

意图驱动的物联网双时间尺度资源分配方法

宋航¹, 才建¹, 袁运栋¹, 张宇¹, 刘锐¹, 王见素¹, 刘刚¹, 张敏², 王敬宇²

(1. 中油国际管道公司, 北京 102200; 2. 北京邮电大学网络与交换技术国家重点实验室, 北京 100876)

摘要: 随着物联网技术的发展, 不同业务场景对服务质量的需求日趋多样化。当前, 如何精准解析物联网业务需求、有效保障差异化业务场景的服务质量, 仍是行业面临的巨大挑战。针对这一挑战, 亟待深入研究意图驱动的物联网资源分配机制。物联网环境具有动态复杂性, 且业务需求存在显著差异, 传统需求解析方式难以实现用户意图到物联网策略的精准映射。为此, 提出一种意图驱动的双时间尺度资源分配方法。首先, 根据业务服务质量需求对场景进行分类, 并设计基于大规模语言模型与检索增强的意图转译算法, 结合设备及业务信息, 将用户意图转译为可执行的物联网策略。其次, 面向资源分配效率与物联网动态状态变化, 构建以最大化系统整体收益为优化目标的双时间尺度资源分配框架。该框架包括: 在长时间尺度下, 采用竞争双深度 Q 网络算法对切片间资源进行全局分配; 在短时间尺度下, 通过混合整数线性规划算法对切片内业务细粒度资源进行调配。实验结果表明, 所提方法通过融合意图转译算法实现了上层策略精准生成, 并结合资源分配算法实现下层资源的弹性调度。相较于单一时间尺度的算法, 该方法能够进行更高效且贴合下游物联网状态的资源分配, 进而保障同一物联网中不同业务场景的差异化服务质量。

关键词: 资源分配; 自智网络; 意图驱动网络; 深度强化学习

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2026.00501

Intent-driven dual-time-scale resource allocation approach for Internet of things

Song Hang¹, Cai Jian¹, Yuan Yundong¹, Zhang Yu¹, Liu Rui¹, Wang Jiansu¹, Liu Gang¹,
Zhang Min², Wang Jingyu²

1. SINO-PIPELINE International Company, Beijing 102200, China

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

Abstract: With the development of IoT technologies, the demand for quality of service across different business scenarios has become increasingly diverse. Currently, how to accurately interpret IoT service requirements and effectively guarantee quality of service (QoS) for differentiated business scenarios remains a significant challenge in the industry. To address this challenge, in-depth research on intent-driven IoT resource allocation mechanisms is urgently needed. Given the dynamic and complex nature of IoT environments, along with the notable differences in service requirements, traditional demand interpretation methods are found to be inadequate for achieving accurate mapping from user intents to IoT policies. Therefore, an intent-driven dual-time-scale resource allocation method was proposed. Firstly, scenarios were catego-

收稿日期: 2025-04-09; 修回日期: 2025-06-09

通信作者: 王敬宇, wangjingyu@bupt.edu.cn

基金项目: 国家自然科学基金项目 (No. 62471055, No. U23B2001, No. 62071067); 教育部-中国移动科研基金项目 (No. MCM20200202, No. MCM20180101)

Foundation Items: The National Natural Science Foundation of China (No. 62471055, No. U23B2001, No. 62071067), Ministry of Education-China Mobile Research Fund Project (No. MCM20200202, No. MCM20180101)

rized based on their QoS requirements, and an intent translation algorithm based on a large language model with retrieval enhancement was designed. By integrating device and service information, user intents were translated into executable IoT policies. Secondly, focusing on both resource allocation efficiency and the dynamic state changes in IoT environments, a dual-time-scale resource allocation framework was constructed with the optimization objective of maximizing the overall system revenue. This framework included: at the long time scale, the dueling double deep Q-network (D3QN) algorithm was adopted for global resource allocation among slices; at the short time scale, the mixed-integer linear programming (MILP) algorithm was employed for fine-grained resource scheduling within slices. Experimental results demonstrated that the proposed method enabled accurate generation of upper-level policies through intent translation and achieved elastic scheduling of lower-level resources via the resource allocation algorithms. Compared with single-time-scale algorithms, the proposed approach allowed for more efficient resource allocation that better adapted to the state of downstream IoT systems, thereby ensuring differentiated QoS for various business scenarios within the same IoT environment.

Key words: resource allocation, autonomous network, intent-driven network, deep reinforcement learning

0 引言

随着物联网技术的蓬勃发展，业务复杂度呈现指数级增长态势。各垂直行业对服务质量（QoS, quality of service）的差异化需求，催生了多维度的性能指标体系^[1]。相较于5G定义的三大基础场景，即增强型移动宽带（eMBB, enhanced mobile broadband）、超可靠低时延通信（uRLLC, ultra-reliable low latency communications）和海量机器类通信（mMTC, massive machine type communications）^[2]，当前物联网领域进一步演化出三大交叉场景：支持超高清流媒体实时传输的大规模eMBB（meMBB, massive eMBB）、兼具高吞吐量与高可靠性的移动宽带可靠低时延通信（MBRLLC, mobile broadband reliable and low latency communication），以及面向大规模物联网设备接入的增强型uRLLC（muRLLC, massive uRLLC）^[3-4]。

实现差异化业务场景的按需服务质量保障，已成为当前物联网研究的核心课题。当前研究聚焦于自智网络架构^[5]。该架构依托意图驱动的网络切片技术实现智能化资源管理，其中自智网络通过实现“三零三自”，即零等待、零接触、零故障、自服务、自发放和自保障，将整个网络自动化、智能化，从而为用户提供更好的服务体验^[6-8]。目前，自智网络仍面临诸多挑战：一是缺乏能够将用户意图精准映射为具体资源划分策略并下发到网络的框架^[9]；二是缺乏高效、细粒度的动态资源分配方法。

对此，本文主要从基于大语言模型的意图转译和双时间尺度的资源分配机制两个方面展开研究。

相较于预训练语言模型（PLM, pre-trained lan-

guage model），大语言模型（LLM, large language model）参数量更大、训练数据集更丰富且整体计算能力更强。凭借其千亿级参数量、多任务适应能力及代码生成优势，LLM为从自然语言到网络配置的意图转译提供了新的技术范式^[10-13]。意图在此上下文中可定义为面向网络服务的高级抽象描述及其相关属性，其更加注重网络服务的预期结果^[14]。意图转译的核心任务是从用户输入中识别意图实体，并根据网络实时状态将其转换为可执行的网络配置^[15-18]。现有研究多采用直接映射方式，将业务意图转化为具体的网络配置策略。然而，直接映射方式存在明显局限：受限于业务场景的多样性，其网络策略描述能力不足；基础指标的可变空间有限；映射过程与业务上下文脱节，难以适应动态网络环境。这些因素共同制约了网络策略效益的预期上限。例如，传统规则匹配算法在面对“高清视频会议”业务时，仅能生成基础带宽配置，无法根据视频分辨率等动态调整参数；而PLM在处理“物理网设备低功耗远程监控”业务时，难以准确捕捉数据压缩比等深层业务需求。

李凤凯等^[19]提出一种名为NEMO的声明式网络编程与业务定制语言，通过基于领域特定语言（DSL, domain specific language）^[20]的抽象网络模型，为用户提供了一个相对易于使用的软件定义网络北向接口。该语言允许用户仅输入少量关键词即可将业务策略转译为网络策略，但难以在复杂场景下有效提取用户意图。JinJing系统^[21]专注于设备访问控制列表管理，基于DSL设计了意图语言。然而，上述方法均无法直接处理自然语言等非结构化输入。针对这一问题，Jacobs等^[22]提出Nile语言，

即先利用序列标注技术挖掘意图实体，再利用 Seq2Seq 模型生成一种填充好的结构化命令模板，最后根据命令模板中的各个属性生成策略集合。该语言可增强交互性，但其性能受限于特定网络场景的标注数据。文献[23]提出的 CONFPILOT 框架通过语义解析生成配置策略，但存在策略生成与下游网络资源解耦的问题。Khan 等^[24]提出了一种基于对抗生成网络的仿真策略生成与深度强化学习优化选择的意图转译机制，但未考虑下游网络状态。本文创新性地引入检索增强生成 (RAG, retrieval-augmented generation) 算法，通过构建网络知识库来增强 LLM 的领域适应性，有效缓解模型的幻觉问题^[25-26]，从而提升配置策略的准确性和可解释性。

随着当前物联网向多业务交叉场景演进，差异化 QoS 约束下的资源分配问题面临全新挑战。基于前文定义的六类业务场景，其 QoS 指标呈现显著异质性：uRLLC 与 muRLLC 需满足工业物联网等场景的亚毫秒级时延与高可靠性；eMBB 类业务则需要保障高带宽资源。为应对此类多维需求，网络切片技术借助网络功能虚拟化 (NFV, network functions virtualization) 技术^[27]，构建相互隔离的逻辑网络实例，实现物理资源的灵活切分与按需供给^[28-29]。然而，多切片共存场景下的动态资源管理仍存在以下核心难题：如何基于实时物联网状态（如剩余带宽等），在满足各切片差异化 QoS 约束的前提下实现资源最优配置。

当前资源分配策略主要围绕深度强化学习 (DRL, deep reinforcement learning) 和数学优化方法^[30-32]两类方法论展开。Dong 等^[33]提出一种图卷积网络驱动的多任务 DRL 框架，用于处理多用户场景下的网络切片资源分配和路由选择问题，但该方法在网络状态不稳定时性能较差。Leconte 等^[34]设计了一种基于乘法器交替方向法的分布式网络切片资源分配算法，该算法的重点是平衡资源分配和路由选择。元伟敬等^[35]针对软件定义多模态车联网提出了一种双时间尺度的无线接入网切片资源分配算法，在满足不同切片用户服务质量需求的同时提高频谱利用率，但其静态策略难以响应动态网络条件变化。陈赓等^[36]面向 B5G 多业务场景，提出一种基于竞争双深度 Q 网络的双时间尺度网络切片算法，在保障差异化 QoS 方面取得进展，但该研究未对业务特性进行深入分析。郭令奇等^[37]提出一种结合全

场景适用的意图转译与网络切片框架，该框架能够提高网络资源的整体利用率，并感知下游网络状态的变化，但未考虑到资源分配的时效性。针对现有研究在状态感知完备性与决策时效性间的平衡缺陷，本文创新性地提出一种双时间尺度协同优化算法来解决这一问题。

现有方法在意图到底层指标的映射精度、资源分配粒度与动态调整敏捷性的平衡上仍面临显著挑战。为应对这一挑战，本文创新性地提出一种意图驱动的双时间尺度资源分配方法，将用户意图映射为物联网策略，并结合下游物联网状态，对物联网中不同类型的业务进行快速资源分配与动态调整。其核心贡献在于：

1) 提出一种意图驱动的双时间尺度资源分配方法，该方法利用 LLM 进行意图转译，并融合双时间尺度的算法实现高效资源调度；

2) 构建一种 LLM 到 RAG 协同的意图转译算法，通过知识检索约束生成空间，实现对业务需求更精准的分析，提升物联网配置策略的可行性；

3) 设计一种双时间尺度的资源分配机制。在长时间尺度内，采用 DRL 进行全局资源规划；在短时间尺度内，通过混合整数线性规划 (MILP, mixed-integer linear programming) 算法实现基于实时物联网状态的资源微调。该机制有效兼顾了策略的最优性与计算的时效性。

1 意图驱动的双时间尺度资源分配方法

本节分为 3 小节，在第 1 小节中主要介绍意图驱动的双时间尺度资源分配方法，在第 2 小节中介绍如何利用 LLM 并结合设备及业务信息来完成意图转译工作，在第 3 小节中介绍提出的基于双时间尺度的资源分配算法。

1.1 意图驱动的双时间尺度资源分配方法

本文提出的意图驱动的双时间尺度资源分配方法主要包括两个部分：基于 LLM 的意图转译算法和基于双时间尺度的资源分配算法。在意图转译算法中，系统采用自然语言交互界面，允许用户以非结构化语言表达需求。结合 LLM 的语义理解能力和 RAG 技术，系统能够进行多维度的意图解析，最终生成相应的物联网策略并下发到下游物联网系统。资源分配算法采用一种创新的双时间尺度协同机制，以有效平衡资源优化的全局性和实时性需

求。在长时间尺度内，部署基于DRL的全局优化模型，通过离线训练获得的策略实现全网资源的初始最优配置；在短时间尺度上，则采用MILP模型进行实时微调。两个时间尺度的协同优化，确保了系统在动态环境下的运行稳定性和资源利用效率。意图驱动的双时间尺度资源分配方法架构图如图1所示。

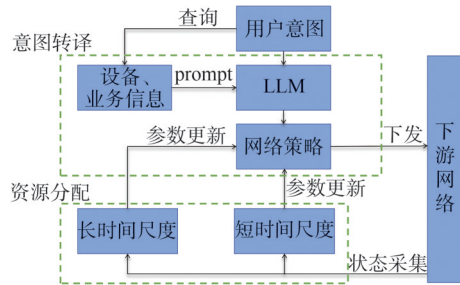


图1 意图驱动的双时间尺度资源分配方法架构

1.2 基于LLM的意图转译算法

在采用LLM的检索增强意图转译算法中，系统充分利用LLM在上下文语义理解方面的卓越性能，通过构建模型推理机制，将用户以自然语言表达的意图精准转译为可执行的物联网策略。用户输入自然语言意图后，首先经由领域适配模块对基础GPT-3模型进行微调，该过程基于文献[38]提出的双阶段训练策略实现。第一阶段利用人工标注的意图-模板配对数据，采用动态掩码注意力机制和分层损失函数，使模型学习领域语义特征；第二阶段引入强化学习机制，结合模板结构约束和语义连贯性指标，进一步提升策略生成质量。最终，微调后的GPT-3模型能够将自然语言映射为意图模板，并通过上下文感知填充算法动态补充缺失参数。

值得注意的是，在意图转译过程中需考虑外部设备与业务信息等约束条件，包括但不限于参数阈值范围、取值类型等，这些约束条件直接影响策略生成的准确性。为此，本算法创新性地引入RAG技术，通过构建设备与业务知识库的实时检索机制，有效提取关键参数约束信息，从而显著提升LLM生成物联网策略的合规性与准确性。在检索阶段，算法通过训练一个索引生成器实现高效检索，具体实现方法可参考文献[39]。

RAG技术通过有机整合外部知识检索与生成模型的运算过程，构建了一种动态增强的上下文理解环境。其工作流程主要包含两个核心阶段：首

先，基于用户意图进行多维度知识检索，将检索所得的参数约束转化为结构化的提示符，用以辅助LLM生成更加准确的物联网策略。以典型业务场景为例，当用户提出“在爱奇艺平台观看原画画质直播”这一需求时，RAG通过查询外部知识库，可生成包含“该业务属于时延敏感型业务，需保障带宽稳定性以保证用户体验”等关键参数的提示内容，而此类提示符可作为增强LLM生成内容的上下文基础。

基于LLM的检索增强意图转译算法的整体流程如下：用户首先以自然语言形式输入其意图；RAG模块结合用户意图与设备、业务知识库生成相关提示符；最终，LLM根据用户意图与相关提示符生成物联网策略，并将该物联网策略下发到下游物联网。

1.3 基于双时间尺度的资源分配算法

1.3.1 双时间尺度的资源分配

面向多业务场景的差异化服务需求，在用户意图经过前述基于LLM的检索增强意图转译算法处理后，系统将生成物联网策略并下发到下游物联网设备。此后，由本小节提出的动态资源分配机制对策略参数进行自适应更新。相较于单一时间尺度的资源分配方法，本文提出的算法同时兼顾资源分配效率与物联网状态波动，在长时间尺度上进行协同优化。长时间尺度指持续时间较长的资源编排间隔，在每个间隔开始时进行切片间资源分配决策，该决策在此期间保持不变，本文使用DRL算法进行长时间尺度内的全局资源调度；短时间尺度指在长时间尺度间隔内、频次更高的资源重配置周期，通过动态调整切片内各业务的资源，本文在短时间尺度内，基于实时物联网状态，采用MILP算法进行切片级资源的在线微调。基于双时间尺度的资源分配算法的整体框架如图2所示。首先，针对长时间尺度的跨切片资源分配，采用基于竞争双深度Q网络(D3QN, dueling double deep Q-network)算法实现切片间资源优化；其次，在短时间尺度层面，采用MILP方法结合实时物联网状态，实现切片内业务级资源的敏捷调整，从而有效提升业务的QoS。在建模方面，本文构建了六种典型业务场景，并以系统整体收益最大化为目标，建立相应的复杂优化问题。

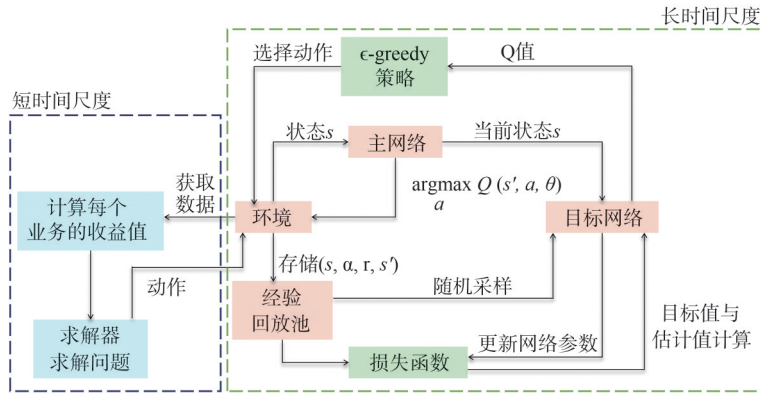


图2 基于双时间尺度的资源分配算法的整体框架

1.3.2 长时间尺度的资源分配

本文构建的基于深度强化学习的动态分配框架，通过马尔可夫决策过程（MDP, Markov decision process）实现物联网资源的全局分配。当新业务请求到达系统时，DRL代理基于当前物联网状态实施全局粗粒度资源分配，其决策过程严格遵循状态转移的马尔可夫特性，即下一时刻的物联网状态仅由当前状态与动作联合决定。该过程可形式化为一个三元组 (S, A, R) ，其中 S 是智能体所有状态组成的环境状态空间； A 是智能体所有可能选择的动作集合； R 是奖励函数，用来量化资源分配方案对服务级别协议（SLA, service level agreement）满意率等的影响。在每个决策时隙，智能体通过策略网络生成动作的概率分布，继而从环境中获得即时奖励并观测转移后的新网络状态。

在本文中，将同一业务场景下的所有业务视为一个物联网切片。在长时间尺度的建模中，有如下定义：状态空间由分配给各切片的带宽资源和计算资源共同定义。在第 k 个时隙，状态空间表示为：

$$S^k = S_B^k \cup S_C^k \quad (1)$$

其中， $S_B^k = \{S_B^{k1}, S_B^{k2}, \dots, S_B^{k6}\}$ ， S_B^{ki} 为第 k 个时隙分配给切片 i 的带宽资源；类似地， $S_C^k = \{S_C^{k1}, S_C^{k2}, \dots, S_C^{k6}\}$ ， S_C^{ki} 为第 k 个时隙分配给切片 i 的计算资源。其中 $i \in [1, 6]$ 。

在长时间尺度内，对切片间的带宽资源与计算资源进行分配。动作空间可表示为：

$$A_L = \{A_B, A_C\} \quad (2)$$

其中， $A_B = \{\Phi_B^1, \Phi_B^2, \dots, \Phi_B^6\}$ ， Φ_B^i 为在长时间尺度内分配给切片 i 的带宽资源比例，满足 $\Phi_B^1 + \Phi_B^2 + \dots + \Phi_B^6 \leq 1$ ；类似地， $A_C = \{\Phi_C^1, \Phi_C^2, \dots, \Phi_C^6\}$ ， Φ_C^i 为在长时间尺度内分配给切片 i 的计算资源比例，

满足 $\Phi_C^1 + \Phi_C^2 + \dots + \Phi_C^6 \leq 1$ 。其中 $i \in [1, 6]$ 。

长时间尺度的优化目标是最大化六种切片的整体收益。奖励函数考虑各切片带宽资源与计算资源的满足情况，切片 i 的奖励函数表示为：

$$R_i = \alpha_i(\Phi_B^i \times B_{\text{sum}} - N_B^i) = \beta_i(\Phi_C^i \times C_{\text{sum}} - N_C^i) \quad (3)$$

其中， α_i 和 β_i 分别为切片 i 带宽资源和计算资源的重要性系数， B_{sum} 和 C_{sum} 分别为总的带宽资源和总的计算资源， N_B^i 和 N_C^i 分别为切片 i 需要的带宽资源和计算资源。长时间尺度的优化目标表示为：

$$\max \{R_1 + \dots + R_6\} \quad (4)$$

其中， R_i 为切片 i 的奖励值，满足 $R_i \geq 0$ 。

本文使用D3QN算法作为长时间尺度的资源分配算法，其架构融合双深度Q网络（DDQN, double DQN）与竞争深度Q网络（Dueling DQN）的双重优势。首先，Dueling DQN通过解耦状态价值函数与动作优势函数的评估，能够更精准地刻画不同资源分配策略的价值差异；其次，针对传统DQN存在Q值过高估计的问题，DDQN通过主网络选择最优动作、目标网络进行价值估计，有效抑制了Q值估计偏差的累积。在算法实现中，构建了双重网络体系：主网络通过经验回放机制实时更新参数 θ ；目标网络采用延迟更新策略，以降低Q值估计的方差。DQN网络的参数更新是通过梯度下降法计算损失函数的梯度来完成的。其中， $Q(s, a; \theta)$ 为主网络的Q值函数，表示智能体在状态 s 下执行动作 a 时，由主网络参数 θ 刻画的动作价值估计。损失函数 $L(\theta)$ 的数学式可表示为：

$$L(\theta) = E \left[r + \gamma Q \left(s', \arg \max_a Q(s, a; \theta); \theta' \right) - Q(s, a; \theta)^2 \right] \quad (5)$$

长时间尺度下，基于D3QN算法进行切片间资

源分配。首先，初始化主网络与目标网络参数，并定义动作空间与经验回放池。智能体通过与环境交互获取初始网络状态。在训练过程中，采用 ε -greedy策略选择动作。每次动作执行后，系统观测奖励信号及转移后的新状态，并将状态转移四元组存储至经验池。随后，通过随机采样从经验池中抽取批次数据，基于主网络和目标网络的输出计算损失函数，进而进行反向传播来更新网络参数，该过程循环迭代，直至训练完成。通过不断循环以上过程，最终获得最优资源分配策略。其过程如算法1所示。

算法1 基于D3QN的长时间尺度资源分配算法

输入：经验回放池 D ，批度大小 B ，预训练步数 P ，参数 ε ，折扣系数 γ ，学习率 α ，训练总步数 T

输出：带宽与计算资源分配策略

1) 初始化主网络参数 θ ，目标网络参数 θ' ，并将 θ 赋值给 θ' ；定义动作集合 A ；初始化经验回放池 D ；设置训练步数 $i=0$

2) 从初始化网络环境中获取网络状态 s

3) **While** $i \leq T$ **do**

 根据 ε -greedy策略选择动作 a

 执行动作 a ，得到奖励值 r 和新的网络状态 s'

 将四元组 $\langle s, a, r, s' \rangle$ 添加至经验回放池 D

 定义当前网络状态 $s = s'$

$i=i+1$

 从经验池 D 中对样本进行随机抽样

 计算损失函数 $L(\theta)$

 采用梯度下降法更新主网络参数 θ

 以较低的速率更新目标网络参数 θ'

 更新参数 ε 的值

end if

1.3.3 短时间尺度的资源分配

为根据采集到的物联网状态和当前的物联网策略对资源分配策略进行快速、细粒度的调整，本文使用MILP模型来实现短时间尺度的资源分配与调整。短时间尺度的状态空间与长时间尺度的状态空间一致，但在短时间尺度内，对切片 i 内业务的带宽资源与计算资源进行分配，其动作空间表示为：

$$A_s^i = \{K_b^i, K_c^i\} \quad (6)$$

假定切片 i 共有 n 个业务。 K_b^i 可以表示为： $K_b^i = \{K_b^{i1}, K_b^{i2}, \dots, K_b^{in}\}$ ，其中 K_b^{ij} 为分配给切片 i 内业务 j 的带宽资源，满足 $K_b^{i1} + K_b^{i2} + \dots + K_b^{in} \leq \Phi_b^i \times B_{\text{sum}}$ 。类似地， K_c^i 可以表示为： $K_c^i = \{K_c^{i1}, K_c^{i2}, \dots, K_c^{in}\}$ ，

其中 K_c^{ij} 为分配给切片 i 内业务 j 的计算资源，满足 $K_c^{i1} + K_c^{i2} + \dots + K_c^{in} \leq \Phi_c^i \times C_{\text{sum}}$ 。其中 $i \in [1, 6]$ ， $j \in [1, n]$ 。

短时间尺度的优化目标是最大化切片内部所有业务的总收益，其中奖励函数重点关注各业务时延指标被满足的情况。参照文献[37]中不同业务收益的计算方法，本文在收益函数中对时延敏感型业务（如uRLLC和muRLLC）与其他业务场景进行区分，从而构建差异化的建立机制。

针对uRLLC或muRLLC这类时延敏感型业务场景，奖励函数可以表示为：

$$R_j^i(x) = \begin{cases} 0, & 0 \leq x < 1 \\ 1, & x \geq 1 \end{cases} \quad (7)$$

其中， x 为SLA满意率； R_j^i 为切片 i 中业务 j 的奖励值。

针对其他业务场景，奖励函数可以表示为：

$$R_j^i(x) = \begin{cases} ux^2 + (1-u)x, & 0 \leq x < 1 \\ 1, & x \geq 1 \end{cases} \quad (8)$$

其中， u 为灵敏度，可以通过调整该参数来表示业务可以容忍的服务指标波动的范围， $u \in [0, 1]$ ； R_j^i 为切片 i 中业务 j 的奖励值。

若切片 i 为uRLLC或muRLLC类型切片，则根据式(8)计算其奖励；若切片 i 为其他业务场景对应的切片，则根据式(9)计算。短时间尺度的优化目标可以表示为：

$$\max \{R^1(x_1) + R^2(x_2) + \dots + R^n(x_n)\} \quad (9)$$

其中，假定切片 i 共有 n 个业务， x_j 为业务 j 的SLA满意率。

基于MILP的短时间切片内资源分配算法如算法2所示。

算法2 基于MILP的短时间尺度资源分配算法

输入：当前网络状态 s ；新到达业务所属切片类型

输出：该切片内所有业务的带宽与计算资源分配策略

根据剩余资源定义带宽与计算资源的可选参数数组
根据切片所属类型，结合式(7)和式(8)计算收益值
根据切片所属类型定义目标函数为式(9)

定义约束条件：切片内所有业务分配到的资源之和不超过该切片在长时间尺度分配到的资源比例所应对的资源总量；任一业务所分配到的资源 ≥ 0

使用MILP求解器进行求解

输出结果

2 仿真实验

2.1 仿真实验设置

本文针对物联网带宽与计算资源分配问题，提出一种基于双时间尺度的协同分配算法。该算法包含两个协同机制：在长时间尺度上，采用 D3QN 算法进行全局粗粒度的跨切片资源调度；在短时间尺度上，采用 MILP 模型对切片内业务级资源进行细粒度优化。

仿真实验基于 Python 平台实现，其中深度强化学习部分借助 Pytorch 框架实现。网络拓扑的构建参考经典数据中心网络架构模型及其参数配置原则：在小规模网络的仿真实验中，拓扑结构包含 24 个节点（9 个主机节点、15 个交换机节点）和 50 条通信链路；在大规模网络的仿真实验中，拓扑结构包含 100 个节点（37 个主机节点、63 个交换机节点）和 180 条通信链路。其中，大规模网络中设置的节点数量参考文献[40]；主机与交换机比例（9：15 和 37：63）设置模拟云计算场景中边缘服务器与核心网络设备的典型部署密度^[41]；50 条链路及 180 条链路的连接关系通过广度优先算法生成，符合数据中心网络低时延通信需求^[42]。该拓扑设计的复杂度既能模拟多切片资源竞争场景，又能有效控制仿真计算复杂度。

设置长时间尺度的资源编排间隔为 30 min，该设置可从整体上对切片间资源进行合理规划，同时避免因频繁调整造成的资源浪费^[43]；短时间尺度上的资源编排间隔为 5 min，以确保系统能够及时响应物联网状态的动态变化。

在长时间尺度层面，D3QN 算法包含两个全连接隐藏层，每层分别有 128 和 256 个神经元；选择 ReLU 作为激活函数；优化器选用 Adam；学习率设定为 0.01；目标网络参数每 500 步进行一次同步更新，折扣因子设置为 0.9。每次学习时从经验回放池中随机抽取样本的批量大小和经验回放池大小分别为 512 和 1 000。探索策略采用 ϵ -greedy 算法，设置最小探索概率的下限为 0.01，以避免随机探索完全消失，衰减系数设置为 0.999 8。本文参考文献[44]的差异化权重方法，通过引入切片重要性系数构建多维奖励函数。

在短时间尺度层面，采用 MILP 算法实现切片

内多维资源的动态适配。模型通过精确约束条件刻画不同资源间的耦合关系，并基于分支定界算法求解最优资源分配方案。该算法的核心步骤包括：分支，即将问题分解为子问题；定界，即计算子问题的目标函数上下界，并根据界值信息对无效分支进行剪枝。通过系统枚举潜在解空间，并利用上下界信息有效剪枝，算法能够高效缩小搜索空间，最终求得资源分配的最优解。

2.2 仿真结果分析

为全面评估本文提出的基于双时间尺度资源分配算法的性能，设计了 3 组对比实验，分别用于验证：与传统单一时间尺度方法相比，双时间尺度协同机制在资源分配方面的优势；短时间尺度上，使用 MILP 算法在资源分配求解速度上的优势；相较于其他 DRL 算法，本文在长时间尺度所使用的 D3QN 算法的优势。

(1) 为验证双时间尺度协同机制的性能优势，分别对比了不同算法在小规模与大规模网络中系统整体收益随训练迭代次数的变化情况。在小规模网络和大规模网络中，基于双时间尺度算法与单一时间尺度算法（单一长时间 D3QN 算法与单一短时间 MILP 算法）的收益变化曲线分别如图 3、图 4 所示。其中，MILP 算法中的迭代对应分支界定过程中对节点的搜索次数；各类切片的收益值由式(3)计算得到。分析图 3、图 4 可知：当迭代次数达到 500 次时，在小规模网络中，本文提出的基于双时间尺度资源分配算法的整体收益较单一使用 D3QN 算法和单一使用 MILP 算法分别提升 23.6% 和 46.9%；在大规模网络中，使用本文提出的资源分配算法的整体收益较单一使用 D3QN 算法和单一使用 MILP 算法分别提升 55% 和 41.2%。这一性能的提升主要源于双时间尺度的协同优化机制：长时间尺度通过 D3QN 实现跨切片间资源的全局调度，短时间尺度借助 MILP 完成切片内细粒度的动态调整。实验结果表明，本文所提双时间尺度的资源分配机制能够有效克服单一时间尺度带来的局部最优问题，从而显著提升系统整体收益。

(2) 为验证短时间尺度使用 MILP 算法在资源分配速度方面的优势，在不同网络规模下对比了使用短时间尺度 MILP 算法与使用长时间尺度 D3QN 算法的响应时间，结果见表 1。根据表 1 数据分析可知：在不同网络规模下，短时间尺度使用 MILP

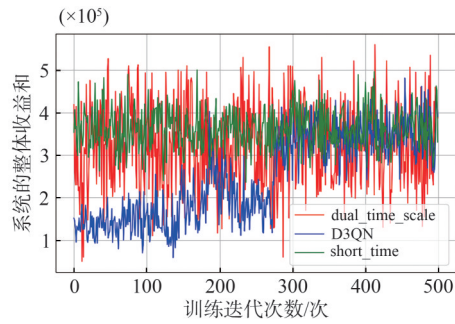


图3 小规模网络中单时间尺度与双时间尺度算法的收益变化曲线

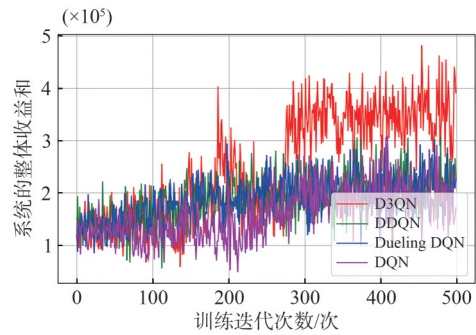


图5 4种DRL算法在系统整体收益上的对比




图4 大规模网络中单时间尺度与双时间尺度算法的收益变化曲线

表1 不同网络规模下两种算法的响应时间对比

网络规模	网络节点数量	短时间尺度 响应时间/ms	长时间尺度 响应时间/ms
小规模	50	5.2	18.7
中规模	200	22.4	120.3
大规模	1 000	180.5	320.6

算法的响应时间较长时间尺度使用D3QN算法平均缩短65.7%。相较于D3QN算法，MILP算法通过定向搜索与解空间压缩，展现出显著速度优势。

(3) 为验证在长时间尺度中使用D3QN算法相较于其他DRL方法的优势，本文将其与DQN、DDQN、Dueling DQN 3种代表性DRL算法进行对比。随着训练迭代次数的变化，4种DRL算法在系统整体收益上的对比如图5所示。实验结果表明：D3QN算法达到稳定收益值的收敛速度较DQN、DDQN、Dueling DQN分别提升33.3%、25%和14.3%，且最终稳定收益值较次优的Dueling DQN提高5%。D3QN通过集成Dueling架构的状态价值分解机制与双Q网络的目标值估计策略，有效降低Q值过高估计偏差，从而在切片间带宽与资源分配场景中展现出更强的策略稳定性。基于该性能测试结果，可证实D3QN算法在长时间尺度资源分配场景中具有显著的稳定性和优化能力。

3 结束语

本文聚焦6G多业务场景下的资源分配问题，创新性提出一种基于意图驱动的双时间尺度资源分配方法。该方法在保证业务QoS需求的前提下，以最大化系统收益为优化目标，构建了“意图转译、资源分配”的一体化流程。具体而言，基于LLM与检索增强设计意图转译算法，结合设备状态及业务信息，将用户意图精准映射为可执行的物联网策略；然后，采用双时间尺度资源分配框架动态优化网络配置。该框架在长时间尺度内，采用基于D3QN的智能体实现切片间资源的全局动态规划；在短时间尺度内，构建MILP模型，根据实时物联网状态进行切片内资源细粒度调整。仿真实验结果表明，相较于传统单一时间尺度方法，本文所提算法在最大化系统整体收益与收敛速度方面具有更好的性能表现，能够有效兼顾多业务服务质量保障与资源效率的平衡。本文虽已覆盖eMBB、uRLLC等6G典型业务场景，但随着物联网服务向触觉互联网等新兴领域扩展，未来需进一步探索面向差异化服务需求的高动态资源适配机制。

参考文献：

- [1] Cheng N, Lyu F, Quan W, et al. Space/aerial-assisted computing offloading for IoT applications: a learning-based approach[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(5): 1117-1129.
- [2] Maule M, Vardakas J, Verikoukis C. 5G RAN slicing: dynamic single tenant radio resource orchestration for eMBB traffic within a multi-slice scenario[J]. IEEE Communications Magazine, 2021, 59(3): 110-116.
- [3] Wang C X, You X H, Gao X Q, et al. On the road to 6G: visions, requirements, key technologies, and testbeds[J]. IEEE Communications Surveys & Tutorials, 2023, 25(2): 905-974.

- [4] Latva-Aho M, Leppänen K. Key drivers and research challenges for 6G ubiquitous wireless intelligence[R]. 2019.
- [5] TM Forum. Autonomous networks: empowering digital transformation for telecoms industry[R]. 2019.
- [6] De Alwis C, Kumar P, Pham Q V, et al. Towards 6G: key technological directions[J]. *ICT Express*, 2023, 9(4): 525-533.
- [7] Boasman-Patel A R E, Sun D, Wang Y, et al. Autonomous networks: empowering digital transformation for the telecoms industry[R]. 2019.
- [8] Beshley M, Kryvinska N, Beshley H. Quality of service management method in a heterogeneous wireless network using big data technology and mobile QoE application[J]. *Simulation Modelling Practice and Theory*, 2023, 127: 102771.
- [9] Khurana D, Koli A, Khatter K, et al. Natural language processing: state of the art, current trends and challenges[J]. *Multimedia tools and applications*, 2023, 82(3): 3713-3744.
- [10] Achiam J, Adler S, Agarwal S, et al. Gpt-4 technical report[PP]. V4, arXiv (2023-11-19)[2025-06-09]. arXiv: 2303.08774.
- [11] Min B, Ross H, Sulem E, et al. Recent advances in natural language processing via large pre-trained language models: a survey[J]. *ACM Computing Surveys*, 2023, 56(2): 1-40.
- [12] Chen L J, Zaharia M, Zou J. How is ChatGPT's behavior changing over time [J]. *Harvard Data Science Review: Special Issue 5: Grappling With the Generative AI Revolution*, 2024, 6(2): 1-26.
- [13] Hu L M, Liu Z Y, Zhao Z W, et al. A survey of knowledge enhanced pre-trained language models[PP]. V4. arXiv(2023-8-30) [2025-06-09]. arXiv: 2211.05994.
- [14] Clemm A, Ciavaglia L, Granville L Z, et al. Intent-based networking-concepts and definitions:RFC 9315[EB]. 2022.
- [15] Velasco L, Signorelli M, De Dios O G, et al. End-to-end intent-based networking[J]. *IEEE communications Magazine*, 2021, 59(10): 106-112.
- [16] Leivadeas A, Falkner M. VNF placement problem: a multi-tenant intent-based networking approach[C]//*Proceedings of the 2021 24th Conference on innovation in clouds, internet and networks and workshops (ICIN)*. Piscataway: IEEE Press, 2021: 143-150.
- [17] Leivadeas A, Falkner M. A survey on Intent-based networking[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(1): 625-655.
- [18] Mcnamara J, Camps-Mur D, Goodarzi M, et al. Nlp powered Intent based network management for private 5G networks[J]. *IEEE Access*, 2023, 11: 36642-36657.
- [19] 李凤凯,张亚丽,夏寅寅. NEMO:一种声明式网络编程与业务定制语言[J]. *信息通信技术*, 2016, 10(4):65-74.
LI F K, Zhang Y L, XIA Y B. NEMO: a declarative network programming and service customization language[J]. *Information and Communications Technologies*, 2016, 10(4): 65-74.
- [20] Van Deursen A, Klint P. Domain-specific language design requires feature descriptions[J]. *Journal of Computing and Information Technology*, 2002, 10(1): 1-17.
- [21] Tian B C, Zhang X Y, Zhai E N, et al. Safely and automatically updating in-network ACL configurations with Intent language[C]//*Proceedings of the ACM Special Interest Group on Data Communication*. New York: ACM Press, 2019: 214-226.
- [22] Jacobs A S, Pfitscher R J, Ribeiro R H, et al. Hey, Lumi! Using natural language for Intent-based network management[C]//*Proceedings of the 2021 USENIX Annual Technical Conference*. 2021: 625-639.
- [23] Zhao J Y, Sun H F, Wang J Y, et al. CONFPILOT: a pilot for faster configuration by learning from device manuals[C]//*Proceedings of the 2023 IEEE 43rd International Conference on Distributed Computing Systems (ICDCS)*. Piscataway: IEEE Press, 2023: 108-119.
- [24] Khan T A, Abbas K, Muhammad A, et al. GAN and DRL based Intent translation and deep fake configuration generation for optimization[C]//*Proceedings of the 2020 International Conference on Information and Communication Technology Convergence (ICTC)*. Piscataway: IEEE Press, 2020: 347-352.
- [25] Ji Z W, Lee N, Frieske R, et al. Survey of hallucination in natural language generation[J]. *ACM Computing Surveys*, 2023, 55(12): 1-38.
- [26] Lin B H, Bouneffouf D, Cecchi G, et al. Towards healthy AI: large language models need therapists too[C]//*Proceedings of the 4th Workshop on Trustworthy Natural Language Processing (TrustNLP 2024)*. ACL Press, 2024:61-70.
- [27] NGMN. Description of network slicing concept[EB]. 2016.
- [28] Trivisonno R, An X L, Wei Q. Network slicing for 5G systems: a review from an architecture and standardization perspective[C]//*Proceedings of the 2017 IEEE Conference on Standards for Communications and Networking (CSCN)*. Piscataway: IEEE Press, 2017: 36-41.
- [29] Chergui H, Verikoukis C. Big data for 5G intelligent network slicing management[J]. *IEEE Network*, 2020, 34(4): 56-61.
- [30] Hurtado Sánchez J A, Casilimas K, Rendon O M C. Deep reinforcement learning for resource management on network slicing: a survey[J]. *Sensors*, 2022, 22(8):3031.
- [31] Su R Y, Zhang D Y, Venkatesan R, et al. Resource allocation for network slicing in 5G telecommunication networks: a survey of principles and models[J]. *IEEE Network*, 2019, 33(6): 172-179.
- [32] Han B, Schotten H D. Machine learning for network slicing resource management: a comprehensive survey[J]. *ZTE Communications*, 2019,17(4):27-32.
- [33] Dong T J, Zhuang Z R, Qi Q, et al. Intelligent joint network slicing and routing via GCN-powered multi-task deep reinforcement learning[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 8(2): 1269-1286.
- [34] Leconte M, Paschos G S, Mertikopoulos P, et al. A resource allocation framework for network slicing[C]//*Proceedings of the IEEE INFOCOM 2018-IEEE Conference on Computer Communications*. Piscataway: IEEE Press, 2018: 2177-2185.
- [35] 元伟敬, 宋清洋, 郭磊. 面向软件定义多模态车联网的双时间尺度 RAN 切片资源分配[J]. *通信学报*, 2022, 43(4): 60-70.
QI W J, S Q Y, GUO L. Dual time scale resource allocation for RAN slicing in software-defined oriented polymorphic IoV[J]. *Journal on Communications*, 2022, 43(4): 60-70.
- [36] 陈赓, 齐书虎, 沈斐, 等. 面向 B5G 多业务场景基于 D3QN 的双

时间尺度网络切片算法[J]. 通信学报, 2022, 43(11):213-224.

Chen G, Qi S H, Shen Fei, et al. Dual time scale network slicing algorithm based on D3QN for B5G multi-service scenarios[J]. Journal on Communication, 2022, 43(11):213-224.

- [37] 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.
- [38] Winata G I, Madotto A, Lin Z J, et al. Language models are few-shot learners[C]//Proceedings of the 1st Workshop on Multilingual Representation Learning. ACL Press, 2021, 1-15.
- [39] Tay Y, Tran V, Dehghani M, et al. Transformer memory as a differentiable search index[C]//Proceedings of the 36th International Conference on Neural Information Processing System. New York: Curran Associates Inc., 2022: 21831-21843.
- [40] Han R X, Wang J Y, Qi Q, et al. NetRen: service migration-driven network renaissance with synthesizing updated configuration[C]//Proceedings of the 29th ACM International Conference on Architectural Support for Programming Languages and Operating Systems, New York: ACM Press, 2024: 708-721.
- [41] Guo D K, Li C I, Wu J, et al. DCube: a family of network structures for containerized data centers using dual-port servers[J]. Computer communications, 2014, 53: 13-25.
- [42] Singla A, Hong C Y, Popa L, et al. Jellyfish: networking data centers randomly[C]//Proceedings of the 9th USENIX conference on Networked Systems Design and Implementation. 2012: 225-238.
- [43] Bega D, Gramaglia M, Fiore M, et al. AZTEC: Anticipatory capacity allocation for zero-touch network slicing[C]//Proceedings of the IEEE INFOCOM 2020 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2020: 794-803.
- [44] Bega D, Gramaglia M, Bernardos Cano C J, et al. Toward the network of the future: from enabling technologies to 5G concepts[J]. Transactions on Emerging Telecommunications Technologies, 2017, 28(8): e3205.

[作者简介]



宋航(1989-), 男, 中油国际管道公司工程师, 主要研究方向为石油通信。



才建(1980-), 男, 博士, 中油国际管道公司高级工程师, 主要研究方向为油气管道建设及运行管理。



袁运栋(1971-), 男, 中油国际管道公司高级工程师, 主要研究方向为油气管道运行管理。



张宇(1983-), 男, 博士, 中油国际管道公司高级工程师, 主要研究方向为油气储运。



刘锐(1974.10-), 男, 中油国际管道公司高级工程师, 主要研究方向为长输油气管道自动化和通信。



王见素(1987-), 女, 中油国际管道公司会计师, 主要研究方向为网络信息。



刘刚(1982-), 男, 中油国际管道公司高级工程师, 主要研究方向为自动化与无线通信。



张敏(2002-), 女, 北京邮电大学网络与交换技术全国重点实验室硕士生, 主要研究方向为意图网络。



王敬宇(1978-), 男, 博士, 北京邮电大学网络与交换技术全国重点实验室长聘教授, 国家级高层次人才, 国家自然科学基金重点项目负责人, 中国通信学会高级会员, 主要研究方向为智能网络、机器学习、边缘计算。