

面向6G的跨域知识驱动网络元智能算法框架

林佳琦^{1,2}, 钱琪杰^{2,3}, 钟旭东², 冯涛², 高先明², 葛嘉鑫², 彭木根¹, 任保全²

(1. 北京邮电大学网络与交换技术全国重点实验室, 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: 为应对现有自动化运维模型在6G多场景、实时化智能管理中的能力瓶颈, 提出了一种跨域知识驱动的网络元智能算法框架。现有方案多依赖静态规则或单域优化, 难以适配6G网络在复杂环境感知、动态策略迁移与多目标调度方面的综合需求。该框架将网络状态建模为环境域、网络域与用户行为域3类知识源, 基于轻量化模型与图神经网络实现高层意图解析与跨域知识的在线融合, 并通过知识蒸馏机制动态地更新全局知识库。在此基础上构建多层网络元智能体, 形成“感知→推理→知识生成→决策下发→验证优化→记忆检索”的闭环控制流程, 辅以自监督、强化与元学习, 实现策略的快速迁移与持续演进。围绕低空交通管控场景, 设计了3类典型任务: 跨域组网、意图引导的智能体管理与蜂群路径规划。实验结果表明, 所提方法在吞吐量、故障恢复时间、流量预测精度、决策时延、执行成功率、资源公平度、路径效率与任务成功率等关键指标上均取得了显著的提升。

关键词: 网络知识; 知识驱动网络; 网络元智能; 智能网络

中图分类号: TN915.5

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2026.00503

Cross-domain knowledge-driven meta-intelligent network algorithm framework for 6G

Lin Jiaqi^{1,2}, Qian Qijie^{2,3}, Zhong Xudong², Feng Tao², Gao Xianming², Ge Jiaxin²,
Peng Mugen¹, Ren Baoquan²

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 cross-domain knowledge-driven meta-intelligent network algorithm framework was proposed in this paper to address the limitations of existing automated operation and maintenance models in supporting multi-scenario and real-time intelligent management in 6G networks. Traditional approaches often rely on static rules or single-domain optimization, which are insufficient for 6G demands such as heterogeneous perception, dynamic policy adaptation, and multi-objective scheduling. The framework modeled network states across environmental, network, and user behavior domains, leveraging lightweight models and graph neural networks for high-level intent parsing and online knowledge fusion. A global knowledge base was dynamically updated via knowledge distillation. Multi-layer meta-intelligent agents formed a closed-loop control process of perception, reasoning, knowledge generation, decision issuance, validation, and memory retrieval. Self-supervised learning, reinforcement learning, and meta-learning techniques were integrated to support rapid policy adaptation and continual optimization. Centered on a low-altitude traffic control scenario, the framework was evaluated through three tasks: knowledge-driven networking, intent-guided agent management, and swarm path planning.

收稿日期: 2025-05-14; 修回日期: 2025-07-02

通信作者: 任保全, renbq88@126.com

基金项目: 国防重点实验室基金重点资助项目 (No. 6142006240401)

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

Experimental results show that the proposed method consistently outperforms baseline approaches in throughput, failure recovery time, traffic prediction accuracy, decision latency, execution success rate, resource fairness, path efficiency, and task success rate.

Key words: network knowledge, knowledge-driven network, network meta-intelligence, intelligent network

0 引言

近年来,随着6G移动通信技术时代对超高带宽、超低时延和海量连接的苛刻需求不断涌现,互联网通信面临了更为严峻的挑战^[1]。软件定义网络(SDN, software-defined network)通过将控制平面与数据平面分离,实现了集中化管理,并赋予控制器对网络全局的可视化能力,从而在一定程度上优化了路由决策^[2]。然而,面对6G网络中千亿级终端、动态异构接入和业务场景的多样化,SDN依然无法满足全网自动化的实时运维需求^[3]。为此,知识定义网络(KDN, knowledge-defined network)^[4]应运而生,它在SDN架构之上引入了“知识平面”^[5],利用机器学习技术从6G网络中采集海量拓扑、频谱与流量数据,提炼出可操作的网络知识,再由控制平面将策略下发至各接入节点,以支持实时、智能化的网络管理与自适应优化^[6]。

在KDN中,关键在于构建高效的机器学习方法,将网络采集的拓扑、流量等海量信息转化为支持全局决策的知识,而不仅仅关注局部优化^[7]。尽管这一过程需要时间来分析与学习网络状态,一旦模型训练完成,这些知识即可被复用,从而大幅简化后续的自动化管理与策略下发,并显著提升决策效果^[8]。除了KDN,近年来基于意图的网络(IBM, intent-based network)也成为实现网络自动化的重要方向。IBM通过意图获取、语义转译、策略生成、执行反馈等模块,构建起从用户目标到网络行为的自动映射机制,实现了“业务驱动”的网络管理流程。与KDN主要关注知识提炼与下发不同,IBM强调从高层语义表达中解析用户目标,并将其映射为可执行策略^[9]。

早期的网络自动化研究通常将调度或资源分配问题简化为最小化最大链路负载等组合优化或整数规划模型,通过数学编程获得近似最优解^[10]。然而,此类方法对网络规模和动态性敏感,难以满足自动驾驶汽车、无人机编队等6G场景中多变的需求。随机组合优化模型虽能应对一定程度的不确定

性,却通常需要多次迭代才能收敛,部署后亦难以达到理想的实时管理效果^[11]。

近年来,深度强化学习(DRL, deep reinforcement learning)已成为网络自动化管理的前沿技术^[12]。DRL不依赖预先构建的网络模型,而是直接从实时监测数据中学习,对动态变化的网络环境具有出色的适应能力,能够根据业务需求即时调整管理策略。随着研究的深入,学者们尝试将深度学习应用于更广泛的网络优化任务——通过训练数据自动提取启发式规则,突破了传统求解器只能针对单一实例优化的局限。尤其是基于图神经网络(GNN, graph neural network)的架构,已在组合优化场景(如调度与资源分配)中展现出潜力,尽管这一领域还处于早期探索阶段^[13]。

目前,深度学习模型不仅被用于网络优化决策,还被直接开发用于多种自动化子任务,包括虚拟网络嵌入、网络功能虚拟化与定位,以及网络切片中的资源管理等^[14]。作为这一体系的核心,强化学习通过构建智能代理,在每个网络状态下选择能够最大化长期收益的动作,从而实现端到端的自动化管理^[15]。

近年来,联邦学习(FL, federated learning)为网络自动化管理提供了新的范式。在该框架下,接入节点或边缘设备仅在本地完成模型训练并共享模型参数,而无须上报原始数据,既保障了用户隐私,又高效地利用了分布式设备所蕴含的丰富数据资源。在异构网络环境中,联邦学习通过周期性地聚合全局模型,使系统获得对整体网络行为的洞察能力,同时保留各地局部模型对特定环境的敏感性。这种“本地训练、集中优化”的协同机制,赋予了智能代理在面对不同拓扑结构与服务场景时快速适应和持续演化的能力,有效地缓解了集中训练模型泛化能力不足的问题^[16-17]。与此同时,元学习(meta-learning)在智能网络优化中的研究也日益受到关注。相关文献表明,元学习在小样本条件下具有较强的快速适应与策略迁移能力^[18],可有效地提升模型在新任务和新环境

中的收敛速度与初始表现。将元学习与联邦机制结合，有望在保障隐私的前提下实现跨节点策略迁移和低成本泛化，是提升网络智能体实时决策能力的重要方向。

然而，在6G网络环境中，频谱资源的动态调度、接入方式的多样化以及服务场景的不断演化，使智能代理所面临的决策环境高度非平稳且复杂多变。传统的无模型强化学习方法由于缺乏对环境结构的显式建模，其策略难以直接迁移至新拓扑或多域融合场景，通常需要重新采集交互数据并重复训练，难以满足6G对实时性与高可用性的严苛要求。尽管已有研究尝试引入迁移学习以提升模型的泛化能力，但在效率、成本和稳定性方面仍面临着显著的瓶颈，深度学习驱动的自动化运维在实际部署中尚难落地。从现有研究现状看，当前智能网络管控仍存在以下3方面关键局限：1) 特征局限性突出，多数方法仍依赖流量、拓扑等单一维度信息，忽略了无线接入、边缘节点与云服务等多域异构要素在6G场景中的重要作用；2) 泛化能力受限，训练模型难以适应未知网络结构与动态业务请求，缺乏高效迁移与跨场景部署能力；3) 目标优化维度单一，多数方案聚焦某一性能指标优化，难以在性能、能耗、可靠性与服务质量等多重目标间取得平衡。因此，构建具备知识迁移、自适应演化与跨域协同能力的智能管控框架，成为支撑6G网络智能化演进的核心课题。

本文基于跨域知识驱动，提出了一种网络元智能框架，旨在推动6G网络的自主学习、自主优化、自主管理与自主演进，具体如下。

1) 跨域知识协同演进

与以往聚焦业务域或地理域的跨域研究不同，本文将网络智能所需的知识拆分为环境域、网络域与用户行为域3个范畴，并基于图神经网络实现在线增量融合；通过知识蒸馏对旧知识进行压缩与更新，持续完善全局知识库，确保各域知识协同进化。

2) 网络元智能闭环管理

本文发展“网络元智能”概念——“对网络智能的智能化管理”，构建了“感知→推理→执行→验证→反馈”的端到端闭环流程，形成自动化的知识发现与传播机制，使网络能够自主感知新场景并快速适应，保障在多域融合与大规模部署下持续调优与演进。

3) 多范式学习下的自演进决策模型

提出了一个融合元学习、强化学习、联邦学习与知识蒸馏的认知决策框架，旨在从零开始自主掌握网络配置与流量调度策略。首先，通过联邦学习在分布式节点上并行训练，在保护各自数据隐私的同时，汇聚多场景的运维经验；接着，利用自监督学习与深度强化学习，从实时交互的网络数据中持续优化决策策略；最后，借助元学习机制，在遇到新拓扑或业务需求时，仅凭少量样本即可快速微调模型，实现策略的动态迁移与自适应调整，从而不断推动网络运维智能在异构、多变环境中的自演进。

本文聚焦6G典型复杂场景——低空交通智能调度，涵盖大规模无人机编队、异构接入与动态资源管理等挑战。在该统一场景中，本文以3个阶段性任务为主线展开验证：一是“跨域知识驱动组网”，实现动态链路配置与全局状态感知；二是“意图引导的智能体管理”，实现高层需求到个体动作的落地；三是“蜂群路径规划”，面向协同任务生成最优轨迹与策略。3个任务在统一场景中体现了方法从底层感知到高层调度的闭环性能。

1 系统架构

在低空交通调度场景中，网络须同时应对链路动态波动、任务多样化与环境感知不确定性。本文所提的跨域知识驱动元智能框架，正是为应对此类复杂多任务智能管控而设计。接下来将结合该场景，分阶段介绍各模块的系统功能与协同关系。

1.1 网络元智能框架

“元智能”概念强调对智能系统自身的动态审视与自我调控——赋予系统在多种学习、推理与决策机制之间进行协调与自治的能力^[19]。在网络场景中，“网络元智能”可被理解为对网络智能行为的再度智能化：每个元智能单元能够在本地环境中同时感知多源信息、进行知识推理、生成最优策略，并在运行过程中不断自我调整^[20]。作为系统中最小的功能单元，网络元智能体集成了跨域感知、在线推理、策略制定与实时优化等核心能力，是实现6G网络端到端自适应与长期演进的基础执行实体^[21]。

为实现多域智能网络的泛化管理与持续演进，本文提出了一种基于跨域知识融合的网络元智能框架。该框架整体由6个核心模块构成：高层意图解

析模块、多域知识感知模块、联邦-元学习优化模块、知识融合与蒸馏模块、策略生成与下发模块、记忆回写与持续演化模块。各模块围绕“感知—学习—决策—记忆”4类功能协同构建，通过数据流与控制流的高效耦合，形成动态闭环。

1) 高层意图解析模块

该模块用于接收来自上层管理者或应用系统的策略意图，识别用户需求、目标约束与优先级等要素。通过意图图谱构建、语义抽取与模板匹配机制，完成从任务抽象到可执行策略目标的转译过程。模块输出将驱动下游感知、优化与调度流程启动，是全系统的任务源。

2) 多域知识感知模块

该模块负责在网络运行过程中，对环境态势、拓扑结构、用户行为等多域异构数据进行实时感知与预处理。为增强泛化能力与效率，采用轻量化图神经网络建模知识图谱，并引入局部感知触发机制实现重要信息过滤。感知结果作为知识输入，传入后续优化与融合模块。

3) 联邦-元学习优化模块

为适应6G网络中高频任务变化与复杂环境扰动，该模块采用联邦学习机制进行本地模型协同训练，提升数据隐私性与分布鲁棒性。同时引入元学习框架，实现策略对新任务的快速迁移与少样本适配。模块输出为结构化策略参数，供策略生成模块调用。

4) 知识融合与蒸馏模块

该模块聚焦于多源知识的异构融合，集成联邦优化、本地智能体与历史经验库中的模型知识。基于注意力引导的知识蒸馏机制，提取代表性知识用于构建稳定全局表示，降低冗余性并提升泛化能力。蒸馏结果同步写入知识库，并指导后续策略生成。

5) 策略生成与下发模块

该模块负责根据目标意图与全局知识，生成满足服务质量约束的多维调度策略。结合深度强化学习与图优化机制，输出可执行的路由、频谱分配或任务调度方案。最终策略通过控制通道下发至各智能体节点执行，并实时接收反馈闭环优化。

6) 记忆回写与持续演化模块

该模块通过记录执行过程中的状态转移、反馈表现与策略有效性，构建支持长期学习的演化记忆库。结合自监督学习与经验回放机制，实现局部策略的自我修正与长期演化，增强系统适应力。模块

定期更新全局知识图谱，并保持与优化模块的参数一致性。

基于跨域知识融合的网络元智能框架运转流程如图1所示，展示了网络元智能从接收高层意图到执行—反馈闭环的完整流程。首先，意图下发与经验获取将高层运营指令转化为结构化意图并检索历史运维经验；接着，多域信息感知与处理并行采集环境、网络和业务3个域的数据，经过过滤与编码后输出统一特征；随后，在线学习与推理通过图神经网络融合跨域特征，并依托联邦强化、自监督微调和元学习实现策略生成与自适应^[18]；然后，全局知识同步通过知识蒸馏与联邦聚合不断更新并下发全局模型；最后，决策下发与持续优化结合语义分析和规则匹配，将策略下发至网络设备，并通过实时反馈闭环持续调优。

网络元智能的行为可映射为一个状态机，网络元智能状态机如图2所示。认知模型对环境域、网络域和行为域的状态进行感知，提取与当前任务最相关的信息并演进自身模型；然后，基于语义状态与全局知识，生成并执行最优策略。即便部分感知数据缺失，状态机仍可凭借语义推理与既有经验，推断出近似最优的解决方案，使网络真正成为自主认知与决策的主体。

状态转换过程可形式化地建模为

$$S_{t+1} = f \begin{pmatrix} \text{Perceive}(E_t, N_t, B_t), \\ \text{Parse}(I_t), \\ \text{UpdateKG}(K_t, I_t, S_t), \\ \text{Learn}(K_t, D_{\text{train}}), \\ \text{Decide}(\pi(a|s); \Phi_{\text{Meta}}, \Phi_{\text{FL}}) \end{pmatrix} \quad (1)$$

其中， f 是感知函数； $\text{Perceive}(E_t, N_t, B_t)$ 是多模态感知模块，融合环境、网络与行为域信息， E 为环境域信息， N 是网络域信息， B 是用户行为域信息， t 是时间； $\text{Parse}(I_t)$ 为意图解析模块，将自然语言指令转化为结构化约束条件， I 为用户或上层系统 i 下达的高层意图； $\text{UpdateKG}(K_t, I_t, S_t)$ 是知识图谱更新模块，动态注入意图与状态信息， K_t 为知识库， S_t 是系统状态； $\text{Learn}(K_t, D_{\text{train}})$ 为学习模块，实现快速适配与全局优化， D_{train} 为训练数据集； $\text{Decide}(\pi(a|s); \Phi_{\text{Meta}}, \Phi_{\text{FL}})$ 为决策生成模块， $\pi(a|s)$ 在状态 s 下选择 a 的概率，即策略的条件概率分布，结合元学习与联邦学习策略生成最优动作， Φ 是通

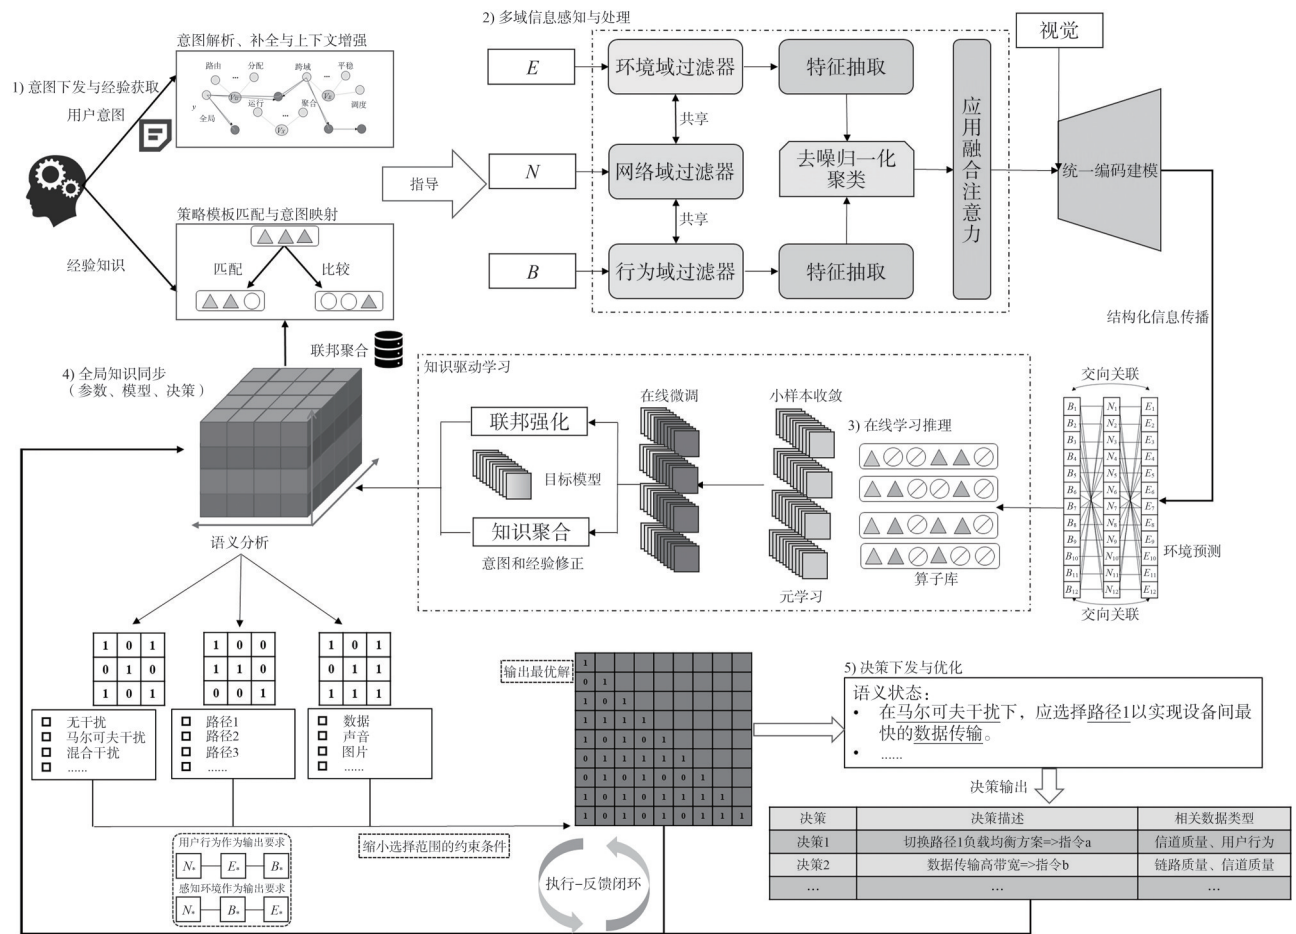


图1 基于跨域知识融合的网络元智能框架运转流程

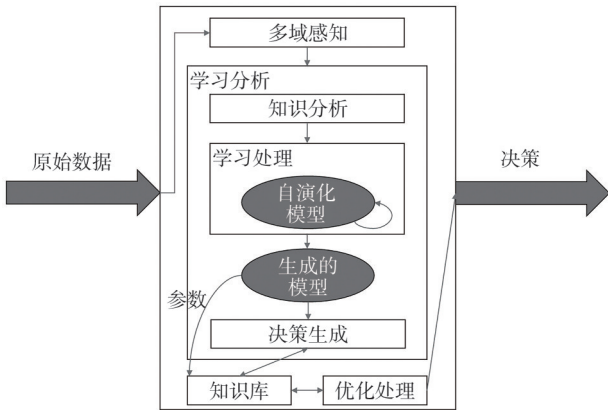


图2 网络元智能状态机

过学习得到的策略模型或策略参数， Φ_{Meta} 代表元学习框架或能力，使策略能快速适应新任务，具体实现细节在后文章节中详细阐述。

1.2 与现有架构的区别与创新

本文元智能方法与现有架构的区别见表1，不同于传统KDN侧重知识提取与控制器调度，或IBN强调从高层意图驱动控制策略的映射与执行，

本文所提的“元智能体”架构在每个网络功能单元内部构建“感知→学习→决策→执行→反馈→记忆”的闭环路径，实现本地自治与全局协同兼顾的演进机制。

每个智能体不仅具备独立感知与决策能力，还能通过联邦融合与自监督机制，实现跨场景知识迁移与策略持续演化，突破现有体系在泛化能力、响应速度与知识共享方面的瓶颈。该设计可视为传统网络智能代理的扩展与升级，具备“主动适应+协同演化+可扩展部署”等新质特性。

1.3 多域信息感知与处理/跨域知识融合

尽管框架以高层意图为起点，跨域知识融合却是承上启下的核心环节，因此本节将其置于前文优先介绍。

真正的网络自治必须从单一的连通性监测，转向对物理环境与业务需求的深度感知与协同决策，以6G天地一体化与低空交通的应用场景为例，其网络信息可拆分为以下3个域。

表1 本文元智能方法与现有架构的区别

模块功能	传统KDN	ONOS/IBN	本文方法
知识来源	流量数据、拓扑信息	模板规则、用户意图	多域异构数据+感知图像/视觉输入
策略生成	离线学习、静态建模	意图转译+控制规则映射	联邦学习+元学习融合优化
执行机制	控制器集中下发	IBN编排器驱动下发	多智能体协同决策与自治执行
演进机制	手动配置、重训练	策略替换与再部署	自监督+记忆检索+持续进化

1) 环境域：搭载在无人机和地面基站的气象与电磁传感器实时采集空气密度、风速、雨量，以及信道状态信息、干扰源分布、覆盖盲区和路径衰减，为飞行安全与链路可靠性提供底层支撑。

2) 网络域：集中监控无人机队列与网关的多跳拓扑、空地切换时延、网络切片资源分配和链路利用率，跟踪信噪比（SNR, signal-to-noise ratio）、误码率（BER, bit error rate）、时延抖动等关键指标，以确保高清图像回传、导航指令与调度命令的低时延高可靠。

3) 用户行为域：根据包裹配送、紧急医疗物资投送或交通监控等不同任务，分析流量特征、飞行路径与服务等级要求（带宽、时延容忍度），并基于优先级生成资源调度策略。

这种跨域拆分能够将故障或性能瓶颈迅速锁定到环境、网络或业务任一环节，实现精细化排查和决策回溯，同时大幅提升系统的透明度和自治效率。

设整个网络系统感知矩阵为

$$\hat{G} \in \mathbf{R}^{N_s \times T} \quad (2)$$

其中， N_s 表示传感器/数据源的数量， T 表示时间维度，将其分解为3个主要域：环境域 $\mathbf{E} \in \mathbf{R}^{N_e \times T}$ ， N_e 表示电磁参数的维度；网络域 $\mathbf{N} \in \mathbf{R}^{N_n \times T}$ ， N_n 表示与网络状态相关的特征数量；行为域 $\mathbf{B} \in \mathbf{R}^{N_b \times T}$ ， N_b 表示行为特征的数量。

对应地，在感知方面，每个元智能体 m 级第 i 个节点在其局部环境中感知多域信息，具体包括^[21]以下3类。

1) 电磁环境域输入 $\mathbf{E}_b^{m,i}$ ：信道质量 $q_k^{m,i}$ ，干扰强度 $p_k^{m,i}$ ，传输信号时延 $t_k^{m,i}$ ，以及其他电磁环境特

征参数；

2) 网络状态域输入 $\mathbf{N}_b^{m,i}$ ：网络拓扑 $n\tau_k^{m,i}$ ，网络拥塞级别 $ncl_k^{m,i}$ ，丢包率 $ph_k^{m,i}$ ，以及其他网络状态特征；

3) 用户行为域输入 $\mathbf{U}_b^{m,i}$ ：用户业务类型 $ubt_k^{m,i}$ ，用户优先级 $up_k^{m,i}$ ，用户位置 $upos_k^{m,i}$ ，以及其他用户行为特征参数。

在归一化之前，这些多域感知输入可以表示为如下特征向量

$$\mathbf{P}_k^{m,i} = \begin{bmatrix} \mathbf{E}_k^{m,i} \\ \mathbf{N}_k^{m,i} \\ \mathbf{U}_k^{m,i} \end{bmatrix} = \begin{bmatrix} \mathcal{A}_e(\mathbf{E}_b^{m,i}) \\ \mathcal{A}_n(\mathbf{N}_b^{m,i}) \\ \mathcal{A}_u(\mathbf{U}_b^{m,i}) \end{bmatrix} \quad (3)$$

其中， $\mathcal{A}(\cdot)$ 代表该域的感知方法，具体感知结果如下

$$\begin{aligned} \mathbf{E}_k^{m,i} &= \{q_k^{m,i}, p_k^{m,i}, t_k^{m,i}, \dots\} \\ \mathbf{N}_k^{m,i} &= \{n\tau_k^{m,i}, ncl_k^{m,i}, ph_k^{m,i}, \dots\} \\ \mathbf{U}_k^{m,i} &= \{ubt_k^{m,i}, up_k^{m,i}, upos_k^{m,i}, \dots\} \end{aligned} \quad (4)$$

通过特征分解过程，可以将粗粒度的全局感知矩阵 \hat{G} 表示为 $\hat{G} \approx f(\mathbf{E}, \mathbf{N}, \mathbf{B})$ ，其中 $f(\cdot)$ 表示特征分解函数。

网络信息知识化如图3所示，各种多维传感器的时间序列数据经过分段处理，通过滑窗机制对时间序列数据进行聚合，将连续时间 t 划分为多个块（block），块大小为 b （即bsize，并设定窗口长度 l 和步长 d ，以捕捉数据中的短时变化和局部特征

$$\mathbf{X}_{\text{windowed}}(t) = [x_t, x_{t-d}, x_{t-2d}, \dots, x_{t-(l-1)d}] \quad (5)$$

其中， $\mathbf{X}_{\text{windowed}}(t)$ 为滑窗聚合后的特征向量。随后，




图3 网络信息知识化

不同来源的数据通过去噪、归一化等处理，转化为统一格式，并利用聚类算法将相似特征聚类在一起，生成一个结构化的特征矩阵。该矩阵进一步被分解为3个主要特征域，如 $\mathbf{E}' = \text{Normalize}(\mathbf{E})$ 。同时捕捉短时变化和局部特征。

为了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。系统中每个域的特征向量通过注意力机制进行加权融合，定义为

$$\mathbf{F}_{\text{fusion}} = \sigma(\alpha_E \cdot \mathbf{E}' + \alpha_N \cdot \mathbf{N}' + \alpha_B \cdot \mathbf{B}') \quad (6)$$

其中， α_E 、 α_N 、 α_B 是不同域的注意力权重，通过 Softmax 函数计算

$$\alpha_i^j = \text{Softmax}_j \left(-\|\mathbf{s}_i^t - \mathbf{s}_j^t\|^2 \right) = \frac{\exp\left(-\|\mathbf{s}_i^t - \mathbf{s}_j^t\|^2\right)}{\sum_k \exp\left(-\|\mathbf{s}_i^t - \mathbf{s}_k^t\|^2\right)} \quad (7)$$

其中， $\mathbf{s}_i^t, \mathbf{s}_j^t \in \mathbf{R}^d$ 是时间步 t 下节点 i 和 j 的特征向量； $\|\mathbf{s}_i^t - \mathbf{s}_j^t\|^2$ 是欧氏距离平方，用于衡量特征相似度； α_i^j 表示节点 j 对节点 i 的注意力权重。

环境信息通过知识图谱的形式进行建模。知识图谱三元组定义为：设知识图谱为 $G = \{(u, r, v)\}$ ，那么 $u, v \in \mathcal{E}$ 表示实体（如基站、无人机（UAV, unmanned aerial vehicle）、干扰源）； $r \in \mathcal{R}$ 表示关系（如“包含”、“影响”、“触发”等）。TransE（知识图谱经典算法）的嵌入目标函数为

$$\min_{(u, v, r) \in G} \mathbf{E}[u] + \mathbf{R}[r] - \mathbf{E}[v]^2 \quad (8)$$

其中， $\mathbf{E}[u], \mathbf{E}[v] \in \mathbf{R}^d$ 是实体 u, v 的嵌入向量， $\mathbf{R}[r] \in \mathbf{R}^d$ 是关系 r 的嵌入向量。约束条件（知识图谱推理规则）即为对于每个三元组 $(u, r, v) \in G$ ，满足 $\mathbf{E}[u] + \mathbf{R}[r] \approx \mathbf{E}[v]$ ，若地区 A 包含干扰源 X ，则有 $\mathbf{E}[A] + \mathbf{R}[\text{Contains}] \approx \mathbf{E}[X]$ 。

其中，Contains 表示关系 r 的具体取值，即“包含”的语义关系。

在全球层面，为了在全球控制层聚合多 UAV 上报的行为数据，并优化路径策略，采用图卷积网络（GCN, graph convolutional network）进行结构化信息传播。

$$\mathbf{h}_i^{(l+1)} = \sigma \left(\mathbf{W}^{(l)} \sum_{j \in \mathcal{N}_i} \frac{1}{c_{ij}} \mathbf{h}_j^{(l)} \right), c_{ij} = \sqrt{|\mathcal{N}_i| \cdot |\mathcal{N}_j|} \quad (9)$$

其中， $\mathbf{h}_i^{(l)} \in \mathbf{R}^d$ 代表第 l 层中节点 i 的特征， \mathcal{N}_i 是节

点 i 的邻居集合， c_{ij} 是归一化因子， $\mathbf{W}^{(l)} \in \mathbf{R}^{d \times d}$ 为可学习参数矩阵， $\sigma(\cdot)$ 为非线性激活函数。

结合注意力机制，可得

$$\mathbf{h}_i^{(l+1)} = \sigma \left(\mathbf{W}^{(l)} \sum_{j \in \mathcal{N}_i} \alpha_i^j \cdot \frac{1}{c_{ij}} \mathbf{h}_j^{(l)} \right) \quad (10)$$

对于以上知识分解，在一种具体实践中，对于低空交通管控中的典型业务实体 UAV 路径规划而言，也可引入视觉输入， $\mathbf{I} \in \mathbf{R}^{N_h \times N_w \times N_f}$ ，其中， N_h 和 N_w 分别为图像的高度和宽度， N_f 为帧数，通过 CNN 对视觉信息进行特征提取，生成特征向量 $\mathbf{V} \in \mathbf{R}^N$ 。

进一步，UAV 路径规划优化目标通常在最优化碰撞率与航向角变化率^[22]。本文将为碰撞率建模， α 、 β 、 γ 、 δ 为调节参数，分别调节环境、网络、行为和视觉特征的影响。 $d_{i,t}$ 表示在时间 t 与电磁信号源的距离， $e_{i,t}$ 是 t 时刻第 i 个环境特征的值，其他域以此类推， $P(e_{i,t})$ 是电磁环境的干扰概率，即在 t 时刻无人机在特定电磁环境条件下发生碰撞的概率， v_j 是第 j 个视觉特征的值，通常代表障碍物的位置和特性。 η_{ik} 和 ζ_{ij} 为交互权重系数，分别用于调节环境与网络、行为与视觉之间的相互作用对碰撞风险的影响。

$$\text{CollisionRate} = \sum_{t=1}^T \left(\alpha \sum_{i=1}^{N_e} \frac{1}{d_{i,t}^2} \cdot P(e_{i,t}) + \beta \sum_{k=1}^{N_n} \frac{1}{\|\mathbf{n}_{k,t}\|_2^2} + \gamma \sum_{l=1}^{N_b} \frac{1}{\|\mathbf{b}_{l,t}\|_2^2} + \delta \sum_{j=1}^{N_v} \frac{1}{\|\mathbf{v}_j\|_2^2} \right) + \quad (11)$$

$$\sum_{t=1}^T \left(\sum_{i=1}^{N_e} \sum_{k=1}^{N_n} \eta_{ik} \cdot \frac{P(e_{i,t}) \cdot n_{k,t}}{d_{i,t} \cdot \|\mathbf{n}_{k,t}\|_2} + \sum_{l=1}^{N_b} \sum_{j=1}^{N_v} \zeta_{lj} \cdot \frac{b_{l,t} \cdot v_j}{\|\mathbf{b}_{l,t}\|_2 \cdot \|\mathbf{v}_j\|_2} \right)$$

同时，航向角的建模为

$$\text{YawRate} = \sum_{t=2}^T \Delta \theta_t \cdot \left(\lambda \sum_{i=1}^{N_e} e_{i,t} + \mu \sum_{k=1}^{N_n} n_{k,t} + \nu \sum_{l=1}^{N_b} b_{l,t} + \tau \sum_{j=1}^{N_v} v_j \right) \quad (12)$$

航向角的变化量（航向差分）基于传感器测量 $\Delta\theta_t = \theta_t - \theta_{t-1}$, λ 、 μ 、 ν 、 τ 是调节各个子域对航向角变化率的影响的权重系数，差分项表示环境、网络、行为和视觉信息在 t 时刻对航向角变化的正交贡献。

为了使路径规划在各个维度上更精准，本文定义了一个广义相似度度量 $\rho(\cdot, \cdot)$ ，用于衡量当前路径的多域特征与理想路径的多域特征之间的相似度。本文的优化目标是最大化这种相似度，以确保路径规划的平滑性和避障性能。定义当前路径特征向量为 $\mathbf{X}_t = (E_t, N_t, B_t, V_t)$, $\mathbf{X}'_t = (E'_t, N'_t, B'_t, V'_t)$ ，路径相似量为

$$\rho(\mathbf{X}_t, \mathbf{X}'_t) = \frac{|\mathbf{X}_t^H \mathbf{X}'_t|}{\|\mathbf{X}_t\|_2 \cdot \|\mathbf{X}'_t\|_2} \quad (13)$$

最终优化目标为

$$\min_F w_1 \cdot \text{CollisionRate} + w_2 \cdot \text{YawRate} - \frac{1}{T} \sum_{t=1}^T \rho^2(\mathbf{X}_t, \mathbf{X}'_t) \quad (14)$$

(E_t, N_t, B_t, V_t) 表示当前路径在 t 时刻的多域特征， (E'_t, N'_t, B'_t, V'_t) 表示理想路径在 t 时刻的多域特征， $(\cdot)^H$ 表示共轭转置的内积计算，即对多域特征向量的内积操作，通常用于计算相似度， $\|\cdot\|_2$ 为 L_2 范数，用于计算特征向量的模长， w_1 和 w_2 分别是碰撞率和航向角变化率在优化目标中的权重。

1.4 意图下发与经验获取

“用户意图”体现了用户对网络服务能力、资源分配以及性能指标的高层诉求，是实现以人为本网络管理的启动信号^[23-25]。它既可能以自然语言指

令或声明式策略的形式显性表达，也可能潜藏于用户的行为模式和环境上下文中，需要通过元智能体的推理与反馈加以确认。

“经验知识”是源自网络运维过程中沉淀的历史数据、成功案例、策略模板与专家规则的集合，通过快速检索为系统在类似场景中提供参考方案和决策建议。

“用户行为域知识”位于二者之间，集中反映当前业务特征和运行态势，如，流量分布、任务类型、服务等级协议要求等，它既支持将高层意图具体化，也为借鉴经验知识提供了必要的上下文条件。

在网络元智能框架中，这3类知识分别承担不同职责：用户意图指明目标与约束，经验知识提供可复用的解决路径，用户/业务知识负责在当前环境中对意图和经验进行有效地映射。用户行为域、用户意图与经验知识的对比见表2。

进一步归纳，意图认知三角如图4所示，这3类信息（知识）共同构成了的意图认知三角。

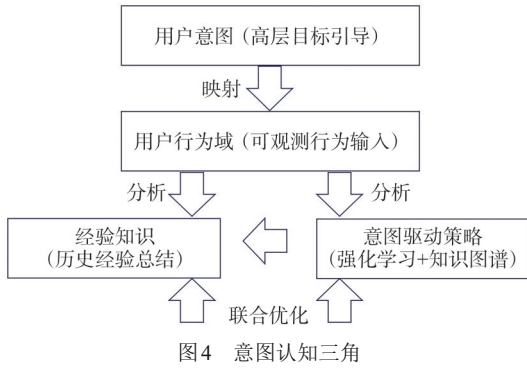
- 1) 行为域是“现在发生什么”的感知；
- 2) 用户意图是“我希望变成什么样”的目标；
- 3) 经验知识是“过去本文是怎么做的”的参考。

通过轻量级自然语言处理（NLP, natural language processing）模型等，对用户输入进行语义分析，提取关键词与约束项：

$$I^{(m,i)} = \text{BERT}(x_{\text{intent}}) = \left\{ \begin{array}{l} T_{\max}, B_{\min}, W_{\text{res}} \\ \text{Strategy}_{\text{avoid}} \\ \text{Scenario}_{\text{priority}} \end{array} \right\} \quad (15)$$

表2 用户行为域、用户意图与经验知识的对比

维度	用户行为域	用户意图	经验知识
定义	用户在网络中的实际操作、动作轨迹、业务类型、优先级等可观测的行为特征	用户对网络服务、资源配置、性能优化等方面的高层次期望或目标，通常以自然语言或结构化任务描述形式存在	在网络管理过程中积累的历史数据、成功案例、策略模板和专家系统的总结，为系统在遇到类似问题时提供参考依据
用户意图	网络日志、流量数据、QoS指标、历史任务记录等	用户输入指令、策略模板、服务级别协议、专家规则等	历史任务数据、路径规划案例、联邦学习聚合结果、知识图谱三元组等
经验知识	可直接观测，是模型训练的原始数据之一	需要解析与推理，可能隐含在行为中，也可能显式输入	可通过历史数据分析获得，也可从其他节点迁移而来
是否可变	是，随时间变化，反映用户当前行为状态	是，可动态变化，反映用户对网络的期望演化	是，支持增量更新与联邦传播，反映系统经验积累过程
功能定位	提供实时感知数据支撑，是路径规划、资源调度的底层输入	表达用户的主观需求，构成优化目标的高层引导信号	提升模型泛化能力，增强系统鲁棒性与自适应性
是否具备迁移能力	有限迁移，主要适用于相同或相似场景	具备一定迁移能力，可用于新任务的目标设定	具备强迁移能力，支持跨域、跨任务的知识复用



其中, T_{\max} 是最大允许时延, B_{\min} 是最小带宽需求, w_{res} 是资源分配权重, $\text{Strategy}_{\text{avoid}}$ 为特定场景中的规避策略, $\text{Scenario}_{\text{priority}}$ 是场景优先级设定, x_{intent} 是用户输入的自然语言指令, 输出为结构化意图集合 $I^{(m,i)}$ 。举例: “我希望无人机在 30 s 内送达包裹, 并避免进入强电磁干扰区域” 的意图解析结果为 $T_{\max} = 30 \text{ s}$, $\text{Strategy}_{\text{avoid}} = \text{EM Interference}$ 。与单纯的用户域知识不同, 用户意图和经验知识直接或间接地指导系统生成符合用户预期的决策, 并以约束条件或奖励函数的形式融入任务目标函数中进行体现与评估。在路径规划或资源调度任务中, 意图被建模为优化目标的一部分, 如以 $R(s, a) \geq R_{\min}(I)$, $T(s) \leq T_{\max}(I)$, $B(s) \geq B_{\min}(I)$ 为约束, 其中, $R(s, a)$ 是当前状态下的奖励, $T(s)$, $B(s)$ 都为时延与带宽, $R_{\min}(I)$, $T_{\max}(I)$, $B_{\min}(I)$ 是来自用户意图的约束, 这种约束做法在后文均有体现。

知识库中同样保存了大量已成功任务策略模板, 如:

- 1) 低电量→最短路径优先;
- 2) 高优先级任务→多链路冗余通信;
- 3) 应急救援→避开山区/高楼遮挡。

在解析用户意图时, 系统会计算当前意图向量与经验知识三元组之间的语义相似度:

$$\text{MatchScore}(I^{(m,i)}, S_k) = \cos(\mathbf{E}[I^{(m,i)}], \mathbf{E}[S_k]) \quad (16)$$

其中, $I^{(m,i)}$ 是当前用户的结构化意图向量式(15), S_k 是第 k 条策略模板, $\cos(\cdot, \cdot)$ 为余弦相似度。接着, 系统调用经验知识库访问模块, 检索该意图在历史运维中对应的执行记录与成功率指标, 如过去对相似航线的切片配置耗时、资源占用、故障率等。当 MatchScore 大于阈值时, 激活策略模板推荐

$$\text{Strategy}_{\text{rec}} = \{S_k \mid \text{MatchScore}(I^{(m,i)}, S_k) > \tau\} \quad (17)$$

其中, τ 为相似度阈值, $\text{Strategy}_{\text{rec}}$ 是推荐的策略集

合。同时, 基于用户行为域模型, 系统使用聚类算法提取典型任务模式与关联数据流量特征, 为策略生成提供上下文支撑:

$$T_{\text{pattern}} = \text{Cluster}(U_b^{m,i}) \quad (18)$$

其中, $U_b^{m,i}$ 如前文所述, 为用户行为域输入, T_{pattern} 是提取的任务模式(如投递路径偏好、流量高峰期分布等)。

最后, 意图对象与上下文经验(包含参数推荐、失败原因及最佳实践)被封装成“初始策略候选”, 并下发到下游的多域感知层, 作为后续决策的输入先验:

$$\text{CPlan}^{(m,i)} = \text{Encapsulate}(I^{(m,i)}, T_{\text{pattern}}, S_{\text{history}}) \quad (19)$$

其中, $\text{CPlan}^{(m,i)}$ 是初始策略候选, T_{pattern} 是行为模式, S_{history} 为历史执行记录, 包括过去执行该类任务的耗时、资源占用与故障率等统计信息。存储在知识库中。通过结合历史成功率与资源效率, 系统对多个策略候选进行排序, 确保下发最优策略:

$$\text{Rank}(\text{CPlan}^{(m,i)}) = w_1 \cdot \text{SuccessRate}(S_k) + w_2 \cdot \text{ResourceEfficiency}(S_k) \quad (20)$$

其中, $\text{SuccessRate}(S_k)$ 是历史成功率, $\text{ResourceEfficiency}(S_k)$ 是资源利用率, w_1 , w_2 为权重系数, 由场景优先级动态调整, 经验知识先验决策匹配结果见表 3, 完整展示了用户自然语言意图如何通过结构化匹配历史模板, 最终生成高成功率的可执行策略, 验证了知识驱动决策的可行性与效率。

1.5 在线学习与推理

跨域特征在图神经网络推理引擎中进行增量融合, 生成当前时刻的全局知识表征。在此基础上, 系统并行执行。

首先, 调用算子库中的学习模型 Φ_0 , 输入当前时刻 k 的多域感知特征 $P_k^{m,i}$, 输出下一时刻 $k+1$ 多域环境预测信息 $P_{k+1}^{m,i} = \Phi_0(\mathbf{E}_k^{m,i}, \mathbf{N}_k^{m,i}, \mathbf{U}_k^{m,i})$ 。

为了实现快速适应新任务的能力, 本文使用元学习框架式(21), 通过历史任务数据预训练通用模型参数, 使新任务仅需少量样本即可完成微调。

$$\arg \min_{\theta} \mathbb{E}_{T_j \sim T_{\text{meta}}} \left[\begin{aligned} & \lambda_{\text{data}} \cdot \mathcal{L}_{T_j}^{\text{data}}(f(\theta, D_{T_j}^{\text{train}})) + \\ & \sum_{i=2}^M \lambda_i \cdot \mathcal{L}_{T_j}^{\text{phys}, k, i}(f(\theta, D_{T_j}^{\text{train}})) + \\ & \lambda_{\text{meta}} \cdot \mathcal{L}_{T_j}(f(\theta - \alpha \nabla_{\theta} \mathcal{L}_{T_j}^{\text{train}}, D_{T_j}^{\text{test}})) + \\ & \text{CosDist}(y_b, \hat{v}^T x_b^l) \end{aligned} \right] \quad (21)$$

表3 经验知识先验决策匹配结果

用户意图	意图向量	匹配策略模板	成功率	推荐策略
“航线X配置低时延切片”	[T_max=5 ms, Strategy=“Low latency”]	“High-priority slice allocation”	92%	下发高带宽链路
“避开干扰区域Y飞行”	[Strategy=“Avoid EM zone”, Scenario=“Urban”]	“EM interference avoidance”	88%	触发备用通信路径

其中, \mathcal{L}_{T_j} 是在任务 T_j 上的损失函数, $f(\theta, \mathcal{D}_{T_j}^{\text{train}})$ 表示基于元参数 θ 的模型在训练数据 $\mathcal{D}_{T_j}^{\text{train}}$ 上进行的训练; $\lambda_{\text{meta}} \cdot \mathcal{L}_{T_j}(f(\theta - \alpha \nabla_{\theta} \mathcal{L}_{T_j}^{\text{train}}, \mathcal{D}_{T_j}^{\text{test}}))$ 表示在进行一次梯度更新后, 在测试数据 $\mathcal{D}_{T_j}^{\text{test}}$ 上的损失, 其中, α 是用于梯度更新的学习率; $E_{T_j \sim T_{\text{meta}}}$ 表示在元任务分布 T_{meta} 中采样任务 T_j 后, 对目标函数的期望值进行计算; λ_{meta} 表示内外层损失函数的平衡系数, 用于调节训练阶段损失与测试阶段损失在优化目标中的相对权重; ∇_{θ} 表示对元参数 θ 求梯度, 反映当前模型在训练损失函数上的方向性更新信息; $\mathcal{L}_{T_j}^{\text{train}}$ 表示任务 T_j 上的训练集损失函数; $E_{T_j \sim T_{\text{meta}}}[\cdot]$ 表示在元任务集合 T_{meta} 中采样任务 T_j 后, 对任务 T_j 上的整体损失函数进行期望运算; $\mathcal{L}_{T_j}^{\text{data}}(\cdot)$ 表示在任务 T_j 上, 基于训练数据 $\mathcal{D}_{T_j}^{\text{train}}$ 和当前模型元参数 θ 计算得到的数据驱动损失项; $\mathcal{L}_{T_j}^{\text{phys}, k, i}(\cdot)$ 表示在任务 T_j 上的物理引导及经验知识损失项, 包括香农容量、路径损耗、能量消耗等物理规律, CosDist为余弦距离, $\mathbf{y}_b, \hat{\mathbf{v}}^r, \mathbf{x}'_b$ 分别为某个样本的真实标签或目标向量, 模型对同一样本的预测值, 其中 \mathbf{x}'_b 为输入特征, $\hat{\mathbf{v}}$ 为可学习的权重向量。在训练过程中, 元学习分为两个阶段:

1) 内循环 (inner loop): 对每个任务 T_j 使用梯度下降进行微调, 得到任务专用参数 ϕ_i ;

2) 外循环 (outer loop): 基于微调后的模型在测试集上的表现, 反向传播并更新元参数 θ , 使模型具备跨任务泛化能力。

在线微调如式 (22)

$$\phi_i = \theta - \alpha \cdot \nabla_{\theta} (\mathcal{L}_{\text{KD}}(\theta; D_{\text{train}}) + \mathcal{L}_{\text{intent}}(I)) \quad (22)$$

其中, ϕ_i 是当前任务下的本地模型参数, α 是学习率, D_{train} 是当前任务的数据集, $\mathcal{L}_{\text{intent}}(I)$ 是意图匹配损失。学习分析模块还支持多种决策方法的选择, 例如, 端到端学习模型、多目标优化方法等。为了实现意图驱动的个性化网络管理, 本文将用户意图与经验知识协同建模为一个联合优化目标

$$\text{CPlan}^{(m, i)} = Q(P_k^{(m, i)}, P_{k+1}^{(m, i)}, \text{CPlan}^{(m, j)}, I^{(m, i)} | D^{(m, i)}) \quad (23)$$

其中, $Q(\cdot)$ 为决策方法集合, $D^{m, i}$ 是当前节点的任务需求, $\text{CPlan}^{m, j}$ 是其他节点的决策方案, $P_k^{(m, i)}, P_{k+1}^{(m, i)}$ 表示在迭代步 k 和 $k+1$ 时, 对应于索引 (m, i) 的变量 P 的取值。

1.6 全局知识同步

环境信息、模型参数与决策经验都被网络元智能视为知识。为了实现多个元智能体之间的协同优化, 采用联邦学习机制聚合各节点模型参数:

$$W_{\text{global}}^{(r+1)} = W_{\text{global}}^{(r)} - \eta \cdot \frac{1}{N} \sum_{i=1}^N \nabla_W \mathcal{L}_{\text{KD}}(W_{\text{global}}^{(r)}, D_i) \quad (24)$$

其中, $W_{\text{global}}^{(r)}$ 是全局模型参数, D_i 是第 i 个节点的数据, \mathcal{L}_{KD} 是知识蒸馏损失, η 为学习率, N 为参与联邦学习的节点总数。为了保持本地模型与全局模型的一致性, 定义蒸馏损失为

$$\mathcal{L}_{\text{KD}} = \beta \cdot \mathcal{L}_{\text{CE}}(f_{\text{local}}, y) + (1 - \beta) \cdot \mathcal{L}_{\text{KL}}(f_{\text{local}}, f_{\text{global}}) \quad (25)$$

其中, \mathcal{L}_{CE} 是交叉熵损失, \mathcal{L}_{KL} 是Kullback-Leibler散度损失, 在动态环境中衡量本地与全局模型输出的分布差异, $\beta \in [0, 1]$ 为权重系数, 控制本地准确率与全局一致性之间的平衡, y 是真实标签, $f_{\text{local}}, f_{\text{global}}$ 分别表示本地模型的输出和全局模型的输出。

低空交通中路径规划或资源调度可视为一个序列决策问题, 本文采用强化学习来建模状态转移与奖励机制, 策略优化目标为

$$\pi^* = \arg \max_{\pi} E_{s \sim \rho} \left[R(s) + \gamma \sum_a \pi(a|s) V^{\pi}(s', a) \right] \quad (26)$$

其中, $\pi(a|s)$ 是状态 s 下采取动作 a 的概率, $R(s)$ 是即时奖励 (如避障成功、能耗降低), $V^{\pi}(s', a)$ 是下一状态的价值估计, $\gamma \in [0, 1]$ 为折扣因子。值函数递归定义为 $V^{\pi}(s) = E_{s' \sim P(s, a)} [R(s) + \gamma V^{\pi}(s')]$, 最终奖励函数 (联邦强化学习) 为

$$R_{\text{total}}(s, a) = R_{\text{local}}(s, a) + \lambda \cdot \mathcal{K}(s) \quad (27)$$

其中, $R_{\text{local}}(s, a)$ 是本地奖励, $\mathcal{K}(s)$ 为知识图谱的风险评分 (如干扰强度、链路稳定性), λ 是控制全局知识影响的权重。使用知识图谱三元组 $(u, r, v) \in G$ 提升语义理解与跨域推理能力, 但用户意图不仅作为任务输入, 还通过知识图谱的形式融

入系统推理机制。意图信息被结构化三元组并注入知识图谱中，从而实现意图驱动的知识演化与策略优化。

考虑到全网的通信同步，引入同时为不同节点赋予不同的权重，以反映性能与通信质量为

$$w_i(t) = \frac{\exp(\lambda \cdot \text{Fitness}(i, t))}{\sum_j \exp(\lambda \cdot \text{Fitness}(j, t))} \quad (28)$$

其中， $\text{Fitness}(i, t)$ 是节点*i*在时间*t*的综合性能指标， $w_i(t)$ 是节点*i*的重要性权重， λ 是控制权重敏感性的温度因子。当 $\lambda = 0$ 时，所有节点权重一致，当 $\lambda \rightarrow \infty$ 时，仅最优节点主导聚合过程。

1.7 决策下发与持续优化

在网络元智能框架中，决策生成并非一次性的终点，而是形成一个持续优化的闭环流程。指令下发后，系统启动实时监测组件，跟踪关键性能指标 $\mathcal{M}(t) = [T(t), L(t), D(t), E(t)]$ ，包括吞吐量、丢包率、时延波动与能耗等。这些反馈数据随后被回传至多域感知与在线学习模块，参与下一时刻的状态更新

$$S_{i+1} = f(S_i, A_i, \mathcal{M}_i) \quad (29)$$

其中， $f(\cdot)$ 包含注意力机制、GCN传播、知识图谱推理等多个子模块。与此同时，动态参数调整器对本地模型进行在线微调，确保策略能快速响应环境变化

$$\theta_{i+1} = \theta_i - \eta \cdot \nabla_{\theta} (\mathcal{L}_{\text{KD}}(\theta_i; D_{\text{train}}) + \mathcal{L}_{\text{intent}}(I)) \quad (30)$$

通过这一机制，系统能够在面对突发故障或业务激增时，动态调整路径规划、资源调度与链路配置策略。此外，在联邦学习框架下，各节点的综合性能指标也被用于调节其在聚合过程中的权重贡献。最终，所有执行反馈都将注入知识图谱，完成意图→经验→知识的闭环演化

$$G' = G \cup \{(u, r, v)\} \quad (31)$$

其中， (u, r, v) 是从反馈中提取的新三元组，例如，“某区域经历高干扰”、“某路径失败次数超过阈值”等。

2 低空交通调度场景中的任务验证与性能评估

本文所有实验均围绕低空交通调度这一统一场景展开，所选任务涵盖了网络组网、节点管理与路径控制3个阶段，分别体现了所提方法在组网泛化能力、意图落地精度与动态协同策略等方面的优势。

6G低空交通管控场景设置如图5所示，本文研究构建了“多机编队+路侧单元”混合场景：无人机蜂群与地面车载终端在同一频段并行通信，且在KDN框架下对外隐藏底层链路配置与路由表。链路质量会因风速、地形起伏及突发干扰而波动，同时无人机配备视觉单元以提供辅助感知。

本文聚焦于低空交通调度统一场景中的网络自组织与智能管理问题，围绕所提的“跨域知识驱动元智能框架”，从3个代表性任务模块进行功能验证，分别对应本文所提的关键机制与方法组件。实验与方法对应关系见表4，上述任务对应所提系统中不同层级的智能体感知与推理机制，构成“网络建模→个体调度→协同路径”的完整验证链条，体现了框架的闭环演进能力。所有实验均基于Python与TensorFlow实现，并运行于配备NVIDIA RTX 4080 GPU的服务器集群上。

KDN数据集：覆盖10 000个网络节点，用于验证跨域知识在组网与流量调度中的应用。

PULP-Dronet v3数据集：包含66 000张室内/室外静态障碍环境中的无人机图像，并配有二元障碍检测（2 m范围）和飞行方向标签，用以检验视觉感知与导航模块；

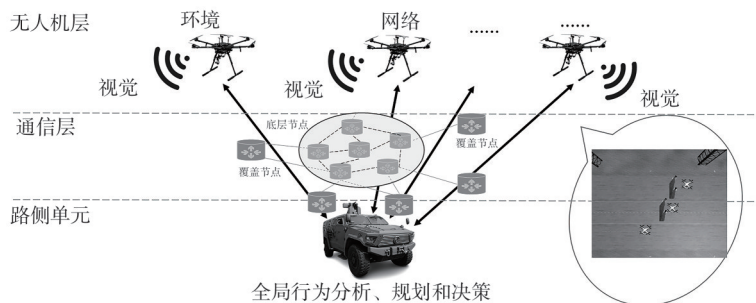


图5 6G低空交通管控场景设置

表 4 实验与方法对应关系

任务模块	对应方法模块	对应实验指标	使用数据集/仿真环境
知识驱动组网	跨域GNN建模+联邦优化	吞吐量、流量预测精度、恢复时间、路由控制开销	KDN 仿真数据集
智能体管理	轻量NLP意图解析+经验知识召回	决策时延、执行成功率、资源公平度	自建多智能体调度仿真平台
蜂群路径规划	跨域元学习+自监督优化	路径效率、平均飞行时延、任务成功率、内存占用	Meta-UAV 数据集 (含图像/标签)

Meta-UAV 最优路径数据集：本文自设，专为复杂多域路径规划设计，包含 150 个任务与 90 000 张图像，覆盖静态/动态障碍及丘陵、平地等多种地形，并在高/中/低 3 档信道质量与时延条件下测试。每个任务包含 500~1 000 帧，标注多域最优路径与跨域目标设置。元训练/元测试比例设为 4 : 1，并在元测试中引入单样本与五样本任务，以验证模型在样本受限情况下的快速适应能力。

为全面验证所提的跨域知识驱动网络元智能框架的多维性能，本文在“6G 低空交通调度”统一场景中选取了多种具有代表性的对比机制，涵盖网络控制的不同技术层级，具体包括以下 3 类方法。

1) 传统协议层方法：如开放式最短路径优先 (OSPF, open shortest path first)，为经典静态路由协议，用作底线基准，评估本文在基本吞吐和恢复能力方面的提升。

2) 知识/架构层方法：如 KDN 原生框架，基于深度强化学习和图神经网络的链路可靠性感知流量工程 (RDG-TE, reliability-aware deep reinforcement learning and graph neural network-based traffic engineering) 等方法，在控制层或策略层对网络进行全局优化，是与本文“知识平面+联邦推理”机制最接近的对比对象。

3) 智能控制/意图层方法：如基于模板的意图映射控制器、融合 GNN 与强化学习的多路径优化算法、基于意图驱动的蜂群路径规划控制器，与本文在智能体调度和策略演化层面接近，构成意图驱动与自学习方向的代表。

本文所提方法综合了上述 3 类方法的能力，通过多域感知、意图解析、知识推理与联邦同步构建统一的元智能体管理框架，因此，在实验中横向对比各层机制，旨在系统地评估不同层级优化策略的

性能边界与协同潜力。

2.1 低空交通中的知识驱动组网任务

本节验证框架在低空交通场景中的组网自适应能力，主要对应系统中的“多域信息建模+联邦优化”模块。核心目标是评估其对动态拓扑和突发事件的适应性。

知识驱动组网是“知识平面”与 KDN 的经典应用场景。本用例旨在展示网络元智能框架如何以知识为驱动、以业务为导向，对网络行为进行精准地建模与优化。所谓“组网”，即通过预定义的连接方式和通信协议将多个网络设备或节点组合成可共享资源与信息的计算机网络，并实现高效路由。

在通信层面，本文基于 OMNeT++ 2 平台对低空交通管控场景进行仿真：构建了包含 12 台覆盖节点与 19 台底层节点、共 72 条链路的混合拓扑。覆盖节点随机生成流量，目标节点独立接收；底层网络采用常数链路容量、固定传播时延，并基于最短路径的泊松流量模型进行路由。本实验将 OSPF、原生 KDN^[4]、RDG-TE^[26]、ONOS Intent^[27] 及 MPDRL^[28] 5 种方案依次视为从静态路由、单域机器学习优化、DRL+GNN、意图驱动到消息传递 DRL 的代表，从以下 4 个指标进行评估。

1) 端到端吞吐量：统计低空交通管控网络的平均吞吐量与峰值吞吐量，衡量数据搬运能力提升。

2) 故障恢复时间：在随机注入链路或节点故障后，测量从故障检测到网络策略收敛并恢复至基线吞吐水平所需的时间。

3) 流量预测精度：比较认知平面对下一时隙流量的预测值与实际观测值的均方误差 (MSE, mean squared error)，反映模型对网络状态的理解深度，是 KDN 的基准指标。

4) 路由开销：统计因知识驱动策略下发所产生的控制报文数量与总字节数，衡量自治组网的信令负担。

为便于比较，各方法所处技术层级说明见表 5，标注了各方法所处的技术层级 (协议、架构、意图/学习)，充分考虑各方法所属技术层级的差异，在评估时分别选取能够反映其核心优化能力的指标维度，确保对比分析的客观性与科学性。

知识驱动组网对比如图 6 所示，吞吐量对比如图 6(a) 所示，展示了 6 种组网方案在低空交通场景中网络负载从 0.2 到 1.0 变化时的峰值吞吐量。可以

表5 各方法所处技术层级说明

方法	分类标签
OSPF	协议层方法
KDN	知识定义架构
RDG-TE	知识驱动优化框架
ONOS Intent	意图驱动控制器
MPDRL	自学习优化算法
本文方法	跨域知识+元智能方法

看到，随着负载增加，各方案均经历了“快速上升—增速放缓”的饱和过程，其中，OSPF最慢、KDN次之，而RDG-TE、ONOS Intent和MPDRL依次提升了在线感知与调度能力。本文所提方法在满载时达93.2 Mbit/s，相比传统的OSPF提升近100%，较MPDRL有约6%的额外增益。

流量预测如图6(b)所示，KDN的MSE最高，说明仅单域离线模型无法准确地捕捉动态流量变化；KDN初始MSE为0.149，RDG-TE为0.133，ONOS Intent为0.121，MPDRL为0.108，而本文所提方法最低仅为0.086；到第5步时，本文所提方法已降至0.037，比下降第二快的MPDRL（MSE为0.054）快逾30%；到第10步时，本文所提方法的MSE为0.016，而MPDRL、ONOS Intent和RDG-

TE的MSE分别为约为0.026、0.034、0.041；到第20步后，本文所提方法的MSE收敛至0.0087，几乎是KDN（MSE为0.0275）和RDG-TE（MSE约为0.0197）的1/3，优于MPDRL（MSE为0.0122）和ONOS Intent（MSE为0.0156）。本文所提方法的MSE曲线下降最陡，表明其在少量预测步骤内即可快速适应网络状态变化，为实时调度提供了高质量输入。

故障恢复时间对比如图6(c)所示，随着并发故障数量从1增至20，OSPF的恢复时间从约8.6 s增至24.6 s，增长近185%；KDN的恢复时间从7.0 s增至21.5 s，增长约207%；RDG-TE、ONOS Intent和MPDRL的恢复时间分别从5.1 s、6.0 s、4.1 s提升至17.3 s、19.8 s、13.8 s，表明DRL+GNN与意图驱动机制在单域或意图层面均能加速收敛，但仍有饱和瓶颈；本文所提方法恢复时间从3.1 s增至11.1 s，始终最短，在20个并发故障时相比OSPF缩短超50%、相较MPDRL缩短近20%。

路由开销如图6(d)所示，展示了6种组网方案的控制报文数随网络负载呈现出明显的动态增长趋势，其中，本文所提方法报文数增长最快，峰值接近150条，表明其在高负载下须下发更多细粒度策略；MPDRL次之，动态开销介于66~120条；ONOS

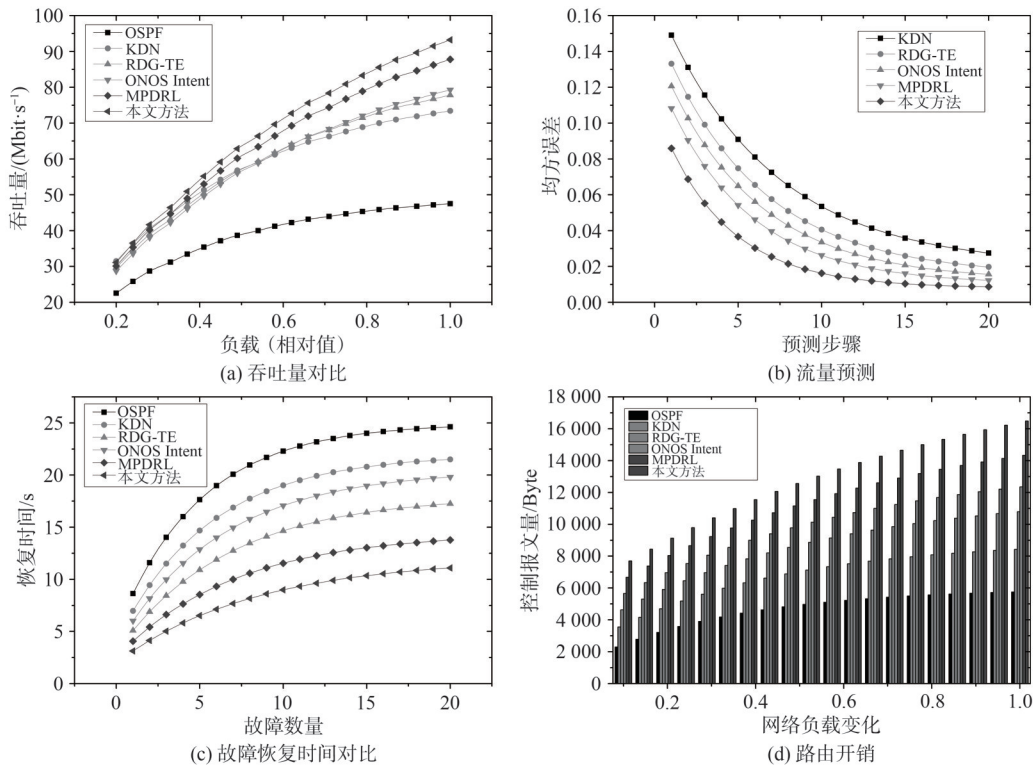


图6 知识驱动组网对比

Intent 与 RDG-TE 的动态开销分别位于 56~95 条和 46~90 条之间；KDN 与 OSPF 的动态开销最少，分别维持在 20~80 条和 10~50 条左右。从字节开销来看，OSPF 最低，仅从约 2 296 Bytes 增长至 5 751 Bytes；KDN 由 3 548 Bytes 增至 8 425 Bytes；RDG-TE、ONOS Intent 与 MPDRL 的字节数分别从 4 631 Bytes 增长至 10 781 Bytes、5 647 Bytes 增长至 12 347 Bytes 与 6 671 Bytes 增长至 14 322 Bytes，反映了在线学习与意图处理机制带来的额外信令负担；本文所提方法的控制字节数最高，从 7 696 Bytes 升至 16 482 Bytes，说明其在追求高性能自治的同时，也付出了更密集的信令代价。

2.2 低空交通中意图引导的智能体管理

本节聚焦高层意图驱动下的智能体控制与执行能力，主要对应“意图解析—经验调度—策略微调”模块。目标是验证在多业务/高负载情况下，框架是否能够快速响应用户指令并完成最优动作落地。本节使每架 UAV 或路侧单元 (RSU, road side unit) 作为一个智能体，接受高层“业务意图”（如，“优先保证低时延”、“最大吞吐”）指令后，自主完成本地资源调度与故障自愈。为了突出本文所提方法在这一环节的优势，本文选取了以下 3 项精简指标进行对比。

1) 决策时延：从高层意图下达到智能体发出具体配置命令的时间间隔，衡量系统对意图解析、模型推理与调用执行器的端到端响应速度。

2) 执行成功率：在一次意图驱动的试验中，智能体成功完成指定目标（如，保持时延<10 ms 或吞吐>50 Mbit/s）的比例，反映模型在动态环境中对意图的精准落地能力。

3) 资源分配公平度：基于 Jain’s 公平指数，评估多智能体间带宽或计算资源分配的均衡程度，验证本文所提方法在满足业务意图的同时，能否兼顾全网公平性，避免“饿死”部分节点。


针对上述指标，本文在上节机制的前提下增加以下两种对比机制。

基于规则的范式 (rule-based agent)^[29]：静态规则映射意图，无在线学习能力。


KP-XAI Agent^[30]：知识图谱+因果推理+可解释性模块，融合上下层知识。

基于意图的智能体管理如图 7 所示。不同智能体机制下决策时延随意图请求数量变化如图 7(a)所


示，决策时延随并发意图请求数的变化呈现出不同机制的特征：Rule-Based 时延几乎线性增长，仅从 5.1 ms 上升到 8.0 ms，反映了静态规则解析的极低开销；DRL Agent^[26]与 MPDRL Agent^[28]在并发请求数较少时时延迅速攀升至 40~50 ms，随后增速放缓，最终分别逼近 117 ms 与 124 ms，体现了深度模型推理与下发动作的固定成本；ONOS Intent 时延较 DRL 方案更高，收敛于约 141 ms，主要由于意图解析与模板映射环节增加了时延；KP-XAI Agent 时延最高，从大约 67 ms 上升至 大约 181 ms，可解释推理与约束校验引入了显著额外开销；本文所提方法 Agent 的起步时延低于其他 ML/DRL 方案，



(a) 不同智能体机制下决策时延随意图请求数量变化



(b) 不同智能体机制下决策成功率随任务复杂度变化



(c) 不同智能体机制下资源分配公平度随智能体数量变化

图 7 基于意图的智能体管理

在高并发（300 请求）时仍能控制在大约 105 ms，较 KP-XAI 提速约 20%，表明元智能体与在线微调在兼顾模型深度与响应速度方面取得了良好的平衡。

综上，本文所提方法在满足高层业务意图的同时，依托跨域元智能体的全局调度能力，能够在大规模部署中保持最优的资源分配公平度。

2.3 低空交通中蜂群路径规划

本节侧重验证框架在蜂群协同任务下的路径生成与动态规避能力，主要对应“跨域特征编码—元学习快速迁移—路径优化”模块。为评估各方案在 6G 低空交通蜂群任务中的表现，本节在同一仿真平台上复现了包含静态与动态障碍、频谱抖动与链路中断的典型场景。选取 5 种代表性路径规划机制进行横向对比。

1) A*[31]：基于网格代价地图的经典最短路算法，不考虑网络与蜂群协同。

2) Meta-UAV[32]：面向无人机的知识驱动元学习框架，侧重环境态势的少样本快速适应。

3) MPDRL：将图神经网络与深度强化学习用于单域流量与路径优化的扩展算法。

4) IBN-Swarm[23]：意图驱动的蜂群编队控制，

将上层“最大吞吐”或“最低时延”意图映射到分布式策略。

5) 本文所提方法：融合环境域、网络域与行为域 3 类知识，配合多层元智能体和在线自监督或元学习，完成端到端的动态重规划。

关注 4 个关键指标：路径效率，即实际飞行路径长度与理想最短路径长度之比，衡量绕行程度；平均飞行时延，即蜂群完成一次任务的平均耗时，反映调度与协同速度；占用内存大小，即模型在每架 UAV 上任务所占用的平均内存，评估资源消耗；任务成功率在高密度障碍与链路抖动场景中，蜂群按时完成的比例，体现规划鲁棒性。

6G 蜂群路径规划如图 8 所示，从图 8 综合来看，5 种路径规划机制在性能与资源消耗上呈现出明显的权衡格局。

路径效率与时延：本文所提方法以 91% 的路径效率和 10.7 s 的平均飞行时延位居第一，说明它生成的航线最接近最短路径，且蜂群响应最快；IBN-Swarm 紧随其后（87%/11.3 s），凸显意图驱动在高层策略映射上的优势；MPDRL（84%/12.1 s）凭借单域 DRL+GNN 优化也取得不俗成绩；Meta-UAV




图8 6G蜂群路径规划

(83%/13.5 s) 和最基础的 A* (78%/18.2 s) 分别位列中后, 反映少样本元学习与纯最短路径算法在综合性能上的局限。

资源消耗: 本文所提方法的峰值内存占用最高 (240 KB), 主要用于维护 3 类域知识、元智能体状态与在线模型更新; IBN-Swarm (200 KB) 和 MPDRL (190 KB) 次之; Meta-UAV (170 KB) 和 A* (150 KB) 因模型轻量或无在线学习, 占用最少资源。

任务成功率: 在高密度障碍与链路抖动的极端场景中, 本文所提方法仍保持 95% 的高成功率, 展现出最强鲁棒性; IBN-Swarm (90%) 和 MPDRL (88%) 在动态重规划中也表现稳定; Meta-UAV (83%) 与 A* (72%) 在复杂度极高时失败增多。

综合来看, 本文所提方法在“性能 (路径效率与时延)-资源 (内存占用)-鲁棒 (成功率)”的三维权衡中实现了最优平衡, 充分验证了本文所提的跨域知识融合与网络元智能体设计的核心优势。

3 结束语

本文针对 6G 网络的多场景异构与实时化运维挑战, 系统地设计并实现了跨域知识驱动的网络元智能算法框架。该框架创新性地将环境、网络与业务 3 类域信息统一编码, 并借助图神经网络与注意力机制实现在线融合, 通过知识蒸馏保持全局知识库与时俱进。多层元智能体与端到端闭环流程, 保障了高层意图的精准落地与动态优化。

本文所有实验设计均围绕低空交通统一场景展开, 3 个任务分别体现所提系统在建模、决策、执行各阶段的能力。实验覆盖感知预测、策略生成到任务落地全过程, 验证了元智能框架在多域场景中的闭环演进能力。通过低空交通调度场景中的 3 类关键任务, 跨域组网、意图引导智能体管理与蜂群路径规划进行验证, 本文所提方法在性能 (吞吐与时延)、鲁棒性 (故障恢复与成功率) 及资源效率 (信令与存储开销) 三维权衡上均实现了最优表现, 验证了其在 6G 复杂场景中的可行性与实用价值。未来工作将进一步扩展至卫星-地面协同、语义通信与大模型辅助的全局决策, 深入探讨知识演化与安全隐私保护等开放性课题, 推动在未来网络中的落地与普适应用。

参考文献:

- [1] 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.
- [2] 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.
- [3] Coronado E, Behraves 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.
- [4] Mestres A, Rodriguez-Natal A, Carner J, et al. Knowledge-defined networking[J]. *ACM SIGCOMM Computer Communication Review*, 2017, 47(3): 2-10.
- [5] 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.
- [6] Dang W S, Huang R, Yu Y J, et al. Autonomous driving network: network architecture in the era of autonomy[M]. Boca Raton: CRC Press, 2023.
- [7] Yang K Q, He Q, Wang X W, et al. KDN-based adaptive computation offloading and resource allocation strategy optimization: maximizing user satisfaction[J]. *IEEE Transactions on Computers*, 2025, 74(5): 1743-1757.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] 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: e1521.
- [15] Dayaratne T, Vo V, Lai S, et al. Exploiting and securing ML solutions in near-RT RIC: a perspective of an xApp[PP]. V1. arXiv (2024-06-18)[2025-04-20]. arXiv: 2406.12299.
- [16] 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.
- [17] 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 ,2024, preprint arXiv: 2410.08934.
- [18] 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.
- [19] 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.
- [20] 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. Intelligent information network theory and technology [M]. Beijing: Posts & Telecom Press, 2024.
- [21] 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.
- [22] Lamberti L, Bellone L, Macan L, et al. Distilling tiny and ultra-fast deep neural networks for autonomous navigation on nano-UAVs[J]. IEEE Internet of Things Journal, 2024, 11(20): 33269-33281.
- [23] Ouyang Y, Yang C, Song Y, et al. A brief survey and implementation on refinement for intent-driven networking[J]. IEEE Network, 2022, 35(6): 75-83.
- [24] Song Y, Yang C, Zhang J, et al. Full-life cycle intent-driven network verification: challenges and approaches[J]. IEEE Network, 2022, 37(5): 145-153.
- [25] Ouyang Y, Li C, Zhang J, 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.
- [26] Farhan M, Shah N, Wang L, et al. RDG-TE: link reliability-aware DRL-GNN-based traffic engineering in SDN[J]. Expert Systems with Applications, 2025, 265: 125963.
- [27] Ouyang Y, Lin J, Feng T, et al. Intent-driven CoX resource management for space-terrestrial networks[J]. IEEE Wireless Communications, 2023, 31(3): 339-347.
- [28] He Q, Wang Y, Wang X, et al. Routing optimization with deep

reinforcement learning in knowledge defined networking[J]. IEEE Transactions on Mobile Computing, 2023, 23(2): 1444-1455.

- [29] Zhou S, Zhao S Z, Ren Z Q. Loosely synchronized rule-based planning for multi-agent path finding with asynchronous actions[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2025, 39(14): 14763-14770.
- [30] 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.
- [31] Hart P E, Nilsson N J, Raphael B. A formal basis for the heuristic determination of minimum cost paths[J]. IEEE Transactions on Systems Science and Cybernetics, 1968, 4(2): 100-107.
- [32] Lin J Q, Qian Q J, Ren B Q, et al. A knowledge-driven meta-learning method for ultra-fast path planning in lightweight UAVs[C]// Proceedings of the ICC 2025 - IEEE International Conference on Communications. Piscataway: IEEE Press, 2025: 1292-1297.

[作者简介]



林佳琦(1999-), 男, 北京邮电大学网络与交换技术全国重点实验室博士生, 军事科学院系统工程研究院联合培养, 主要研究方向为智能网络、知识驱动网络。



钱琪杰(1997-), 男, 南京邮电大学通信与信息工程学院博士生, 主要研究方向为人工智能、物联网、未来网络。



钟旭东(1991-), 男, 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。



冯涛(1979-), 男, 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、网络管理。



高先明(1988-), 男, 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。



彭木根(1978-), 男, 博士, 北京邮电大学网络与交换技术全国重点实验室教授、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。



葛嘉鑫(1990-), 女, 军事科学院系统工程研究院工程师, 主要研究方向为信号处理、人工智能。



任保全(1974-), 男, 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。