构紧凑且位置最低，集中分布在接近 0~5 ms 的狭窄区间内，几乎所有数据点都完美控制在虚线标识的 5 ms 目标时延基准线下方，显示出极高的时间效率和响应速度。相较之下，KDN 系统的表现最为逊色，其箱体位置最高且结构最为松散，箱体主体范围横跨 15~25 ms，分布范围从 10 ms 到接近 25 ms 不等，数据点散布在广阔区间中，显示出明显的性能波动和不稳定性，完全超出目标时延线。IBN 系统的表现居中，箱体集中在 10~17 ms，虽也超出目标线但相较 KDN 更为收敛，呈现出中等水平的稳定性

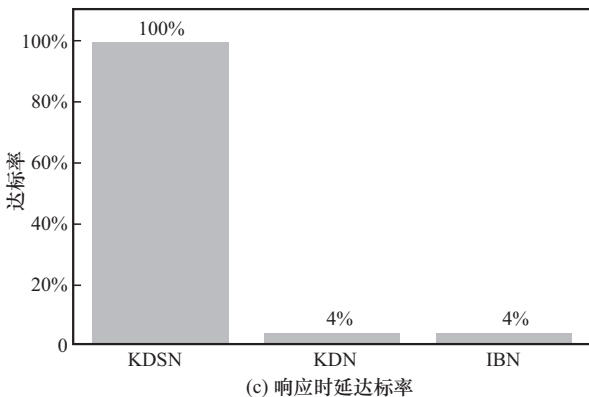
能表现。图 6(b)提供了在模拟干扰事件条件下各系统的实时性能对比。最为显著的是KDSN系统展现出了卓越的稳定性，在干扰发生区间保持响应时延稳定在约 5 ms 范围内，几乎没有明显波动。相比之下，KDN 系统在干扰期间响应时延会急剧攀升至 23~24 ms 的高峰，之后虽有所下降但仍维持在约 20 ms 的高水平；IBN 系统在干扰发生时响应时间上升至 13~14 ms，之后稳定在 12ms 水平。这些实时数据差异展示了KDSN在抗干扰能力方面的明显优势。



(a) 策略生成时延分布



(b) 动态扰动响应时间




(c) 响应时延达标率


图 6 策略生成效率对比

图 6(c)进一步证实了KDSN的领先性能，实现了 100% 的达标率，完美控制在目标时延范围内。而KDN和IBN的达标率仅为4%，表明在应对动态干扰时稳定性存在显著不足。KDSN系统在多域特征融合中保持更均衡的权重分配，同时在动态扰动环境下展现出卓越的稳定性和响应控制能力，而KDN和IBN系统则在各自领域表现出特征权重偏移，但在整体抗干扰性能和稳定性方面存在明显短板。这些分析结果共同展示了策略系统中多域融合设计与动态环境适应性的密切关系。

策略收敛曲线如图 7(a)所示，KDSN系统展现出卓越的收敛效率，其曲线以陡峭的斜率迅速下降至目标阈值区域，在迭代约 20 次时即稳定贴近 0.5 的收敛阈值，呈现出明显优于 PPO 系统和 Random 系统的学习动力学特性；后两者不仅耗时更长，且在整个训练周期内均呈现显著振荡特征，最终仍无法紧密逼近预定收敛目标，反映出其核心优化机制存在的本质局限。图 7(b)展示了不同系统在梯度范数收敛过程中的表现。KDSN 系统的梯度范数呈现出快速的下降趋势，表明在初始阶段快速收敛，且梯度变化趋于稳定，验证了其高效的优化过程。相比之下，PPO 和 Random 系统的梯度范数下降较为缓慢，且在训练过程中存在较大的波动，无法稳定下降至较低的梯度值，表明这些方法在优化过程中受到了较大的扰动和不稳定性影响，导致收敛速度较慢，难以达到理想的优化效果。



(a) 策略收敛曲线



(b) 梯度范数收敛曲线

图 7 策略收敛曲线

策略相似度比较如图 8 所示，通过双视角系统地展示了策略相似度的分布特征。图 8(a)展示了“相似策略”与“随机策略”的显著差异：高相似

度策略的箱体紧密集中在 0.8~1.0, 表现为低熵分布, 且其须线较短, 表明高度聚集的策略相似性; 相反, 随机策略的箱体分布较宽, 从 -0.2~0.2, 且有显著的离群点, 呈现高熵波动特征。图 8(b) 进一步强化了这一对比: 相似策略的分布曲线在 0.9 处形成陡峭的单峰, 80% 的密度集中在 0.8~1.0, 形成尖锐的边界; 随机策略的曲线则呈现为平缓的丘陵形态, 均匀分布在 0 值周围, 表现出更大的波动性和分散性。

失败策略检出效率比较如图 9 所示, 精确率-短横线混淆矩阵分析显示 KDSN 系统在故障检测任务中具有卓越性能表现。图 9(a) 明确展示 KDSN 系统的精确率即将达到 0.98, 远超 0.95 的基准线, 显著优于 KDN 和 IBN 系统。图 9(b) 展示出在 133 个实

际失败样本中, KDSN 正确识别了其中 130 个 (真阳性 TP=130), 仅误判 3 个为正常 (假阴性 FN=3); 在 57 个实际正常样本中, 正确识别 50 个 (真阴性 TN=50), 仅将 7 个误判为失败 (假阳性 FP=7)。这种性能特征表明 KDSN 系统同时具备高精度 (接近 98% 准确识别故障) 与低误判率 (仅 7 个正常样本误报), 验证了其在故障检测任务中的高可靠性和低误差特性。

图 10 系统性地验证了知识复用机制的核心价值, 通过 3 组关键数据的综合展示, 清晰地论证了知识复用对系统性能的全面优化作用。图 10(a) 以量化形式呈现了知识复用的效率优势, 显示采用完整记忆库的 KDSN 系统实现了 0.444 的平均复用效率, 显著优于有限记忆库 (0.346), 而无知识复用




图 8 策略相似度比较




图 9 失败策略检出效率比较

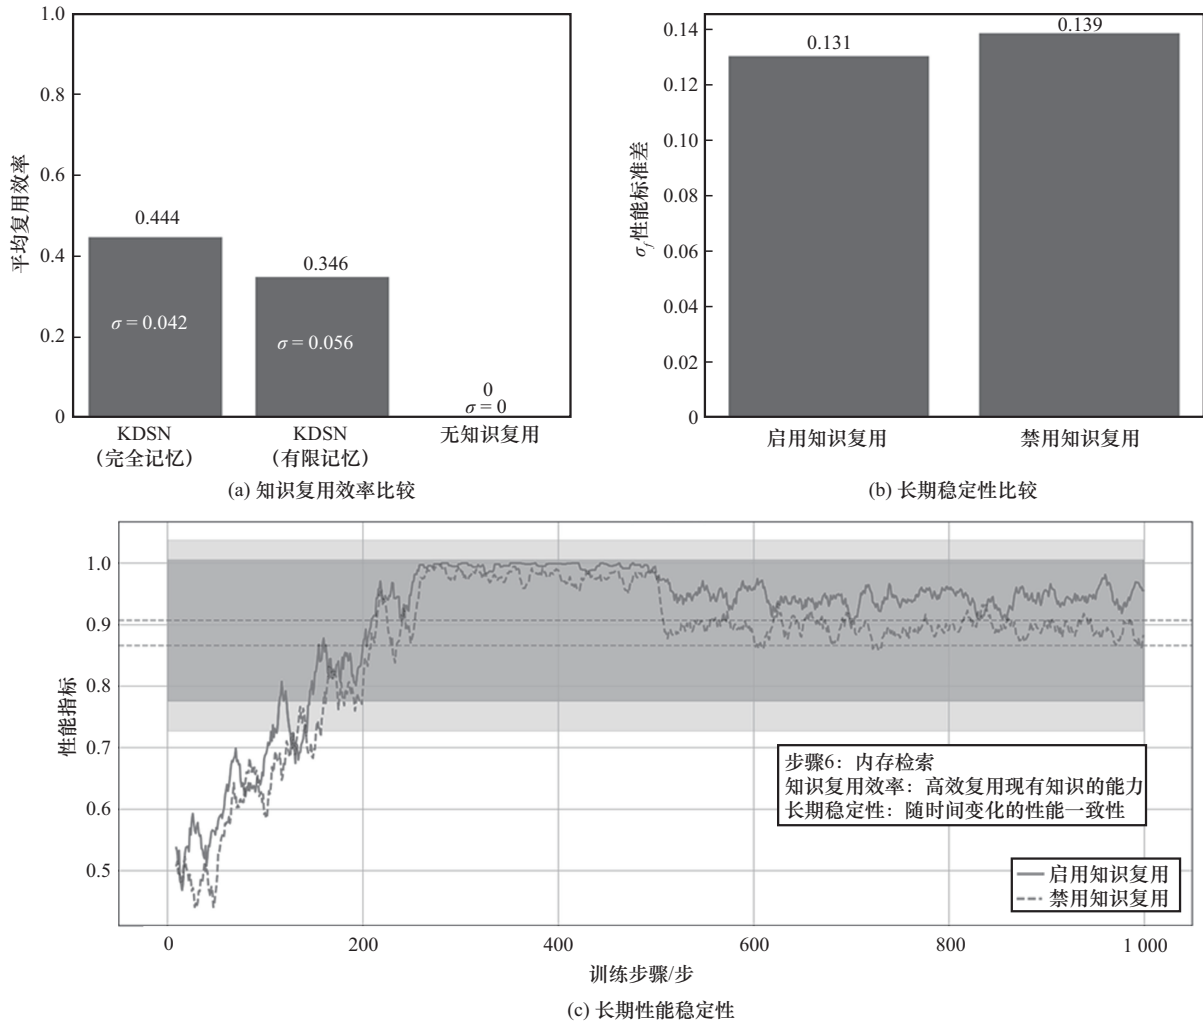


图 10 知识复用与长期稳定性分析

的系统复用效率为零。3 组数据点的标准差分别为 0.042、0.056、0，进一步印证了知识库规模对操作稳定性的关键影响。

图 10(b)聚焦于长期可靠性指标，通过性能标准差公式计算的实证数据表明，启用知识复用的系统稳定性 ( $\sigma=0.131$ ) 明显优于禁用方案 ( $\sigma=0.139$ )，尽管 0.008 的差距看似微小，却揭示了知识复用在提升系统抗波动能力方面的本质作用。

图 10(c)展示了这种优势的持续效应。在 1 000 步的训练过程中，知识复用曲线始终保持领先基准线约 0.1 个性能点，并在 600 步后成功稳定在 0.9 的高位平台。其平滑的上升轨迹和狭窄的波动区间直观体现了知识复用带来的双重增益：不仅加速了性能提升（500 步即可突破 0.8 的阈值），还显著抑制了训练过程中的性能波动（全程振幅小于 0.1）。这一现象展示了“知识复用效率”和“长期稳定性”

在协同优化方面的作用。

## 4 关键挑战与开放性研究问题

### 4.1 关键挑战

在设计与部署过程中，系统能否真正实现实时、多域、可演进的自治运维能力主要面临以下几大关键挑战。

#### 4.1.1 实时跨域知识融合

在 6G 网络中，物理环境（如毫米波链路质量、气象条件）、网络态势（如拓扑结构、切片利用率）与业务行为（如用户意图、服务等级）等信息均以海量、高速的 Telemetry 形式产生，且来源极其分散。要在毫秒级完成对这些多源数据的清洗、预处理、特征抽取和语义融合，以支持认知平面的实时决策，既要求底层管道具备极低的系统时延，也需要上层模型能够在分布式架构中高效协

同。当前常用的分布式图神经网络与知识图谱嵌入方法,能够借助并行消息传递实现跨域特征编码,但其对网络带宽和算力有较高依赖。如何在保证表示精度的同时,通过模型剪枝、量化、轻量级推理引擎等手段,将端到端的信息流转时延严格控制在数毫秒范围内,并避免控制信令在核心与边缘间泛滥,仍然是亟待攻克的技术难题。

#### 4.1.2 大规模系统的可扩展性与稳定性

随着 6G 边缘节点、无人机编队和车联网终端规模的爆发式增长,单一集中式控制器或统一推理平台将难以支撑全网自治,其一旦出现瓶颈或故障,便会导致大范围服务中断。为了提升系统的弹性,研究者提出采用微服务化架构,将推理、决策与策略下发拆分为可按需扩缩的容器模块,并利用 Kubernetes 等编排平台进行自动化运维;在模型更新层面,通过联邦学习和差分隐私技术,实现跨域模型的安全协同。然而,这种“多域分片、跨域聚合”模式下,如何在节点失联或网络抖动时快速重配置、保证全网策略的一致性,以及如何避免“分布式一致性协议”带来的额外时延开销,都是设计时必须平衡的核心难题。

#### 4.1.3 复杂场景下的策略可解释性与风险控制

6G 网络自治策略往往由深度强化学习<sup>[109]</sup>、元学习和因果推理等多种人工智能技术混合生成,策略链条渐趋复杂,这也对应更高的安全与合规审计要求:当网络出现异常或策略失效时,需快速回溯到具体的输入数据、推理路径和策略参数。当前,部分方案通过在模型内部嵌入因果风控和后置可解释模块,或在数字孪生沙盒中执行灰度测试来评估风险,但这些方法多属“事后补偿”,难以实现对整体决策流程的实时监控与审计<sup>[110]</sup>。未来需要将“可解释性约束”与“合规验证”深度融合到模型训练和在线推理阶段,并建立从策略生成到执行的全链路可追溯框架,确保每一次下发的网络策略都可被即时审计并在必要时自动回滚。

#### 4.1.4 多类型终端与自治主体的协同调度

6G 生态中,边缘设备种类丰富,包括传统基站、边缘服务器、无人机、车载终端、工业物联网节点等,它们在算力、通信能力和安全信任域上差异巨大。要让所有自治主体在同一知识驱动框架下协同工作,需要定义统一的 northbound/southbound 接口(如 YANG、ONOS Intent),并在协议层与调

度算法层进行深度耦合设计。现阶段多依赖数字孪生对多体协同进行离线仿真,或通过本地快速回退策略增强容错,但在真实网络中,协议交互的异步性与链路时延抖动会导致控制指令乱序或丢失。如何设计轻量级可靠传输协议、智能调度算法和动态信任管理机制,以实现跨设备、跨域的实时自适应与自动容错,是当前推动 6G 自智网络大规模部署的另一条瓶颈路径。

## 4.2 开放性研究问题

以下几个开放性研究问题,聚焦“大模型”、语义通信、卫星互联网与具身智能在 6G 自智网络中的融合与协同,旨在指出今后的发展方向,引发进一步探索。

### 4.2.1 基于大规模预训练模型的网络控制与推理

当前网络智能多依赖于轻量化、专门训练的深度学习模型,却难以同时承担丰富的跨域语义理解与复杂策略规划的任务。有必要探索将 GPT、BERT 等大型预训练模型引入网络控制域,以统一解析多源网络与业务数据,并基于少量示例与提示方式,快速生成高质量的网络策略。其关键难点在于:如何在保证低时延的前提下,将数十亿参数的预训练模型高效部署于边缘节点;如何设计增量微调与联邦蒸馏流程,实现模型的实时在线更新;以及如何量化评估提示工程在网络控制中的收益与潜在风险。

### 4.2.2 语义通信驱动的资源优化与故障预防

6G 的万物互联将产生海量冗余报文,传统按比特计费或逐包转发的模式已难满足低功耗低时延需求。语义通信驱动的资源优化与故障预防,则要求在控制平面与数据平面引入统一的语义层,通过自动识别关键拓扑变更、罕见故障模式或业务意图,仅对这些高价值语义事件进行优先传输。为此,需要设计端到端的语义压缩与恢复算法,并在 6G 网络切片中建立分级保障机制,以兼顾传输效率与系统可靠性。

### 4.2.3 低轨卫星互联网与地面自智网络的无缝融合

在低轨卫星互联网与地面自智网络的无缝融合方面,必须解决高动态多跳拓扑与剧烈链路抖动所带来的路由与调度挑战。未来可通过知识驱动框架,将地面 SDN/认知平面与卫星控制平面统一管理,并在“地-空-地”链路中实现多源遥测的在线融合与应急策略生成,以完成真正的全球化端到

端自治闭环。

#### 4.2.4 具身智能在网络节点的落地

“具身智能”强调智能体在物理世界中的理解与交互能力，其落地使网络节点拥有物理世界中的交互能力。自智节点将不再仅仅执行命令，而能通过微型天线重构、可再生能源调度等物理动作主动影响环境，并实时观测反馈。研究需回答：如何在安全可控条件下赋予节点物理反馈动作？如何统一管理电子、物理与网络三域的感知与控制？如何在“身-心-体”协同模式下，实现多节点协作学习与故障隔离？

## 5 结束语

本文提出了面向 6G 的知识驱动自智网络，实现了从感知、学习、优化到演进的端到端自治运维。系统以“认知平面”“网络元智能”为核心，将传统规则化、单域化的运维模式升级为闭环自治体系，在感知、学习、决策与演进之间持续循环；其模块化、可插拔的设计及多源知识融合算法，不仅能够满足超低时延、海量连接和复杂场景的需求，也为异构网络协同与跨域融合提供了统一框架。

本文首先通过梳理并对比现有自治网络框架，揭示了规则化与单域优化的局限，进而阐明了知识驱动自智网络的设计动机；随后详述了知识驱动“自智”网络的整体架构与运行流程，以及核心“网络元智能”模块的闭环控制机制，说明了如何在“智能之上再智能”中实现持续自演进。针对实时性、大规模部署、复杂场景可解释性和异构网络协同四大挑战，分析了在现有系统中得以应用的关键技术。

通过系统的实验验证，本文展示了基于知识驱动的“自智”网络架构在 6G 低空交通管控场景中的显著优势。实验结果表明，KDSN 系统在多域特征融合和策略生成方面具有明显的优势，尤其在处理动态环境下的规则匹配和用户意图理解时，其高匹配度和低时延表现极为突出。同时，知识复用机制在提升系统长期稳定性和抗扰动能力方面起到了至关重要的作用。与传统的 KDN 和 IBN 系统相比，KDSN 不仅能实现更高效的资源管理和决策制定，还在长期训练过程中展现了更强的自我修复和优化能力。该实验不仅验证了知识复用在智能系统中的

核心作用，也为未来智能网络在复杂环境中的应用提供了有效的技术路径。

最后结合大模型、语义通信、卫星互联网和具身智能等新兴技术，勾勒了知识驱动“自智”网络未来的研究方向。

## 参考文献：

- [1] ALHAMMADI A, SHAYEA I, EL-SALEH A A, et al. Artificial intelligence in 6G wireless networks: opportunities, applications, and challenges[J]. *International Journal of Intelligent Systems*, 2024, 2024(1): 8845070.
- [2] GUO H Z, LI J Y, LIU J J, et al. A survey on space-air-ground-sea integrated network security in 6G[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(1): 53-87.
- [3] GUO F X, YU F R, ZHANG H L, et al. Enabling massive IoT toward 6G: a comprehensive survey[J]. *IEEE Internet of Things Journal*, 2021, 8(15): 11891-11915.
- [4] SHI Y D, LIAN L X, SHI Y M, et al. Machine learning for large-scale optimization in 6G wireless networks[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(4): 2088-2132.
- [5] RUSEK K, SUÁREZ-VARELA J, ALMASAN P, et al. RouteNet: leveraging graph neural networks for network modeling and optimization in SDN[J]. *IEEE Journal on Selected Areas in Communications*, 2020, 38(10): 2260-2270.
- [6] GHEISARI M, KHAN W Z, NAJAFABADI H E, et al. CAPPAD: a privacy-preservation solution for autonomous vehicles using SDN, differential privacy and data aggregation[J]. *Applied Intelligence*, 2024, 54(4): 3417-3428.
- [7] CASAS-VELASCO D M, RENDON O M C, DA FONSECA N L S. Intelligent routing based on reinforcement learning for software-defined networking[J]. *IEEE Transactions on Network and Service Management*, 2021, 18(1): 870-881.
- [8] TOSOUNIDIS V, PAVLIDIS G, SAKELLARIOU I. Deep Q-learning for load balancing traffic in SDN networks[C]//*Proceedings of the 11th Hellenic Conference on Artificial Intelligence*. New York: ACM Press, 2020: 135-143.
- [9] BENOUDIFA O, AIT WAKRIME A, BENAINI R. Autonomous solution for controller placement problem of software-defined networking using MuZero based intelligent agents[J]. *Journal of King Saud University - Computer and Information Sciences*, 2023, 35(10): 101842.
- [10] LONG S F, TANG F X, LI Y F, et al. 6G comprehensive intelligence: network operations and optimization based on large language models[J]. *IEEE Network*, 2025, 39(4): 192-201.
- [11] CLARK D D, PARTRIDGE C, RAMMING J C, et al. A knowledge plane for the Internet[C]//*Proceedings of the 2003 Conference on Applications, Technologies, Architectures, and Protocols for Computer Communications*. New York: ACM Press, 2003: 3-10.
- [12] MESTRES A, RODRIGUEZ-NATAL A, CARNER J, et al. Knowledge-defined networking[J]. *ACM SIGCOMM Computer Communication Review*, 2017, 47(3): 2-10.
- [13] YANG K Q, HE Q, WANG X W, et al. KDN-based adaptive computa-

- tion offloading and resource allocation strategy optimization: maximizing user satisfaction[J]. *IEEE Transactions on Computers*, 2025, 74(5): 1743-1757.
- [14] CHEN W S, LIN X Q, LEE J, et al. 5G-advanced toward 6G: past, present, and future[J]. *IEEE Journal on Selected Areas in Communications*, 2023, 41(6): 1592-1619.
- [15] LI Y H, SU X, DING A Y, et al. Enhancing the Internet of things with knowledge-driven software-defined networking technology: future perspectives[J]. *Sensors*, 2020, 20(12): 3459.
- [16] AHAMMED T B, PATGIRI R, NAYAK S. A vision on the artificial intelligence for 6G communication[J]. *ICT Express*, 2023, 9(2): 197-210.
- [17] 王敬宇, 周铖, 张蕾, 等. 知识定义的意图网络自治[J]. *电信科学*, 2021, 37(9): 1-13.  
WANG J Y, ZHOU C, ZHANG L, et al. Knowledge-defined intent-based network autonomy[J]. *Telecommunications Science*, 2021, 37(9): 1-13.
- [18] JIANG Y H, LI X Y, ZHU G X, et al. 6G non-terrestrial networks enabled low-altitude economy: opportunities and challenges[J]. *arXiv Preprint*, arXiv: 2311.09047, 2023.
- [19] MOZAFFARI M, LIN X Q, HAYES S. Toward 6G with connected sky: UAVs and beyond[J]. *IEEE Communications Magazine*, 2021, 59(12): 74-80.
- [20] HUANG J, YU T, ZHU X G, et al. Energy efficiency maximization in UAV-assisted intelligent autonomous transport system for 6G networks with energy harvesting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, PP(99): 1-11.
- [21] LANGLEY P, LAIRD J E, ROGERS S. Cognitive architectures: research issues and challenges[J]. *Cognitive Systems Research*, 2009, 10(2): 141-160.
- [22] JIANG F B, PENG Y B, DONG L, et al. Large language model enhanced multi-agent systems for 6G communications[J]. *IEEE Wireless Communications*, 2024, 31(6): 48-55.
- [23] CHEN Z Q, SUN Q, LI N, et al. Enabling mobile AI agent in 6G era: architecture and key technologies[J]. *IEEE Network*, 2024, 38(5): 66-75.
- [24] ABD ELAZIZ M, AL-QANESS M A A, DAHOU A, et al. Evolution toward intelligent communications: Impact of deep learning applications on the future of 6G technology[J]. *WIREs Data Mining and Knowledge Discovery*, 2024, 14(1): e1521.
- [25] XIAO Y, SHI G M, ZHANG P. Towards agentic AI networking in 6G: a generative foundation model-as-agent approach[J]. *arXiv preprint arXiv:2503.15764*, 2025.
- [26] CHACCOUR C, SAAD W, DEBBAH M, et al. Less data, more knowledge: building next-generation semantic communication networks[J]. *IEEE Communications Surveys & Tutorials*, 2025, 27(1): 37-76.
- [27] DONG N N, YIN H, REN B Q, et al. Research on network cognition model and mechanism of intelligent information network[J]. *China Communications*, 2023, 20(2): 257-277.
- [28] 尹浩. 智能信息网络理论与技术[M]. 北京: 人民邮电出版社, 2024.  
YIN H. Theory and technology of intelligent information networks[M]. Beijing: Posts & Telecom Press, 2024.
- [29] BRINGHENTI D, MARCHETTO G, SISTO R, et al. Automation for network security configuration: state of the art and research trends[J]. *ACM Computing Surveys*, 2024, 56(3): 1-37.
- [30] RAFIQUE D, VELASCO L. Machine learning for network automation: overview, architecture, and applications [invited tutorial][J]. *Journal of Optical Communications and Networking*, 2018, 10(10): D126-D143.
- [31] GILBERT M. Artificial intelligence for autonomous networks[M]. New York: Chapman and Hall/CRC, 2018.
- [32] MEHMOOD K, KRALEVSKA K, PALMA D. Intent-driven autonomous network and service management in future cellular networks: a structured literature review[J]. *Computer Networks*, 2023, 220: 109477.
- [33] 中国移动通信有限公司研究院. 6G 天地一体分布式自治网络白皮书[R]. 2024.  
China Mobile Research Institute. 6G integrated space-air-ground distributed autonomous network white paper[R]. 2024.
- [34] ECKERT T. Autonomic networking integrated model and approach (ANIMA): secure autonomic network infrastructure[M]. Hershey IGI Global, 2018.
- [35] LEIVADEAS A, FALKNER M. A survey on intent-based networking[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(1): 625-655.
- [36] ALTAMIRANO J C. Towards autonomic network management powered with DRL, GAN and SDN for routing optimization[D]. Toulouse: Université de Toulouse, 2024.
- [37] WANG Y, FORBES R, CAVIGIOLI C, et al. Network management and orchestration using artificial intelligence: overview of ETSI ENI[J]. *IEEE Communications Standards Magazine*, 2018, 2(4): 58-65.
- [38] FORBES R, STRASSNER J, ZENG Y. Transformers and large language models as used in ETSI ISG experiential networked intelligence[C]// *Proceedings of the 2024 IEEE International Conference on Communications Workshops (ICC Workshops)*. Piscataway: IEEE Press, 2024: 1250-1255.
- [39] WANG Y, FORBES R, ELZUR U, et al. From design to practice: ETSI ENI reference architecture and instantiation for network management and orchestration using artificial intelligence[J]. *IEEE Communications Standards Magazine*, 2020, 4(3): 38-45.
- [40] FENG S, SEIDEL E. Self-organizing networks (SON) in 3GPP long term evolution[J]. *Nomor Research GmbH, Munich, Germany*, 2008, 20: 1-15.
- [41] JORGUSESKI L, PAIS A, GUNNARSSON F, et al. Self-organizing networks in 3GPP: standardization and future trends[J]. *IEEE Communications Magazine*, 2014, 52(12): 28-34.
- [42] LIN X Q. 3GPP evolution from 5G to 6G: a 10-year retrospective[J]. *arXiv Preprint*, arXiv: 2412.21077, 2024.
- [43] LIN X Q. The bridge toward 6G: 5G-advanced evolution in 3GPP release 19[J]. *IEEE Communications Standards Magazine*, 2025, 9(1): 28-35.
- [44] MEKRACHE A, KSENTINI A, VERIKOUKIS C. Intent-based management of next-generation networks: an LLM-centric approach[J]. *IEEE Network*, 2024, 38(5): 29-36.
- [45] FONSECA J, ADHANE G, TOGIAS K, et al. Realizing intent-driven network management with TM forum standards[C]// *Proceedings of the 2024 IEEE 29th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)*.

- Pisca-taway: IEEE Press, 2024: 1-5.
- [46] PARK K, SUNG S, KIM H, et al. Technology trends and challenges in SDN and service assurance for end-to-end network slicing[J]. *Computer Networks*, 2023, 234: 109908.
- [47] KINSEY D, SUDARSAN P, JANA R. Open RAN software[J]. *Open RAN: The Definitive Guide*, 2023: 137-144.
- [48] CORONADO E, BEHAVESH R, SUBRAMANYA T, et al. Zero touch management: a survey of network automation solutions for 5G and 6G networks[J]. *IEEE Communications Surveys & Tutorials*, 2022, 24(4): 2535-2578.
- [49] 程强, 刘姿杉. 电信网络智能化发展现状与未来展望[J]. *信息通信技术与政策*, 2020, 46(9): 16-22.
- CHENG Q, LIU Z S. Intelligent telecommunication networks: current status and future prospects[J]. *Information and Communications Technology and Policy*, 2020, 46(9): 16-22.
- [50] MWANJE S S, BANERJEE A. Intent-driven management: a comparative evaluation of 3GPP, TMF and O-RAN standards[R]. 2024.
- [51] DUAN X Y, KANG H H, ZHANG J J. Autonomous network technology innovation in digital and intelligent era[J]. *ZTE Communications*, 2022, 20(4): 52.
- [52] DANG W, HUANG R, YU Y, et al. Autonomous driving network: network architecture in the era of autonomy[M]. Boca Raton: CRC Press, 2024.
- [53] 中国信息通信研究院. 信息通信网运营管理智能化水平分级评估技术要求[R]. 工业和信息化部, 2024.
- China Academy of Information and Communications Technology. Technical requirements for graded evaluation of intelligent operation and management level of information and communication networks[R]. Ministry of Industry and Information Technology, 2024.
- [54] 张宏科, 权伟, 刘康. 算力网络研究与探索[J]. *中兴通讯技术*, 2023, 29(1): 1-5.
- ZHANG H K, QUAN W, LIU K. Research and exploration of computing power network[J]. *ZTE Technology Journal*, 2023, 29(1): 1-5.
- [55] FROST L, MERIEM T B, BONIFACIO J M, et al. Artificial intelligence and future directions for ETSI[R]. 2020.
- [56] GRAHAM B L B. TM forum future architecture strategy discussion paper[R]. 2017.
- [57] SULTANA S, DOOZE P, KUMAR V V. Realization of an intrusion detection use-case in ONAP with acumos[C]//*Proceedings of the 2021 International Conference on Computer Communications and Networks (ICCCN)*. Piscataway: IEEE Press, 2021: 1-6.
- [58] BENZAÏD C, TALEB T, SONG J. AI-based autonomic and scalable security management architecture for secure network slicing in B5G[J]. *IEEE Network*, 2022, 36(6): 165-174.
- [59] DAYARATNE T, VO V, LAI S Q, et al. Exploiting and securing ML solutions in near-RT RIC: a perspective of an xApp[J]. *arXiv Preprint*, arXiv: 2406.12299, 2024.
- [60] MARINOVA S, LEON-GARCIA A. Intelligent O-RAN beyond 5G: architecture, use cases, challenges, and opportunities[J]. *IEEE Access*, 2024, 12: 27088-27114.
- [61] SANTOS J, WAUTERS T, VOLCKAERT B, et al. Towards low-latency service delivery in a continuum of virtual resources: state-of-the-art and research directions[J]. *IEEE Communications Surveys & Tutorials*, 2021, 23(4): 2557-2589.
- [62] ALALMAEI S, ELKHATIB Y, BEZAHAF M, et al. SDN heading north: towards a declarative intent-based northbound interface[C]//*Proceedings of the 2020 16th International Conference on Network and Service Management (CNSM)*. Piscataway: IEEE Press, 2020: 1-5.
- [63] OUYANG Y, YANG C G, SONG Y B, et al. A brief survey and implementation on refinement for intent-driven networking[J]. *IEEE Network*, 2021, 35(6): 75-83.
- [64] SONG Y B, YANG C G, ZHANG J M, et al. Full-life cycle intent-driven network verification: challenges and approaches[J]. *IEEE Network*, 2023, 37(5): 145-153.
- [65] SZIGETI T, ZACKS D, FALKNER M, et al. Cisco digital network architecture: intent-based networking for the enterprise[M]. New York: Cisco Press, 2018.
- [66] YU H, RAHIMI H, JANZ C, et al. Building a comprehensive intent-based networking framework: a practical approach from design concepts to implementation[J]. *Journal of Network and Systems Management*, 2024, 32(3): 47.
- [67] IRFAN T. Implementing the Johnson algorithm: a new approach to ONOS intent path forwarding[C]//*Proceedings of the 2023 International Conference on Electrical Engineering and Informatics (ICEEI)*. Piscataway: IEEE Press, 2023: 1-6.
- [68] LIGHTENBERG D, MEIER A. Cisco DNA center multi tenant manager[R]. 2019.
- [69] ZINNER M, FELDHOFF K, NAGEL W E. Strategy for early recognition and proactive handling of disruptions regarding the service of computer centres and its infrastructures based on statistical methods[C]//*2022 10th International Conference on Sustainable Environment and Agriculture (ICSEA)*. Can Tho: IJESD, 2022: 103.
- [70] FORUM T. Intent Management API 5.0[R]. 2024.
- [71] SONG Y B, FENG T, YANG C G, et al. IS2N: intent-driven security software-defined network with blockchain[J]. *IEEE Network*, 2024, 38(3): 118-127.
- [72] LI T Y, OUYANG Y, ZHANG L L, et al. Autonomous intent detection for intent-driven satellite network[C]//*Proceedings of the 2023 International Wireless Communications and Mobile Computing (IWCMC)*. Piscataway: IEEE Press, 2023: 1649-1653.
- [73] OUYANG Y, LI C L, ZHANG J W, et al. Intent-driven 6G end-to-end network orchestration[C]//*Proceedings of the IEEE INFOCOM 2024 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*. Piscataway: IEEE Press, 2024: 1-2.
- [74] 中国通信学会, 中国联合网络通信有限公司研究院, 中兴通讯股份有限公司. 电信运营商智能化体系白皮书[R]. 2023.
- China Institute of Communications, China Unicom Research Institute, ZTE Corporation. White paper on intelligent system for telecom operators[R]. 2023.
- [75] 华为. 通信网络 2030[R]. 2024.
- Huawei. Communication networks 2030[R]. 2024.
- [76] AYKURT K, KELLERER W. Autonomous network management in multi-domain 6G networks based on graph neural networks[C]//*Proceedings of the 2023 IEEE 9th International Conference on Network Softwarization (NetSoft)*. Piscataway: IEEE Press, 2023: 338-341.
- [77] VETTORUZZO A, BOUGUELIA M R, VANSCHOREN J, et al. Advances and challenges in meta-learning: a technical review[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(7):

- 4763-4779.
- [78] 邓灵莉, 顾宁伦, 袁向阳, 等. 网络智能化标准、开源与产业研究[J]. 电信科学, 2021, 37(10): 12-21.  
DENG L L, GU N L, YUAN X Y, et al. Network intelligence standards, open source and industry research[J]. Telecommunications Science, 2021, 37(10): 12-21.
- [79] YAN Q, YU F R, GONG Q X, et al. Software-defined networking (SDN) and distributed denial of service (DDoS) attacks in cloud computing environments: a survey, some research issues, and challenges[J]. IEEE Communications Surveys & Tutorials, 2016, 18(1): 602-622.
- [80] BINZ M, DASGUPTA I, JAGADISH A K, et al. Meta-learned models of cognition[J]. Behavioral and Brain Sciences, 2024, 47: e147.
- [81] STERNBERG R J, GLAVEANU V, KARAMI S, et al. Meta-intelligence: understanding, control, and interactivity between creative, analytical, practical, and wisdom-based approaches in problem solving[J]. Journal of Intelligence, 2021, 9(2): 19.
- [82] 郭令奇, 张蕾, 杨红伟, 等. 知识定义的意图网络策略生成技术[J]. 北京邮电大学学报, 2024, 47(3): 36-41.  
GUO L Q, ZHANG L, YANG H W, et al. Intent-based network policy generation for knowledge definition[J]. Journal of Beijing University of Posts and Telecommunications, 2024, 47(3): 36-41.
- [83] 杨静雅, 唐晓刚, 周一青, 等. 意图抽象与知识联合驱动的 6G 内生智能网络架构[J]. 通信学报, 2023, 44(2): 12-26.  
YANG J Y, TANG X G, ZHOU Y Q, et al. 6G native intelligence network architecture enabled by intent abstraction and knowledge[J]. Journal on Communications, 2023, 44(2): 12-26.
- [84] BOURAOU Z, CAMACHO-COLLADOS J, SCHOCKAERT S. Inducing relational knowledge from BERT[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(5): 7456-7463.
- [85] KAKANTOUSIS T, KOUZOUPIA A, BUSO F, et al. Horizontally scalable ml pipelines with a feature store[C]//Proceedings of the 2nd SysML Conference. Piscataway: IEEE Press, 2019: 1-3.
- [86] SOLOVE D J, HARTZOG W. Kafka in the age of AI and the futility of privacy as control[J]. BUL Rev, 2024, 1(104): 1021.
- [87] SANJUAN E B, ABAD CARDIEL I, CERRADA J A, et al. Message queuing telemetry transport (MQTT) security: a cryptographic smart card approach[J]. IEEE Access, 2020, 8: 115051-115062.
- [88] CHEN X Z. Design and implementation of knowledge graph of listed companies based on Neo4j[C]//Proceedings of the International Conference on High Performance Computing and Communication (HPCCE 2021). Bellingham: SPIE Press 2022: 248-254.
- [89] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2014, 28(1): 1112-1119.
- [90] SONG Y Q, LI W F, DAI G R, et al. Advancements in complex knowledge graph question answering: a survey[J]. Electronics, 2023, 12(21): 4395.
- [91] WANG F, ZHENG Z, ZHANG Y J, et al. To see further: Knowledge graph-aware deep graph convolutional network for recommender systems[J]. Information Sciences, 2023, 647: 119465.
- [92] WANG L, SONG Z Y, ZHANG X Y, et al. SAT-GCN: Self-attention graph convolutional network-based 3D object detection for autonomous driving[J]. Knowledge-Based Systems, 2023, 259: 110080.
- [93] BI W D, CHENG X Q, XU B B, et al. Bridged-GNN: knowledge bridge learning for effective knowledge transfer[C]//Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2023: 99-109.
- [94] WEI W X, SONG Y T, YAO B. Enhancing heterogeneous knowledge graph completion with a novel GAT-based approach[J]. ACM Transactions on Knowledge Discovery from Data, 2024, 18(4): 1-20.
- [95] BACHHOFNER S, KIESLING E, REVOREDO K, et al. Automated process knowledge graph construction from BPMN models[C]//Database and Expert Systems Applications. Berlin: Springer, 2022: 32-47.
- [96] KADDOUR J, LYNCH A, LIU Q, et al. Causal machine learning: a survey and open problems[J]. arXiv Preprint, arXiv: 2206.15475, 2022.
- [97] YAO F J, TIAN G H, WANG Y H, et al. Active object detection based on PPO learning algorithm with decision knowledge guidance[J]. Machine Intelligence Research, 2025, 22(2): 386-396.
- [98] CHEN H Z, SHEN X, LV Q T, et al. SAC-KG: exploiting large language models as skilled automatic constructors for domain knowledge graphs[J]. arXiv Preprint, arXiv: 2410.02811, 2024.
- [99] ZHANG M, WANG D L, GAI S B: Knowledge distillation for model-agnostic meta-learning[M]. Amsterdam: IOS Press, 2020.
- [100] KUNDRÁT J, VOJTĚCH J, ŠKODA P, et al. YANG/NETCONF ROADM: evolving open DWDM toward SDN applications[J]. Journal of Lightwave Technology, 2018, 36(15): 3105-3114.
- [101] HE C, ANNAVARAM M, AVESTIMEHR S. Group knowledge transfer: federated learning of large cnns at the edge[J]. Advances in Neural Information Processing Systems, 2020, 33: 14068-14080.
- [102] YU X, HE Z, SUN Y, et al. The effect of personalization in fedprox: a fine-grained analysis on statistical accuracy and communication efficiency[J]. arXiv Preprint, arXiv: 2410.08934, 2024.
- [103] DESFONTAINES D, MOHAMMADI E, KRAHMER E, et al. Differential privacy with partial knowledge[J]. arXiv Preprint, arXiv: 1905.00650, 2019.
- [104] RASTOGI A, MARDZIEL P, HICKS M, et al. Knowledge inference for optimizing secure multi-party computation[C]//Proceedings of the Eighth ACM SIGPLAN Workshop on Programming Languages and Analysis for Security. New York: ACM Press, 2013: 3-14.
- [105] WISTUBA M, RAWAT A, PEDAPATI T. A survey on neural architecture search[J]. arXiv Preprint, arXiv: 1905.01392, 2019.
- [106] XIAO H, TIAN W Q, LIU W D, et al. A knowledge-driven meta-learning method for CSI feedback[C]//Proceedings of the IEEE International Conference on Communications. Piscataway: IEEE Press, 2023: 4138-4143.
- [107] 朱海龙, 杨帆, 蒋如一, 等. 算网自智: 研究进展与展望[J]. 通信学报, 2024, 45(10): 191-206.  
ZHU H L, YANG F, JIANG R Y, et al. Computing-network intelligence: research progress and prospects[J]. Journal on Communications, 2024, 45(10): 191-206.
- [108] 周晓茂, 贾庆民, 胡玉姣, 等. 自智算力网络: 架构、技术与展望[J]. 物联网学报, 2023, 7(4): 1-12.  
ZHOU X M, JIA Q M, HU Y J, et al. Autonomous computing and network convergence: architecture, technologies, and prospects[J]. Chinese Journal on Internet of Things, 2023, 7(4): 1-12.
- [109] FOLEY M, WANG M A, ZOE M, et al. Inroads into autonomous network defence using explained reinforcement learning[J]. arXiv Preprint, arXiv: 2306.09318, 2023.
- [110] WU Y L, LIN G Z, GE J G. Knowledge-powered explainable artificial intelligence for network automation toward 6G[J]. IEEE Network, 2022, 36(3): 16-23.

[作者简介]



林佳琦 (1999-), 男, 黑龙江佳木斯人, 北京邮电大学博士生, 主要研究方向为智能网络、知识驱动网络等。



高先明 (1988-), 男, 山东章丘人, 博士, 军事科学院系统工程研究院高级工程师, 主要研究方向为智能网络、韧性网络等。



钱琪杰 (1997-), 男, 江苏南通人, 南京邮电大学博士生, 主要研究方向为人工智能、物联网和未来网络。




葛嘉鑫 (1990-), 女, 辽宁建平人, 军事科学院系统工程研究院助理工程师, 主要研究方向为信号处理、人工智能等。



钟旭东 (1991-), 男, 湖南常德人, 博士, 军事科学院系统工程研究院副研究员, 主要研究方向为智能信息网络技术、卫星通信、无线资源管理与优化。



彭木根 (1978-), 男, 江西吉安人, 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。



冯涛 (1979-), 男, 山东招远人, 博士, 军事科学院系统工程研究院正高级工程师、硕士生导师, 主要研究方向为网络人工智能、软件定义网络和网络管理。



任保全 (1974-), 男, 陕西西安人, 博士, 军事科学院系统工程研究院研究员、博士生导师, 主要研究方向为物联网、无线通信、移动通信网络技术等。