

# 任务场景驱动的无线通信跨层智能适变方法

钟天尧, 姚欢, 冯智斌, 郑学强, 徐煜华, 徐逸凡, 陈瑾

(陆军工程大学通信工程学院, 江苏南京 210014)

**摘要:** 传统无线通信分层优化架构性能受限, 且往往缺乏特定任务场景的专门设计, 任务场景驱动的跨层联合优化已成为必然发展趋势。然而, 其面临多层次参数复杂耦合、不同层级参数响应时间差异大、多节点自主决策冲突严重等挑战。为此, 受人脑条件反射快速决策和深度思考高效决策的行为启发, 提出任务场景驱动的无线通信跨层智能适变架构, 系统阐述面向链路级跨层决策的一体化智能适变和面向网络级多节点协同的高效认知适变等方面的关键技术, 并结合具体跨层优化案例对部分关键技术进行验证。

**关键词:** 无线通信; 跨层优化; 类脑决策架构; 任务驱动; 智能适变

**中图分类号:** TN911

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2026015

## Task scenario-driven cross-layer intelligent adaptation approaches for wireless communication

Zhong Tianyao, Yao Huan, Feng Zhibin, Zheng Xueqiang, Xu Yuhua, Xu Yifan, Chen Jin

College of Communications Engineering, Army Engineering University, Nanjing 210014, China

**Abstract:** Traditional wireless communication architectures with hierarchical optimization exhibit limited performance and often lack dedicated designs for specific task scenarios. Consequently, task scenario-driven cross-layer joint optimization has become an inevitable trend. However, it faces challenges such as complex coupling of multi-level parameters, large differences in response times at different levels, and severe conflicts in autonomous decision-making among multiple nodes. Therefore, inspired by the fast conditioned reflex and efficient decision-making of the human brain through deep thinking, a brain-like intelligent cross-layer joint decision-making architecture driven by task scenarios was proposed. The key technologies of integrated intelligent adaptation for link-level cross-layer decision-making and efficient cognitive adaptation for multi-node collaboration at the network level were systematically expounded. Some key technologies were verified through specific cross-layer optimization cases.

**Keywords:** wireless communication, cross-layer optimization, brain-like decision architecture, task-driven, intelligent adaptation

### 0 引言

在无线通信领域, 利用人工智能 (artificial

intelligence, AI) 技术挖掘无线通信的本质特点, 创新和重塑新型智能无线通信理论、体系、架

收稿日期: 2025-09-25; 修回日期: 2026-01-20

通信作者: 徐煜华, xuyuhua@aeu.edu.cn

基金项目: 国家自然科学基金联合基金资助项目(No.U22B2002); 江苏省前沿引领技术基础研究专项基金资助项目(No.BK20212001); 国家自然科学基金资助项目(No.62401625, No.62501641); 江苏省青年基金资助项目(No.BK20231027)

**Foundation Items:** The Joint Funds of the National Natural Science Foundation of China (No.U22B2002), Jiangsu Province Special Fund for Leading-edge Technology Basic Research (No.BK20212001), The National Natural Science Foundation of China (No.62401625, No.62501641), Jiangsu Province Science Foundation for Youths (No.BK20231027)

构、模型和方法,已成为世界各国争夺的技术制高点。然而,无线网络是一种复杂的网络系统,现有AI方法的融入,仍是在传统无线通信物理层、网络层等各层级分层自治的架构<sup>[1]</sup>下,针对每一层的功能和职责进行特定的优化设计。这种分层优化架构有助于简化复杂系统,使其更易于实现和管理,被广泛应用于通信网络中。对于信道环境相对封闭稳定的有线通信网络来说,分层优化架构在有线通信网络中几乎可实现最优性能;但在通信机理复杂、通信信道具有开放性的无线网络中,分层优化效果却大打折扣。例如,分层优化架构不利于通信参数精准适变,当通信传输失败时,网络层难以分辨是物理层信道衰落还是链路层碰撞冲突所引起的;且分层架构往往只考虑对某一层进行单独优化,未考虑多层级间相互作用影响的复杂耦合关系,导致系统性能提升有限,而航空航天<sup>[2]</sup>、无人机集群<sup>[3]</sup>、移动边缘计算<sup>[4]</sup>和智能驾驶<sup>[5]</sup>等多种新兴场景对无线传输的时延、容量、可靠性等性能提出了更高的要求。因此,亟须打破传统分层自治的束缚,结合AI技术研究无线通信系统的跨层联合优化,以全面提升系统性能。

为此,本文针对现有无线通信跨层联合优化与AI技术进行了阐述和总结,分析了跨层联合优化的难点与挑战,梳理了现有研究中的不足与下一步发展方向。以完成多样化任务为目标,考虑人脑思维天然具有任务驱动和多维多层次决策的特点,对于简单任务可做出条件反射式的快速决策,对于复杂任务可做出深入思考后的高效决策,上述特性有望为无线通信多层次一体化智能决策提供新的解决思路。因此,本文聚焦无线通信跨层联合决策适变问题,受人脑思维“任务驱动和多层级决策”<sup>[6]</sup>的特点启发,分别将“快而较优”的决策模型和“慢而更优”的决策模型称为“快脑”和“超脑”,设计了一种无线通信跨层“快脑-超脑”决策引擎,如图1所示,并针对性设计AI方法达到短时快速响应、长时认知推理等综合决策的目的。以任务场景驱动为出发点,将所需的通信体制映射到无线通信多层架构中,通过“快脑-超脑”决策引擎完成不同时间尺度下具体通信参数的优化,最终实现对多样化任务场景的高效支撑。

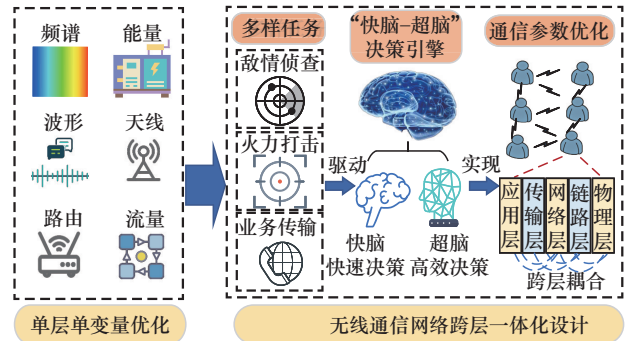


图1 无线通信跨层“快脑-超脑”决策引擎

## 1 研究进展与挑战

本节对现有无线通信跨层联合优化和AI方法的相关研究进行阐述和总结,并梳理了未来技术发展可能面临的挑战与对应的解决思路。

### 1.1 现有研究工作

通信跨层决策联合优化作为进一步提升系统性能的技术手段,已在5G和6G通信、边缘计算、车联网、物联网等诸多无线通信场景<sup>[7-23]</sup>中被广泛研究,下面围绕优化目标、优化变量、优化方式和理论方法4个维度对现有工作进行简要分析。

从优化目标来看,现有研究多针对通信性能本身进行优化,如文献[7]研究了5G低时延高可靠通信场景中链路层时延约束下的传输能量最小化问题;文献[8]研究了车联网通信场景中延迟违规概率约束下的期望吞吐量最大化问题;文献[9]研究了移动边缘计算系统中端到端延迟约束下的丢包率最小化问题。然而,通信需求源自具体任务,为高效地完成具体任务,应面向任务效能而非通信指标进行通信参数或资源的优化<sup>[10]</sup>。

从优化变量来看,现有跨层研究多针对多层变量进行联合优化<sup>[11-13]</sup>,如文献[11]提出一种针对水下通信的启发式蜂群算法,对物理层功率、链路层时隙调度以及网络层路由进行了联合优化;文献[12]在工业物联网的低时延无线通信问题中对物理层功率、网络层队列调度以及应用层有损压缩比率进行了联合优化。然而,上述工作忽视了不同层变量的时间尺度的差异,均在同一时间尺度上对多层变量进行联合优化,这将导致信道估计开销和计算复杂度增大等问题<sup>[14]</sup>。

从优化方式来看,现有跨层研究大多以分层级联优化的方式解决复杂联合优化问题,如文献[15]将原问题拆分为路由子问题和资源分配子问题,在

求解路由子问题时提出一种仅考虑距离因素的启发式路由算法。文献[16]将原问题拆分为传输参数决策子问题和用户关联子问题,在解决前者时的计算是孤立的,并未考虑多用户间的影响。然而,上述分层级联优化的方式没有充分考虑跨层变量间以及多节点间的深度耦合关系<sup>[17]</sup>,对系统性能的提升有限。

从理论方法来看,无论是传统的信息论、凸优化等方法<sup>[18-20]</sup>,还是新兴的机器学习等人工智能方法<sup>[21-23]</sup>,都在不同的特定场景下得到了广泛的应用。凸优化等方法的优势在于具有可靠的理论性能保证,如文献[18]研究了5G网络中基站功率最小化问题,基于凸优化理论在时延与可靠性的约束下对功率、带宽以及丢包策略进行了联合优化。人工智能方法凭借其强大的学习和拟合能力,常用于解决跨层设计中的复杂问题建模和高维参数优化,如文献[21]研究了6G物联网超可靠低时延的通信约束下如何兼顾能效与频谱效率的问题,提出了一种基于迁移异步优势演员-评论家的深度强化学习算法(deep reinforcement learning, DRL),对物理层的时频资源和链路层的数据包副本数量进行了联合优化。然而,从上述分析可知,任务场景驱动的无线通信多尺度跨层联合决策问题十分复杂,传统单一的理论方法不再能完全胜任。

得益于脑科学知识在机器人控制<sup>[24]</sup>、智能导航<sup>[25]</sup>等领域中的交叉应用,研究者开始在设计机器学习方法时从不同层面上借鉴大脑结构,从而衍生出一些类脑智能方法<sup>[26-27]</sup>。例如文献[27]借鉴了人脑决策机制背后的“快-慢”系统思想,针对主动目标跟踪任务中严重异常情况导致算法性能急剧下降的问题,提出了一种创新的认知具身学习方法,可自适应切换不同的算法分别处理正常追踪和异常情况,提高目标追踪的鲁棒性。由此可见,这种借鉴人脑特性的方式有望为任务场景驱动的无线通信多尺度跨层联合决策提供新的解决思路。

## 1.2 不足与挑战

虽然现有研究在无线通信跨层联合设计以及AI方法应用方面取得了一定的成果,但整体上还存在以下几个共性不足。

1) 缺少有效的任务映射机制和决策理论指导。现有研究优化目标往往聚焦于如何提升通信性能指

标本身,缺乏对上层任务效能的考虑<sup>[7-9]</sup>,而跨层联动的本质是为了更好地完成任务<sup>[10]</sup>,不同层级及多层参数对通信性能及任务完成的影响关系是十分复杂的,导致不同层级之间交互作用建模不清晰、通信性能和任务需求匹配不精准、通信资源分配不均衡。

2) 不同参数时间尺度差异易被忽视且协调困难。不同协议层的参数具有显著差异的时间尺度<sup>[11-13]</sup>,例如物理层、链路层、网络层参数更新尺度通常呈由快到慢的相对变化趋势。如果还在同一时间粒度上对跨层变量进行联合优化,将导致计算、感知等开销增加或部分参数更新滞后<sup>[14]</sup>,且不同层级之间可能存在的内在约束及目标冲突进一步导致相互协调困难,难以高效权衡系统的有效性和时效性。

3) 多节点跨层优化问题的求解处理往往过于简化。面对多节点的跨层优化问题,现有研究工作在求解方法上多采用“分而治之、级联优化”的简化思路<sup>[15-16]</sup>,本质是将一个复杂高维联合优化问题分解为若干个按层级或功能划分的顺序求解子问题,往往忽视了节点间与跨层变量间的深度耦合关系<sup>[17]</sup>,对系统性能的提升有限,尚缺少可行有效的方法实现多节点无线通信跨层设计中复杂度与性能提升的权衡。

基于上述对现有工作中“缺少任务考虑、忽略时间尺度差异、复杂跨层求解简化”等不足的总结,针对任务场景驱动的无线通信跨层联合决策优化问题,本文进一步结合大规模场景下网络资源竞争冲突严重、多节点决策优化问题复杂度激增等现象,梳理出以下3个核心挑战,并提出对应的解决思路。

1) 如何将多样化任务映射为通信需求并提取关键跨层优化参数。无线通信系统面临多样化任务场景,不同任务场景下通信需求差异明显;此外,即便在特定任务场景中,通信需求也常常随时间动态变化。因此,需精确感知电磁环境,并结合任务特点、任务流程、节点关系、地理环境等因素,挖掘任务需求和通信需求的内在联系,实现两者之间的精准映射及关键跨层通信参数的选择,为多维多尺度智能适变提供需求支撑。

2) 如何分析不同参数的耦合影响关系并实现跨层多尺度联合适变。无线通信多层级参数复杂耦

合（如不同层级需要优化的参数关系复杂且相互作用影响）和决策时间多尺度异构变化（如物理层响应时间快、网络层相对较慢）等挑战，使问题求解复杂度急剧增加。因此，需探索脑认知科学和无线通信 AI 的融合机制，创新具备多维多尺度自适应能力的类脑智能决策模型，并对该模型进行一定的轻量化处理，以兼顾无线通信多层级参数自适应的时效性和有效性。

3) 如何实现多节点间的高效自主协同自适应及全网性能提升。多节点无线系统中决策问题复杂度随节点数增加而呈指数级增长；同时，多节点间竞争、共享和合作等多种关系耦合并存，网络资源竞争冲突严重；节点间频繁的信息交互导致网络开销剧增，难以高效协同；加之跨层优化中多维多尺度复杂决策的困难挑战，导致多节点协同自适应问题变得异常复杂，常规方法难以奏效。因此，需提出面向类脑智能决策的极简信息表征模型，降低节点信息交互开销；针对集中式和分布式两种典型网络形态，探索高效智能协同机理，实现多节点通信参数的整体自适应，提升全网通信性能和任务效能。

## 2 无线通信跨层智能自适应方法

针对现有工作的不足和当前面临的主要挑战，本文提出一种任务场景驱动的无线通信跨层智能自适应方法，并围绕跨层智能自适应架构以及链路级跨层决策和网络级多节点协同 3 个方面，对涉及的关键技术进行阐述。

### 2.1 任务场景驱动的无线通信跨层智能自适应

无线通信系统存在不同层级响应时间差异大、多维域参数复杂耦合等特点，传统面向单层级或单一时间尺度的多参数优化方法难以直接适用。而人脑具有的快速条件反射和深度思考高效决策的行为特点，较为适配无线通信的多维多域跨层联合优化问题。除此之外，为支撑复杂多样的任务场景，还需明晰不同任务场景下相应的通信指标与通信体制，通过关键通信参数的优化实现快速高效的自适应。最后形成闭环，对任务效能与通信自适应能力进行评估，为面向任务的智能通信自适应提供优化方向。

综上所述，将类脑行为特征和无线通信理论相结合，从应用层出发，以任务驱动为指导，提出无

线通信跨层智能自适应架构，指导物理层、链路层、网络层等 5 层贯穿一体的参数自适应，如图 2 所示。下面主要从“快脑-超脑”智能自适应架构、协同频谱感知、关键通信参数选择和任务效能与通信自适应能力评估 4 个方面，对所提出的任务场景驱动的无线通信跨层智能自适应架构进行详细论述。

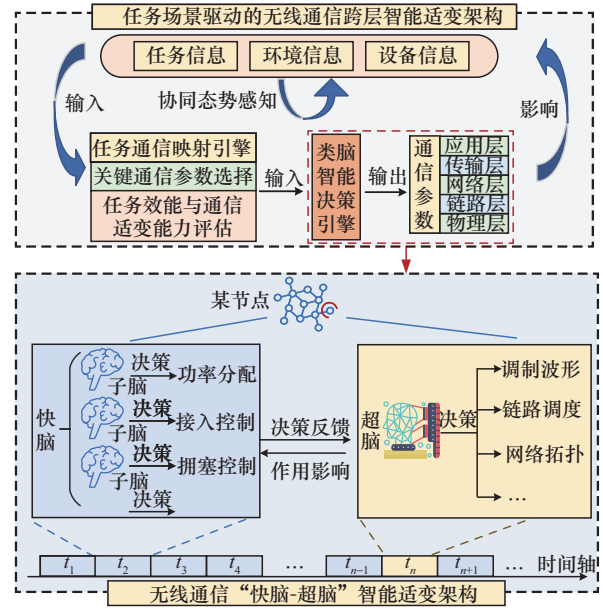


图2 任务场景驱动的无线通信跨层智能自适应架构

#### 2.1.1 无线通信“快脑-超脑”智能自适应架构

受人脑认知行为启发，构建如图 2 所示的无线通信“快脑-超脑”智能自适应架构。一方面，超脑支配快脑，主导整体决策，包括选择优化参数、优化算法及任务分配，并主要负责长时的决策优化（如数据流的调度优化）；另一方面，超脑和快脑协同优化通信参数。快脑优先处理实时性要求高的适配任务（如频率快速选择），其输出与环境反馈共同作为训练样本供超脑学习。根据不同的决策任务可进一步将快脑分为多个独立的子脑，每个子脑负责不同的参数优化；超脑在算法收敛或时效允许时接替快脑优化，并将其学习结果反馈至快脑，用于调整其算法参数。在多节点的智能通信中，节点间还需要进行高效的信息交互，该信息也会辅助快脑和超脑的决策，最终实现面向复杂任务目标的“任务场景-通信需求-智能自适应”的认知决策流程。

#### 2.1.2 多智能体协同频谱态势感知

频谱态势获取是无线通信系统实时认知环境并

及时做出适变调整的前提,包括频谱态势感知和频谱态势生成两个重要方面。频谱态势是指电磁频谱的状态、形势和趋势,孤立的、离散的、碎片化的频谱状“态”可构成频谱空间的形“势”。频谱态势生成是在频谱态势感知获取频谱状态的基础上,挖掘频谱状态间的相关性和规律性,获取频谱空间的综合形势。针对复杂电磁环境下感知能力、数据样本和训练时间受限等问题,设计基于机器学习的多智能体协同频谱态势感知与生成方法,考虑感知任务场景和信息交互开销,运用联盟博弈等方法对问题进行建模求解,实现感知节点的选择部署和任务分配;进一步,为提升感知节点频谱感知效率和准确率,利用匹配博弈和在线学习方法,对节点感知参数进行协同优化,并提出低复杂度的分布式共识方法,实现频谱态势信息的高效汇聚与安全共享。

此外,通信与感知一体化融合<sup>[28]</sup>已被列为面向6G的主要场景之一。面向通感一体化场景,通过特定场景下合理分配通信和感知资源,实现通信与感知两者之间的性能折中和深度协同;同时,对多源异构的感知数据进行特征级融合,实现感知准确性、精度和效率的持续提高。

### 2.1.3 面向复杂任务场景的通信需求映射及关键参数选择

实际应用中有有效通信系统的标准是能满足任务场景对通信联络的需求,其核心是实现传输速率、误码率、抗干扰能力等相应的性能指标,而通信体制则在很大程度上决定了这些性能指标的上限。因此,针对任务场景选择适宜的通信体制是设计通信系统的关键,然而一个重要前提是需要对任务场景的通信业务强度和通信性能指标要求进行估计。

为解决上述问题,建立典型任务情景知识库,将任务类型、任务阶段、电磁地理环境、关联关系等多维域属性建模为任务情景,利用包含多层推理机的专家系统对任务场景进行分解,明晰不同任务情景下对于通信体制、传输技术等方面的要求。采用因果关联分析、大模型分析等方法,对任务需求和通信需求进行分解,通过系统级行为与各层参数的匹配,生成决策的动作约束与响应约束,即给出指定任务场景下决策优化所需的关键通信参数,为后续决策提供基础。

### 2.1.4 任务效能与通信适变能力评估

任务效能直接反映了无线通信对于任务的支撑效果。由于任务环境复杂多变,影响因素众多且相互耦合,在建立评价指标体系时需要总体统筹,区分不同层次、准则。综合考虑上层任务与电磁环境,将质量、规模、时效、成本作为一级指标,从4个维度衡量单个任务完成情况。以任务驱动的通信映射为基础,明晰不同任务场景、不同任务阶段下的任务需求,建立评估的二级关键指标。例如,误码率、可通率作为任务质量的衡量因素,网络容量、带宽等作为任务规模的衡量因素,信息传输时延、服务时间作为任务时效的衡量因素,频谱效率、能量效率作为任务成本的衡量因素。针对评价指标之间相互影响、制约的关系,利用网络层次分析法建立评价模型,给出任务效能的评估结果。

通信适变能力反映的是适变方法面对各种因素变化的鲁棒性。适变能力的评估难点在于智能适变方法受到外部环境、输入数据、学习模型、硬件等多因素影响,因素之间维度不同,难以建立统一的映射框架表征所提方法的稳健性、效率等性能。同时,这些不确定因素使环境变得非平稳,导致通信策略失效。因此,在建立适变能力评估指标体系时,将通信架构的安全性、可靠性作为一级指标。在指标计算时,利用扰动数据集测试模型的泛化能力,采用贝叶斯、深度学习等方法评估扰动情况下通信适变能力,为多维多尺度复杂决策和多节点协同决策优化提供方向性指导。

## 2.2 面向链路级跨层决策的一体化智能适变

在点对点的链路级通信适变决策过程中,通过跨层多维域关键参数联合优化预期可大幅提升通信性能,但决策数量增加、优化参数跨层将导致决策空间剧增且不同层级参数响应时间差异大,传统面向单层级或单一时间尺度下的多参数优化方法难以直接适用。因此,如何结合多种AI方法实现跨层一体化决策以及如何实现决策算法轻量化是本节的核心内容。如图3所示,结合“快脑-超脑”的类脑结构,融合利用多模型集成学习<sup>[29]</sup>、知识蒸馏<sup>[30]</sup>等理论方法,提出面向链路级跨层决策的一体化智能适变框架。一方面,结合多个模型的预测结果或决策输出,实现多维度、多尺度的通信参数智能决策;另一方面,挖掘通信领域知识和学习方法的融合嵌入机理,设计通信知识嵌入的轻量化快

速决策模型。需要注意的是，点对点链路级适应是多节点网络级适应的前提，因此在跨层适应设计中，前者涉及网络层参数相对较少，后者会对网络层参数优化更加侧重。

### 2.2.1 基于自适应集成学习的联合适应决策

为了应对多维度决策（物理层、链路层、网络层等）和多尺度决策（物理层响应时间快、网络层相对较慢）的挑战，采用集成学习方法协同利用多个基决策器。具体而言，可使用协议规则、专家系统、统计分析等方法形成快脑及其子脑，快脑基于外部输入在短时间尺度上实现快速决策；可使用深度学习、强化学习、知识图谱等智能学习方法形成多层多维域的超脑，超脑可主动深入思考，在长时间尺度上进行多维策略推理。快脑和超脑并行协同工作，超脑除了利用自身的历史决策信息，还可利用快脑的历史决策信息，对决策输出进行融合优化，从而实现多维度、多尺度、自适应的一体化智能适应决策。

### 2.2.2 通信知识嵌入的轻量化适应决策

尽管快脑复杂度低、响应时间快，但是超脑需对多维域通信决策进行统一调度，还存在模型参数复杂、模型交叠严重及响应时间慢的问题。为此，需研究融合通信知识嵌入与交叉知识蒸馏的方法，在保证模型性能的同时，大幅度降低模型复杂度。首先，利用通信领域的专业知识（如信道特性建模、通信特征提取等）设计特定的通信知识层，为神经网络提供有效的特征参数，并设计定制化损失函数，加快模型响应速度。其次，通过交叉知识蒸馏方法压缩模型参数、简化模型结构，将决策模型提炼为适用于实时决策的轻量化决策模型。

### 2.3 面向网络级多节点协同的高效认知适应

在网络级无线智能通信系统中，多节点间竞争、共享和合作等多种关系并存，导致网络资源竞争冲突严重；且由于信息表征复杂、多智能体交互效率低，智能体间需要大量交互，占用过多通信资源。针对上述问题，结合语义通信<sup>[31]</sup>、大

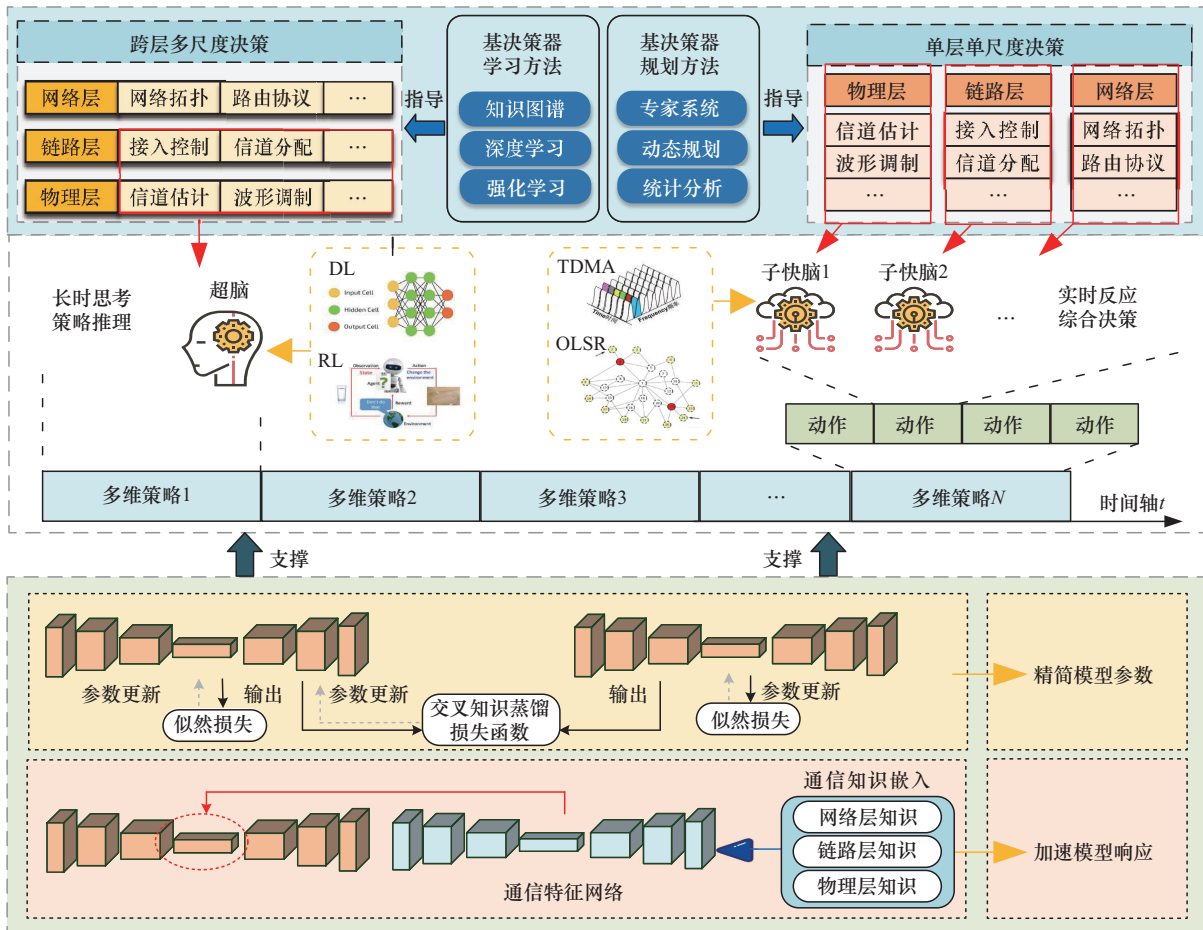


图3 面向链路级跨层决策的一体化智能适应框架

模型<sup>[32-33]</sup>、多智能体博弈学习<sup>[34]</sup>等方法, 提出面向高效协同的多节点智能通信适变框架, 如图 4 所示。首先, 针对信息表征难和节点间交互效率低等问题, 设计基于智能语义通信的极简信息表征方法, 为节点的“快脑-超脑”引擎交互提供基础; 进一步, 针对集中决策空间大等问题, 设计基于大模型的集中式网络通信适变方法; 然后, 针对分布式网络面临的信息交互受限和决策变量多等挑战, 设计基于多智能体博弈学习的分布式网络通信适变方法, 实现网络内多节点的高效协同适变。

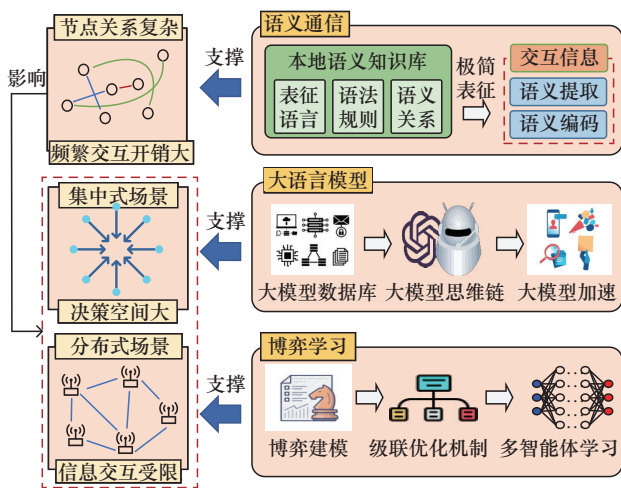


图4 面向高效协同的多节点智能通信适变框架

### 2.3.1 基于智能语义通信的极简信息表征

多节点智能通信需要频繁的信息交互, 因此, 需要设计面向“快脑-超脑”通信范式的信息表征方法, 为多节点高效协同奠定基础。首先, 基于最大熵原理和 DRL 算法, 建立“快脑-超脑”引擎交互需求到最优表征语言的映射关系; 然后, 利用最优二叉树、马尔可夫链等理论方法, 完成表征语言优化、语义提取、语义编码、信息交互、推理决策等过程; 同时, 评估交互信息和表征语言的适配性和简洁度, 并引入反馈学习机制, 实现表征语言的在线优化, 保证节点间的高效协同和上层任务的有序推进。

### 2.3.2 基于大模型的集中式网络通信适变

除单个节点多维域决策空间巨大外, 多节点网络的决策复杂度随节点数增加呈指数级增长, 这两方面的共同作用, 使得多节点无线通信网络适变问题异常复杂, 常规方法几乎难以奏效。为此, 探索

基于大模型的集中式网络通信适变方法。首先, 结合无线网络通信分层架构和数据集合标注, 建立多维多尺度通信样本库, 为通信大模型提供数据支撑; 然后, 搭建大模型思维链, 实现多节点通信复杂决策问题向大模型的转换。最后, 提出大模型决策加速设计方法, 采用混合精度量化、高效稀疏矩阵编码等方式加速大模型收敛。

### 2.3.3 基于多智能体博弈学习的分布式网络通信适变

由于缺乏中心节点, 分布式网络中存在节点间信息交互受限、多用户决策难收敛等问题, 需研究基于多智能体博弈学习的分布式网络通信适变方法。首先, 利用二元图、超图等模型精准刻画节点间的通联状态, 基于势能博弈和演化博弈等模型对节点间无线网络资源的共享/竞争关系进行建模, 结合“快脑-超脑”工作机制设计效用函数, 分析证明纳什均衡解的存在性; 然后, 设计多节点通信参数的级联优化机制, 在保证网络基本通联的条件下, 按照任务场景需求和通信参数的重要程度, 依次对多维度多尺度参数进行优化; 最后, 在不确定、动态和不完全信息等约束下, 提出基于分布式学习的多智能体高效协同算法, 实现全网核心关键通信参数的高效协同优化。

## 3 案例分析

本文所提任务场景驱动的无线通信跨层智能适变方法整体上仍处于起步阶段, 团队前期已开展相关工作并对部分内容进行了初步探索, 下面分别就物理层-传输层联合抗干扰<sup>[35]</sup>和多接入移动边缘计算 (mobile edge computing, MEC)<sup>[36]</sup>两个场景给出具体案例和分析。

### 3.1 面向认知通信的物理层、传输层联合抗干扰

传统传输层拥塞控制机制主要依赖端到端确认字符 (acknowledge character, ACK) 包丢失或时延作为评估链路状态恶化的间接指标, 由于缺乏对底层信道状态的直接感知能力, 其反应速度远远滞后于干扰引起的信道变化速度, 严重制约了系统吞吐量与可靠性, 这一点在竞争激烈的多用户无线接入网络中尤为突出。除动态信道状态与用户接入冲突外, 网络中还可能存在恶意干扰, 因此本节研究了恶意干扰下物理层参数 (信道、功率、调制方式) 与传输层拥塞控制 (窗口大小) 的联合优化机

制<sup>[35]</sup>，以实现可变背景流量下的稳健抗干扰决策。

如图 5 所示，考虑了一个无线接入网络场景，其中包含多个主用户、一个智能（次级）用户以及一个恶意干扰设备，每个用户都配备一对收发信机。主用户采用固定频段接入序列和基于载波侦听的竞争接入机制，在传输层采用经典传输控制协议（transmission control protocol, TCP），干扰用户在通信频段内发送高功率信号进行干扰，智能用户通过动态调整物理层的信道、功率、调制编码以及拥塞控制策略以适应变化的信道环境。

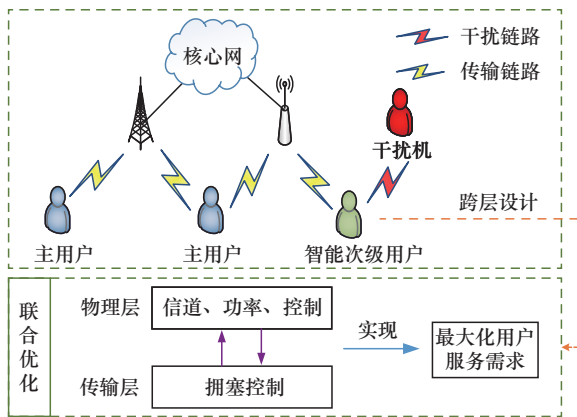


图 5 面向认知通信的物理层传输层联合抗干扰网络

对于智能用户，其目标是通过理解和适应干扰情况及信道变化，做出最佳跨层决策，从而在有限的传输能量下保证最大化数据传输量。因此，智能用户的优化目标建模为吞吐量、平均时延以及发射功率的加权和。

$$\max_{f_i^u, p_i^u, m_i, \text{cwnd}_i} \alpha_1 B_i - \alpha_2 \log(t_{\text{RTT}}) - \alpha_3 \text{lb}(p_i^u) \quad (1)$$

其中， $B_i$ 、 $t_{\text{RTT}}$  和  $p_i^u$  分别为吞吐量、平均时延和发

射功率， $\alpha_1$ 、 $\alpha_2$ 、 $\alpha_3$  为正常数系数，优化变量分别为信道变量  $f_i^u$ 、功率变量  $p_i^u$ 、调制模式  $m_i$  和拥塞窗口大小  $\text{cwnd}_i$ 。

为解决上述问题，本节提出一种如图 6 所示的知识嵌入抗干扰跨层决策架构。首先，为压缩动作空间和加速学习过程，将上述跨层耦合决策问题分解为两个子问题，子问题一确定用户信道与传输速率（中间变量）的选择，子问题二确定所适配的功率、调制模型与拥塞窗口，并分别用混合近端策略优化<sup>[37]</sup>解决信道和速率的联合选择以及用深度 Q 网络求解拥塞控制等策略。其次，为解决传输层反应滞后问题，打通了物理层与传输层信的信息壁垒，使子问题一的决策结果纳入子问题二的决策考量之中。最后，为解决跨层联合优化中传统 DRL 算法易出现的奖励稀疏、反馈估计不全与  $Q$  值过估计等问题，将频谱感知的先验与后验知识嵌入强化学习的动作选择与奖励函数中，以减小动作空间、改善决策评估并提升优秀策略的重要性。

在仿真实验中，分别考虑了两种场景：无干扰情景和混合干扰情景（有一个固定的干扰者和一个移动的干扰者），并根据层间有无信息交互、层间决策是否独立设计了对比算法，包括层间无信息交互、独立决策的 DRL 算法，层间有信息交互、独立决策的 DRL 算法，以及层间有信息交互、联合决策的分层 DRL 算法。所提算法相关参数设置为：奖励权重  $\alpha_1 = 1$ ， $\alpha_2 = \alpha_3 = 0.5$ ，折扣系数  $\gamma = 0.95$ ，深度 Q 网络学习率为 0.000 5，混合近端策略优化（hybrid proximal policy optimization, H-PPO）网络学习率为 0.001，策略网络学习率为 0.000 5。

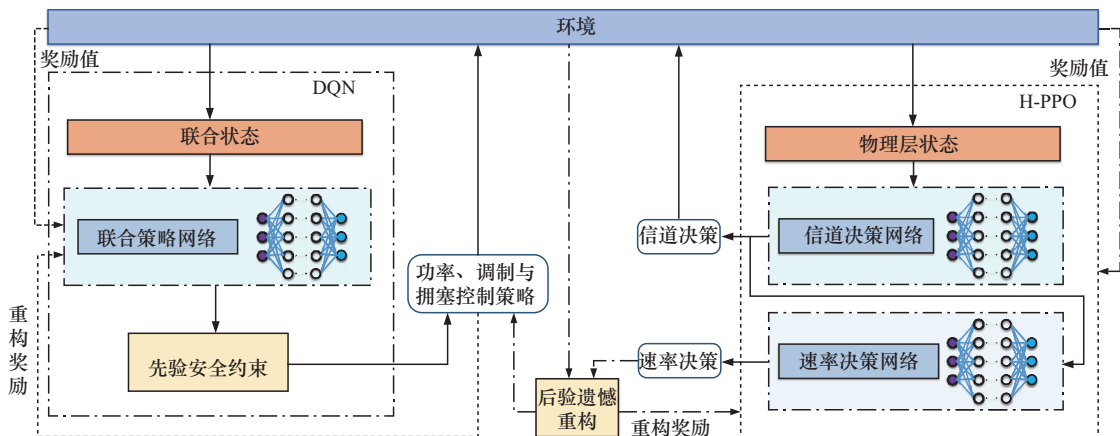


图 6 知识嵌入抗干扰跨层决策架构

图7为不同场景下算法平均服务质量 (quality of service, QoS) 性能上的对比。其中平均QoS通过随时隙的累加得到, 计算为95%累积量加上5%本时隙QoS。从图7可以看出, 层间隔离的决策算法性能均远低于所提算法, 证明了层间信息交互的必要性。且所提算法在无干扰和有干扰场景中均超过基准算法, 实现了吞吐量和数据包成功率率的显著提升, 证明知识嵌入模块将决策的即时反馈与反思产生的后悔值相结合, 能够有效引导智能体寻找更好的策略, 在保证决策安全的同时达到最优的系统性能。

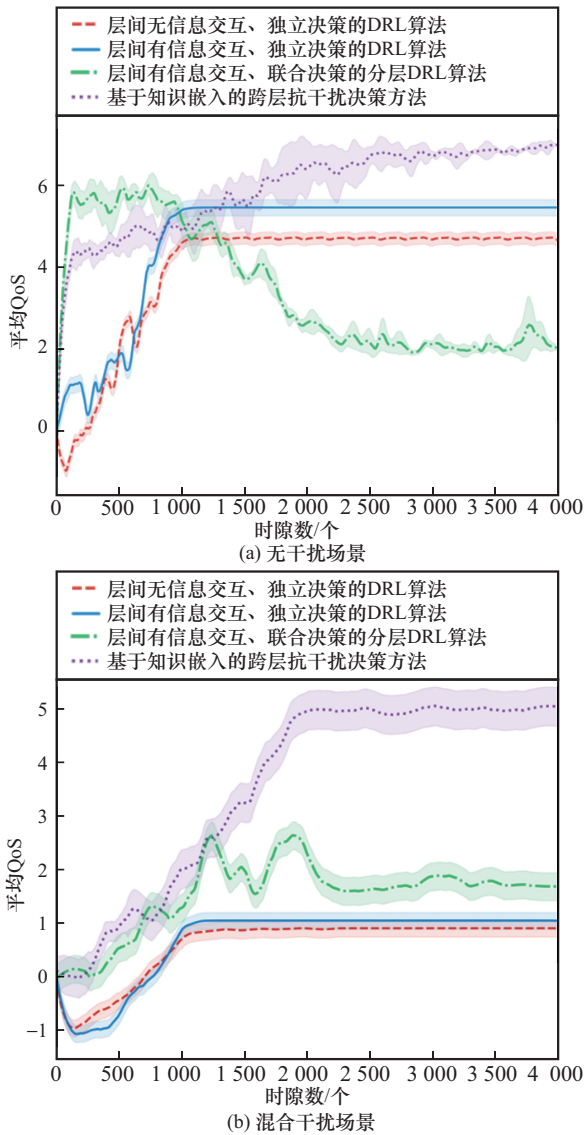


图7 不同场景下算法平均QoS性能上的对比

### 3.2 面向MEC网络数据卸载任务的物理层、应用层资源联合管理

在多接入MEC网络中, 网内用户用频互扰与

外界恶意干扰威胁加剧了MEC网络计算资源分配的不确定性, 为此本节研究了多接入MEC网络中的多维跨层资源管理优化问题, 通过物理层 (频率、带宽、功率) 和应用层 (卸载比例) 的联合优化, 在确保满足用户任务计算时延要求的前提下, 最小化MEC网络的长期计算成本<sup>[36]</sup>。

如图8所示, 考虑场景中包含多个移动用户、基站、MEC服务器以及恶意干扰机。每个基站为  $N$  个随机分布的用户设备提供服务, 一个基站配备一个MEC服务器, 为接入的用户提供计算服务。移动用户有不同类型的应用任务, 但一次只能执行一种类型的任务, 且只能将任务卸载给一个MEC服务器。

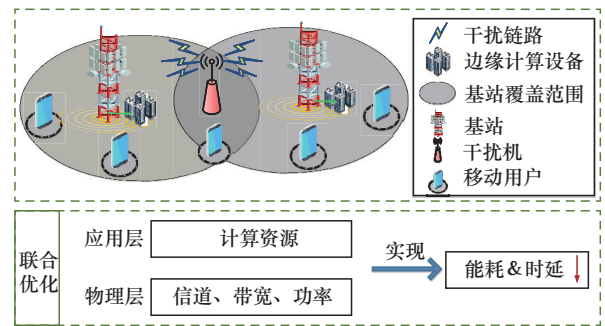


图8 多接入MEC网络的多用户抗干扰数据卸载系统模型

本节定义任务的计算成本为任务处理时延和任务处理能耗的加权和, 根据需要处理的业务类型, 定义任务数据的计算成本  $G_{i,m}^{all}(t)$  为

$$G_{i,m}^{all}(t) = \gamma_i \max(T_{i,m}^{tot}(t), T_i^l(t)) + \varphi_i (E_i^l(t) + E_{i,m}^{tran}(t)) \quad (2)$$

其中,  $\gamma_i (0 \leq \gamma_i \leq 1)$  和  $\varphi_i (0 \leq \varphi_i \leq 1)$  分别为时延和能耗的权重系数, 且  $\gamma_i + \varphi_i = 1$ ,  $T_{i,m}^{tot}(t)$  和  $T_i^l(t)$  分别为卸载总时延和本地计算时延,  $E_i^l(t)$  和  $E_{i,m}^{tran}(t)$  分别为本地计算能耗和传输能耗。最后系统的优化目标定义为最小化网络平均计算成本, 即  $\min_{P, \alpha, B, f} W_t =$

$$\frac{1}{T \sum_{t=1}^T \sum_{i=1}^N G_{i,m}^{all}(t)}$$

优化变量为功率  $P$ 、卸载比例  $\alpha$ 、带宽  $B$  和频率  $f$ 。

由于该问题属于混合整数规划的跨层联合优化问题, 现有的基于强化学习的资源分配方案大多聚焦于单一离散或连续决策空间, 不能很好地适用于该问题。且强化学习算法在高维参数问题中面临着

稀疏奖励的问题，会导致算法收敛慢和优化方向模糊。为克服上述挑战，基于图9所示的网络架构，本节提出了一种集中式训练分布式执行的混合决策强化学习算法，该算法基于演员-评论家（actor critic, AC）算法，采用分层异步神经网络架构，其中上层网络负责离散信道接入策略优化，下层网络负责数据卸载连续决策优化。具体而言，所提算法设计了多个并行子网络以解决多维混合异构决策问题，并通过一个全局Critic网络来更新各子网络的决策参数。

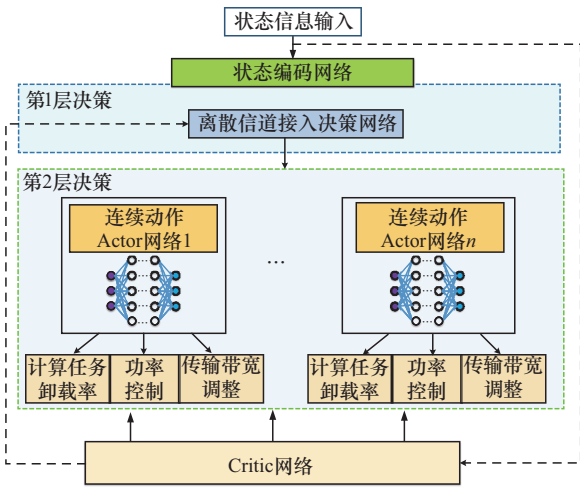


图9 基于分层学习的混合决策AC网络架构

本节仿真实验根据决策变量是否离散、优化框架是否是纯分布式设计了对比算法，包括集中式训练分布式执行的离散决策强化学习算法、集中式混合决策的分层强化学习算法、纯分布式离散决策的深度Q学习算法。部分参数设置如下：可用信道数量为10，用户设备带宽范围为2~4 MHz，发射功率为5~20 dBm，用户算力为 $1.5 \times 10^8$  cycle，计算能效系数为 $10^{-27}$  J/cycle。

图10和图11给出了MEC网络在系统开销以及任务卸载成功率方面的性能表现。为确保算法的稳定性得到全面验证，每种算法均进行了500次的蒙特卡罗仿真，并计算了每迭代100次的平均值。从图10和图11可以看出，所提算法的优化效果显著优于对比算法，证明在跨层参数混合规划问题中，所提算法要优于只优化离散或连续变量的学习算法，且在相同迭代次数下更快速实现对目标的优化，展现出了对跨层多维混合异构决策问题的精准适应性。




图10 动态干扰场景中不同算法下的MEC系统开销对比




图11 动态干扰场景下各算法的任务卸载成功率对比

上述案例对2.2.2节和2.3.3节中的部分关键技术进行了验证，但仍存在需要改进的地方。例如，3.1节虽然采用两种不同的算法来分别优化物理层和传输层中的通信策略，但没有深入考虑跨层优化问题下不同策略之间的关联性和时间尺度的差异性。下一步将以现有工作为基础，一方面，分析任务效能与通信需求的映射关系，明晰不同任务场景的系统设计目标；另一方面，深入研究能够完美契合无线通信特点的智能适应架构，以“快脑-超脑”多尺度决策思想为指引，实现任务驱动的无线网络的一体化跨层设计与优化。

### 4 结束语

在无线通信跨层联合优化发展趋势下，针对其面临的多层级参数复杂耦合、不同层级响应时间差异大、多节点自主决策冲突严重等问题挑战，


本文将无线通信跨层联合优化和类脑智能相结合。首先,对现有跨层联合优化设计工作与类脑智能相关工作进行梳理,并总结现有工作的共性问题以及未来工作的可能挑战;其次,为应对上述问题和挑战,受人脑快速条件反射和深度思考高效决策的行为启发,提出任务场景驱动的无线通信跨层智能决策架构;而后,详细介绍了面向链路级跨层决策的一体化智能适变和面向网络级多节点协同的高效认知适变等关键技术;最后,基于前期工作的两个具体案例,对部分关键技术进行论证和说明,表明所提“快脑-超脑”智能适变架构的理论指导意义。

### 参考文献:

- [1] Jiang X L, Shokri-Ghadikolaei H, Fodor G, et al. Low-latency networking: where latency lurks and how to tame it[J]. *Proceedings of the IEEE*, 2019, 107(2): 280-306.
- [2] 韩晨, 刘爱军, 安康. 卫星互联网抗干扰策略研究展望[J]. *天地一体化信息网络*, 2022, 3(1): 50-55.  
Han C, Liu A J, An K. Research prospect of anti-jamming strategy for the satellite Internet[J]. *Space-Integrated-Ground Information Networks*, 2022, 3(1): 50-55.
- [3] 尹浩, 魏急波, 赵海涛, 等. 面向有人/无人协同的智能通信与组网关键技术: 现状与趋势[J]. *通信学报*, 2024, 45(1): 1-17.  
Yin H, Wei J B, Zhao H T, et al. Intelligent communication and networking key technologies for manned/unmanned cooperation: states-of-the-art and trends[J]. *Journal on Communications*, 2024, 45(1): 1-17.
- [4] 余礼苏, 李彪, 姚元志, 等. 区块链辅助无人机移动边缘计算系统的性能优化[J]. *信息安全*, 2024, 24(9): 1432-1443.  
Yu L S, Li B, Yao Y Z, et al. Performance optimization of blockchain-assisted unmanned aerial vehicle mobile edge computing system[J]. *Netinfo Security*, 2024, 24(9): 1432-1443.
- [5] 张新钰, 国纪龙, 李骏, 等. 基于信息论的智能驾驶可解释多模态感知[J]. *中国科学: 信息科学*, 2024, 54(6): 1419-1440.  
Zhang X Y, Guo G L, Li J, et al. Information-theoretic-based interpretable multimodal perception for intelligent vehicles[J]. *Scientia Sinica (Informationis)*, 2024, 54(6): 1419-1440.
- [6] Kahneman D. *Thinking, fast and slow*[M]. New York: Farrar, Strans and Girous, 2011.
- [7] Xu S F, Chang T H, Lin S C, et al. Energy-efficient packet scheduling with finite blocklength codes: convexity analysis and efficient algorithms[J]. *IEEE Transactions on Wireless Communications*, 2016, 15(8): 5527-5540.
- [8] Guo C T, Liang L, Li G Y. Resource allocation for low-latency vehicular communications: an effective capacity perspective[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(4): 905-917.
- [9] She C Y, Duan Y F, Zhao G D, et al. Cross-layer design for mission-critical IoT in mobile edge computing systems[J]. *IEEE Internet of Things Journal*, 2019, 6(6): 9360-9374.
- [10] Shi Y M, Zhou Y, Wen D Z, et al. Task-oriented communications for 6G: vision, principles, and technologies[J]. *IEEE Wireless Communications*, 2023, 30(3): 78-85.
- [11] Yuan Y F, Zhuo X X, Liu M Y, et al. A centralized cross-layer protocol for joint power control, link scheduling, and routing in UWSNs[J]. *IEEE Internet of Things Journal*, 2024, 11(7): 12823-12833.
- [12] Hu S L, Chen W. Joint lossy compression and power allocation in low latency wireless communications for IIoT: a cross-layer approach[J]. *IEEE Transactions on Communications*, 2021, 69(8): 5106-5120.
- [13] Li K, Zhu P C, Wang Y, et al. Cross-layer resource allocation for URLLC industrial automation over multi-connectivity[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(7): 7334-7348.
- [14] Yuan J, Zhou H, Liang Y C. A two-timescale resource allocation scheme for RIS-aided cognitive radio systems[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2026, 12: 115-127.
- [15] Hu Z F, Han C, Wang X D. Deep reinforcement learning based cross-layer design in terahertz mesh backhaul networks[J]. *IEEE/ACM Transactions on Networking*, 2024, 32(3): 2159-2173.
- [16] Wu C, Lu H C, Chen Y A, et al. Cross-layer optimization for statistical QoS provision in C-RAN with finite-length coding[J]. *IEEE Transactions on Communications*, 2024, 72(6): 3393-3407.
- [17] He S W, An Z Y, Zhu J Y, et al. Cross-layer optimization: joint user scheduling and beamforming design with QoS support in joint transmission networks[J]. *IEEE Transactions on Communications*, 2023, 71(2): 792-807.
- [18] She C Y, Yang C Y, Quek T Q S. Cross-layer optimization for ultra-reliable and low-latency radio access networks[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(1): 127-141.
- [19] Hu Y L, Ozmen M, Gursoy M C, et al. Optimal power allocation for QoS-constrained downlink multi-user networks in the finite block-length regime[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(9): 5827-5840.
- [20] Wang Z, Bi T, Zhang Y, et al. Frame-level cross-layer power optimization for uplink wireless low-latency streaming[J]. *IEEE Transactions on Wireless Communications*, 2026, 25: 5110-5126.
- [21] Zhang J X, Xu X D, Zhang K J, et al. Learning-based flexible cross-layer optimization for ultrareliable and low-latency applications in IoT scenarios[J]. *IEEE Internet of Things Journal*, 2022, 9(16): 14629-14643.
- [22] Lu X Z, Xiao L, Li P M, et al. Reinforcement learning-based physical cross-layer security and privacy in 6G[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(1): 425-466.
- [23] Zhao H Q, Si J B, Li Z, et al. A multi-timescale cross-layer anti-jamming scheme under rule guidance[J]. *IEEE Communications Letters*, 2025, 29(2): 259-263.
- [24] Bing Z S, Meschede C, Röhrbein F, et al. A survey of robotics control based on learning-inspired spiking neural networks[J]. *Frontiers in Neurobotics*, 2018, 12: 35.
- [25] 朱祥维, 沈丹, 肖凯, 等. 类脑导航的机理、算法、实现与展望[J]. *航空学报*, 2023, 44(19): 1-33.  
Zhu X W, Shen D, Xiao K, et al. Mechanisms, algorithms, implementation and perspectives of brain-inspired navigation[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(19): 1-33.
- [26] Bergamaschi Ganapini M, Campbell M, Fabiano F, et al. Fast, slow, and metacognitive thinking in AI[J]. *npj Artificial Intelligence*, 2025, 1: 27.

- [27] Wu Q H, Li J H, Zhou F H, et al. Cognitive embodied learning for anomaly active target tracking[J]. *Communications Engineering*, 2025, 4: 224.
- [28] 武刚, 崔琪楣, 刘凡, 等. 6G 通信感知一体化技术专题简介[J]. *中国科学: 信息科学*, 2025, 55(5): 1253-1254.  
Wu G, Cui Q M, Liu F, et al. Special topic: integrated sensing and communications techniques for 6G[J]. *Scientia Sinica (Informationis)*, 2025, 55(5): 1253-1254.
- [29] Dong X B, Yu Z W, Cao W M, et al. A survey on ensemble learning[J]. *Frontiers of Computer Science*, 2020, 14(2): 241-258.
- [30] Gou J P, Yu B S, Maybank S J, et al. Knowledge distillation: a survey[J]. *International Journal of Computer Vision*, 2021, 129(6): 1789-1819.
- [31] Luo X W, Chen H H, Guo Q. Semantic communications: overview, open issues, and future research directions[J]. *IEEE Wireless Communications*, 2022, 29(1): 210-219.
- [32] Qiu K H, Bakirtzis S, Wassell I, et al. Large language model-based wireless network design[J]. *IEEE Wireless Communications Letters*, 2024, 13(12): 3340-3344.
- [33] 郭祥鑫, 林璟翎, 贾世杰, 等. 针对大语言模型生成的密码应用代码安全性分析[J]. *信息网络安全*, 2024, 24(6): 917-925.  
GUO X X, LIN J Q, JIA S J, et al. Security analysis of cryptographic application code generated by large language model[J]. *Netinfo Security*, 2024, 24(6): 917-925.
- [34] 王军, 曹雷, 陈希亮, 等. 多智能体博弈强化学习研究综述[J]. *计算机工程与应用*, 2021, 57(21): 1-13.  
Wang J, Cao L, Chen X L, et al. Overview on reinforcement learning of multi-agent game[J]. *Computer Engineering and Applications*, 2021, 57(21): 1-13.
- [35] Yuan H C, Chen J, Jiao Y T, et al. DRL-based cross-layer design for PHY scheduling and congestion control in anti-jamming communications[C]//*Proceedings of the GLOBECOM 2024 -2024 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2025: 3164-3169.
- [36] Liu S Y, Xu Y H, Li G X, et al. Multidimensional resource management for distributed MEC networks in jamming environment: a hierarchical DRL approach[J]. *IEEE Internet of Things Journal*, 2024, 11(9): 16859-16872.
- [37] Fan Z, Su R, Zhang W, et al. Hybrid actor-critic reinforcement learning in parameterized action space[J]. *arXiv Preprint*, arXiv: 1903. 01344, 2019.

## [作者简介]



钟天尧 (1998-), 男, 四川中江人, 陆军工程大学博士生, 主要研究方向为无人机通信、资源分配和博弈理论等。



姚欢 (2000-), 女, 江西南昌人, 陆军工程大学博士生, 主要研究方向为无线通信系统优化。



冯智斌 (1995-), 男, 河南平顶山人, 博士, 陆军工程大学讲师, 主要研究方向为无线通信对抗、无人集群通信等。



郑学强 (1981-), 男, 山东阳谷人, 博士, 陆军工程大学副教授, 主要研究方向为移动通信、认知无线电技术、频谱感知技术等。



徐煜华 (1983-), 男, 贵州毕节人, 博士, 陆军工程大学教授、博士生导师, 主要研究方向为机会频谱接入、智能抗干扰通信以及智能无人集群系统等。



徐逸凡 (1995-), 男, 湖南永州人, 博士, 陆军工程大学副教授, 主要研究方向为智能通信抗干扰、无人系统通信网络等。



陈瑾 (1971-), 女, 福建福州人, 博士, 陆军工程大学教授、博士生导师, 主要研究方向为无线通信网络和认知无线网络。