



# 计算机科学

COMPUTER SCIENCE

## 知识图谱的复杂逻辑查询方法研究综述

陈昱胤, 李贯峰, 秦晶, 肖毓航

### 引用本文

陈昱胤, 李贯峰, 秦晶, 肖毓航. 知识图谱的复杂逻辑查询方法研究综述[J]. 计算机科学, 2026, 53(2): 273-288.

CHEN Yuyin, LI Guanfeng, QIN Jing, XIAO Yuhang. [Survey on Complex Logical Query Methods in Knowledge Graphs](#) [J]. Computer Science, 2026, 53(2): 273-288.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

### [基于背景结构感知的小样本知识图谱补全](#)

Background Structure-aware Few-shot Knowledge Graph Completion  
计算机科学, 2026, 53(2): 331-341. <https://doi.org/10.11896/jsjcx.250100107>

### [个性化教育资源推荐综述](#)

Review of Personalized Educational Resource Recommendations  
计算机科学, 2026, 53(2): 1-15. <https://doi.org/10.11896/jsjcx.250700184>

### [基于元学习的跨语言知识图谱实体对齐框架](#)

Cross-language Knowledge Graph Entity Alignment Based on Meta-learning  
计算机科学, 2026, 53(1): 271-277. <https://doi.org/10.11896/jsjcx.241100069>

### [大模型赋能战术对抗仿真实验体系架构及技术路径研究](#)

Research on Architecture and Technology Pathways for Empowering Tactical Adversarial Simulation Experiments with LLMs  
计算机科学, 2026, 53(1): 39-50. <https://doi.org/10.11896/jsjcx.250400064>

### [基于大语言模型的业务流程长尾变化应变方法](#)

LLM-based Business Process Adaptation Method to Respond Long-tailed Changes  
计算机科学, 2026, 53(1): 29-38. <https://doi.org/10.11896/jsjcx.250100001>

# 知识图谱的复杂逻辑查询方法研究综述

陈昱胤 李贯峰 秦晶 肖毓航

宁夏大学信息工程学院 银川 750021

宁夏“东数西算”人工智能与信息安全重点实验室 银川 750021

(12023131985@stu.nxu.edu.cn)

**摘要** 复杂逻辑查询作为一种深度挖掘知识图谱底层逻辑关系的技术,旨在通过从现有事实中进行推理,来精准回答复杂查询。该技术在语义搜索、推荐系统等场景中表现优异,促进了知识图谱在人工智能领域的深入发展。然而,目前针对复杂逻辑查询方法的研究仍旧不足,整合大语言模型的系统性综述尤为匮乏。鉴于以上现状,深入探讨了涵盖几何对象、概率分布、模糊逻辑及大语言模型四大类别的复杂逻辑查询技术,全面回顾了现有模型的技术特点,并系统总结了这些方法所采用的典型数据集及评价指标。在此基础上,进一步剖析了各方法的优势与局限,旨在为复杂逻辑查询技术的发展提供全面而深入的理论参考。最后,指出了当前复杂逻辑查询技术面临的挑战,并探讨了潜在的研究方向,为未来技术的革新与发展提供有益启示。

**关键词**: 复杂逻辑查询; 知识图谱; 推理; 大语言模型

中图分类号 TP391.1

## Survey on Complex Logical Query Methods in Knowledge Graphs

CHEN Yuyin, LI Guanfeng, QIN Jing and XIAO Yuhang

School of Information Engineering, Ningxia University, Yinchuan 750021, China

Ningxia Key Laboratory of Artificial Intelligence and Information Security for Channeling Computing Resources from the East to the West, Yinchuan 750021, China

**Abstract** CLQA as a technique for deeply mining the underlying logical relationships within knowledge graphs, aims to accurately respond to complex queries through reasoning from existing facts. This technology occupies an important position in the field of knowledge graph research and has demonstrated significant advantages in various application scenarios such as semantic search and recommendation systems, effectively promoting the widespread application and in-depth development of knowledge graphs in the field of artificial intelligence. However, current research on complex logic query techniques is still scattered, especially a systematic review of integrating large language models is particularly lacking. In light of this, this paper delves into complex logical querying techniques encompassing four major categories: geometric objects, probability distributions, fuzzy logic, and large language models. It comprehensively reviews existing models and systematically summarizes the typical datasets and evaluation metrics employed by these methods. Building on this foundation, the paper further analyzes the strengths and limitations of each method, aiming to provide comprehensive and in-depth insights into the development of complex logical querying techniques. Finally, the paper identifies the challenges currently faced by complex logical querying technologies and discusses potential research directions, offering valuable insights for future technological innovation and development.

**Keywords** Complex logical querying answering (CLQA), Knowledge graph (KG), Inference, Large language model

## 1 引言

随着人工智能技术的迅猛发展,知识图谱在多个领域的应用逐渐显现出重要性。作为一种强大的信息管理和表示方式,知识图谱通过将现实世界中的实体及其关系以图形化的方式呈现,极大地提升了机器对信息的理解与处理能力。知

识图谱不仅是对大量信息的存储,还通过将现实世界中的实体(如人、地点、事件等)以及它们之间的关系(如亲属关系、地理位置、时间顺序等)以图形化的方式表示,使得机器可以更加精准地理解和推理人类语言。这种图形化的网络结构对于信息的组织、检索和分析具有至关重要的作用。在语义搜索领域,谷歌的知识图谱已经跨越了传统关键词搜索,能提供更

到稿日期:2025-04-08 返修日期:2025-09-11

基金项目:宁夏全职引进高层次人才科研启动项目(2023BSB03066);宁夏自然科学基金(2024AAC03098);国家自然科学基金(62066038)

This work was supported by the Key Research and Development Program of Ningxia(2023BSB03066), Natural Science Foundation of Ningxia(2024AAC03098) and National Natural Science Foundation of China(62066038).

通信作者:李贯峰(ligf@nxu.edu.cn)

加丰富和精准的搜索结果;在推荐系统中,知识图谱帮助理解用户兴趣,并提供更加个性化的推荐内容。

与此同时,知识图谱在精准医疗、智能问答系统、自动驾驶等领域的广泛应用,进一步凸显了它在现代信息技术中的核心地位。以搜索引擎为例,谷歌的知识图谱已被用于提供更加精准的搜索结果,帮助用户快速找到相关信息。在医疗领域,利用知识图谱进行疾病诊断和药物推荐,已经在多个研究中被证明能够显著提高治疗的准确性。然而,随着知识图谱规模的不断膨胀和应用范围的不断拓展,如何有效解决数据的不完整性、查询低效和推理问题,已成为知识图谱研究中的核心挑战,尤其在复杂逻辑查询任务中,这一问题更加突出。

传统的查询方法通常难以应对复杂的逻辑结构和信息缺失问题,特别是在处理多跳推理和模糊关系时表现出效率低下和精确度不足的缺点<sup>[1]</sup>。为了应对这些挑战,基于神经网络和深度学习的复杂逻辑查询方法应运而生,这种方法通过高效的学习和推理机制,能够在动态变化的知识图谱中处理复杂的查询需求,显著提升了查询的精度和推理的灵活性<sup>[2]</sup>。

目前,大多数综述文章主要集中在知识图谱领域,而复杂逻辑查询是知识图谱领域的一个重要研究方向。在复杂逻辑查询的综述中,研究者通常将其分为基于规则的查询和基于嵌入的查询<sup>[3]</sup>。然而,以往的研究往往将基于神经网络的方法和大模型分开阐述<sup>[4-5]</sup>。本文则聚焦于基于知识图谱嵌入的复杂逻辑查询,旨在整合神经网络方法和大模型的应用,提供一个更为全面的视角。本文根据复杂逻辑查询方法在知识表示方式、逻辑推理机制和对知识图谱数据特性的适配程度等方面的内在差异,将现有方法系统地分为基于几何对象、概率分布、模糊逻辑和大语言模型 4 个类别,并从这 4 个角度对最新的研究方法进行了详细的阐述和总结。本文主要贡献如下:

- (1) 将现有方法分类并加入大模型进行对比,角度新颖;
- (2) 对现有复杂逻辑查询方法分类,分别从几何对象、概率分布、模糊逻辑和大语言模型这 4 个角度进行详细分析;
- (3) 通过对现有典型数据集的分析,总结了在评估模型性能和泛化能力时评估指标的使用情况及其局限性;
- (4) 在分析当前技术挑战的基础上,提出新的研究可能,为复杂逻辑查询的进一步优化和应用提供了新的思路。

本研究旨在对现有的复杂逻辑查询方法进行全面回顾和分析。首先,介绍知识图谱及其在各个领域的应用;然后,重点讨论复杂逻辑查询的定义、发展历程与主要技术,详细探讨基于几何对象、概率分布、模糊逻辑和大语言模型的查询方法;最后,总结现有研究的优势与局限,展望复杂逻辑查询技术在未来人工智能和知识图谱领域的潜力与发展方向。

## 2 相关工作

### 2.1 知识图谱

知识图谱通过对错综复杂的文档数据进行有效的加工、处理、整合,将其转换为简单、清晰的“实体,关系,实体”的三元组,最后聚合大量知识,实现知识的快速响应和推理。

三元组是知识图谱的一种通用表示方式,即  $G \in (E, R, S)$ 。其中,  $E = \{e_1, e_2, \dots, e_{|E|}\}$  是知识库中的实体集合,共包含  $|E|$  种不同实体;  $R = \{r_1, r_2, \dots, r_{|R|}\}$  是知识库中的关系集合,共包含  $|R|$  种不同关系;  $S \subseteq E \times R \times S$  代表知识库中的三元组集合,三元组的基本形式主要包括实体 1、关系、实体 2 和概念、属性、属性值等。实体是知识图谱中最基本的元素,不同实体间存在不同的关系<sup>[6]</sup>;概念主要指集合、类别、对象类型、事物的种类,如人物、地理等;属性主要指对象可能具有的属性、特征、特性、特点以及参数,如国籍、生日等;属性值主要指对象指定属性的值,如中国、1988-09-08 等。每个实体(概念的外延)可用一个全局唯一确定的 ID 来标识,每个属性-属性值对(Attribute-Value Pair, AVP)可用来刻画实体的内在特性;而关系可用来连接两个实体,刻画它们之间的关联。

如图 1 所示,知识图谱是由大量事实三元组组成的。例如,图灵奖获得者是 Pearl 和 Hinton 等,这些三元组是真实世界中的知识,可以用“实体-关系-实体”的形式表示,其中实体表示头或尾,关系表示两个实体之间的关联。然而,真实世界中的知识是无限增长的,而知识图谱无法包含所有的知识。因此,需要在知识库中进行知识补全或链接预测<sup>[7]</sup>。

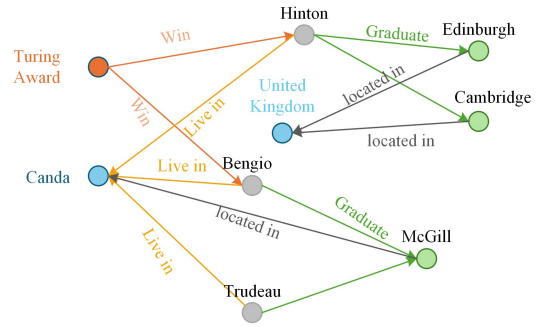


图 1 知识图谱

Fig. 1 Knowledge graphs

知识图谱的应用领域非常广泛,它已经成为许多智能系统的核心组件。在搜索引擎中,知识图谱有助于提供更加丰富和准确的搜索结果,通过链接到相关的实体和概念,使用户能够更快地找到所需信息。在推荐系统中,知识图谱可被用于分析用户的兴趣和偏好,从而提供更加个性化的内容推荐<sup>[8]</sup>。在自然语言处理领域,知识图谱可以增强机器对语言的理解能力,使得机器能够更好地理解用户的意图和上下文。此外,知识图谱还可以用于智能问答系统,通过链接到相关的知识,快速准确地回答用户的问题。尽管知识图谱在理论和实践中都取得了显著的进展,但它的构建和应用仍然面临一些挑战。例如,如何确保知识图谱中数据的质量和可靠性,如何处理知识图谱的实时更新问题,以及如何支持多语言和跨文化的情境等<sup>[9]</sup>。此外,随着知识图谱规模的不断扩大,如何有效地管理和维护这些知识也成为一个问题。

### 2.2 一阶逻辑

在知识图谱中,复杂逻辑查询尤为重要,因为知识图谱的数据结构通常包含丰富的实体关系和属性信息。通过使用复杂逻辑,可以构建出能够表达复杂逻辑查询条件的查询语句,

从而实现从知识图谱中深层次信息的提取和推理<sup>[10]</sup>。

复杂逻辑是指涉及多层条件、嵌套关系和高级运算的逻辑表达形式,被广泛用于处理复杂的信息和决策问题。而在查询中,会将复杂的逻辑查询命题转换为简单的原子命题。如果一个命题不能分解成更小的命题,它就被称为原子命题<sup>[11]</sup>。原子命题的例子包括“所有人都会死”“苏格拉底是人”和“苏格拉底是会死的”,它们可以分别表示为  $P, Q$  和  $R$ 。每个原子命题都被赋予一个二进制真值,这被称为解释。例如,  $P$  为 True, 表示为  $I(P)=1$ 。原子命题可以通过逻辑连接词(或逻辑运算符)来定义更复杂的命题,包括否定( $\neg$ )、析取( $\vee$ )、合取( $\wedge$ )和蕴涵( $\rightarrow$ )。逻辑连接词可以被视为以命题为参数并输出更复杂命题的函数。复合命题的真值由每个逻辑连接的真值表决定。例如,如果  $I(\neg P)=1$ , 则  $I(P)=0$ 。这些运算符不是独立的,它们中的任何两个都可以定义另外两个。

一阶逻辑(First-Order Logic, FOL)中主要包含量化量词和逻辑连接词。其中,量化量词包括全称量词( $\forall$ 表示“对于所有”)和存在量词( $\exists$ 表示“存在”),通过量化量词来量化变量;逻辑连接词包括与( $\wedge$ )、或( $\vee$ )、非( $\neg$ )、蕴含( $\rightarrow$ )、等价( $\leftrightarrow$ )等,用于构建复合语句。一阶逻辑是知识图谱中常用的逻辑框架之一,特别是在描述实体之间的关系和属性时。例如,在知识图谱中,可以使用一阶逻辑来表达“所有人都是哺乳动物”,其一阶表达式为  $(\forall x(\text{Human}(x) \rightarrow \text{Mammal}(x)))$ 。这种表达能力使得一阶逻辑成为知识表示和推理的强大工具。

### 2.3 复杂逻辑查询的定义和特点

复杂逻辑查询是一种高级的数据检索技术,它允许用户通过构建包含多个条件、逻辑运算符和嵌套查询的查询语句来精确地定位和检索数据。这种查询方式超越了简单的关键词搜索,能够深入挖掘数据的内在联系和属性,为用户提供更加丰富和精确的信息。

在进行复杂逻辑查询时,一般会将 FOL 查询转换为具有有向无环图(Directed Acyclic Graph, DAG)结构的计算图,借助该计算图,可以使用嵌入空间中的逻辑运算迭代计算查询表示,如图 2 所示。在数据库查询中,复杂逻辑允许对多个条件进行组合和嵌套查询,从而获得更精确的结果<sup>[12]</sup>。复杂逻辑的主要组成部分包括复合条件、嵌套查询、量词逻辑、时态逻辑、模态逻辑、逻辑推理和谓词逻辑等,这些技术在知识图谱的查询和应用中扮演着关键角色。用户可以利用布尔逻辑运算符,如 AND, OR 和 NOT 来组合不同的查询条件,实现条件的交集、并集或差集。例如,用户可能想要找到同时满足多个属性的所有记录,或者排除包含某些特定属性的记录。此外,复杂逻辑查询还支持使用比较运算符,如等于、不等于、大于、小于等,来对数据的数值或日期等属性进行筛选<sup>[13]</sup>。为了进一步增强查询的灵活性和精确度,复杂逻辑查询还支持使用通配符和正则表达式进行模式匹配,以及使用括号来明确运算的优先级。这使得用户能够构建更加复杂的查询语句,如嵌套查询,其中可以将一个查询作为另一个查询的条件或结果。在实际应用中,复杂逻辑查询被广泛应用于数据库管理、搜索引擎、数据分析和信息检索等领域。例如,在数据库中,复杂逻辑查询可以帮助用户快速定位到具有特定属性组合的记录;在搜索引擎中,它可以帮助用户缩小搜索范围,找到更加相关的搜索结果;在数据分析中,它可以用来筛选和聚合数据,以支持决策制定。然而,复杂逻辑查询也带来了一定的挑战,如查询语句的编写可能相对复杂,需要用户具备一定的逻辑推理能力和对数据结构的理解<sup>[14]</sup>。此外,对于数据库系统来说,处理复杂的查询语句可能会增加计算负担,影响查询性能。总的来说,复杂逻辑查询是一种强大的工具,它通过提供丰富的查询选项和灵活的逻辑组合,帮助用户深入挖掘数据的潜在价值,实现更加精确和高效的信息检索。随着技术的发展和用户需求的提高,复杂逻辑查询将继续在各个领域发挥重要作用,推动数据利用的深度和广度。




图 2 将 FOL 转换为 DAG

Fig. 2 Convert FOL to DAG

## 3 复杂逻辑查询方法

目前,用于解决复杂逻辑查询的方法包括:(1)几何对象;(2)概率分布;(3)模糊逻辑;(4)大语言模型。

本章根据上述类别,分别阐述复杂逻辑查询方法中的发展与改进,并且在每一节中总结了近年来的研究成果。由于方法数量多,本文将模型用时间轴的方式呈现,如图 3 所示。




图3 模型时间轴

Fig. 3 Model timeline

### 3.1 几何对象

较为复杂的问题可能有多个答案实体,因此将这种复杂问题表示成单一的向量显然不合理。从几何上看,利用几何对象覆盖语义空间中的某个范围,被覆盖的实体可以有多个,其从直观上更为合理。这些方法被称为几何对象方法,它们使用点(如 GQE<sup>[15]</sup>),盒(如 Query2Box<sup>[16]</sup>, NewLook<sup>[17]</sup>, Query2Geom<sup>[18]</sup>, RotatE-Box<sup>[19]</sup>, OMCQA<sup>[20]</sup>),锥(如 ConE<sup>[21]</sup>),庞加莱球中的双曲面(如 HypE<sup>[22]</sup>),以及基于层代数的知识层嵌入(Knowledge Sheaves<sup>[23]</sup>)等来表示查询集。通过这些几何对象,复杂逻辑查询中的多答案实体可以被自然地表达,同时支持合取、析取、补集等多种逻辑操作,使得几何表示学习在复杂逻辑查询中展现出高效且直观的特点。

在复杂逻辑查询任务中,点嵌入方法是最早用于构造查询表示的几何范式。以 GQE<sup>[15]</sup> 为代表,该方法将查询表示为低维向量点,并通过几何操作(如平移和旋转)执行逻辑推理。GQE 在早期 CLQA 任务中表现出优越的计算性能,其点嵌入机制使得模型可以在大规模知识图谱中实现快速推理,适合合取与简单投影类查询。然而,其表达能力有限,不支持否定与析取等复杂逻辑操作,逻辑封闭性弱,不适合多跳或复杂组合型查询场景。为突破这一局限,ConE<sup>[21]</sup> 提出了锥体嵌入方法,通过将查询表示为二维锥的笛卡尔积扩展了点嵌入的表达空间。它是首个在几何空间中实现合取( $\wedge$ )、析取( $\vee$ )、否定( $\neg$ )3 种核心逻辑操作闭合的模型,具备较高的逻辑完备性,特别是在涉及逻辑复杂度较高及包含否定条件的 CLQA 任务中表现出显著优势。但是,其计算复杂度高于 GQE,在高维空间下存在效率瓶颈。在复杂逻辑表达和多跳查询任务中,相比于 GQE,ConE 能够更自然地表示查询的范围和逻辑关系,特别是在复杂逻辑查询中的表现显著优于点嵌入。ConE 的逻辑算子如图 4 所示。然而,点及锥体的表示在多解查询场景和高维复杂查询中的表达能力仍然有限。

尽管 ConE 实现了逻辑表达能力的跃升,但点与锥体的几何结构在处理高维空间下的复杂交互和多解问题时仍存在表达瓶颈,难以全面刻画查询的语义边界等问题。因此,后续方法逐步引入更具结构灵活性和表示能力的几

何对象,如高维盒和超球体嵌入,进一步拓展了复杂查询的建模范式。

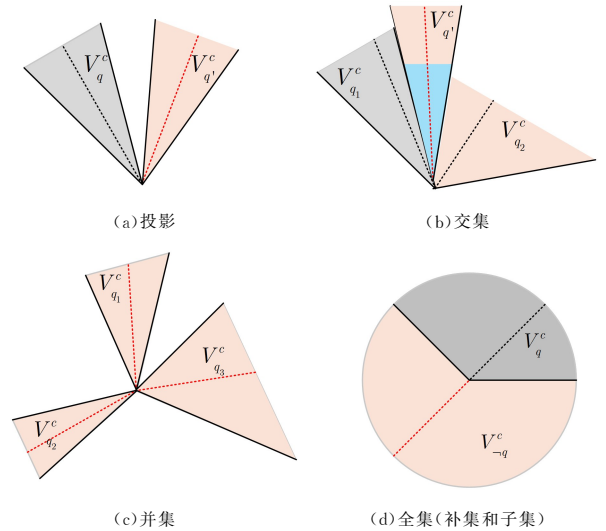


图4 ConE的逻辑算子

Fig. 4 ConE's logical operators

随着研究的深入,盒嵌入方法逐步成为表示复杂逻辑查询的一种主流几何方法。与点嵌入不同,Query2Box<sup>[16]</sup> 将查询表示为高维盒子,自然支持查询范围的多解表示,特别适用于多跳路径与集合查询场景,是 CLQA 中处理查询答案空间非单点特性的有效模型。其通过交集和析取操作构建复杂逻辑表达结构,逻辑支持较好。但是,其对否定支持较弱,且高维计算较为复杂。其逻辑操作如图 5 所示。

后续方法在盒嵌入框架上进行了多维扩展与优化。NewLook<sup>[17]</sup> 针对 Query2Box 中的线性变换假设所带来的表达瓶颈,在其基础上引入了神经网络来对投影、交集、差集等逻辑操作进行非线性建模,有效缓解了级联误差的累积问题,并扩展了支持的逻辑操作范围(如差集)。NewLook 不仅能够同时生成多个变量节点的几何表示,提升查询表达能力,还为图匹配提供了有效的剪枝机制。NewLook 尽管在逻辑操作的支持范围和表达能力上有所提升,但其计算复杂度相应增加,且在高维空间中处理否定逻辑时仍面临挑战。




图5 Query2box中的两个逻辑操作的几何直观和距离函数

Fig. 5 Geometric intuition and distance functions of two logical operations in Query2box

在盒嵌入模型基础上, Query2Geom<sup>[18]</sup>与 RotatE-Box<sup>[19]</sup>通过引入更为复杂的几何对象(如超球体、旋转盒等),进一步提升了逻辑推理的能力,支持包括正则表达式逻辑在内的复杂逻辑操作。尽管这些方法在逻辑封闭性上取得了显著进展,但随着几何对象复杂度的提升,其可解释性有所减弱,且计算效率显著降低,尤其是在处理高维复杂查询时,计算成本大幅增加。尽管如此,高阶几何嵌入方法在处理复杂逻辑操作与大规模答案集合时仍展现出强大的逻辑推理能力。

然而,盒嵌入方法在面对高维复杂查询时仍存在计算效率瓶颈,尤其在处理否定逻辑(¬)方面缺乏统一的建模框架。为此,后续研究引入了更为多样的几何表示方式。

例如, HypE<sup>[22]</sup>通过在庞加莱球中使用双曲面嵌入表示查询,捕获了知识图谱中的层次信息,并通过动态调整计算图提升了复杂逻辑查询的效率。相比于盒嵌入, HypE在层次化知识图谱中具有更强的表示能力,但仍无法支持否定逻辑(¬)。针对不完整知识图谱中事实缺失的问题, OMCQA<sup>[20]</sup>则结合了几何嵌入与本体推理,扩展了 Query2Box 框架,通过引入本体驱动的查询重写和约束增强技术,实现了归纳推

理与演绎推理的结合。这使模型能够捕捉由本体蕴含规则隐含的查询包含关系,从而更准确地推理出缺失事实,尤其适用于领域知识密集型的场景。另一方面, Knowledge Sheaves<sup>[23]</sup>将知识图谱嵌入建模推广到层代数(Sheaf Theory)框架中,通过在拓扑结构上定义局部一致性约束和全局调和扩展(Harmonic Extension),首次在理论上统一了结构化嵌入模型的表达能力。该模型不仅能够处理多跳推理和复杂逻辑查询,还支持对拓扑一致性和实体类型的精细控制,适用于任意结构的复合查询图。

综上所述,基于几何对象的方法按照点→盒→高阶结构逐步演化,不断提升查询表示的覆盖性与逻辑支持范围,在逻辑推理的形式化和复杂性处理上展现出独特优势,但其复杂的计算结构可能限制实际应用中的扩展性。基于几何对象的处理方法通常具有很强的几何先验性,这样可以更好地模拟或满足逻辑或集合操作的属性。未来研究中,如何在保持逻辑封闭性的同时兼顾计算效率与可解释性,仍是几何方法面临的重要挑战。这些模型的嵌入空间和逻辑操作的公式描述如表1所列。

表1 几何对象空间

Table 1 Geometry object space

方法	嵌入空间	关系投影	交集	并集	否定
GQE	$\mathbf{q}, \mathbf{r} \in \mathbb{R}^{2d}, \mathbf{e} \in \mathbb{R}^d$	$\mathbf{q}' = R, \mathbf{q}$	$q_c = MLP([q_1, q_2, \dots])$ $q_c = Attn(\{q_c^i\})$	—	—
Q2B	$\mathbf{q}, \mathbf{r} \in \mathbb{R}^{2d}, \mathbf{e} \in \mathbb{R}^d$	$\mathbf{q} + \mathbf{r}$	$q_o = \min(\{q_o^i\}) \odot \sigma(DS(\{q_o^i\}))$	DNF	—
ConE	$\mathbf{q}, \mathbf{r} = (\theta_{ax}, \theta_{ap})$ $\mathbf{e} = (\theta_{ax}, 0)$ $\theta_{ax} \in [-\pi, \pi]^d$ $\theta_{ap} \in [0, 2\pi]^d$	$g(MLP(\mathbf{q} + \mathbf{r}))$ $g \text{ gates } \theta_{ax} \text{ and } \theta_{ap}$	$\theta_{ax} = \text{SemanticAvg}(q_1, \dots, q_n)$ $\theta_{ap} = \text{CardMin}(q_1, \dots, q_n)$	DNF/DM	$\theta_{ax} = \theta_{ax} \pm \pi$ $\theta_{ap} = 2\pi - \theta_{ap}$
Hype	$\mathbf{q}, \mathbf{r} \in \mathbb{R}^{2d}, \mathbf{e} \in \mathbb{R}^d$	$\mathbf{q} \oplus \mathbf{r}$	$q_c = Attn(\{q_c^i, x^i\})$ $q_o = \min(\{q_o^i\}) \odot \sigma(DS(\{q_o^i\}))$ $q_c = Attn(\{q_c^i, x^i\})$	DNF	—
Newlook	$\mathbf{q}, \mathbf{r} \in \mathbb{R}^{2d}, \mathbf{e} \in \mathbb{R}^d$ $\mathbf{x} \in \mathcal{T}^{ \mathcal{R}  \times  \mathcal{E}  \times  \mathcal{E} }$	$MLP[MLP(q_c + r_c) \parallel MLP(r_o) \parallel x_i]$	$q_o = \min(\{q_o^i\}) \odot \sigma(DS(\{q_o^i\}))$	DNF	$Attn(\{q_c^i\})$ $Attn(\{q_o^i, x^i\})$
RotaE-Box	$\mathbf{q}, \mathbf{r} \in \mathbb{C}^{2d}, \mathbf{e} \in \mathbb{C}^d$	$(q_c \circ r_c, q_o + r_o)$	—	DNF/DS( $\{q^i\}$ )	—
Query2 Geom	$\mathbf{q}, \mathbf{r} \in \mathbb{R}^{2d}, \mathbf{e} \in \mathbb{R}^d$	$\mathbf{q} + \mathbf{r}$	$q_c = \frac{1}{2}((q_c^i + q_o^i) + (q_c^i - q_o^i))$ $q_o = q_o - (q_c^i - q_o^i)$	DNF	—

### 3.2 概率分布

考虑到知识的模糊性,概率分布被广泛用于表达知识的多个语义,以建模不确定性并支持逻辑推理。基于概率分布的复杂逻辑查询经历了从简单分布(高斯分布、Beta分布)到混合分布(混合高斯分布)的演进过程。早期模型(如 GaussianPath<sup>[24]</sup>和 BetaE<sup>[25]</sup>)注重不确定性建模和逻辑运算的封闭性,而后续模型(如 PERM<sup>[26]</sup>, GammaE<sup>[27]</sup>和 NMP-

QEM<sup>[28]</sup>)逐渐扩展到更复杂的分布建模与逻辑操作支持。

GaussianPath<sup>[24]</sup>是该领域的早期工作之一,通过引入高斯分布来建模知识图谱中实体和关系的不确定性。其核心思想是利用高斯分布的均值表示语义位置,用方差表示关系或实体的不确定性。

然而, GaussianPath存在显著局限。尽管该方法在不确定性建模和路径推理中表现出色,但其并未处理复杂逻辑运

算(如交集、联合和补集等)的封闭性问题。这使得 Gaussian-Path 的应用范围局限于多跳路径推理,而难以支持复杂逻辑查询任务。此外,其主要依赖高斯分布的对称性假设,对知识图谱中常见的非对称或层次关系的支持较弱。

为提升逻辑表达能力,PERM<sup>[26]</sup> (Probabilistic Entity Representation Model)改进了高斯建模的表达能力,通过多元高斯分布建模实体与关系,引入了封闭逻辑操作(如交集和投影)的显式公式,在逻辑表达性上取得突破。其优势在于边界可控、逻辑操作平滑可微,适合需要高精度集合逻辑推理的场景。但其对否定操作的支持不完整,且高斯分布对非对称关系的建模能力不足,影响了对复杂异构结构的泛化。然而,PERM 对补集运算的支持仍然有限,这使得其在完整逻辑推理中的表现不如 BetaE<sup>[25]</sup>。此外,高斯分布的假设也限制了 PERM 在非正态分布任务中的泛化能力。为了弥补高斯分布在逻辑运算上的不足,BetaE 提出了使用 Beta 分布建模实体和查询的框架。Beta 分布定义在  $[0,1]$  区间内,其概率密度函数能够自然表达实体的不确定性和模糊性。BetaE 的最大创新在于,其首次实现了全套一阶逻辑运算的封闭性,包括存在量化( $\exists$ )、交集( $\wedge$ )、联合( $\vee$ )和否定( $\neg$ )。在 CLQA 任务中,特别是涉及补集或否定逻辑的场景下,BetaE 表现突出,是目前逻辑完备性最强的概率方法之一。其不足在于,对多模态或非对称分布表达力弱,在表达复杂结构或非标准知识图谱时存在泛化限制。为进一步提升逻辑操作的封闭性与模型的表示能力,GammaE<sup>[27]</sup> 通过引入 Gamma 分布,进一步强化了逻辑操作的线性表达能力与高效计算结构。该方法弥补了 BetaE 在联合操作效率方面的不足,适合高并发查询与大规模推理任务,具有良好的工程落地潜力。但其在建模复杂语义形状(如多峰或非凸结构)方面存在适配性问题,导致对复杂实体语义空间的拟合能力受到限制。GammaE 的优

势在于其全面支持逻辑运算。相较于 BetaE<sup>[25]</sup> 与 PERM<sup>[26]</sup>,GammaE 在联合逻辑支持的效率和封闭性方面具有显著优势。

然而,由于 Gamma 分布在某些复杂分布(如多峰分布)上的适用性较差,其在处理更高维和复杂任务时可能受到限制。为了突破概率分布假设的限制,LinE<sup>[29]</sup> 抛弃了具体概率分布的假设,直接学习从分布到通用逻辑空间的变换,提升了逻辑表达的灵活性与模型泛化能力。该方法对层级化知识结构(如 WordNet)等具有较强的适应性,适用于结构复杂、概念抽象的图谱推理任务。但其缺乏显式的概率解释机制,对不确定性表达有限,不适合噪声敏感或数据不完整的 CLQA 应用场景。

作为对上述模型能力的综合提升,NMP-QEM<sup>[28]</sup> 使用混合高斯分布建模答案集合,以灵活表达真实知识图谱中复杂分布的特性。混合高斯分布通过多个均值和协方差矩阵的组合,能够近似任意复杂分布。NMP-QEM 的另一大创新是,通过神经网络定义逻辑运算(包括投影、交集和补集),解决了混合分布补集运算的封闭性问题。NMP-QEM 的混合分布建模为复杂逻辑查询提供了前所未有的灵活性,能够适应真实知识图谱中的多模态和复杂分布。然而,NMP-QEM 的计算成本较高,特别是在大规模知识图谱上的应用可能受到限制。

总而言之,概率分布方法在 CLQA 中的最大优势是自然处理语义不确定性与模糊边界,逻辑操作可以通过概率闭合支持较好建模。例如,BetaE 适合否定查询,GammaE 适合效率优先任务,NMP-QEM 适合表达能力复杂的场景。然而,这些方法普遍面临逻辑操作公式复杂、计算开销大、不易解释等现实问题,需要在语义精度与推理效率之间做出取舍。这些模型的嵌入空间和逻辑操作的公式描述如表 2 所列。

表 2 概率分布空间

Table 2 Probability distribution space

方法	嵌入空间	关系投影	交集	并集	否定
BetaE	$q, e \in \mathbb{R}^{2d}$	$MLP_r(q)$	$q = [(\sum w_i \alpha_i, \sum w_i \beta_i)]$	DNF/DM	$\frac{1}{q}$
PERM	$q, e, r = \mathcal{N}(\mu, \Sigma)$	$\mathcal{N}(\mu_q + \mu_r, (\Sigma_q^{-1} + \Sigma_r^{-1})^{-1})$	$\Sigma_q^{-1} = \Sigma_{q_1}^{-1} + \Sigma_{q_2}^{-1}$ $\mu_q = \Sigma_q (\Sigma_{q_1}^{-1} \mu_1 + \Sigma_{q_1}^{-1} \mu_2)$	$\text{Attn}(\{q_i\})$	—
GammaE	$q, e \in \mathbb{R}^{k \times h}$	$MLP_r(q)$	$\min\{q_1, q_2\}$	$\max\{q_1, q_2\}$	$\left[\frac{1}{p_1^q}, \dots, \frac{1}{p_k^q}\right]^h$
LinE	$q, e \in \mathbb{R}^{2d}$	$MLP_r(q)$	$q = [(\sum w_i \alpha_i, \sum w_i \beta_i)]$	$\text{Attn}(\{q_i\})$	$\left[\frac{1}{\alpha}, \beta\right]^h$
NMP-QEM	$e \in \mathbb{R}^d$ , $q = \sum_{i=1}^K \omega_i \mathcal{N}(\mu_i, \Sigma_i)$	$MLP_r(q)$	$\text{Attn}(\{q_i\})$	DNF	$MLP_r(q)$

### 3.3 模糊逻辑

几何对象方法和概率分布方法都需要在新的向量空间中定义逻辑运算,但所定义的逻辑运算不一定封闭,很多性质并不是定义良好的,缺乏数学解释。因此,人们考虑利用数学中的模糊逻辑领域里已被深入研究的模糊逻辑。具体地,模糊逻辑方法将查询集视为模糊集,其中的推理由模糊操作执行。模糊逻辑处理方法直接使用现有的模糊逻辑理论对所有逻辑运算建模,从而避免了前两种处理方法需要手动设计或学习

神经逻辑算子的不足,而是直接使用表示为向量上的可微元元素代数算子的既定模糊算子。虽然交、并、负是非参数的,但投影算子仍然可以用神经网络参数化。

EmQL<sup>[30]</sup> 是最早将模糊逻辑系统性引入复杂逻辑查询的模型之一。它基于模糊集合的 T 范数和余范数,支持包括存在量词( $\exists$ )、合取( $\wedge$ )、析取( $\vee$ )逻辑的连续性,有效地缓解了知识图谱不完整性带来的问题,特别是在逻辑查询结果的柔性表达和优化方面表现良好。然而,EmQL 对否定逻辑

和复杂逻辑操作的支持不足,仅适用于简单逻辑查询。为提升表达能力,TractOR<sup>[31]</sup>与CQD<sup>[32]</sup>相继引入几何增强、近似优化策略,拓宽了模糊逻辑方法的适用范围。尤其是CQD,通过T范数的组合与神经链接预测结合,提升了逻辑操作在近似场景下的精度和效率。但 these 方法仍多局限于基本逻辑形式,对否定逻辑、多分支查询和动态结构等场景的支持有限。随后,LogicE<sup>[33]</sup>提出了通过几何对象(如球体和锥体)表示逻辑运算的创新方法,不仅提升了逻辑操作的灵活性,还在复杂查询场景中展现了更强的几何直观性。但是,其在高维嵌入空间中的效率尚未达到最佳。

2022年,基于模糊逻辑的复杂逻辑查询方法开始被广泛应用。其中,fuzzQE<sup>[34]</sup>通过系统引入模糊集合理论,利用T范数、余范数和否定运算,实现了对复杂逻辑查询的柔性表达。相较于早期的LogicE,FuzzQE在逻辑算子范围及组合表达性方面均实现突破,尤其在处理具有模糊性、不确定性的图谱环境中表现出色。但由于模型结构复杂,其在大规模知识图谱上的推理效率仍有优化空间。同年,ENeSy<sup>[35]</sup>结合模糊逻辑与神经符号推理框架,进一步增强了复杂逻辑查询的泛化能力,通过模态数据的交互支持更多场景应用。但是,其符号投影的计算代价较高,对动态知识图谱的支持尚有限。FLEX<sup>[36]</sup>则通过引入特征逻辑嵌入进一步扩展了模糊逻辑的应用范围,支持多种复杂逻辑运算,相较于ENeSy显著提升了对逻辑公式的嵌入能力。但是,其训练时间较长,且计算复杂度较高。与此同时,GNN-QE<sup>[37]</sup>将神经网络与模糊逻辑结合,用于逻辑操作和关系投影,在处理大规模复杂逻辑查询时效率更高,参数调优能力更强。

2023年,模糊逻辑的应用进一步拓展至时序和动态场,支持时间运算符(如After和Before)的逻辑框架被提出。TFLEX<sup>[38]</sup>首次将模糊逻辑扩展到时序知识图谱中,通过模糊逻辑的时间维度建模实现了对动态场景中复杂查询的支持,填补了此前模型在时序推理上的空白。但是,其在处理大规模时序数据时仍存在性能优化需求。同年,QTO<sup>[39]</sup>提出了

一种基于模糊逻辑的查询计算树优化方法,通过前向-后向传播进行局部优化,不仅进一步提升了查询准确性,还使得复杂查询的可解释性取得了显著进步。Var2Vec<sup>[40]</sup>则通过结合模糊逻辑与变量嵌入,优化了逻辑查询的推理效率。相较于QTO,Var2Vec在推理效率与查询类型覆盖方面展现出更强的实用性与灵活性,成为结构复杂查询建模的一项重要补充。与此同时,CQDA<sup>[41]</sup>通过模糊逻辑的分数校准优化复杂查询任务,进一步减少了对大规模训练数据的需求。但是,其对复杂逻辑公式的支持范围仍相对有限。TAR<sup>[42]</sup>模型提出了在TBox和ABox上跨逻辑空间的推理方法,将模糊逻辑与神经符号推理结合,通过引入知识约束大幅提高了推理的精确性,特别是在处理多模态推理任务时展现了极大的潜力。NQE<sup>[43]</sup>模型进一步拓展了模糊逻辑在复杂查询中的应用范围,其通过双异构Transformer架构支持了N元逻辑查询(包括存在量词、合取、析取和否定),并提出了一种高效的并行算法来处理多种查询形式,显著提升了模型的通用性和扩展性。此外,NQE还引入了基于模糊空间的实体嵌入,有效应对了超关系知识图谱的复杂查询任务。ARN<sup>[44]</sup>通过将模糊逻辑与强化学习框架结合,创新性地将预期嵌入纳入查询推理过程中,优化了逻辑查询在时序场景中的适应性。

2024年,Yin等<sup>[45]</sup>将模糊逻辑与神经符号方法深度融合,提出了一种端到端推理框架FIT,以支持更复杂的逻辑公式。与之前的方法相比,FIT不仅扩展了模糊逻辑的应用范围,还在处理复杂逻辑公式时实现了更高的推理性能和理论完备性。然而,在实时性要求高的场景下,FIT的性能仍有进一步优化空间。

综上,模糊逻辑处理器通过已构建的模糊逻辑形式化框架直接执行查询中的逻辑运算,避免了在(可能)无界的嵌入空间中对神经算子的手动设计和学习过程。随着模型逐步支持更复杂结构、多模态信息与动态时序逻辑,模糊逻辑正逐渐发展为兼具理论严谨性与实际适应性的关键技术路径之一。这些模型的嵌入空间和逻辑操作的公式描述如表3所列。

表3 模糊逻辑空间  
Table 3 Fuzzy logic space

方法	嵌入空间	关系投影	交集	并集	否定
	$e, r \in \mathbb{R}^d, q \in \mathbb{R}^{3d}$	$MIPS(q, [r, e_k, e_t])$	$(q_1 + q_2)/2$ $b_1 \odot b_2$	$(q_1 + q_2)/2$ $b_1 + b_2$	—
CQD	$q, e, r \in \mathbb{C}^d$	$\min_{q_2} d(q_1, r, q_2)$ or $\text{top}_k(d(q_1, r, e_k))$	Product: $q_1 \cdot q_2$ Gödel: $\min(q_1 \cdot q_2)$	$q_1 + q_2 - q_1 \cdot q_2$ $\max(q_1, q_2)$	—
LogicE	$q, e = ([l_i, u_i]),$ $l_i, u_i \in [0, 1]_{i=1}^d$ $r \in \mathbb{R}^d$	$\sigma(\max(0, \max(0,$ $[r, q]F_1)F_2)F_3)$	$([T(l_i^{(1)}, \dots, l_i^{(n)}),$ $T(u_i^{(1)}, \dots, u_i^{(n)})])$ $i=1, \dots, d$	DM	$([1-l_i, 1-u_i])$ $i=1, \dots, d$
TAR	$q, e, r \in \mathbb{R}^d$	$q+r$	Attn( $q_1, q_2$ )	$\max(q_1, q_2)$	$1-q$
Fuzz-QE	$q, e \in [0, 1]^d$	$\sigma(\text{MLP}_r(q))$	Product: $q_1 \cdot q_2$ Gödel: $\min(q_1 \cdot q_2)$	$q_1 + q_2 - q_1 \cdot q_2$ $\max(q_1, q_2)$	$1-q$
ENeSy	$q, e, r \in \mathbb{C}^d$ $p_q, p_e \in \{0, 1\}^{ \mathcal{E} }$ $M_r \in \{0, 1\}^{ \mathcal{E}  \times  \mathcal{E} }$	Neural: $q \cdot r$ Symbol: $g(p_q M_r)^T$ $g = x/\text{sum}(x)$	$g(p_1 \cdot p_2)$	$g(q_1 + q_2 - q_1 \cdot q_2)$	$g\left(\frac{\alpha}{ \mathcal{E} } - p\right)$
FLEX	$q = (\theta_f, \theta_t)$ $\theta_f \in [-L, L]^d$ $e = (\theta_f, 0)$ $\theta_t \in [0, 1]^d$	$g(\text{MLP}([\theta_f + \theta_{f,r},$ $\theta_t + \theta_{t,r}]))$ $g \text{ gates } \theta_f, \theta_e.$	$\theta_f = \sum_i a_i \theta_{q_i, f}$ $\theta_t = \prod_i \theta_{q_i, t}$	$\theta_f = \sum_i a_i \theta_{q_i, f}$ $\theta_t = \sum_i \theta_{q_i, t} -$ $\sum_{1 \leq i < j \leq n} \theta_{q_i, t} \theta_{q_j, t} + \dots +$ $(-1)^{n-1} \prod_i \theta_{q_i, t}$	$\theta_f = L \cdot \tanh(\text{MLP}([\theta_f; \theta_t]))$ $\theta_t = 1 - \theta_i$

(续表)

方法	嵌入空间	关系投影	交集	并集	否定
TFLEX	$q, r = (q_f^e, q_f^i, q_f^l, q_f^t)$ $q_f^e, q_f^i, q_f^l, q_f^t \in \mathbb{R}^d$	Entity, $g(MLP(q+r+t))$	$\sum_i \alpha q_{i,f}^e \otimes_i (\{q_{i,t}^e\})$ , $\sum_i \beta q_{i,f}^i \otimes_i (\{q_{i,t}^i\})$	$\sum_i \alpha q_{i,f}^e \otimes_i (\{q_{i,t}^e\})$ , $\sum_i \beta q_{i,f}^i \otimes_i (\{q_{i,t}^i\})$	$f_{\text{not}}(q_f^e)$ , $!(q_f^i, q_f^l, q_f^t)$
GNN-QE	$q, r \in \mathbb{R}^E$	$\sigma(GNN(q, g))$	$q_1 \cdot q_2$	$q_1 + q_2 - q_1 \cdot q_2$	$1 - q$
QTO	$q, e, r \in \mathbb{C}^d$ $M \in [0, 1]^{ X  \times  E  \times  E }$	$d(q_1, r, q_2)$ $\text{row}_{q_1}(M_r)$	$q_1 \cdot q_2$	$q_1 + q_2 - q_1 \cdot q_2$	$d(q_1, r, q_2)$ $\text{row}_{q_1}$ $(1 - M_r)$
Var2Vec	$q, e, r \in \mathbb{C}^d$ $W \in \mathbb{R}^{2 \times 2d}$	$q_2 = W[q_1, r]$ $d(q_1, r, q_2)$	Product: $q_1 \cdot q_2$ Gödel: $\min(q_1 \cdot q_2)$	$q_1 + q_2 - q_1 \cdot q_2$ $\max(q_1 \cdot q_2)$	$1 - q$
CQDA	$q, e, r \in \mathbb{C}^d$ $W \in \mathbb{R}^{2 \times 2d}$	$\theta = W[q_1, r]$ $\text{top}_k[\rho_\theta(d(q_1, e, e_k))]$	Product: $q_1 \cdot q_2$ Gödel: $\min(q_1 \cdot q_2)$	$q_1 + q_2 - q_1 \cdot q_2$ $\max(q_1 \cdot q_2)$	$1 - q$ $(1 + \cos(\pi q)) / 2$

### 3.4 大语言模型

大语言模型 (Large Language Models, LLMs) 在复杂逻辑查询中展现了独特的优势, 这主要得益于其强大的语言理解和生成能力, 使其能够将逻辑推理问题转换为自然语言处理任务<sup>[46]</sup>。相比传统的概率分布或几何对象方法, LLMs<sup>[47]</sup> 无需在向量空间中手动设计逻辑算子, 而是直接利用预训练的语言知识和上下文推理能力实现端到端推理。这种方法通过自然语言表达动态建模逻辑运算, 具有灵活性和一定的可解释性, 避免了传统方法中逻辑运算不封闭或数学性质不良的不足。

为克服传统 KBQA 系统中结构匹配与推理效率低下的问题, GPT-3<sup>[48]</sup> 等大模型展现了在零样本设置下处理复杂查询任务的能力, 尤其在逻辑推理和多跳问答中具备潜力。Luo 等<sup>[49]</sup> 提出的 ChatRule 框架, 利用大语言模型挖掘知识图谱上的逻辑规则, 以提高推理性能并提供可解释的结果, 借助 LLMs 提升 KB 推理解释性, 弥补 GPT-3 缺乏逻辑显式性的不足。

Liu 等<sup>[50]</sup> 提出了一种基于知识图谱 Transformer 的预训练框架 KG-Transformer, 其通过掩码学习增强模型对复杂逻辑操作的理解, 同时利用稀疏激活策略 (Mixture-of-Experts) 来提高模型的计算效率。相比于 GPT-3 强调语言模型的零样本泛化, KG-Transformer 关注图结构对逻辑理解的增强; 而相比于 ChatRule 只利用 LLMs 生成规则, KG-Transformer 通过掩码逻辑任务让模型内嵌推理能力。该方法的核心创新在于通过掩码任务学习逻辑推理能力, 使模型能够在处理复杂查询时表现出更强的泛化能力和解释性。然而, 该方法主要依赖预训练阶段的静态特征, 因此在适应不同复杂度的查询任务时表现出一定的局限性。

Luo 团队<sup>[51]</sup> 提出的 ChatKBQA 框架开创性地采用微调范式优化 LLMs 的语义解析能力, 构建了“生成-检索”双阶段处理机制。该框架首先通过参数微调的 LLMs 生成初步逻辑形式, 继而引入无监督语义检索模块进行实体与关系的精准匹配, 有效解决了生成结果与知识库模式对齐的难题。Choudhary<sup>[52]</sup> 的 SP-LLM 框架则构建动态子图检索机制, 通过语义解析驱动的上下文选择策略, 确保生成的 SPARQL 查询与知识库模式保持严格兼容。两者均聚焦“自然语言 → 结构逻辑”映射的精度问题, 前者强调生成校正流程, 后者聚焦于结构兼容性约束的动态增强。

类似地, Li 等<sup>[53]</sup> 提出的 UniOQA 框架创新性地采用双

工作流并行架构, 通过翻译器模块将自然语言问句映射为 Cypher 查询语言 (CQL), 配合搜索器模块实现知识图谱的高效遍历, 在复杂多跳推理任务中展现出显著优势。Zhang 团队<sup>[54]</sup> 提出的 FC-KBQA 框架建立细粒度到粗粒度的递进式组合模型, 成功解决了复杂查询中的组件组合爆炸问题。其三级处理架构包含: 基于语义相似度的细粒度组件检测, 基于图连通性的中间粒度约束, 以及基于序列生成的粗粒度组合模块。Taffa 等<sup>[55]</sup> 突破传统微调方法的限制, 提出基于 BERT 的少样本提示策略。该方法通过语义相似度计算构建上下文示例, 引导 LLMs 生成符合知识库模式的 SPARQL 查询, 在低资源场景下保持了较高的泛化能力。Taffa 框架关注资源不足场景下的结构映射能力提升, 是对 ChatKBQA 等重微调范式方法的有效补充。

Jiang 等<sup>[56]</sup> 提出的 ReasoningLM 框架, 创新性地将子图序列化技术与图注意力机制结合, 通过设计子图感知的自注意力模块, 使 LLMs 能够动态捕捉知识图谱中的拓扑关系, 显著增强了多跳推理能力。StructGPT<sup>[57]</sup> 框架则构建结构化数据接口, 采用迭代式查询生成策略, 通过渐进式信息提取逐步逼近目标答案, 在复杂查询处理中展现出独特优势。ReasoningLM 和 StructGPT 皆用于解决“图结构建模”难题, 一个偏向注意力机制的拓扑建模, 一个偏向查询生成的过程控制, 是图谱推理增强的两种技术路径。Hu 等<sup>[58]</sup> 开发的 GMT-KBQA 框架创新性地采用多任务联合学习架构, 通过参数共享机制同步优化实体消歧、关系分类和逻辑形式生成 3 个子任务, 有效提升了知识检索的端到端性能。值得关注的是, Liu 等<sup>[59]</sup> 提出的 ICSU 方法在上下文学习领域取得重要突破。该方法通过设计基于原始问句、匿名化问句和 SPARQL 三元组的混合检索策略, 有效增强了 LLMs 对知识库模式的理解能力。

Agarwal 团队<sup>[60]</sup> 提出的 BYOKG 框架则创新性地引入符号代理引导的图谱探索机制, 通过程序合成技术生成多样化训练样本, 显著提升了模型对异构知识库的适应能力。Li 团队<sup>[61]</sup> 的 KB-BINDER 框架提出两阶段绑定策略, 首先生成逻辑形式的草稿, 再通过 BM25 优化的实体或关系绑定器完成精确匹配, 在开放域知识库问答任务中展现出强大的泛化能力。

此外, Xia 等<sup>[62]</sup> 引入了逻辑感知课程学习 (Logic-Aware Curriculum Tuning, LACT) 框架。该方法将复杂逻辑查询分解为二叉树结构, 结合课程学习策略逐步优化模型的推理能

力。这种动态训练策略有效缓解了预训练模型在复杂任务中的表现瓶颈。然而,LACT的逻辑分解策略在面对跨知识图谱推理时依然存在不足,尤其是对知识图谱上下文信息的利用较为有限。Chakraborty<sup>[63]</sup>提出了一种基于逻辑链分解的框架 LARK (Complex Logical Reasoning Using Large Language Models)。LARK 的核心思想是将复杂逻辑查询分解为多步的单一逻辑操作(如投影、交集等),并结合知识图谱上下文信息进行递归推理。通过逻辑分解和上下文检索的结合,LARK 不仅在性能上显著超越了传统嵌入模型,还展示了在多跳查询中的优越性。然而,该方法对大规模 LLMs 的依赖导致了计算成本的增加,且其在稀疏或不完整知识图谱上的表现仍有改进空间。

为进一步提升推理的可靠性并减少大模型的幻觉问题,Liu 等<sup>[64]</sup>结合知识图谱推理与 LLMs 多轮推理的优势,提出了 Logic-Query-of-Thoughts(LGOT)。LGOT 通过逻辑分解将复杂查询划分为多个易于解答的子问题,并利用知识图谱推理和 LLMs 分别生成子问题的答案,最后通过聚合操作生成最终结果。与 LARK 相比,LGOT 通过知识图谱提供显式逻辑上下文,大幅减少了 LLMs 在推理过程中的错误积累。

进一步地,FiDeLiS<sup>[65]</sup>提出了一种检索-探索交互方法,通过路径检索增强生成(Path-RAG)模块动态生成推理路径,并将演绎验证机制(Deductive Verification)作为路径终止的标准,从而避免了推理路径中的错误积累。这种方法不仅在无需额外训练的情况下显著提升了推理效率,还通过动态调整搜索空间优化了计算成本。相比于 LGOT,FiDeLiS 在推理可靠性与泛化能力方面表现更优。

此外,Hu 等<sup>[66]</sup>提出的 KGQAcl 和 KGQArr 模型通过综合分析不同预训练语言模型(Pretrained Language Models, PLMs)在知识图谱问答(Question Answering over Knowledge Graph, KGQA)中的性能,发现轻量化模型(如 DistilBERT)和知识增强模型(如 KEPLER)在效率和准确性之间取得了良好的平衡。该研究通过引入人类评估和正则表达式匹配,验证了更灵活的评估方法对于复杂逻辑推理的重要性。

然而,LLMs 在应用于 CLQA 时,也面临幻觉生成、结构对齐困难与逻辑封闭性不足等挑战。当前已有研究通过以下两类策略应对这些问题。

#### (1)结构引导与逻辑可控建模

ChatRule<sup>[49]</sup>利用 LLMs 生成逻辑规则,并通过规则筛选与排序提升推理的准确性;KG-Transformer<sup>[50]</sup>在预训练阶段引入掩码逻辑任务以增强推理能力;ChatKBQA<sup>[51]</sup>和 SP-LLM<sup>[52]</sup>则采用“生成-检索”架构提升语义解析与查询结构对齐性能。StructGPT<sup>[57]</sup>和 LACT<sup>[62]</sup>通过逻辑链分解与课程学习策略,引导模型逐步学习复杂逻辑结构,提高逻辑推理的泛化能力。

#### (2)图结构增强与幻觉规避机制

ReasoningLM<sup>[56]</sup>,UniOQA<sup>[53]</sup>和 FC-KBQA<sup>[54]</sup>将子图信息、图连通性和语义组合嵌入模型输入,显著增强了多跳路径识别能力。LGOT<sup>[64]</sup>与 FiDeLiS<sup>[65]</sup>则结合逻辑链分解与知识图谱演绎机制,引入多轮验证与路径约束,有效缓解了模型幻觉问题,提升了推理稳定性与可解释性。此外,轻量化模型(如 DistilBERT 与 KEPLER)的评估研究<sup>[66]</sup>表明,在效率与精度之间仍存在优化空间,未来可通过参数裁剪与知识增强实现部署友好的 CLQA 解决方案。

相较于几何对象、概率分布与模糊逻辑方法,LLMs 方法在可解释性与语义灵活性方面具有显著优势,尤其适用于自然语言输入、多模态融合与开放领域问答任务。但其逻辑封闭性弱,结构对齐难度高,计算成本高,在结构化知识密集或逻辑一致性要求高的 CLQA 应用中仍显不足。

基于大语言模型的处理方法通过利用大规模语料库中蕴含的丰富语义和上下文信息,能够有效地捕捉复杂的语言结构和逻辑推理能力,适应多样化的任务需求,能较好地处理模糊性和开放域问题。同时,这类方法在设计时注重预训练框架的优化和模型的扩展性,结合知识增强和轻量化策略,提高了推理效率和结果的可靠性,展现出了卓越的通用性和可扩展性。

表 4 总结了本章介绍的所有大语言模型增强的复杂逻辑查询方法,包括每种方法的文献和大致原理描述。

表 4 基于大语言模型的复杂逻辑查询方法

Table 4 Complex logical query methods based on large language models

类型	文献	描述
语义解析	[51-61]	语义解析方法将自然语言处理领域的语义解析技术用于知识图谱复杂逻辑查询,主要通过词汇表映射来实现对知识图谱信息的有效利用。这种方法能够通过系统生成的查询语句或逻辑形式清晰地解释系统的答案来源,从而具备较高的可解释性
信息检索	[48-50,62-66]	基于信息检索的知识图谱复杂逻辑查询方法,是通过自动化处理自然语言问题,并从知识图谱中定位和提取相关信息来提供答案的一种技术

## 4 数据集和评估指标

### 4.1 查询类型和数据集

许多模型的数据集中使用的查询集包括 14 种类型:1p/2p/3p/2i/3i/ip/pi/2u/up/2in/3in/inp/pni/pin。其中,p 表示关系投影,i 表示交集,u 表示并集,n 表示否定,数字表示投影查询的跳数或由逻辑运算符合并的分支数。

图 6 展示了常见的查询模式,其中,蓝色节点表示非变量

实体,灰色节点表示变量节点,绿色节点表示答案节点。在一个典型的训练中,模型在 10 个模式(第一和第三行)上进行训练,并在所有模式上进行评估。在最困难的泛化情况下,模型只在 1p 查询上训练。有些数据集使用限定符或时间戳等附加功能进一步修改模式。例如,3p 是 3 个连续关系投影的链式查询;2i 是 2 个关系投影的交集;3in 是 3 个关系投影的交集,其中一个分支包含否定;up 是 2 个关系投影的并集,后面是另一个投影。GQE 引入了 7 种具有投影和交集的查询模

式,即 1p/2p/3p/2i/3i/ip/pi; Query2Box 添加了 2u/up 的联合查询; BetaE 添加了 5 种具有否定的类型。之后的模型修改了查询类型的标准集,如超关系查询在关系投影上使用实体-关系限定符,或者在边缘上使用时间算子。新的查询模式

包括使用关系正则表达式(属性路径)的查询,更多的树状查询,以及更多的投影、交叉点和联合的组合。通常,研究者从不同的 KGs 中采样查询数据集来研究不同图分布下的模型性能。




图6 标准查询模式(电子版为彩图)

Fig. 6 Standard query mode

在复杂逻辑查询中,目前主要使用的典型基准数据集有以下 30 种,统计数据(部分)如表 5 所列。

(1) Drug Interactions: 该数据集基于公共资源的生物医学研究数据集 DrugBank<sup>[67]</sup>。DrugBank 是一个重要的生物信息学资源,它提供了大量关于药物和药物分子的信息,并被广泛应用于药物发现、药物相互作用预测等领域。Drug Interactions 是 DrugBank 衍生出的一个知识图谱,它描述了药物、疾病、基因、解剖结构、途径、生物过程、分子功能、细胞成分、药理学分类、副作用和症状之间的关系。该图谱包含丰富的药物与疾病之间的相互作用信息,为药物重定位和其他生物医学研究提供了重要的数据支持。

(2) Reddit Dynamics<sup>[68]</sup>: 该数据集包含来自 Reddit 社区的帖子和评论数据,被广泛用于社交网络分析、情感分析和社区结构研究等任务。通过这些帖子和评论,研究人员可以分析用户行为、互动模式以及信息传播机制等方面的内容。

(3) bio<sup>[69]</sup>: 该数据集包含来自公共生物医学数据库的知识,包括药物、疾病、蛋白质、副作用和生物过程等节点,共有 42 种关系类型,图中总共有超过 800 万条边连接,97 000 个实体。

(4) FB15K<sup>[70]</sup>: 该数据集是一个经典的知识图谱数据集,来源于 Freebase<sup>[71]</sup>。它包含了 15 000 个实体和 1 000 多种关系类型,被广泛用于评估知识图谱嵌入模型和关系预测任务。该数据集的实体覆盖多领域信息,如人物、地点和组织等。

(5) FB15K-237<sup>[72]</sup>: 该数据集是 FB15K 数据集的改进版本,删除了反向关系,减少了数据集中的噪声。它包含约 237 种关系类型和 15 000 个实体,是知识图谱嵌入领域常用的标准数据集之一。

(6) FB15K-Regex: 该数据集是 FB15K 的一个变体,专门

设计用于关系抽取任务。它通过正则表达式生成了复杂的实体关系,并以此评估嵌入模型在更复杂的关系建模中的能力。

(7) NELL<sup>[73]</sup>: 该数据集包含了从网络上自动学习的知识图谱。它包含了大量的实体及其关系,数据集随着时间不断更新,提供了一个动态的知识库,被广泛用于评估自动知识图谱构建方法。

(8) NELL-995<sup>[74]</sup>: 该数据集是 NELL 数据集的一个子集,包含了 995 种关系类型。它关注于知识图谱的扩展和关系抽取任务,通常用于评估基于图谱的机器学习方法。

(9) WN18RR<sup>[75]</sup>: 该数据集是基于 WordNet<sup>[76]</sup> 构建的知识图谱数据集,旨在评估知识图谱嵌入模型的性能。它包含 18 000 个关系和 40 000 个实体,经过去噪处理后,被许多基准测试任务所使用。

(10) DBPedia<sup>[77]</sup>: 该数据集基于 Wikipedia,提取了结构化的知识图谱。它涵盖了全球范围内的人物、地点、组织等实体,包含了丰富的语义信息,是自然语言处理和语义网研究的重要资源。

(11) DRKG<sup>[78]</sup>: DRKG 是一个针对药物重定位的知识图谱数据集,包含了药物、疾病、基因和化合物等实体。该数据集为药物重定位提供了丰富的知识支持,能够帮助研究人员通过现有药物发现新的治疗用途。

(12) E-commerce Product Network<sup>[79]</sup>: 该数据集包含了来自电子商务平台的商品信息和用户行为数据,被用于研究推荐系统、用户行为分析和产品关系建模等任务。

(13) LUBM (Lehigh University Benchmark)<sup>[80]</sup>: 该数据集是一个用于测试和评估大规模本体推理系统的数据集。它包含了关于大学的各种实体,如教授、课程、学生等,被广泛用于本体和推理研究。

(14) Wiki100-Regex<sup>[81]</sup>: 该数据集是从 Wikipedia 上提取的一个子集, 特别注重关系的抽取和正则表达式的应用, 被用于评估模型在语义关联性和关系推理方面的表现。

(15) GraphQuestions<sup>[82]</sup>: 该数据集是一个针对图数据库问答任务的数据集, 问题涉及图中的节点和边, 适用于图数据的查询和推理任务。

(16) YAGO4<sup>[83]</sup>: 该数据集是一个高质量的知识图谱, 基于 Wikipedia 和 WordNet, 包含了大规模的实体、事件和关系, 被广泛用于知识图谱的推理、查询和知识发现等任务。

(17) WebQuestionSP (WebQSP)<sup>[84]</sup>: WebQSP 是一个用于语义问答的数据集, 专注于从网络上提取答案。它包含了多种类型的问题, 旨在测试机器学习和自然语言处理系统理解和推理问题的能力。

(18) PathQuestion (PQ)<sup>[85]</sup>: 该数据集专注于路径查询任务, 包含从知识图谱中提取的路径, 旨在评估模型处理路径推理和关系链的能力。

(19) PathQuestion-Large (PQL): 该数据集是 PathQuestion<sup>[85]</sup> 的扩展版, 包含了更多的实体和关系。它为路径推理任务提供了更大规模的挑战, 适用于大型图谱中的路径学习和推理。

(20) MetaQA<sup>[86]</sup>: 该数据集是一个多领域问答数据集, 主要用于测试机器学习模型在回答复杂查询时的性能。它提供了多种类型的问题, 并强调模型在多任务学习上的能力。

(21) WD50K<sup>[87]</sup>: 该数据集是一个用于推理的知识图谱数据集, 包含了大量的实体和关系, 适用于图谱推理和关系抽取任务。

(22) WD50K-QE<sup>[88]</sup>: WD50K-QE 是基于 WD50K 数据集扩展的一个查询扩展数据集, 专门用于评估和训练复杂的查询任务。

(23) ICEWS14<sup>[89]</sup>: 该数据集是一个多国政治事件数据集, 记录了全球范围内的政治事件, 如选举、军事冲突等。该数据集适用于政治事件分析、预测和影响分析等任务。

(24) ICEWS05-15<sup>[90]</sup>: 该数据集是 ICEWS14 数据集的扩展版本, 包含了 2005 至 2015 年间的政治事件数据, 被广泛应用于社会网络分析和事件预测等领域。

(25) GDELT-500<sup>[91]</sup>: 该数据集是一个全球事件数据集, 涵盖了从新闻、社交媒体等多种来源收集的事件数据。它用于分析全球范围内的政治、经济和社会事件及其相互关系。

(26) ComplexWebQuestions<sup>[92]</sup>: 该数据集包含复杂的 Web 问答问题, 旨在评估机器学习模型在复杂问题推理中的能力。该数据集涉及到多个领域, 包括社会、科学、文化等。

(27) SimpleQuestions<sup>[93]</sup>: 该数据集包含简单的问答问题, 专注于知识图谱的查询和关系推理。它是评估实体关系抽取和推理模型的重要资源。

(28) FreebaseQA<sup>[94]</sup>: 该数据集是一个以 Freebase 知识图谱为基础的问答数据集。它包含了大量的问答对, 主要用于知识图谱驱动的问答系统研究。

(29) NQ-OPEN<sup>[95]</sup>: NQ-OPEN 是一个由 Google 提出的开放式自然语言理解 (NLU) 数据集, 主要用于开放域问题回答任务 (Open-domain Question Answering)。该数据集基于 TREC 的标准化测试集构建, 旨在评估大规模模型在处理无

结构文本数据时的表现, 特别是在多种问题类型下的推理能力。NQ-OPEN 包含了由实际用户提问的各种问题, 覆盖广泛的主题, 包括新闻、科学、娱乐、体育等。问题不仅包括事实性问答, 还包括理解复杂背景的推理问题, 力图提高模型在自然语言处理中的综合能力。

(30) CuratedTREC 2002<sup>[96]</sup>: 该数据集是一个用于文本分类和信息检索的标准化数据集, 源自 TREC (Text Retrieval Conference) 2002 的官方任务。它包含多类主题的标注数据, 覆盖了包括新闻报道、文档分类等领域的应用。与其他 TREC 数据集相比, CuratedTREC 2002 经过特别处理和优化, 旨在提供一个高质量、可用于训练和评估信息检索模型的数据集。它广泛应用于文本检索、分类和信息提取任务, 具有较高的标准化和较大的挑战性, 适用于开发和评估多种信息检索系统的性能。

表 5 典型基准数据集

Table 5 Typical benchmark datasets

数据集	实体数量	关系数量
Drug interactions	97 000	42
Reddit dynamics	700 000	—
FBI5K	15 000	1 000+
FBI5K-237	15 000	237
FBI5K-Regex	14 951	1 345
NELL	100 000+	100+
NELL-995	100 000+	995
WN18RR	40 000	18
DBPedia	5 000 000+	10 000+
DRKG	97 000	42
E-commerce Product Network	118 000	4
LUBM	50 000+	10
Wiki100-Regex	100	100
YAGO4	2 000 000+	200+
WebQuestionSP	37 000	1 000
PathQuestion (PQ)	14 000	1 200
PathQuestion-Large (PQL)	100 000	1 200
MetaQA	43 234	18
WD50K-NFOL	47 156	532
ICEWS14	7 128	230
ICEWS05-15	10 488	251
GDELT-500	500	20
Complex WebQuestions	81 272	338
GraphQuestions	64 625	715
SimpleQuestions	—	—
FreebaseQA	—	—
bio	97 000	42

## 4.2 数据集处理

在查询中, 有多个数据集被提出, 用于评估查询推理模型的性能。这些数据集通常采用标准的实验设置, 将知识图谱  $G$  分割为训练集  $G_{\text{train}}$ 、验证集  $G_{\text{val}}$  和测试集  $G_{\text{test}}$ 。标准实验方案是仅在训练集  $G_{\text{train}}$  上训练查询推理模型, 并在验证集  $G_{\text{val}}$  和测试集  $G_{\text{test}}$  上回答查询时对模型进行评估。给定一个查询  $q$ , 表示该查询在训练、验证和测试集上的答案为  $[q]_{\text{train}}, [q]_{\text{val}}$  和  $[q]_{\text{test}}$ 。在求值期间, 查询可能有缺失的答案, 如验证查询  $q$  可能有不在  $[q]_{\text{train}}$  中的答案  $[q]_{\text{val}}$ , 测试查询  $q$  可能有不在  $[q]_{\text{val}}$  中的答案  $[q]_{\text{test}}$ 。复杂逻辑查询任务的目标, 就是找到这些缺失的答案。

## 4.3 训练

查询推理方法在具有不同目标/损失和不同数据集的设置下进行训练。按照标准协议, 方法在 10 个查询模式 (1p/

2p/3p/2i/3i/2in/3in/inp/pni/pin)上进行训练,并对所有14个模式进行评估,包括对不可见的ip/pi/2u/up模式的泛化。也就是说,训练协议假设在原子逻辑运算符上训练的模型将学习使用几个运算符(如ip和pi查询)组合泛化到使用交集和投影的模式。

学习图上查询和实体的表示的大多数方法都优化了对比损失,即最小化查询表示 $q$ 与其正确答案 $e$ 之间的距离,而最大化查询表示与负答案 $e'$ 之间的距离0。主要包括以下目标。

(1)最大边际损失。其目标是否定答案的距离至少比肯定答案的距离大 $\gamma$ 。这种损失的形式通常如式(1)所示。

$$\ell = \max(0, \gamma - \text{dist}(q, e) + \text{dist}(q, e')) \quad (1)$$

(2)LogSigmoid损失。其具有类似的目标,将负的距离增大,反之亦然。通常该损失函数通常还包括一个间隔项,当满足该间隔条件时,对应的梯度就会迅速衰减。

$$\ell = -\log \sigma(\gamma - \text{dist}(q, e) - \sum \frac{1}{k} \log \sigma(\text{dist}(q, e') - \gamma)) \quad (2)$$

其中, $k$ 是否定答案的个数。

其他方法直接对图上所有节点的logit向量建模,可以优化交叉熵损失,而不是对比损失。此外,CQD或QTO等方法的两个变体只优化了链接预测损失,因为它们没有学习查询的表示。

现有的大多数方法,如GQE,Query2Box,BetaE,RegEx,BiQE,Query2Onto,TAR,StarQE,GNNQ,TeMP,TFLEX,InductiveQE和SQE等,通常通过从给定结构中采样一组训练查询来进行训练。此种方法的优点在于,训练过程中不需要进行在线查询采样。然而,由于在训练集上存在指数级的多跳查询,这意味着这些方法仅利用了部分信息,且无法离线预生成所有可能的查询,因此这些方法在处理复杂查询时存在一定的局限性。针对这一问题,SMORE方法提出了一种双向在线查询采样器,其能够直接且高效地进行在线查询采样,避免了离线预生成训练集的需求。此外,某些方法(如CQD)采用非参数化的方式处理逻辑操作,仅需一跳边即可完成训练,进一步简化了训练过程。

#### 4.4 评估指标

目前,已有多重度量方法来评估查询推理模型的性能。由于查询推理模型的目的是对大量不完整图进行推理,因此大多数指标被设计为评估模型在发现缺失答案方面的泛化能力,即对于给定的测试查询 $q$ 的 $\llbracket q \rrbracket_{\text{test}} \setminus \llbracket q \rrbracket_{\text{val}}$ 。作为该领域第一批被提出的方法之一,GQE提出了ROC-AUC和平均百分位排名(APR)。其思想是,对于给定的测试查询 $q$ ,GQE计算其所有缺失答案 $e \in \llbracket q \rrbracket_{\text{test}} \setminus \llbracket q \rrbracket_{\text{val}}$ 和负数 $e' \notin \llbracket q \rrbracket_{\text{test}} \setminus \llbracket q \rrbracket_{\text{val}}$ 的分数。评估该模型性能的指标是ROC-AUC分数和APR,实验中将缺失的答案与最多1000个随机抽样的相同实体类型的否定进行排名。除了GQE,GQE+哈希,CGA和Tractor也使用相同的评估指标。然而,上述指标并不能反映现实世界的情况。在现实世界中,通常会得到比缺失答案更多的数量级的负面答案。Query2Box提出了基于排名的指标,如平均倒数排名(MRR)和hits@ $k$ ,而不是ROC-AUC或APR。给定一个测试查询 $q$ ,对于每个缺失的答案 $e \in \llbracket q \rrbracket_{\text{test}} \setminus \llbracket q \rrbracket_{\text{val}}$ ,将其与所有其他的负值 $e' \notin \llbracket q \rrbracket_{\text{test}}$ 进行排序。给定排名 $m$ ,

MRR和hits@ $k$ 的计算式如下所示。

$$\text{MRR} = \frac{1}{m} \sum_{i=1}^m \frac{1}{\text{rank}_i} \quad (3)$$

$$\text{Hits}@k = \frac{1}{m} \sum_{i=1}^m \mathbb{I}(\text{rank}_i \leq k) \quad (4)$$

这是复杂逻辑查询任务中最常用的指标。请注意,最终排名只计算需要预测至少一个缺失环节的硬答案。通过边遍历可获得的简单答案的排名通常被丢弃。

之后,另一类评估标准被提出,用于考查模型是否能够发现现有的答案。例如,测试查询的目标是模型无须推断缺失的链接,而是专注于记忆图结构中的已有答案(即简单答案)。在EmQL中,这一评估标准被称为“忠实度”(或“隐含度”)。对于数据库查询任务,查询回答模型应首先通过边遍历来恢复图中已经存在的简单答案,然后通过链接预测推断出难度较高的答案,以丰富最终的答案集合。因此,衡量模型将简单答案排在困难答案之前的能力是一个自然的指标。这一指标在InductiveQE中得到了探讨,并被建议作为该任务的主要评估标准。

评价指标除了评估模型发现缺失答案的能力外,还应评估模型学习到的查询表示的质量。BetaE提出了一种方法,用于评估学习到的查询表示是否能够有效模拟查询答案集的基数,并将其作为查询表示质量的一个代理。对于那些具有“体积”概念的模型(如Beta嵌入的微分熵),评估的目标是测量查询表示的“体积”与答案集基数之间的关系。具体而言,通过计算查询表示与答案集基数之间的Spearman等级相关系数和Pearson相关系数来进行量化。此外,BetaE还建议通过ROC-AUC来评估模型在没有答案的查询上的建模能力。

在大语言模型中,使用BLEU<sup>[97]</sup>(Bilingual Evaluation Understudy)和ROUGE<sup>[98]</sup>(Recall-oriented Understudy for Gisting Evaluation)来进行模型评估。

BLEU主要评估生成答案与参考答案的相似性,常用于机器翻译任务,但也适用于复杂逻辑查询。其计算方法是生成答案和参考答案的 $n$ -gram重合度:

$$\text{BLEU} = \text{BP} \times \exp\left(\sum_{i=1}^N w_n \ln p_n\right) \quad (5)$$

其中, $p_n$ 是 $n$ -gram的精确度; $w_n$ 是 $n$ -gram的权重;BP是长度惩罚,定义为:

$$\text{BP} = \begin{cases} 1, & c > r \\ e^{1 - \frac{r}{c}}, & c \leq r \end{cases} \quad (6)$$

其中, $c$ 是生成答案的长度, $r$ 是参考答案的长度。

ROUGE(Recall-oriented Understudy for Gisting Evaluation)评估生成文本与参考文本之间的重合度,适用于对生成答案进行质量评估。ROUGE得分是通过计算生成答案和参考答案之间的字词、短语、句子的重合情况而得的。常用的ROUGE指标包括ROUGE-N和ROUGE-L。

尽管如此,现有的评估指标仍可能无法完全捕捉神经查询回答模型的本质,因此可能需要引入新的评估标准。以下几种未被充分探索但可能具有潜力的指标值得关注。(1)研究“合理答案”(介于简单答案和困难答案之间)。这些答案可以通过符号推理模型,利用更高级别的图模式(如本体)进行推导。计算合理答案时需要注意,符号推理的处理时间可能是无限的,因此必须受到时间或表达能力的限制,确保在有限

的时间内完成推理过程。因此,合理答案的集合可能依然是不完整的。(2)基于开放世界假设(Open World Assumption, OWA)的评估。该假设认为图中的未知三元组不一定为假(与在链接预测中普遍使用的封闭世界假设不同,后者假设未知三元组为假)。

## 5 挑战与展望

根据对现有复杂逻辑查询模型的分析,指出了现有模型的局限和未来工作的几个有希望的方向。

### 5.1 挑战

(1)逻辑操作的局限性。当前复杂逻辑查询方法在支持多样化的逻辑操作时依然存在不足。例如,对补集和否定操作的支持通常不够完备,尤其是在处理高维数据和复杂逻辑组合时,模型往往难以保证逻辑运算的封闭性。这限制了其在推理精确性要求高的场景中的应用。

(2)模型的计算代价。复杂逻辑查询模型的高计算代价,是阻碍其大规模应用的重要问题。几何嵌入方法的高维运算和基于大语言模型的方法的训练需求,都导致了显著的硬件资源消耗。在实际部署中,这种需求往往难以满足,尤其是在实时性要求高的应用场景下。

(3)动态知识图谱的适应性。知识图谱的动态性要求模型能够实时更新查询结果,而现有方法通常依赖预训练或固定的推理机制,难以高效适应动态变化。随着知识图谱规模的扩展,这种限制将更加明显。

### 5.2 展望

复杂逻辑查询技术在知识图谱中的应用前景广阔,未来的研究可以根据以下几条具体的技术路线展开,以进一步提升模型的性能和适应性。

(1)当前复杂逻辑查询方法在支持多样化的逻辑操作时仍存在不足,尤其是在处理补集和否定操作时,模型的封闭性和精确性有待提高。未来的研究可以探索如何设计更加完备的逻辑操作符,确保在高维数据和复杂逻辑组合下的运算封闭性。具体来说,可以借鉴数学逻辑中的形式化方法,结合深度学习模型,设计出能够处理复杂逻辑运算的神经网络架构。例如,可以引入逻辑感知的神经网络层,专门用于处理逻辑运算,确保模型在推理过程中能够保持逻辑一致性。

(2)复杂逻辑查询模型的高计算代价是当前面临的主要挑战之一。未来的研究可以探索如何通过模型压缩、分布式计算和硬件加速等技术来提升计算效率。例如,可以研究如何将几何嵌入方法中的高维运算优化为低维近似计算,或者通过稀疏矩阵计算来降低计算复杂度。

(3)传统的知识图谱主要基于结构化的文本信息,而多模态知识图谱的兴起为复杂逻辑查询开辟了新的研究方向。未来的研究可以探索如何将图像、视频、语音等多模态数据与知识图谱相结合,设计出能够处理多模态信息的复杂逻辑查询模型。例如,可以研究如何通过跨模态嵌入技术,将不同模态的数据映射到统一的向量空间中,从而实现跨模态的复杂逻辑推理。此外,可以探索如何通过多模态注意力机制来增强模型对多模态信息的理解和推理能力。

复杂逻辑查询技术作为知识图谱的核心能力,具有广泛的应用前景。未来的研究可以从逻辑操作的完备性、计算

效率的提升、动态知识图谱的实时推理、多模态知识图谱的复杂逻辑查询、神经符号推理的结合、评估与验证的优化以及跨领域知识图谱的复杂逻辑查询等多条技术路线展开,进一步提升模型的性能和适应性。

**结束语** 本文综述了基于知识图谱的复杂逻辑查询的最新研究进展。作为知识图谱技术的核心能力,复杂逻辑查询在深层次信息挖掘和知识发现中具有重要意义。本文首先介绍了知识图谱的基本概念及应用,随后详细分析了基于几何对象、概率分布、模糊逻辑及大语言模型的主要查询方法。这些方法通过映射低维向量空间,实现了高效的逻辑推理,并各自针对不确定性、动态变化、逻辑操作及结构对齐提供了不同的解决方案。此外,本文讨论了现有数据集和评价指标在评估模型泛化能力中的作用,并指出现有评估指标的局限性。未来研究须进一步优化查询方法,提高性能和可解释性,并设计更全面的评估指标。

## 参考文献

- [1] GAO J T, LI Z H, LIU W J. A Strategy of Efficient and Accurate Cardinality Estimation Based on Query Result[J]. Journal of Northwestern Polytechnical University, 2018, 36(4): 768-777.
- [2] JIA S, LIU X, ZHAO P, et al. Representation of job-skill in artificial intelligence with knowledge graph analysis[C] // 2018 IEEE Symposium on Product Compliance Engineering-Asia (IS-PCE-CN). IEEE, 2018: 1-6.
- [3] REN H, GALKIN M, COCHEZ M, et al. Neural Graph Reasoning: Complex Logical Query Answering Meets Graph Databases[J]. arXiv:2303.14617, 2023.
- [4] FENG T Y, LI W P, GUO Q L, et al. Overview of Knowledge Graph Question Answering Enhanced by Large Language Models[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(11): 2887-2900.
- [5] REN H, GALKIN M, ZHU Z, et al. Neural Graph Reasoning: A Survey on Complex Logical Query Answering[J]. Transactions on Machine Learning Research, 2024, 2024(11): 1-63.
- [6] WU X, JIANG T, ZHU Y, et al. Knowledge graph for China's genealogy[C] // 2020 IEEE International Conference on Knowledge Graph (ICKG). IEEE, 2020: 529-535.
- [7] LUKASIEWICZ T, MARTINEZ M V, PIERIS A, et al. From classical to consistent query answering under existential rules[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2015.
- [8] ZHENG Y, SHI C, CAO X, et al. A meta path based method for entity set expansion in knowledge graph[J]. IEEE Transactions on Big Data, 2018, 8(3): 616-629.
- [9] WANG T, GUO J, WU Z, et al. IFTA: iterative filtering by using TF-AICL algorithm for Chinese encyclopedia knowledge refinement[J]. Applied Intelligence, 2021, 51: 6265-6293.
- [10] BONATTI P A, SAURO L. On the logical properties of the nonmonotonic description logic DLN[J]. Artificial Intelligence, 2017, 248: 85-111.
- [11] MANDREOLI F, MARTOGLIA R, PENZOW. Journal of Computer and System Sciences Special Issue on Query Answering on Graph-Structured Data[J]. Journal of Computer and System Sci-

- ences, 2016, 82:1-2.
- [12] EL MASSARI H, MHAMMEDI S, GHERABI N, et al. Virtual OBDA mechanism Ontop for answering SPARQL queries over Couchbase[C] // International Conference on Advanced Technologies for Humanity. Cham: Springer, 2021: 193-205.
- [13] LYUTIKOVA L A, SHMATOVA E V. Algorithm for constructing logical operations to identify patterns in data[C] // Biologically Inspired Cognitive Architectures Meeting. Cham: Springer, 2020: 212-217.
- [14] LIU S, TAN N, GE Y, et al. Research on automatic question answering of generative knowledge graph based on pointer network[J]. Information, 2021, 12(3): 136.
- [15] HAMILTON W L, BAJAJ P, ZITNIKM, et al. Embedding logical queries on knowledge graphs[C] // Proceedings of the 32nd International Conference on Neural Information Processing Systems. 2018: 2030-2041.
- [16] REN H, HU W, LESKOVEC J. Query2box: Reasoning over knowledge graphs in vector space using box embeddings[C] // International Conference on Learning Representations (ICLR). Washington DC: ICLR, 2020: 1-13.
- [17] LIU L, DU B, JIH, et al. Neural-answering logical queries on knowledge graphs[C] // Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. 2021: 1087-1097.
- [18] SARDINA J, SARDINA C, KELLEHERJ D, et al. Analysis of attention mechanisms in box-embedding systems[C] // Irish Conference on Artificial Intelligence and Cognitive Science. Cham: Springer, 2022: 68-80.
- [19] ADLAKHA V, SHAH P, BEDATHUR S J. Regex Queries over Incomplete Knowledge Bases[C] // Automated Knowledge Base Construction. 2021.
- [20] ANDRESEL M, DOMOKOS C, STEPANOVA D, et al. A Neural-symbolic Approach for Ontology-mediated Query Answering [J]. arXiv. 2106.14052. 2021.
- [21] ZHANG Z, WANG J, CHEN J, et al. Cone: Cone embeddings for multi-hop reasoning over knowledge graphs[J]. Advances in Neural Information Processing Systems, 2021, 34: 19172-19183.
- [22] CHOUDHARY N, RAO N, KATARIYA S, et al. Self-supervised hyperboloid representations from logical queries over knowledge graphs[C] // Proceedings of the Web Conference 2021. 2021: 1373-1384.
- [23] GEBHART T, HANSEN J, SCHRATER P. Knowledge sheaves: A sheaf-theoretic framework for knowledge graph embedding [C] // International Conference on Artificial Intelligence and Statistics. PMLR, 2023: 9094-9116.
- [24] WAN G, DU B. Gaussianpath: a bayesian multi-hop reasoning framework for knowledge graph reasoning[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2021: 4393-4401.
- [25] REN H, LESKOVEC J. Beta embeddings for multi-hop logical reasoning in knowledge graphs[J]. Advances in Neural Information Processing Systems, 2020, 33: 19716-19726.
- [26] CHOUDHARY N, RAO N, KATARIYAS, et al. Probabilistic entity representation model for reasoning over knowledge graphs[J]. Advances in Neural Information Processing Systems, 2021, 34: 23440-23451.
- [27] YANG D, QING P, LI Y, et al. GammaE: Gamma Embeddings for Logical Queries on Knowledge Graphs[C] // 2022 Conference on Empirical Methods in Natural Language Processing, EMNLP 2022. 2022.
- [28] LONG X, ZHUANG L, AODI L, et al. Neural-based mixture probabilistic query embedding for answering fol queries on knowledge graphs[C] // Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. 2022: 3001-3013.
- [29] HUANG Z, CHIANG M F, LEE W C. Line: Logical query reasoning over hierarchical knowledge graphs[C] // Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2022: 615-625.
- [30] SUN H, ARNOLD A, BEDRAX W T, et al. Faithful embeddings for knowledge base queries[J]. Advances in Neural Information Processing Systems, 2020, 33: 22505-22516.
- [31] FRIEDMAN T, BROECK G. Symbolic querying of vector spaces: Probabilistic databases meets relational embeddings [C] // Conference on Uncertainty in Artificial Intelligence. PMLR, 2020: 1268-1277.
- [32] MINERVINI P, ARAKELYAN E, DAZAD, et al. Complex query answering with neural link predictors[C] // 31st International Joint Conference on Artificial Intelligence (IJCAI 2022). International Joint Conferences on Artificial Intelligence Organization, 2022: 5309-5313.
- [33] LUUS F P, SEN P, RIEGEL R N, et al. Logic embeddings for complex query answering: U. S. Patent Application 17/488,226 [P]. 2023-3-30.
- [34] CHEN X, HU Z, SUN Y. Fuzzy logic based logical query answering on knowledge graphs[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2022: 3939-3948.
- [35] XU Z, ZHANG W, YE P, et al. Neural-symbolic entangled framework for complex query answering[J]. Advances in Neural Information Processing Systems, 2022, 35: 1806-1819.
- [36] LIN X, ZHOU G, HU T, et al. Flex: Feature-logic embedding framework for complex knowledge graph reasoning[J]. arXiv: 2205.11039, 2022.
- [37] ZHU Z, GALKIN M, ZHANGZ, et al. Neural-symbolic models for logical queries on knowledge graphs[C] // International Conference on Machine Learning. PMLR, 2022: 27454-27478.
- [38] LIN X, XU C, ZHOU G, et al. TFLEX: temporal feature-logic embedding framework for complex reasoning over temporal knowledge graph[C] // Advances in Neural Information Processing Systems. 2024.
- [39] BAI Y, LYU X, LI J, et al. Answering complex logical queries on knowledge graphs via query computation tree optimization[C] // International Conference on Machine Learning. PMLR, 2023: 1472-1491.
- [40] WANG D, CHEN Y, GRAU B C. Efficient embeddings of logical variables for query answering over incomplete knowledge graphs [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2023: 4652-4659.
- [41] BAI Y, LYU X, LI J, et al. Answering complex logical queries on knowledge graphs via query computation tree optimization[C] //

- International Conference on Machine Learning. PMLR, 2023: 1472-1491.
- [42] TANG Z, PEI S, PENG X, et al. TAR: Neural logical reasoning across tbox and abox[J]. arXiv:2205.14591, 2022.
- [43] LUO H, HAIHONG E, YANG Y, et al. Nqe: N-ary query embedding for complex query answering over hyper-relational knowledge graphs[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2023:4543-4551.
- [44] CUI H, PENG T, XIAO F, et al. Incorporating anticipation embedding into reinforcement learning framework for multi-hop knowledge graph question answering[J]. Information Sciences, 2023, 619:745-761.
- [45] YIN H, WANG Z, SONG Y. Rethinking Complex Queries on Knowledge Graphs with Neural Link Predictors [C] // The Twelfth International Conference on Learning Representations. 2024:19722-19746.
- [46] LEWKOWYCZ A, ANDREASSEN A, DOHAN D, et al. Solving quantitative reasoning problems with language models[J]. Advances in Neural Information Processing Systems, 2022, 35: 3843-3857.
- [47] YAO Y, DUAN J, XU K, et al. A survey on large language model (llm) security and privacy: The good, the bad, and the ugly [J]. High-Confidence Computing, 2024, 4(2):100211.
- [48] BROWN T, MANN B, RYDER N, et al. Language models are few-shot learners[J]. Advances in Neural Information Processing Systems, 2020, 33:1877-1901.
- [49] LUO L, JU J, XIONG B, et al. ChatRule: Mining Logical Rules with Large Language Models for Knowledge Graph Reasoning [C]// Advances in Knowledge Discovery and Data Mining: 29th Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD 2025). 2025:314-325.
- [50] LIU X, ZHAO S, SU K, et al. Mask and reason: Pre-training knowledge graph transformers for complex logical queries[C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2022:1120-1130.
- [51] LUO H, HAIHONG E, TANG Z, et al. ChatKBQA: A Generate-then-Retrieve Framework for Knowledge Base Question Answering with Fine-tuned Large Language Models[C]// Findings of the Association for Computational Linguistics 2024. ACL, 2024:2039-2056.
- [52] CHOUDHARY N, REDDY CK. Complex logical reasoning over knowledge graphs using large language models[J]. arXiv:2305.01157, 2023.
- [53] LI Z, DENG L, LIU H, et al. Unioqa: A unified framework for knowledge graph question answering with large language models [J]. arXiv:2406.02110, 2024.
- [54] ZHANG L, ZHANG J, WANG Y, et al. FC-KBQA: A Fine-to-Coarse Composition Framework for Knowledge Base Question Answering[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023:1002-1017.
- [55] TAFFA T A, USBECK R. Leveraging LLMs in Scholarly Knowledge Graph Question Answering [C] // Proceedings of the Scholarly QALD Challenge at the 22nd International Semantic Web Conference (ISWC 2023). CEUR Workshop Proceedings, 2023.
- [56] JIANG J, ZHOU K, ZHAO W X, et al. ReasoningLM: Enabling Structural Subgraph Reasoning in Pre-trained Language Models for Question Answering over Knowledge Graph [C] // Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. 2023:3721-3735.
- [57] JIANG J, ZHOU K, YE K M, et al. StructGPT: A General Framework for Large Language Model to Reason over Structured Data [C] // Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. 2023:9237-9251.
- [58] HU X, WU X, SHU Y, et al. Logical form generation via multi-task learning for complex question answering over knowledge bases [C] // Proceedings of the 29th International Conference on Computational Linguistics. 2022:1687-1696.
- [59] LIU Y, LI Z, JIN X, et al. An in-context schema understanding method for knowledge base question answering [C] // International Conference on Knowledge Science, Engineering and Management. Singapore: Springer, 2024:419-434.
- [60] AGARWAL D, DAS R, KHOSLA S, et al. Bring Your Own KG: Self-Supervised Program Synthesis for Zero-Shot KGQA [C] // Findings of the Association for Computational Linguistics: NAACL 2024. 2024:896-919.
- [61] LI T, MA X, ZHUANG A, et al. Few-shot In-context Learning on Knowledge Base Question Answering [C] // Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023:6966-6980.
- [62] XIA T, DING L, WAN G, et al. Improving complex reasoning over knowledge graph with logic-aware curriculum tuning [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2025:12881-12889.
- [63] CHAKRABORTY A. Multi-hop question answering over knowledge graphs using large language models [J]. arXiv: 2404.19234, 2024.
- [64] LIU L, WANG Z, QIU R, et al. Logic query of thoughts: Guiding large language models to answer complex logic queries with knowledge graphs [J]. arXiv:2404.04264, 2024.
- [65] SUI Y, HE Y, LIU N, et al. FiDeLiS: Faithful Reasoning in Large Language Models for Knowledge Graph Question Answering [C] // Proceedings of the ICLR 2025 Workshop on Building Trust in Language Models and Applications. 2025.
- [66] HU N, WU Y, QI G, et al. An empirical study of pre-trained language models in simple knowledge graph question answering [J]. World Wide Web, 2023, 26(5):2855-2886.
- [67] WISHART D S, KNOX C, GUO A C, et al. DrugBank: a comprehensive resource for in silico drug discovery and exploration [J]. Nucleic Acids Research, 2006, 34(S1):D668-D672.
- [68] GOGLIA D, VEGA D. Structure and dynamics of growing networks of Reddit threads [J]. Applied Network Science, 2024, 9(1):48.
- [69] HIMMELSTEIN D S, LIZEE A, HESSLER C, et al. Systematic integration of biomedical knowledge prioritizes drugs for repurposing [J]. Elife, 2017, 6:e26726.
- [70] BORDES A, USUNIER N, GARCIA-DURANA, et al. Translating embeddings for modeling multi-relational data [C] // Advances in Neural Information Processing Systems. 2013.
- [71] BOLLACKER K, EVANS C, PARITOSH P, et al. Freebase:

- a collaboratively created graph database for structuring human knowledge[C]//Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data, 2008;1247-1250.
- [72] TOUTANOVA K, CHEN D, PANTEL P, et al. Representing text for joint embedding of text and knowledge bases[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, 2015;1499-1509.
- [73] CARLSON A, BETTERIDGE J, KISIEL B, et al. Toward an architecture for never-ending language learning[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2010;1306-1313.
- [74] XIONG W, HOANG T, WANGW Y. DeepPath: A Reinforcement Learning Method for Knowledge Graph Reasoning[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017;564-573.
- [75] DETTMERS T, MINERVINI P, STENETORPP, et al. Convolutional 2D knowledge graph embeddings[C]//32nd AAAI Conference on Artificial Intelligence, AAAI, 2018;1811-1818.
- [76] MILLER G A. WordNet: a lexical database for English [J]. Communications of the ACM, 1995, 38(11):39-41.
- [77] BIZER C, LEHMANN J, KOBILAROV G, et al. Dbpedia-a crystallization point for the web of data[J]. Journal of Web Semantics, 2009, 7(3):154-165.
- [78] IOANNIDIS V N, SONG X, MANCHANDA S, et al. DRKG-Drug Repurposing Knowledge Graph for Covid-19; 2020 [J]. arXiv;2010.09600, 2020.
- [79] LIN Z, WANG Q. E-commerce product networks, word-of-mouth convergence, and product sales[J]. Journal of the Association for Information Systems, 2018, 19(1):2.
- [80] GUO Y, PAN Z, HEFLIN J. LUBM: A benchmark for OWL knowledge base systems[J]. Journal of Web Semantics, 2005, 3(2/3):158-182.
- [81] ADLAKHA V, SHAH P, BEDATHUR S. Regex Queries over Incomplete Knowledge Bases[J]. arXiv;2005.00480, 2020.
- [82] SU Y, SUN H, SADLER B, et al. On generating characteristic-rich question sets for qa evaluation[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016;562-572.
- [83] PELLISSIER T T, WEIKUM G, SUCHANEK F. Yago 4: A reasonable knowledge base[C]//The Semantic Web; 17th International Conference (ESWC 2020). Springer, 2020;583-596.
- [84] YIH S W, CHANG M W, HE X, et al. Semantic parsing via staged query graph generation: Question answering with knowledge base[C]//Proceedings of the Joint Conference of the 53rd Annual Meeting of the ACL and the 7th International Joint Conference on Natural Language Processing of the AFNLP, 2015.
- [85] ZHOU M, HUANG M, ZHU X. An Interpretable Reasoning Network for Multi-Relation Question Answering[C]//Proceedings of the 27th International Conference on Computational Linguistics, 2018;2010-2022.
- [86] ZHANG Y, DAI H, KOZAREVA Z, et al. Variational reasoning for question answering with knowledge graph[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2018;6069-6076.
- [87] GALKIN M, TRIVEDI P, MAHESHWARI G, et al. Message Passing for Hyper-Relational Knowledge Graphs[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020;7346-7359.
- [88] ALIVANISTOS D, BERRENDORF M, COCHEZ M, et al. Query Embedding on Hyper-Relational Knowledge Graphs[C]//International Conference on Learning Representations, 2022;6321-6342.
- [89] WARD M D, BEGER A, CUTLER J, et al. Comparing GDELT and ICEWS event data[J]. Analysis, 2013, 21(1):267-297.
- [90] LEETARU K, SCHRODT P A. Gdelt: Global data on events, location, and tone, 1979-2012 [C] // ISA Annual Convention, Citeseer, 2013;1-49.
- [91] SHAO P, ZHANG D, YANG G, et al. Tucker decomposition-based temporal knowledge graph completion [J]. Knowledge-Based Systems, 2022, 238:107841.
- [92] LAN Y, JIANG J. Query graph generation for answering multi-hop complex questions from knowledge bases [C] // Annual Meeting of the Association for Computational Linguistics, 2020.
- [93] BORDES A, USUNIER N, CHOPRA S, et al. Large-scale simple question answering with memory networks[J]. arXiv;1506.02075, 2015.
- [94] JIANG K, WU D, JIANG H. FreebaseQA: A new factoid QA data set matching trivia-style question-answer pairs with Freebase[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, 2019;318-323.
- [95] MIN S, MICHAEL J, HAJISHIRZI H, et al. AmbigQA: Answering Ambiguous Open-domain Questions[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020;5783-5797.
- [96] VOORHEES E M, BUCKLAND L. Overview of the TREC 2003 Question Answering Track[C]//TREC, 2003;54-68.
- [97] CAI Z, VASCONCELOS N. Cascade r-cnn: Delving into high quality object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018;6154-6162.
- [98] LAN Y, HE S, LIU K, et al. Knowledge reasoning via jointly modeling knowledge graphs and soft rules[J]. Applied Sciences, 2023, 13(19):10660.



**CHEN Yuyin**, born in 1999, postgraduate, is a member of CCF (No. Y8937G). His main research interest is knowledge graph and reasoning.



**LI Guanfeng**, born in 1979, Ph.D, associate professor, is a member of CCF (No. A0519M). His main research interests include knowledge engineering and intelligent computing.