

控制与决策

Control and Decision

基于知识增强的智能体复杂任务分解方法

金宗瀚, 吴李康, 刘玉祥, 何明, 赵洪科

引用本文:

金宗瀚, 吴李康, 刘玉祥, 等. 基于知识增强的智能体复杂任务分解方法[J]. *控制与决策*, 2026, 41(5): 1359–1369.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0833>

您可能感兴趣的其他文章

Articles you may be interested in

基于复杂昂贵仿真的体系效能多目标优化

Complex and expensive simulation based multi-objective optimization to system-of-system effectiveness

控制与决策. 2021, 36(3): 589–598 <https://doi.org/10.13195/j.kzyjc.2019.0844>

一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于知识粒度特征的多目标粗糙集属性约简算法

Multi objective rough set attribute reduction algorithm based on characteristics of knowledge granularity

控制与决策. 2021, 36(1): 196–205 <https://doi.org/10.13195/j.kzyjc.2019.0490>

结合注意力机制的循环神经网络复述识别模型

Recurrent neural networks based paraphrase identification model combined with attention mechanism

控制与决策. 2021, 36(1): 152–158 <https://doi.org/10.13195/j.kzyjc.2019.0638>

领域专业知识富关联关系提取方法

Extraction method of multiple semantic relations in domain knowledge

控制与决策. 2021, 36(1): 52–60 <https://doi.org/10.13195/j.kzyjc.2019.0727>

基于知识增强的智能体复杂任务分解方法

金宗瀚^{1,2}, 吴李康^{1,2†}, 刘玉祥³, 何明⁴, 赵洪科^{1,2}

(1. 天津大学 管理与经济学部, 天津 300072; 2. 天津大学 复杂管理系统实验室, 天津 300072;
3. 廊坊师范学院, 体育学院, 河北 廊坊 065000; 4. 联想研究院, 北京 100085)

摘要: 基于大语言模型的智能体在复杂任务的处理中表现出卓越的语言理解和深度推理潜力, 然而, 当它在应对更加复杂的挑战时, 尤其是某一特定领域内涉及到领域规则的复杂任务时, 其表现往往不尽人意. 这种不足主要源于大语言模型内部缺乏对领域中专业知识和依赖约束的显式建模, 导致解决问题的过程中生成不符合逻辑或不可执行的子任务序列, 进而引发规划幻觉和领域知识结构性缺失等问题. 为解决这类问题, 提出一种基于知识增强的复杂任务分解框架. 该框架将知识图谱与思维链技术相融合, 旨在以知识增强为核心, 通过构建约束关系和领域知识双图谱, 为大语言模型在解析复杂任务的过程中提供结构化知识约束, 并结合高质量的推理路径输入, 引导模型生成语义完整、逻辑合理且可执行的子任务序列. 实验结果表明, 在 2WikiMultiHopQA、HotpotQA 和 MuSiQue 三类多跳问答数据集上, 基于不同参数规模的 Qwen2.5 模型中, KTD 框架在所有任务和资源配置下均显著优于主流的相关 Prompting 策略方法, 其中在 1.5B 低资源配置下任务准确率最高可提升 13.86%, 进一步表明了 KTD 框架在缓解规划幻觉和弥补领域知识结构性缺失方面的有效性.

关键词: 大语言模型; 智能体; 知识增强; 任务分解; 规划幻觉; 多跳推理

中图分类号: TP182 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0833

引用格式: 金宗瀚, 吴李康, 刘玉祥, 等. 基于知识增强的智能体复杂任务分解方法 [J]. 控制与决策, 2026, 41(5): 1359-1369.

A knowledge-enhanced method for complex task decomposition of agent

JIN Zong-han^{1,2}, WU Li-kang^{1,2†}, LIU Yu-xiang³, HE Ming⁴, ZHAO Hong-ke^{1,2}

(1. College of Management and Economics, Tianjin University, Tianjin 300072, China; 2. Laboratory of Computation and Analytics of Complex Management Systems, Tianjin University, Tianjin 300072, China; 3. School of Physical Education, Langfang Normal University, Langfang 065000, China; 4. Lenovo Research, Beijing 100085, China)

Abstract: LLM-based agents demonstrate impressive capabilities in language understanding and reasoning but often falter when facing complex tasks involving domain-specific rules. This limitation primarily stems from the lack of explicit modeling of expert knowledge and dependency constraints, leading to illogical subtask sequences, planning hallucinations, and structural deficiencies in domain knowledge. To address this, we propose the knowledge-enhanced task decomposition (KTD) framework, which integrates knowledge graphs with chain-of-thought reasoning. By constructing dual graphs that encode both domain constraints and expert knowledge, the KTD provides structured guidance for complex task decomposition, enabling the generation of semantically complete, logically coherent, and executable subtask sequences. Experiments on three multi-hop QA datasets (2WikiMultiHopQA, HotpotQA, and MuSiQue) demonstrate that the KTD consistently outperforms mainstream prompting methods across various Qwen2.5 model sizes. Notably, in the low-resource 1.5B setting, the KTD achieves up to a 13.86% accuracy improvement, confirming its effectiveness in mitigating planning hallucinations and addressing structural knowledge deficiencies.

Keywords: large language models; Agent; knowledge enhancement; task decomposition; planning hallucination; multi-hop reasoning

0 引言

随着人工智能技术的迅猛发展, 智能体 (Agent)

正逐步成为推动各行各业实现智能化转型和技术革新的关键力量^[1]. 从早期依赖人工规则构建的基础

收稿日期: 2025-08-12; 录用日期: 2025-12-05.

基金项目: 天津市教委社会科学重大项目 (2024JWZD04).

†通信作者. E-mail: wulk@tju.edu.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

Agent 系统, 演进至融合深度神经网络与大语言模型 (LLMs) 的复杂架构, Agent 的能力边界不断拓展, 其应用已广泛覆盖机器人控制、智能推荐、企业决策等多个核心领域^[2].

Agent 通常被定义为一种能够感知环境、基于环境状态自主做出决策以达成既定目标的计算实体. 传统 Agent 系统多采用基于专家知识的规则体系进行任务分解和控制决策, 尽管此类方式在结构清晰的环境中具备一定可控性, 但是, 当面对复杂动态的实际问题时常表现出适应性不足^[3]. 强化学习的引入在一定程度上缓解了上述问题, 使得智能体能够通过与环境交互学习任务策略. 然而, 此类方法仍然存在收敛速度慢、样本效率低以及过度依赖环境反馈等现实制约, 难以在高维任务中高效推广^[4].

近年来, 得益于大语言模型技术的突破性发展, Agent 的任务理解和响应能力获得了显著增强^[5]. 以 GPT^[6] 系列、DeepSeek^[7] 等代表性模型为例, 这些预训练模型基于大规模语料学习而来的通用语言理解能力, 为 Agent 系统中的任务建模、推理生成和策略执行提供了强有力的支持, 从而推动了 Agent 从基于规则的传统模式向以 LLM 为核心的智能架构转型. 与传统方法相比, 基于 LLM 的 Agent 具备更强的通用性、迁移能力以及语言交互能力, 已成为当前智能体研究的重要方向^[8].

然而, 在面对现实世界中高度复杂、时变性强且充满约束的任务情境时, 基于 LLM 的 Agent 仍然面临诸多挑战. 一方面, LLM 在任务规划过程中常会产生所谓的规划幻觉现象, 即生成的子任务或操作序列偏离常识逻辑或合理顺序^[9]. 该问题源于大模型在处理长推理链条和多层次依赖时的机制性局限, 如注意力漂移和记忆稀释所引发的系统性认知偏差^[10]. 另一方面, LLM 对于结构化领域知识的建模能力依然不足^[11]. 尽管其从大规模语料中学习到大量通用知识, 但是, 这些信息往往以碎片化和隐式方式呈现, 缺乏明确的层级结构和因果关系表达, 从而难以有效对任务中的专业规范、时序逻辑以及约束条件进行建模和执行^[12]. 上述两类问题相互交织: 结构化知识的缺失使得模型缺乏合理推理的“知识地基”, 而推理路径的混乱又进一步削弱了知识的有效应用, 成为限制 LLM-Agent 在复杂任务分解中可靠性和实用性的重要瓶颈^[13].

为解决上述问题, 本文提出一种面向复杂任务分解的知识增强型智能体方法, 以系统性整合结构化知识与思维链优化机制, 提升基于 LLM 的 Agent 在复杂任务场景中的推理可靠性和分解精度. 具体

包括以下 3 个核心模块:

1) 双图谱知识增强模块: 本文设计由“约束关系图谱”与“领域知识图谱”组成的双重结构化知识图谱. 前者用于捕捉任务中的执行依赖和逻辑约束; 后者则结合实体链接技术, 提供具体领域中的语义背景和规则体系, 协助 Agent 在任务理解和子任务生成过程中获得结构化知识支撑.

2) 子任务分解和顺序校正模块: 该模块结合知识图谱与任务上下文, 帮助 Agent 识别任务中的关键实体和语义单元, 并利用图谱中显式的上下位关系、依赖路径进行知识扩展和补充. 在此基础上, 系统引导 LLM 对初步生成的子任务进行逻辑纠偏和顺序校正, 以确保最终生成的任务结构具备良好的可执行性和语义一致性.

3) 优质思维链记忆库模块: 本文提出一种基于质量评估机制的推理轨迹筛选和存储方法, 构建结构化的高质量思维链记忆库. 在新任务推理过程中, Agent 可自该记忆库中检索 Top- k 高质量相似路径作为提示上下文, 引导 LLM 生成更具连贯性和稳定性的推理链条, 从而有效提升模型在多步推理中的鲁棒性和一致性.

1 文献综述

1.1 知识增强方法

LLM 在复杂任务分解中的广泛应用也逐渐暴露了其推理能力和知识储备的局限性, 尤其是在处理一些专业性极强或依赖某一领域规则的任务^[14]. 为提升 LLM 的性能, 知识增强方法成为近几年研究的热点. 知识增强的方法通常被定义为通过外部知识源或结构化知识对 LLM 进行输入, 为 LLM 提供相关的领域知识文档, 从而提高任务分解的精确性和可控性^[15].

早期的知识增强方法主要依赖非结构化文本资源, 典型代表为检索增强生成 (RAG). RAG 通过动态检索与任务相关的文档片段作为输入上下文, 有效提升了 LLM 对特定领域任务的适应能力^[16]; ITER-RETGEN^[17] 提出了一种迭代式策略, 将检索与生成过程相融合, 循环执行“检索增强生成”和“生成增强检索”; Self-RAG^[18] 在传统 RAG 框架的基础上引入了反思机制, 使得模型能够自适应检索所需信息并进行反思控制, 从而在问答、推理和事实验证等任务中显著提升了准确性和生成质量. 然而, 这类方法本质上仍然依赖非结构化文本, 其结构建模能力有限, 难以系统化地捕捉子任务间的依赖关系和领域规则, 易引发逻辑跳跃和规划误差^[15].

为了弥补非结构化知识的缺陷,研究者转向结构化知识增强,而知识图谱(KG)因其显式表示和推理能力受到广泛关注^[19].知识图谱主要是通过构建实体和关系的三元组形式来系统化地组织知识,这能够有效刻画任务中的约束条件和依赖结构^[20].近期的研究^[21-22]尝试将知识图谱中的结构化信息转化为文本提示,以辅助LLM完成复杂问题求解.Chain-of-Knowledge^[23]通过从Wikipedia、Wikidata和Wikitable检索相关知识,作为模型生成的支撑依据;GraphRAG^[15]将知识图谱与检索技术相结合,利用图结构推理增强了上下文的语义相关性,在长序列任务中展现出更强的鲁棒性;ToG-2^[24]框架提出了一种融合结构化图谱与非结构化文本的协同检索机制,通过迭代的提示词引导LLM获取语义相关的上下文信息,实现了更可靠的推理生成。

然而,值得注意的是,当前多数基于知识图谱的增强方法仍然主要依赖通用性图谱(如常识图谱或百科知识图谱),在应对特定领域任务时常显得针对性不足,难以全面弥补LLM在专业知识建模方面的结构性缺失^[25].

1.2 任务分解方法

在任务分解方法的发展历程中,早期研究主要依赖专家预设规则,通过人工构建的规则体系将复杂任务逐步拆解为若干子任务^[26].这类方法在静态或先验明确的环境下具有较强的可控性,但是,当面对动态变化的任务需求或环境不确定性增强的场景时,往往缺乏足够的灵活性和泛化能力,难以适应任务结构的复杂性.为提升策略自适应水平,后续工作引入了强化学习机制,使得智能体能够在交互过程中自主学习任务拆解策略^[27].尽管此类方法在一定程度上增强了环境适应能力,但是其仍然存在样本效率低、训练周期长以及难以快速引入外部知识等瓶颈,限制了其在高维复杂任务中的应用效果。

近年来,随着LLM技术的突破发展,其强大的语言理解和知识泛化能力为智能体任务分解提供了新的范式.基于LLM的Agent系统能够在极少样本甚至零样本的条件下,自动提取任务关键语义,大幅提升任务分解的效率.根据任务分解顺序和推理策略的不同,当前基于LLM的Agent任务分解方法大致可分为分解优先和交错分解两类代表性模式^[28].

分解优先策略遵循“先分解、后执行”的处理逻辑.典型代表如HuggingGPT系统^[29],该系统依托HuggingFace平台所提供的多模态模型资源,能够处理图像生成、图像分类、目标检测、视频分析和语音

识别等多种任务.HuggingGPT通过Prompt设计引导智能体完成任务拆解,并实现子任务间的依赖管理和系统化执行.另一代表性方法Plan-and-Solve^[30]则提出将任务解决流程显式划分为“规划生成”和“计划执行”两个阶段,通过优化Zero-shot CoT机制,在数学推理和符号推理等领域表现出色。

交错分解方法采用动态的“逐步规划”机制,每次仅基于当前上下文生成1个或2个子任务,从而实现任务拆解与规划同步推进.Chain-of-Thought (CoT)^[31]方法充分展示了LLM在少样本场景下的推理能力,其通过构建多步逻辑链,引导模型在思维链条中逐步推进问题求解过程;Zero-shot^[32]进一步扩展了该方法的适用性,通过“逐步思考”等自然语言指令激发模型的自发推理能力;ReAct^[33]框架则在此基础上提出了推理与行动交替的机制,通过交互式地整合推理判断和规划行为,显著增强了系统在多步任务处理中的灵活性和鲁棒性。

从方法特性上看,分解优先策略的优势在于结构清晰、逻辑紧凑,有助于保持任务语义的一致性,降低任务遗忘和模型幻觉的风险.然而,其高度依赖初始阶段的子任务设计,一旦初期拆解存在偏差,易导致后续规划路径错误积累.相比之下,交错分解策略更具适应性,能够根据实时反馈灵活调整分解路径,具备更强的容错和修正能力.但是在复杂任务场景中,其较长的推理路径也易放大模型的幻觉倾向,影响最终子任务的有效性和一致性^[28].

2 基于知识增强的复杂任务分解框架设计

为解决当前Agent在复杂任务分解中面临的“规划幻觉”和“领域知识结构缺失”两大核心难题,本文提出一种基于知识增强的复杂任务分解框架(KTD).如图1所示,该框架旨在赋予Agent更强的结构认知能力和知识约束建模能力,从而实现复杂任务的精准理解、可控分解以及逻辑执行。

2.1 双图谱知识增强模块

双图谱知识增强模块是KTD框架的关键组成部分,旨在系统化构建任务相关的结构化知识,以增强大语言模型对复杂任务的理解能力和子任务分解的准确性.如图2所示,该模块通过联合构建两类图谱:约束关系图谱和领域知识图谱,分别承担任务执行逻辑建模和专业知识补全的职责.前者注重捕捉任务中的时序依赖和约束规则,后者聚焦于丰富模型对领域背景和语义关系的掌握.两者共同构成支撑复杂任务分解的知识基础,可有效缓解大语言模型在推理中出现的认知偏差和知识断层问题。

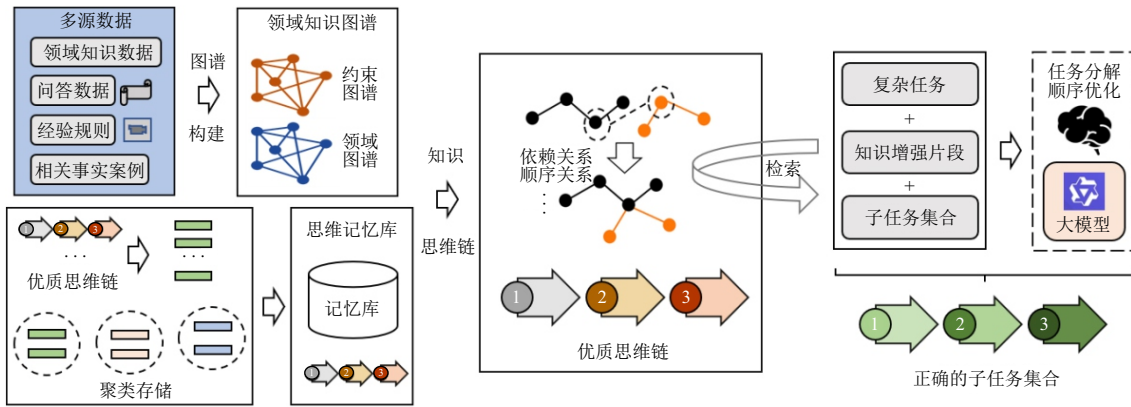


图1 基于知识增强的复杂任务分解框架

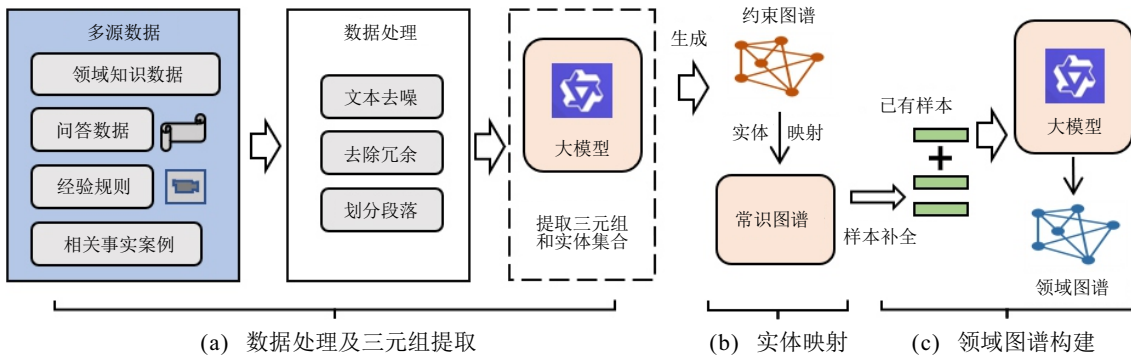


图2 约束关系图谱和领域知识图谱构建过程

2.1.1 约束关系图谱

约束关系图谱旨在从大量非结构化、带有噪声的任务描述文本中,提取与任务依赖和执行规则相关的约束信息,并以结构化的三元组形式加以存储,为复杂任务的精确分解和顺序规划提供知识支撑.在 KTD 框架中,该图谱构建以大语言模型为核心抽取器,结合精心设计的提示词,指导 LLM 从预处理后的语义完整文本段落中提取语义约束单元.

如图 2 所示,构建流程首先对原始任务数据(包括领域知识库、问答数据、经验规则以及相关事实案例等)进行系统化的数据清洗,去除无关内容、多余符号以及格式噪声,并将处理后的数据划分为可被 LLM 高效处理的语义完整文本段落.

根据上述清理后的语义完整的文本段落,本文设计一套基于 Prompt 约束关键词提取工作流,如表 1 所示.使其指导大语言模型对清理好的文本段落进行关键词提取,提取出与任务文本中有关的任务实体(如:人物物品实体、事件实体以及时间实体等)和相关约束逻辑关系(如:依赖关系、约束关系、包含关系等).为增强实体识别与关系抽取的一致性和规范性,本文在设计 Prompt 时引入语义标签体系(Semantic IRI).表 2 和表 3 为 KTD 框架中实体类型、约束关系类型与语义标识间的映射关系.该标签体系为 LLM 提供了明确的识别参考,从而提高实体

表1 实体关系抽取模板

Extracting Prompt
Your task is to identify entities and relations from the provided text, as requested in the user prompt, to support the construction of a knowledge graph for multi-hop reasoning.
You must generate the output in a JSON format containing a list of JSON objects with the following keys: "head", "head_type", "relation", "tail", and "tail_type". The "head" key must contain the text of an extracted entity with one of the types from the provided entity_types list in the user prompt, the "head_type" key must contain the type of the head entity which must be one of the types from the provided list, the "relation" key must contain the type of relation from the provided relation_types list, the "tail" key must represent the text of an extracted entity which is the tail of the relation, and the "tail_type" key must contain the type of the tail entity. Attempt to extract as many entities and relations as possible to enable multi-hop reasoning across the text.
Based on the following example, extract entities and relations from the provided text.
Output
"head": "Animal Cell",
"head_type": "Concept",
"relation": "hasPart",
"tail": "Mitochondrion",
"tail_type": "Concept"

和关系提取的准确性.

在获得由 Prompt 驱动的 LLM 提取结果后,本文将得到的实体与逻辑关系转化为标准化的知识图谱三元组形式.最终生成的约束关系图谱,以结构化三元组的方式存储了文本中实体间的逻辑约束信息,

表2 实体映射

实体类型	语义标识(Semantic IRI)
Person	https://schema.org/Person
Place	https://schema.org/Place
Organization	https://schema.org/Organization
Event	https://schema.org/Event
Time	https://schema.org/DateTime
Concept	https://schema.org/Thing
Work	https://schema.org/CreativeWork

表3 约束映射

约束类型	语义标识(Semantic IRI)
hasPart	https://schema.org/hasPart
isPartOf	https://schema.org/isPartOf
before	http://www.w3.org/2006/time#before
meets	http://www.w3.org/2006/time#meets
generated	http://www.w3.org/ns/prov#generated
sameAs	http://www.w3.org/2002/07/owl#sameAs

为后续任务分解、执行顺序规划和依赖关系校正提供了清晰、可计算的知识支持。

2.1.2 领域知识图谱

约束关系图谱关注任务实体间的约束逻辑和执行顺序, 通过结构化表达支持任务流程建模。然而, 在处理科学常识推理、人物传记问答以及开放域多跳推理等知识密集型复杂任务时, 通用大语言模型往往面临显著的领域知识缺失和事实性幻觉问题。为此, KTD 框架引入领域知识图谱, 专门针对上述领域的专业概念和背景事实进行结构化增强, 以补足模型在专业语义理解和背景推理中的能力缺口。

领域知识图谱的构建围绕任务的背景语义展开。首先, 以上述提取的任务实体集合为线索, 利用 Prompt 驱动的 LLM 定向挖掘与当前任务推理路径强关联的领域特定实体。如: 针对科学常识推理任务中的文本“James Watson and Francis Crick described the double-helix structure of DNA.”, 系统将识别出领域语义锚点, 精准提取出“James Watson”“Francis Crick”等关键实体。这些承载核心领域知识的实体构成了领域知识图谱的初始节点集合。然后, 本文采用基于嵌入匹配的实体链接技术, 通过对核心实体以及知识图谱中候选实体的文本描述分别进行向量化编码, 并基于余弦相似度计算两者间的语义相似度, 从而将文本中的实体映射至开放知识图谱(如 Wikidata)中相似度最高的实体节点, 以实现知识扩展。

通过遍历每一核心实体在 Wikidata 中的邻接结构, 获取与其相关联的上下游实体及其语义关系。为确保扩展知识的相关性和准确性, 系统进一步结合

LLM 对提取的结构化知识片段进行语义筛选, 保留与原始任务语境密切相关的信息, 从而实现领域知识的有效补全和增强。如表 4 所示, 该过程显著提升了领域知识图谱对任务语义的覆盖能力。

表4 知识图谱三元组示例

Head	Head Type	Relation	Tail	Tail Type
James Watson	Person	CollaboratedWith	Francis Crick	Person
James Watson	Person	WorkedAt	University of Cambridge	Organization
James Watson	Person	BornIn	Chicago	Place

经实体链接实现知识补全的领域知识图谱往往包含高相似度的实体, 造成知识图谱的过度复杂, 为此, 本文将使用语义对齐机制, 对后续补全的知识图谱进行实体对齐等操作, 将使用 all-MiniLM-L6-V2 模型对领域知识图谱中的实体进行编码, 并计算每个实体间的余弦相似度, 对相似度较高的实体节点进行实体对齐操作。如: 对于“James Watson”与“J. Watson”, 在嵌入空间中具有高度相似性, 可被识别为同一语义单元并归并为统一的标准实体节点, 从而消除掉知识图谱中的冗余和歧义, 令领域知识图谱更加紧凑。

通过上述过程构建的领域知识图谱, 与约束关系图谱共同构成 KTD 框架中的双图谱系统。在后续的子任务分解和顺序校正过程中, 该图谱系统可为智能体提供结构化、语义一致的知识支撑, 显著增强其对复杂任务的理解、推理和规划能力。

2.2 子任务分解和顺序校正模块

大语言模型虽然具备强大的语言生成和推理能力, 但是, 其在缺乏足够领域知识支持的情况下, 易出现子任务划分不全、任务顺序不合理或对任务语义理解片面等问题。为提升分解结果的准确性和合理性, 本文设计一套子任务分解和顺序校正模块, 如图 3 所示, 对初始子任务集进行逻辑重构。

首先, 借助大语言模型对输入的复杂任务 T 进行语义理解和分解, 生成初始的子任务集合, 如下所示:

$$S = \text{Decompose}(T) = \{s_1, s_2, \dots, s_n\}. \quad (1)$$

其中: 函数 $\text{Decompose}(\cdot)$ 表示基于提示词或上下文引导下的任务分解过程; 所得的子任务集合 S 具有语言合理性, 但是常因缺乏上下文知识、过程依赖约束等而表现出语义片段化或逻辑跳跃等问题。

由于初始子任务集可能存在语义残缺或结构冲突, 需要借助领域知识库 K 中的结构化语义信息进行修正, 需要从每个子任务中识别出关键概念词或

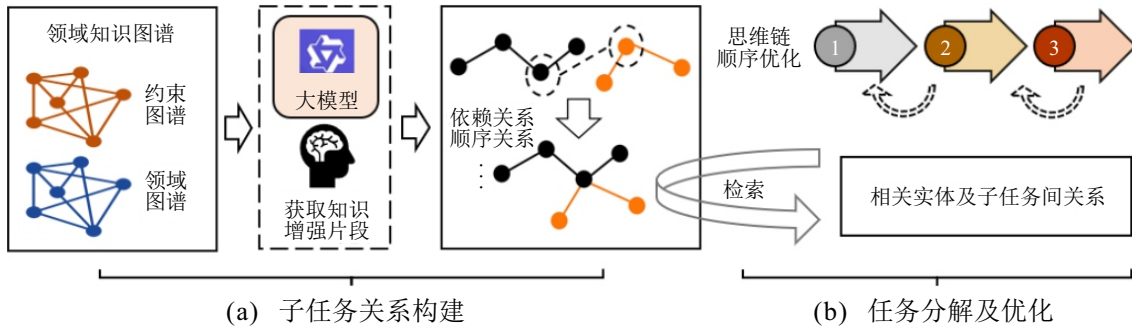


图3 结合知识图谱的子任务分解和顺序校正流程

主题实体, 作为图谱检索的起始点. 本文定义实体抽取函数 $\text{Extract}(\cdot)$, 通过结合大语言模型与语义相似度计算的方式, 针对每个子任务 s_i 提取任务知识库 K 中实体一致或高度相关的主题实体集合, 如下所示:

$$E_{\text{topic}}^i = \text{Extract}(s_i, K) = \{e_1^i, e_2^i, \dots, e_j^i\}. \quad (2)$$

这些实体可视为子任务的语义核心, 用于引导后续的图谱检索操作. 在实体集合的基础上, 本文在领域知识库 K 中进行深度为 D 的结构化图扩散操作, 以捕捉与其存在语义关联或推理依赖的相关概念. 该过程类似于一种受限宽度的子图采样, 可表达为

$$\text{Subgraph}(e_k^i, D) = \bigcup_{d=0}^D \langle e_a, r, e_b \rangle, \\ e_a \in E_d, e_b \in N(e_a). \quad (3)$$

其中: E_d 为扩散至第 d 层的实体集合; $N(e_a)$ 为实体 e_a 的邻接实体集合; $\langle e_a, r, e_b \rangle$ 为知识图谱中的三元组; 通过设置扩散深度 D , 可以平衡语义覆盖广度与上下文相关性, 避免噪声知识干扰.

将所有从实体集合 E_{topic}^i 检索到的子图合并, 即可获得子任务 s_i 对应的知识增强文档, 有

$$\text{Knowledge}_i = \bigcup_{k=1}^j \text{Subgraph}(e_k^i, D). \quad (4)$$

该知识文档可视为对原始子任务的领域补充和语义扩展, 覆盖其可能忽略的上下文条件、前置约束、依赖资源以及逻辑衔接等关键元素. 其结合每个子任务 s_i 的知识增强文档, 利用图谱中提供的上下文关系、操作依赖、前置约束等知识, 对子任务内容以及执行逻辑进行语义重构和顺序校正, 不仅在语义上对每个子任务进行重构, 确保子任务表达符合领域目标和约束, 还通过考虑任务的依赖关系和执行顺序等因素, 重新组织子任务顺序, 引导模型重新生成更具逻辑连贯性和领域一致性的子任务表达以获得最优的任务执行路径, 如下所示:

$$S' = \text{Re}(S, \{\text{Knowledge}_{i=1}^n\}) = \{s'_1, s'_2, \dots, s'_n\}, \quad (5)$$

其中 $\text{Re}(\cdot)$ 通过结合图谱中提供的结构性依赖信息、任务间的前后关系约束以及领域内的最佳实践知识, 实现对子任务集的修正和排序. 通过这种方法, 任务的执行顺序将依据子任务间的关联度和约束条件进行动态优化, 确保任务解法具备逻辑一致性和执行可行性.

2.3 优质思维链记忆库模块

本节首先介绍如何从优化后的子任务序列中识别和评估高质量的推理路径, 确保所存储的思维链在逻辑结构和推理效果上均具备可复用价值.

2.3.1 优质思维链的提取

思维链 (CoT)^[31] 是指在复杂任务求解过程中, 从输入任务到最终答案所经历的逻辑推理路径, 通常由一系列具有语义连贯性和执行可行性的子任务构成. 在所构建的知识增强任务分解框架中, 思维链由第 2.2 节生成并优化后的子任务序列构成, 如下所示:

$$S' = \{s'_1, s'_2, \dots, s'_n\}, \quad (6)$$

其中每个子任务 s_i 均为在双图谱知识增强 (即约束关系图谱和领域知识图谱) 作用下生成的语义明确、操作可执行的推理步骤, 这些子任务序列共同组成解决一个多跳复杂任务的完整逻辑路径.

在多种推理路径建模方式中, 本文选择以思维链作为基础结构进行知识组织和复用, 相较于思维树 (ToT) 与思维图 (GoT) 等多分支或图状推理结构, 线性化的思维链具备更高的结构可控性和评估可行性.

复杂任务中的树状或图状推理虽然能够捕捉多路径探索的特征, 但是易导致推理路径爆炸、分支控制复杂等问题, 不利于在有限计算和样本条件下实现稳定的质量评估. 然而, 尽管子任务序列已被优化, 其生成过程中仍然可能会出现推理断裂、顺序错误等规划幻觉问题, 进而影响整体推理链的质量. 为此, 本文提出一种基于大语言模型思维链质量评估框架, 通过引入思维链筛选器 $\text{Evaluator}(\cdot)$, 实现对候

选推理路径的多维质量判定。

该筛选器结合 Prompt 工程与少量高质量样本微调, 使得大语言模型具备在复杂任务场景下对思维链推理质量进行综合判别的能力。其核心目标是对给定的输入任务 T 、候选思维链 C 、基于该链生成的任务解答 A 、以及参考标准答案 A^* 进行多维对齐, 从而判定该思维链是否为高质量推理路径, 即

$$\text{Score} = \text{Evaluator}(T, C, A, A^*). \quad (7)$$

具体而言, 筛选器遵循一套基于 Prompt 的评估流程, 如表 5 所示。综合考虑逻辑完整性、任务贴合度和结果一致性 3 个方面: 首先, 检验思维链中各子任务间是否构成连贯闭环, 避免推理中断或逻辑跳跃; 然后, 评估其内容是否能够充分覆盖原始任务的语义要求, 确保整个推理过程具备结构上的完备性; 最后, 通过比较思维链生成的答案 A 与标准答案 A^* 的相似程度, 判断其推理输出是否符合预期目标, 从而全面评估候选思维链的有效性和可用性。

表5 思维链质量评估标准

Evaluating Prompt
Evaluate the CANDIDATE CHAIN-OF-THOUGHT (C) in the context of the INPUT TASK (T), its GENERATED ANSWER (A), and the REFERENCE ANSWER (A^*).
Provide a single numerical score from 0 to 10 (decimals allowed).
Output only: SCORE: $x/10$
Evaluation Criteria:
1) Logical Integrity: assess whether the reasoning steps in C form a coherent and self-consistent logical chain without contradictions, omissions, or circular reasoning.
2) Task Relevance: evaluate whether the reasoning process in C fully aligns with the semantic intent of T and appropriately covers all key aspects required to solve it.
3) Answer Consistency: assess whether the final answer A derived from C is semantically and factually consistent with the reference answer A^* , reflecting correct reasoning outcomes.
4) Clarity & Executability: determine whether the steps in C are expressed clearly, can be operationally executed by an intelligent agent, and lead feasibly from T to A .
Higher scores = better alignment, completeness, and reasoning quality.

2.3.2 思维链的主题聚类

经筛选得到的优质思维链将被系统化组织和管, 构建为思维记忆库。形式上, 该记忆库定义为

$$M = \{C_1, C_2, \dots, C_m\}, \quad (8)$$




图4 优质思维链记忆库存储和检索过程

其中每个 C_i 表示一个通过筛选器验证的高质量思维链, 能够有效表达复杂任务的推理路径。这些优质思维链不仅可作为参考样本用于大语言模型的上下文增强, 还可提升其在处理新任务时的推理连贯性和准确性。

直接检索效率难以进行实验, 为进一步提升记忆库的检索效率与上下文提示的相关性, 本文对优质思维链进行主题聚类。具体而言, 系统将利用语义相似度计算结合 LLM 主题抽取功能, 为每条思维链分配一个或多个语义主题标签, 从而构建结构化的主题层级体系。每个思维链样本将被映射到其所属的主题簇中, 形成按语义聚类的存储结构。

如图 4 所示: 在实际推理过程中, 当智能体接收到一个新的复杂任务输入时, 系统首先对该任务进行语义分析, 识别其所属主题类别, 并在思维记忆库中检索出该主题下与其最相关的 Top- k 条优质思维链。这些检索结果将作为提示信息融入 LLM 的输入上下文中, 为其提供可借鉴的推理路径结构, 从而增强当前任务的推理过程生成质量。

通过思维记忆库与主题聚类机制的协同作用, KTD 框架能够在每轮复杂任务求解中, 动态提供高质量的推理参考路径, 有效提升智能体的逻辑一致性和任务适应性。

3 实验

3.1 实验环境

为验证所提出知识增强型复杂任务分解方法的有效性, 本文选取 3 个具有代表性的多跳问答数据集进行实验评估: 2WikiMultiHopQA^[34]、HotpotQA^[35] 和 MuSiQue^[36]。这些数据集均以多步推理为核心挑战, 要求模型具备跨文档信息整合、语义理解和逻辑推理等综合能力。本文采用准确率 (Accuracy) 作为主要评估指标, 以衡量模型输出答案与标准答案的精确匹配程度^[37]。

在模型选择方面, 本文采用不同参数规模的 Qwen2.5 系列大语言模型作为主干模型, 包括 1.5B、7B 和 14B 共 3 种规模, 以系统性地分析模型规模对任务分解和推理性能的影响。为进一步提升评估的客观性, 本文引入 Qwen2.5-72B 作为判别模型, 对生

成答案的质量进行评估, 确保对模型输出性能的准确判定.

3.2 对比实验

为验证所提出方法的有效性, 本文选取 3 种具有代表性的多步推理基线方法进行对比, 包括 COT^[31]、ReAct^[33] 和 Reflexion^[37]. COT 通过显式生成中间推理步骤增强推理一致性; ReAct 结合推理与操作序列来提高任务适应性; Reflexion 引入反思机制, 基于初始输出进行自我修正, 从而提升推理准确性.

表 6 为 KTD 方法在 2WikiMultiHopQA、HotpotQA 和 MuSiQue 三个多跳问答和复杂任务数据集上的整体表现, 并与当前主流的 Prompting 策略 (COT、ReAct、Reflexion) 进行对比.

由表 6 可见, 在 1.5B 小规模模型上, KTD 在 3 个

表6 对比实验

基层模型	方法	数据集			平均值
		2Wiki	HotPotQA	MuSiQue	
Qwen2.5-1.5B-instruct	COT	0.270	0.370	0.135	0.258
	ReAct	0.300	0.403	0.139	0.281
	Reflexion	0.303	0.410	0.138	0.284
	KTD	0.345	0.426	0.152	0.308
Qwen2.5-7B-instruct	COT	0.404	0.610	0.232	0.415
	ReAct	0.460	0.641	0.274	0.458
	Reflexion	0.473	0.643	0.290	0.469
	KTD	0.498	0.654	0.298	0.483
Qwen2.5-14B-instruct	COT	0.456	0.664	0.270	0.463
	ReAct	0.561	0.665	0.339	0.522
	Reflexion	0.566	0.686	0.345	0.532
	KTD	0.580	0.715	0.357	0.551

数据集上分别达到了 0.345、0.426 和 0.152. 相较于最优基线方法 Reflexion (0.303、0.410、0.138), KTD 分别提升了 13.86%、3.90% 和 10.14%. 这表明 KTD 在低参数规模下仍然能够有效适应复杂任务结构. 随着模型规模扩大至 7B, KTD 在 3 个数据集上的表现进一步提升至 0.498、0.654 和 0.298, 相较于 Reflexion (0.473、0.643、0.290) 提升了 5.29%、1.71% 和 2.76%. 结果表明, KTD 能够更充分地利用中等规模大语言模型的表达能力, 引导其进行更高效地子任务规划和推理执行. 在 14B 的大模型上, KTD 在 2Wiki、HotpotQA 和 MuSiQue 上分别取得了 0.580、0.715 和 0.357 的成绩, 全面超越了 Reflexion (0.566、0.686、0.345), 相对提升了 2.47%、4.23% 和 3.48%, 其中在 HotpotQA 上的得分提升了 2.9%, 显示出 KTD 与大规模大语言模型结合后产生的强协同效应.

在图 5 所示的案例实验中, KTD 模型借助图谱知识增强机制, 首先准确校正了核心实体识别结果——明确将不来梅大教堂的主保圣人修正为 St. Peter, 并基于领域知识图谱关联至梵蒂冈的圣彼得大教堂; 然后通过子任务顺序校正模块, 依托约束关系图谱理清“圣人识别-教堂定位-国家建国时间”间的逻辑依赖; 最终正确推断梵蒂冈于 1929 年 2 月 11 日凭借《拉特兰条约》成为独立国家.

该案例清晰地表明, KTD 框架能够有效缓解规划幻觉, 并弥补领域知识缺失, 从而验证了知识增强对于提升复杂任务推理准确性的积极作用.

3.3 消融实验

为进一步验证 KTD 框架中知识增强机制和复

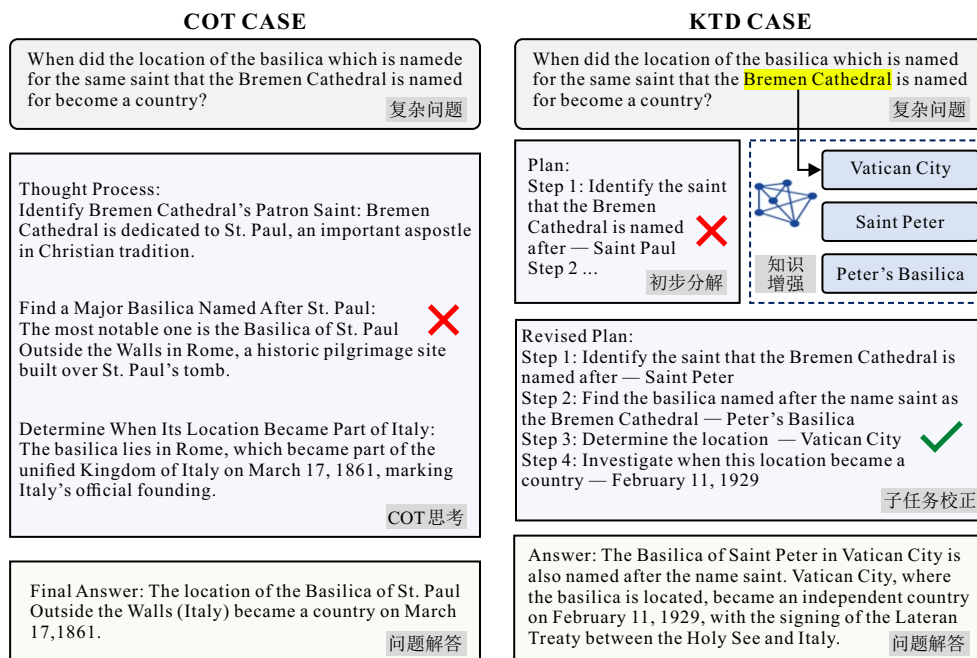


图5 案例实验: COT 案例和 KTD 案例

杂任务分解结构在多跳推理任务中的作用, 本文在 2Wiki、HotPotQA 和 MusiQue 三个数据集上进行系统地消融实验, 实验分别在 Qwen2.5 的 1.5B、7B 和 14B 模型上进行, 如表 7 所示. 具体设置如下:

1) KTD w/o KG: 移除知识图谱的检索和融合, 仅输入原始任务文本;

2) KTD w/o TD: 移除任务分解和顺序校正模块, 仅接受知识增强文本和问题, 直接进行端到端单轮解答.

表7 消融实验

基层模型	消融方法	数据集			平均值
		2Wiki	HotPotQA	MuSiQue	
Qwen2.5-1.5B-instruct	KTD w/o KG	0.270	0.370	0.135	0.258
	KTD w/o TD	0.300	0.403	0.139	0.281
	KTD(full)	0.345	0.426	0.152	0.308
Qwen2.5-7B-instruct	KTD w/o KG	0.404	0.610	0.232	0.415
	KTD w/o TD	0.460	0.641	0.274	0.458
	KTD(full)	0.498	0.654	0.298	0.483
Qwen2.5-14B-instruct	KTD w/o KG	0.456	0.664	0.270	0.463
	KTD w/o TD	0.561	0.665	0.339	0.522
	KTD(full)	0.580	0.715	0.357	0.551

表 7 结果显示, 在移除知识图谱增强机制后, 模型因缺乏外部结构化知识支持, 对任务语义的理解和背景推理能力显著受限. 在 1.5B 模型上, 完整 KTD 在 2Wiki、HotPotQA 和 MuSiQue 上的得分分别为 0.345、0.426 和 0.152, 去除知识增强后降至 0.270、

0.370 和 0.135, 分别下降了 21.7%、13.1% 和 11.2%. 即使在 14B 大模型上, 去除该机制后性能仍然下降了 4.3% ~ 7.3%, 表明外部知识对于增强上下文理解和逻辑连接具有持续作用, 对小模型尤为关键. 当移除任务分解和顺序校正模块时, 模型虽然保留了知识输入, 但是因缺乏推理路径规划, 解答策略趋于粗糙, 推理效率下降. 在 7B 模型上, KTD 相较于无任务分解版本 (KTD w/o TD), 在 3 个数据集上分别提升了 0.038、0.013 和 0.024, 对应提升幅度分别为 8.3%、2.0% 和 8.8%, 表明任务分解机制可有效引导模型拆解复杂任务, 降低错误率, 提升整体完成质量.

上述消融实验从宏观上验证了各模块的必要性, 而关于各模块关键参数的精细定量分析, 详见下文第 3.4 节的参数敏感性实验.

3.4 参数敏感性实验: 扩散深度和思维链设置

为探究知识增强文档和优质思维链数量对模型性能的影响机制, 本研究系统地分析知识图谱扩散深度 D 和优质思维链数量 K 的参数敏感性. 如图 6 所示, 所提出 KTD 框架在 3 个数据集上针对不同参数配置进行全面地性能评估.

图 6 结果表明: 当扩散深度 D 从 1 开始递增时, 模型性能呈现显著提升趋势; 然而, 当扩散深度到 5 时, 性能增益出现边际递减. 这一现象可归因于图谱扩散的指数级扩展特性 —— 随着扩散层级的增加, 每级扩散所关联的实体数量呈指数增长, 从而导

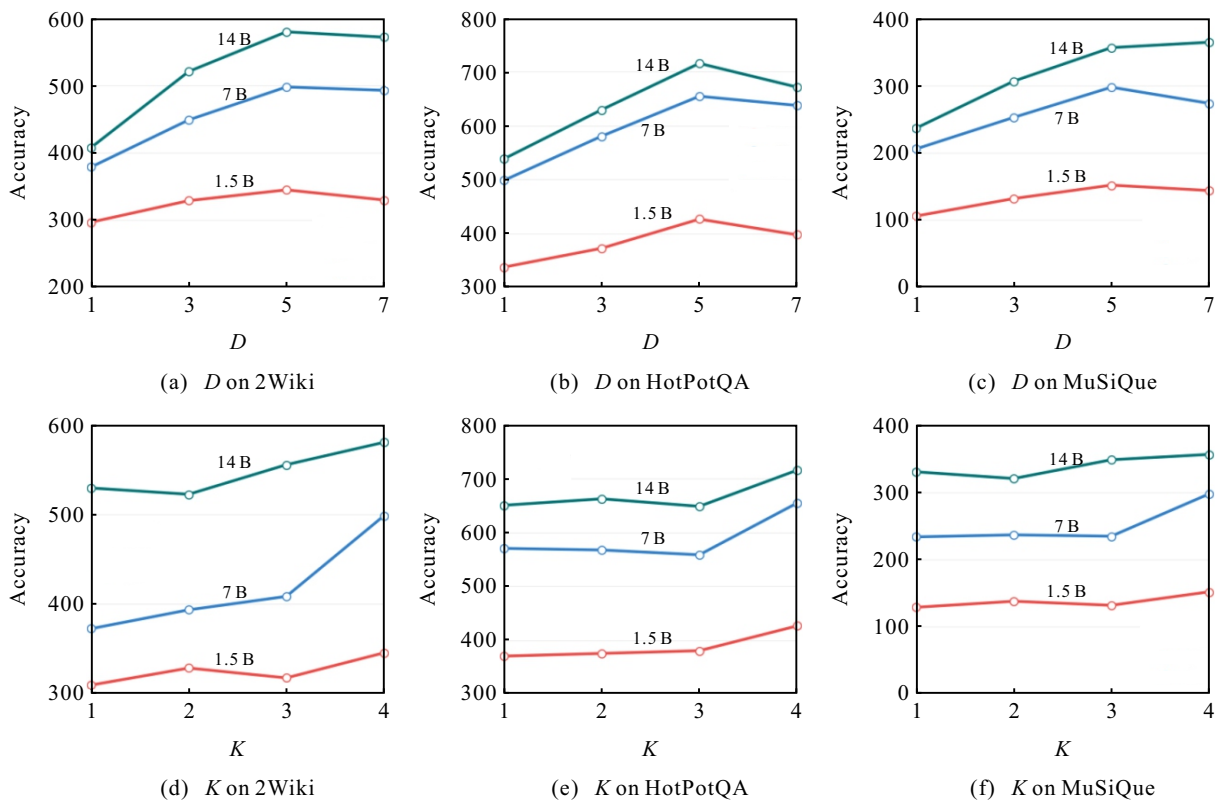


图6 扩散深度和思维链设置

致模型计算负载的显著增加. 在思维链数量维度上, 实验数据显示当 $K = 4$ 时模型达到最优性能. 上述实验表明, 图谱扩散深度和思维链数量均存在最优配置区间, 其取值应综合考虑具体任务的复杂度和模型容量.

4 结论

实验结果表明, 所提出 KTD 框架在不同模型规模和多类型复杂任务中均展现出优越的可扩展性和稳定性. 相较于 COT、ReAct 等静态提示方法, KTD 通过引入知识图谱和任务分解顺序校正, 显著减少了推理中的无效路径和逻辑偏移; 相较于依赖内部记忆更新的 Reflexion 策略, KTD 进一步提升了生成结果的稳定性和准确性, 展现出更强的任务完成能力和推理效率. KTD 的核心创新在于实现了知识增强与任务分解的有机融合, 通过“认知理解-执行规划”的双维度协同机制, 系统性地提升了智能体的语义解析和决策优化能力. 未来的工作可以扩展智能体的多模态信息处理能力, 使其能够融合视觉、语音等多源数据, 进一步提升复杂场景下的决策质量.

参考文献 (References)

- [1] 王路桥, 周洋涛, 李青山, 等. 基于大语言模型的多智能体协作代码评审人推荐[J]. *软件学报*, 2025, 36(6): 2558-2575.
(Wang L Q, Zhou Y T, Li Q S, et al. Multi-agent collaborative code reviewer recommendation based on large language model[J]. *Journal of Software*, 2025, 36(6): 2558-2575.)
- [2] 李国鹏, 吴瑞骐, 谈海生, 等. 面向大语言模型驱动的智能体的计划复用机制[J]. *计算机研究与发展*, 2024, 61(11): 2706-2720.
(Li G P, Wu R Q, Tan H S, et al. A plan reuse mechanism for LLM-Driven agent[J]. *Journal of Computer Research and Development*, 2024, 61(11): 2706-2720.)
- [3] 徐春, 孙恩威, 汪晓洁. 基于知识和数据双驱动的 DRG 医疗问答研究[J]. *计算机工程与科学*, 2025, 47(6): 1121-1132.
(Xu C, Sun E W, Wang X J. DRG medical Q & A research based on both knowledge and data[J]. *Computer Engineering & Science*, 2025, 47(6): 1121-1132.)
- [4] Wu L K, Li Z, Zhao H K, et al. Supporting your idea reasonably: A knowledge-aware topic reasoning strategy for citation recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(8): 4275-4289.
- [5] 孙宇祥, 赵俊杰, 解宇轩, 等. 自生成兵棋 AI: 基于大语言模型的双层 Agent 任务规划[J]. *控制与决策*, 2024, 39(12): 3927-3936.
(Sun Y X, Zhao J J, Xie Y X, et al. Self generated wargame AI: Double layer agent task planning based on large language model[J]. *Control and Decision*, 2024, 39(12): 3927-3936.)
- [6] Radford A, Wu J, Child R, et al. Language models are unsupervised multitask learners[J]. *OpenAI Blog*, 2019, 1(8): 9.
- [7] Achiam J, Adler S, Agarwal S, et al. Gpt-4 technical report[J/OL]. 2023, arXiv: 2303.08774.
- [8] 赵洪科, 叶倩彤, 张志勇, 等. 低碳算法的发展及压缩和加速技术的应用[J]. *控制与决策*, 2025, 40(5): 1409-1428.
(Zhao H K, Ye Q T, Zhang Z Y, et al. Development of low carbon algorithms and application of compression and acceleration techniques[J]. *Control and Decision*, 2025, 40(5): 1409-1428.)
- [9] 刘泽垣, 王鹏江, 宋晓斌, 等. 大语言模型的幻觉问题研究综述[J]. *软件学报*, 2025, 36(3): 1152-1185.
(Liu Z Y, Wang P J, Song X B, et al. Survey on hallucinations in large language models[J]. *Journal of Software*, 2025, 36(3): 1152-1185.)
- [10] Zhao C, Su X, He M, et al. Collaborative knowledge fusion: A novel method for multi-task recommender systems via LLMs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(9): 5017-5033.
- [11] Gao L Y, Dai Z Y, Pasupat P, et al. RARR: Researching and revising what language models say, using language models[C]. *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*. Toronto, 2023: 16477-16508.
- [12] Xiang Z C, Zhao H K, Zhao C, et al. Performative debias with fair-exposure optimization driven by strategic agents in recommender systems[C]. *Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Barcelona, 2024: 3507-3517.
- [13] Gou Z, Shao Z, Gong Y, et al. CRITIC: Large language models can self-correct with tool-interactive critiquing[C]. *The 12th International Conference on Learning Representations*. Virtual, 2024.
- [14] Yu W H, Zhang H M, Pan X M, et al. Chain-of-Note: Enhancing robustness in retrieval-augmented language models[C]. *Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Miami, 2024: 14672-14685.
- [15] 吴信东, 卓兴锐, 常永洋, 等. 华谱通: 基于知识推理的家谱问答大语言模型[J]. *软件学报*, 2025, 36(12): 5572-5598.
(Wu X D, Zhuo X R, Chang Y P, et al. Huaputong: Large language model for genealogical question-answering with knowledge reasoning[J]. *Journal of Software*, 2025, 36(12): 5572-5598.)
- [16] Zhao P H, Zhang H L, Yu Q H, et al. Retrieval-augmented generation for AI-generated content: A survey[J/OL]. 2024, arXiv: 2402.19473.
- [17] Shao Z H, Gong Y Y, Shen Y L, et al. Enhancing retrieval-augmented large language models with iterative

- retrieval-generation synergy[J/OL]. 2023, arXiv: 2305.15294.
- [18] Asai A, Wu Z, Wang Y, et al. Self-rag: Learning to retrieve, generate, and critique through self-reflection[C]. The 12th International Conference on Learning Representations. Virtual, 2023.
- [19] Li X, Zhao R, Chia Y K, et al. Chain-of-Knowledge: Grounding large language models via dynamic knowledge adapting over heterogeneous sources[C]. The 12th International Conference on Learning Representations. Virtual, 2024.
- [20] Sun J, Xu C, Tang L, et al. Think-on-Graph: Deep and responsible reasoning of large language model on knowledge graph[C]. The 12th International Conference on Learning Representations. Virtual, 2024.
- [21] 黄俏娟, 曹存根, 王亚, 等. 基于大语言模型的事件常识知识图谱扩展方法[J]. *软件学报*, 2025, 36(9): 4153-4186.
(Huang Q J, Cao C G, Wang Y, et al. Method for expanding event commonsense knowledge graph based on large language models[J]. *Journal of Software*, 2025, 36(9): 4153-4186.)
- [22] Sun J S, Xu C J, Tang L M Y, et al. Think-on-Graph: Deep and responsible reasoning of large language model on knowledge graph[J/OL]. 2023, arXiv: 2307.07697.
- [23] Li X X, Zhao R C, Chia Y K, et al. Chain-of-Knowledge: Grounding large language models via dynamic knowledge adapting over heterogeneous sources[J/OL]. 2023, arXiv: 2305.13269.
- [24] Ma S J, Xu C J, Jiang X H, et al. Think-on-Graph 2.0: Deep and faithful large language model reasoning with knowledge-guided retrieval augmented generation[C]. International Conference on Learning Representations. Virtual, 2024.
- [25] Baek J, Jeong S, Kang M, et al. Knowledge-augmented language model verification[C]. Proceedings of the Conference on Empirical Methods in Natural Language Processing. Singapore, 2023: 1720-1736.
- [26] 林仁, 周国华. 任务分解控制及人员柔性的车间集成调度[J]. *计算机工程与应用*, 2015, 51(4): 11-16.
(Lin R, Zhou G H. Control of task decomposition and scheduling with flexible personnel[J]. *Computer Engineering and Applications*, 2015, 51(4): 11-16.)
- [27] 伍国华, 李冰洁, 袁于斐, 等. 基于任务分解与强化学习的多平台协同火力分配方法[J]. *控制与决策*, 2024, 39(5): 1727-1735.
(Wu G H, Li B J, Yuan Y F, et al. Multi-platform collaborative firepower allocation method based on task decomposition and reinforcement learning[J]. *Control and Decision*, 2024, 39(5): 1727-1735.)
- [28] Huang X, Liu W W, Chen X L, et al. Understanding the planning of LLM agents: A survey[J/OL]. 2024, arXiv: 2402.02716.
- [29] Shen Y, Song K, Tan X, et al. Hugginggpt: Solving ai tasks with chatgpt and its friends in hugging face[C]. Advances in Neural Information Processing Systems 36. New Orleans, 2023: 38154-38180.
- [30] Wang L, Xu W Y, Lan Y H, et al. Plan-and-solve prompting: Improving zero-shot chain-of-thought reasoning by large language models[C]. Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. Toronto, 2023: 2609-2634.
- [31] Wei J, Wang X, Schuurmans D, et al. Chain-of-thought prompting elicits reasoning in large language models[C]. Advances in Neural Information Processing Systems 35. New Orleans, 2022: 24824-24837.
- [32] Kojima T, Gu S S, Reid M, et al. Large language models are zero-shot reasoners[J/OL]. 2022, arXiv: 2205.11916.
- [33] Yao S Y, Zhao J, Yu D, et al. React: Synergizing reasoning and acting in language models[J/OL]. 2022, arXiv: 2210.03629.
- [34] Ho X, Duong Nguyen A K, Sugawara S, et al. Constructing a multi-hop QA dataset for comprehensive evaluation of reasoning steps[C]. Proceedings of the 28th International Conference on Computational Linguistics. Barcelona, 2020: 6609-6625.
- [35] Yang Z L, Qi P, Zhang S Z, et al. HotpotQA: A dataset for diverse, explainable multi-hop question answering[C]. Proceedings of the Conference on Empirical Methods in Natural Language Processing. Brussels, 2018: 2369-2380.
- [36] Trivedi H, Balasubramanian N, Khot T, et al. μ MuSiQue: Multihop questions via single-hop question composition[J]. *Transactions of the Association for Computational Linguistics*, 2022, 10: 539-554.
- [37] Shinn N, Cassano F, Gopinath A, et al. Reflexion: Language agents with verbal reinforcement learning[C]. Advances in Neural Information Processing Systems 36. New Orleans, 2023: 8634-8652.

作者简介

金宗瀚 (2002–), 男, 硕士生, 主要研究方向为数据挖掘、智能体, E-mail: 3021209069@tju.edu.cn;

吴李康 (1996–), 男, 助理教授, 博士, 主要研究方向为数据挖掘、大模型、信息系统, E-mail: wulk@tju.edu.cn;

刘玉祥 (1980–), 男, 讲师, 硕士, 主要研究方向为运动分析、人工智能应用, E-mail: 1249905835@qq.com;

何明 (1987–), 男, 高级工程师, 博士, 主要研究方向为智能体、数据挖掘, E-mail: heming01@foxmail.com;

赵洪科 (1988–), 男, 研究员, 博士, 主要研究方向为算法治理、大模型, E-mail: hongke@tju.edu.cn.