

大语言模型驱动的多元关系知识图谱补全方法

刘畅成, 桑磊, 李炜, 张以文

引用本文

刘畅成, 桑磊, 李炜, 张以文. 大语言模型驱动的多元关系知识图谱补全方法[J]. 计算机科学, 2025, 52(1): 94-101.

LIU Changcheng, SANG Lei, LI Wei, ZHANG Yiwen. Large Language Model Driven Multi-relational Knowledge Graph Completion Method [J]. Computer Science, 2025, 52(1): 94-101.

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)

[融合情感和常识知识的对话生成模型](#)

Dialogue Generation Model Integrating Emotional and Commonsense Knowledge

计算机科学, 2025, 52(1): 307-314. <https://doi.org/10.11896/jsjcx.231100130>

[一种基于知识图谱的检索增强生成情报问答技术](#)

Retrieval-augmented Generative Intelligence Question Answering Technology Based on Knowledge Graph

计算机科学, 2025, 52(1): 87-93. <https://doi.org/10.11896/jsjcx.240900064>

[SWARM-LLM:基于大语言模型的无人集群任务规划系统](#)

SWARM-LLM:An Unmanned Swarm Task Planning System Based on Large Language Models

计算机科学, 2025, 52(1): 72-79. <https://doi.org/10.11896/jsjcx.241000038>

[提示学习中思维链生成和增强方法综述](#)

Survey of Chain-of-Thought Generation and Enhancement Methods in Prompt Learning

计算机科学, 2025, 52(1): 56-64. <https://doi.org/10.11896/jsjcx.240700172>

[面向联邦大语言模型训练的传输优化技术综述](#)

Survey on Transmission Optimization Technologies for Federated Large Language Model Training

计算机科学, 2025, 52(1): 42-55. <https://doi.org/10.11896/jsjcx.240500095>

大语言模型驱动的多元关系知识图谱补全方法

刘畅成 桑磊 李炜 张以文

安徽大学计算机科学与技术学院 合肥 230601

(charlesliu@stu.ahu.edu.cn)

摘要 知识图谱通过将复杂的互联网信息转化为易于理解的结构化形式,极大地提高了信息的可访问性。知识图谱补全技术进一步增强了知识图谱的信息完整性,显著提升了智能问答和推荐系统等通用领域应用的性能与用户体验。然而,现有的知识图谱补全方法大多专注于关系类型较少和简单语义情景下的三元组实例,未能充分利用知识图谱在处理多元关系和复杂语义方面的潜力。针对此问题,提出了一种由大语言模型(LLM)驱动的多元关系知识图谱补全方法。将 LLM 的深层语言理解能力与知识图谱的结构特性相结合,有效捕捉多元关系,理解复杂语义情景。此外,还引入了一种基于思维链的提示工程策略,旨在提高补全任务的准确性。该方法在两个公开知识图谱数据集上的实验结果都取得了显著的提升。

关键词: 知识图谱; 大语言模型; 知识图谱补全; 多元关系; 候选集构建; 思维链提示

中图分类号 TP311

Large Language Model Driven Multi-relational Knowledge Graph Completion Method

LIU Changcheng, SANG Lei, LI Wei and ZHANG Yiwen

College of Computer Science and Technology, Anhui University, Hefei 230601, China

Abstract Knowledge graphs transform complex Internet information into an easily understandable structured format, significantly enhancing the accessibility of information. Knowledge graph completion(KGC) techniques further enhance the completeness of knowledge graphs, markedly improved the performance and user experience of general domain applications such as intelligent question answering and recommendation systems by enhancing the information completeness of knowledge graphs. However, most existing KGC methods focus on triple instances in scenarios with fewer types of relationships and simpler semantics, failing to fully leverage the potential of graphs in handling multi-relational and complex semantics. In response to this issue, we propose a method for multi-relational knowledge graph completion driven by large language model(LLM). By combining the deep linguistic understanding capabilities of LLM with the structural characteristics of knowledge graphs, this method effectively captures complex semantic scenarios and comprehends multi-relational relationships. Additionally, we introduce a chain-of-thought based prompting engineering strategy, aiming to enhancing the accuracy of the completion tasks. Experimental results on two public knowledge graph datasets have demonstrated the significant performance improvements of this method.

Keywords Knowledge graph, Large language model, Knowledge graph completion, Multi-relational, Candidate set construction, Chain-of-thought prompt

1 引言

知识图谱(Knowledge Graph, KG)^[1]源于 Google 公司的创新概念,是一种基于图结构的语义网络模型,旨在统一各种异构数据,以增强机器对信息的处理和理解能力。知识图谱已在搜索、问答系统、金融、医疗和电商等多个领域得到广泛应用^[2],显著提升了智能系统对人类语言的理解及推理能力^[3]。尽管如此,现有的知识图谱常受限于其结构稀疏性和连通性不足,难以充分挖掘内含的丰富多元关系知识。为解决这些问题,知识图谱补全(Knowledge Graph Completion, KGC)^[4-5]方法应运而生,其主要采用链接预测、基于文本的

关系抽取以及多元关系建模等方法,此类方法不仅补充了图谱中缺失的信息,而且增强了图谱的完整性和实用性。这些优化方法依托于现有的知识结构和语义信息,探索并揭示图谱中尚未明确的多元关系,进而扩展和丰富了知识图谱的内容,使其更加全面和精确。

传统的知识图谱补全方法在处理包含复杂多元关系的知识图谱时存在明显局限,如 TransE^[6]和 TransH^[7]主要依赖链接预测技术来推断图中缺失的知识三元组,并在关系类型较少的知识图谱中,如 WN18^[6]等,展现出较好的效果。然而,在处理包含复杂多元关系的知识图谱时,这些方法常常表现不佳,原因主要在于模型在捕捉关系类型的多样性和语义

信息的复杂性方面存在不足。这些模型通常仅依赖于简单的实体和关系嵌入技术,尽管这些技术在表示基本关系类型时有效,却难以准确捕捉关系间的细微差异和复杂的语义联系。这种技术限制了其泛化能力,并削弱了其在处理具有丰富多元关系的知识图谱时的性能。此外,传统方法在多元关系建模过程中,通常未能有效整合上下文信息,进一步限制了模型在实际应用中的表现。因此,开发能够更有效地理解和表示复杂多元关系的新方法,对于提升知识图谱补全的准确性和实用性至关重要。

近年来,大语言模型(Large Language Model, LLM)^[8]为弥补传统知识图谱补全方法在处理多元关系和复杂语义情境下的不足提供了新的可能性。例如 Llama^[9], Qwen^[10]等通过在大规模且高质量的语料库上进行预训练,已经展现了卓越的语言理解与生成能力,使得它们能够自适应地从海量文本中学习并构建多粒度的语义表征。这一能力在处理复杂的自然语言理解任务,如对话、问答和文本分类等方面已达到先进水平。尤其在知识图谱补全领域,LLM的这些特性开启了通过增强语义理解和多元关系处理能力来提升模型性能的新途径。

尽管基于 LLM 的 KGC 方法^[11]在初步应用中展现了巨大潜力,但它们仍面临若干严峻挑战。首要难题在于如何有效融合图结构信息与 LLM 的预训练知识。鉴于 LLM 本质上是针对序列化文本设计,而非直接处理图结构数据,因此,将图谱中蕴含的结构化信息充分利用并与 LLM 强大的语义理解能力相结合是一个挑战。其次,尽管 LLM 能够生成高质量的预测结果,但其决策过程透明度^[12]不足的问题仍未得到妥善解决,对于需要精确理解复杂关系的 KGC 任务而言,这一点至关重要。

针对上述挑战,本文提出一种大语言模型驱动的多元关系知识图谱补全方法(Large Language Model Driven Multi-relational Knowledge Graph Completion, LMKGC)。LMKGC 不仅结合了 LLM 的强大语言理解能力和知识图谱的结构特性,而且特别引入了基于思维链的提示工程。通过精心设计的思维链提示词,引导 LLM 进行多步推理,有效挖掘知识图谱中的隐性知识,增强其决策过程透明度。

本文的主要贡献如下:

1)提出了一种 LLM 驱动的知识图谱补全方法,该方法利用大语言模型的深层语义理解能力,通过有效的知识融合和匹配策略,提升了模型在处理多元关系和复杂语义情景下的表现。

2)提出了一种基于思维链的提示工程策略,通过构建思维链提示词引导 LLM 进行多步推理,增强了模型在挖掘知识图谱中隐性知识的能力以及决策过程的透明度。

3)在公开的知识图谱数据集 OpenBG-500^[13]和 NATIONS^[14]上进行了广泛测试。结果表明,LMKGC 方法在补全性能上相较于现有技术有显著提升。通过消融实验,进一步证明了思维链提示工程在本方法中的重要作用和有效性。

2 相关工作

2.1 知识图谱补全

知识图谱补全旨在解决知识图谱中存在的信息不完整问题,通过引入先进的算法和模型来预测和补全图中的缺失实体和关系。早期基于嵌入的模型通过将实体和关系映射到低维嵌入空间,并设计评分函数来预测三元组中缺失的值。例如 TransE^[6]将关系看作从头实体到尾实体的翻译向量,即 $h+r \approx t$,其中 h, r, t 分别表示头实体、关系和尾实体的嵌入向量。TransE 为后续的 TransH^[7], TransR^[15], TransD^[16]等工作奠定了基础。与 TransE 等翻译模型不同, RESCAL^[17]是一种基于张量分解的知识图谱表示学习方法。它将知识图谱看作一个三维张量,通过张量分解的方式来学习实体和关系的嵌入表示。在 RESCAL 的基础上, DistMult^[18]和 ComplEx^[19]等模型引入对角矩阵、复数嵌入等技术,在降低计算复杂度的同时提高了模型的表示能力。ConvE^[20]则应用卷积神经网络提取实体与关系的交互模式,而 GIE^[21]在多个几何空间中推进了对空间结构的理解。CausE^[22]采用因果干预来评估混杂因素嵌入的因果效应,用来区分和控制影响知识图谱关系的隐藏变量。为了更好地捕捉实体之间的复杂关系,一些工作开始探索基于图神经网络(Graph Neural Networks, GNNs)^[23]的知识图谱表示学习方法。其中, R-GCN^[24]在图卷积网络的基础上引入了关系特定的变换矩阵,对不同类型的邻居信息进行区分和聚合。CompGCN^[25]则进一步考虑了关系的方向性和组合性,通过设计更加复杂的聚合函数来建模多关系图上的信息传播。此外, MRGAT^[26]通过引入自注意力机制,根据邻居节点的重要性对其进行加权聚合,以获得更加精准的节点表示。SE-GNN^[27]从利用上下文信息的角度出发,尝试在聚合邻居信息时考虑多个语义证据级别。DRR-GAT^[28]从路径的角度分析实体之间的关系,通过动态地建模实体之间的路径信息,获得更加丰富的关系表示。

此外,一些工作利用外部知识来增强知识图谱的表示学习。MMKRL^[29]提出了一种多模态知识表示学习方法,通过融合文本、图像等多种模态信息,学习更加丰富和鲁棒的实体和关系嵌入。DKRL^[30]引入基于文档的知识表示学习,利用实体和关系的上下文文本信息,增强了知识图谱嵌入对语义的捕捉能力,在一定程度上缓解了多元关系知识图谱数据稀疏和语义理解的问题。

尽管已有多种针对知识图谱补全的方法被提出,但现有方法主要依赖于知识图谱的结构信息和浅层文本语义。当面对包含多样化关系和复杂语义的知识图谱时,这些方法很难充分挖掘其中蕴含的丰富知识。

2.2 大语言模型与知识图谱

大语言模型(LLM)通过在大规模语料上进行预训练^[31],习得了强大的语言理解和生成能力^[32]。近期的研究开始探索如何将大语言模型与知识图谱结合,以实现知识的有效表示和推理。ERNIE^[33]提出了一种基于 BERT^[34]的知识增强预训练模型,通过引入知识图谱的

实体信息和丰富的结构化事实来增强语言表征,在各种知识驱动型任务中取得了显著的性能提升。K-BERT^[35]在BERT的基础上引入了知识图谱中的三元组信息,通过构建实体和关系的嵌入表示,增强了模型的语义理解能力。KG-BERT^[36]进一步提出了一种基于知识图谱的预训练框架,通过掩码实体和关系来学习知识感知的语言表示。这些工作验证了知识图谱对于增强语言模型的有效性。Bio-KGLM^[37]通过将生物医学知识图谱与预训练语言模型相结合,有效解决了生物医学信息提取中知识整合不足的问题,并显著提高了信息提取的精度与深度。KICGPT^[38]整合了LLM和基于三元组的KGC检索器,有效缓解了长尾问题,且无需额外的训练开销。KoPA^[11]提出了一种将KG的结构信息整合到LLM中的新方法,以改善KGC任务的性能。Guan等^[39]提出了一种基于知识图谱的调整框架,通过对LLM生成的响应进行自主验证和调整,有效减轻了推理过程中的事实幻觉,提高了模型的可靠性。Yang等^[40]通过对知识图谱增强预训练语言模型的研究,提出开发知识图谱增强语言模型以提高其事实推理能力。Pan等^[41]对大语言模型在知识图谱领域的应用和未来展望进行了全面综述,提出了一项前瞻性的整合计划,旨在融合LLM与KG,具体包括KG增强LLM、LLM增强KG以及LLM与KG的协同作用。尽管上述方法在结合大语言模型和知识图谱方面取得了显著进展,但却难以充分利用大语言模型的强大语言理解能力来进行深层次的知识推理。

本文从上述工作中得到了启发:首先,关于知识增强,研究表明引入外部知识可以显著提升语言模型的表征能力;其次,在三元组信息的利用上,利用知识图谱中的三元组信息来丰富语义表示的方法取得了良好效果;最后,在知识感知的语言表示学习中,一些研究通过掩码技术来增强模型对知识的感知能力。与现有方法不同,本文提出的LMKGC方法利用LLM来引入先验知识,并通过思维链提示工程进一步挖掘LLM的能力,以提升知识图谱补全的性能。现有方法通常仅基于知识图谱的嵌入表示,未能充分引入广泛的先验知识。而LMKGC方法通过LLM引入丰富的先验知识,增加了知识的多样性和覆盖面。传统方法主要依赖浅层次的关系匹配和简单推理,而LMKGC方法不仅利用LLM的强大语言理解和生成能力进行复杂和深层次的知识推理,还采用思维链提示工程逐步展开推理过程,显著提升了推理的准确性和全面性。这种方法不同于现有方法的单步推理,能够更好地捕捉复杂的知识关系。此外,与现有方法通常作为独立工具的情况不同,LMKGC方法采用类似插件的形式集成到基础模型中,从而能够更加便捷和灵活地提升模型的补全性能。

3 大语言模型驱动的多元关系知识图谱补全方法

本章重点介绍所提出的LMKGC方法,3.1节概述总体架构,3.2-3.4节分别描述候选集构建、思维链提示和

最优选选择提示3个核心步骤,展现了LMKGC方法的工作原理与优势。

3.1 总体架构

大型语言模型驱动的多元关系知识图谱补全方法(LMKGC)采用基于思维链的多步骤提示策略,旨在处理具有多元关系和复杂语义的知识图谱场景。该方法利用大型语言模型的强大能力,显著增强传统知识图谱补全模型的性能。图1展示了该方法的完整流程,主要包括3个关键步骤:候选集构建、思维链提示和最优选选择提示。LMKGC方法的具体流程如算法1所示。

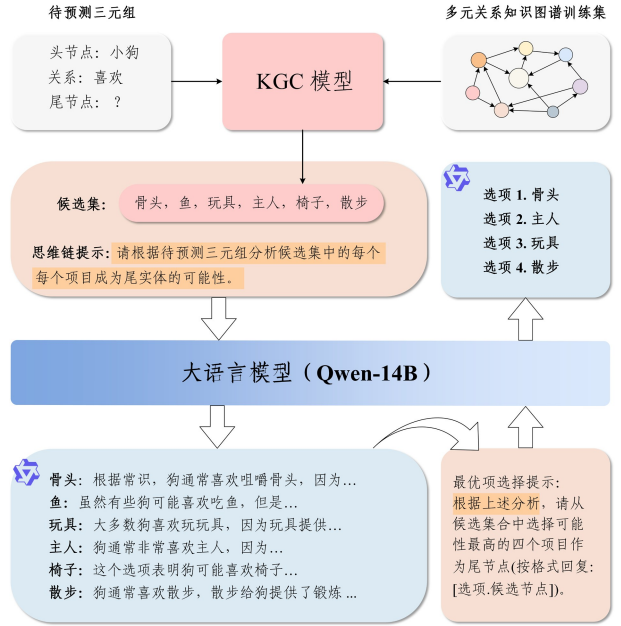


图1 LMKGC流程图

Fig. 1 LMKGC flowchart

算法1 LMKGC算法

输入:知识图谱 G ,知识图谱补全模型 M ,待预测三元组 q ,思维链提示模板 T_c ,最优选选择提示模板 T_r

输出:最优节点集 R

1. function PretrainModel(M, G)
2. for $e \leftarrow 1$ to E do
3. for all(h, r, t) $\in G$ do
4. $L \leftarrow M. ComputeLoss(h, r, t)$
5. $M. UpdateParameters(L)$
6. end for
7. end for
8. return M
9. end function
10. $* M \leftarrow PretrainModel(M, G)$
11. $C \leftarrow * M. predict(q)$
12. $P_c \leftarrow constructPrompts(C, T_c)$
13. $A \leftarrow LLM(P_c)$
14. $P_r \leftarrow constructPrompts(A, T_r)$
15. $R \leftarrow LLM(P_r)$
16. return R

候选集构建:为每个待补全的三元组生成候选集,以缩小

LLM 预测的范围。这些候选集将被用于构建思维链提示词。

思维链提示:该步骤是受思维链概念启发而提出的一种提示策略,旨在利用 LLM 挖掘知识图谱中三元组的先验知识。其核心思想是通过构建有针对性的提示词,帮助大型语言模型在进行逻辑推理时更好地理解和分析问题。这种方法引导模型形成具有逻辑性和连贯性的思维链,从而提高问题解决能力和创造力。

最优项选择提示:该步骤的主要目的是利用 LLM 的知识推理和决策能力从候选集中选出最优的补全结果。

3.2 候选集构建

候选集构建在 LLM 进行任务式对话和自然语言处理中发挥着至关重要的作用。与早期基于规则和模板的对话系统相比,LLM 依赖于模拟人类语言的复杂且流畅的对话能力。然而,由于其庞大的计算开销和难以解释的自然语言生成能力,单纯依靠模型自行回复可能会产生无关、重复或含有偏差的不良结果。在知识图谱补全任务中,直接将整个知识图谱作为输入让大语言模型进行计算推理是一种非常消耗资源且效率低下的做法。通过为模型构建丰富且高质量的候选集,可以在很大程度上克服这些问题。

为了获取高质量的候选集,本文提出利用传统的知识图谱补全模型,如 TransE^[6]和 ComplEx^[19]等,首先对已有的知识图谱进行预训练,学习实体和关系的低维嵌入表示。然后,对于待预测的三元组,固定头实体或尾实体以及关系,利用预训练模型计算所有可能的尾实体或头实体的打分。最后,根据打分结果,选取得分最高的若干个实体作为候选集。该方法充分利用了知识图谱补全模型的强大表示能力,能够为待预测的三元组生成高质量的候选集,有效减小搜索空间,提高链接预测的效率,同时保证候选集的质量。

3.3 思维链提示

近年来,Wei 等^[42]提出了一种通过引入思维链提示来激发 LLM 推理能力的方法,并在不同推理任务上取得了优异的效果。受该研究启发,本文在利用 LLM 进行知识图谱补全任务时,创新性地引入了思维链的思想。

为了更好地利用 LLM 的先验知识,增强其推理能力,本文设计了一种基于思维链的提示策略。具体而言,提示词中包含“请根据待预测三元组分析候选集中的每个项目成为尾实体的可能性。”如图 1 所示,在回答问题时,LLM 通常会按照提示词的指引,对候选集中的数据进行逐条分析,阐明各自的理由。这种思维链式的提示方法引导模型形成了一种类似人类解决问题的思维模式,有助于提高其在知识图谱补全任务中的推理能力和决策过程透明度。

为了更加详细地描述思维链提示的构建过程,本文提出了以下提示词设计的方法和原则:

1)明确任务目标:提示词应清晰地描述模型需要完成的任务。在本研究中,提示词要求模型分析候选集中的每个项目,评估其成为头/尾实体的可能性。

推理。例如,提示词可以先要求模型识别候选集中的所有项目,然后逐一评估每个项目的可能性。

3)强调理由说明:提示词应要求模型在分析时给出详细的理由说明,以增强推理过程的透明度和可信度。

4)优化提示词长度:提示词应简洁明了,避免冗长。过长的提示词可能会导致模型注意力分散,进而影响推理效果。

通过上述设计原则,本文构建了一个有效的思维链提示策略,有助于 LLM 在知识图谱补全任务中发挥更强的推理能力。

3.4 最优项选择提示

最优项选择提示是 LMKGC 的一个重要环节,其目的是从候选集中选取最优项作为预测实体。为了使 LLM 能够有效利用候选集评估结果进行最优项选择,其中提示词包含“根据上述分析,请从候选集中选择可能性最高的 4 个项目作为尾节点。”这一提示引导 LLM 在候选集中进行重新排序和筛选,以获得最终的预测结果。具体而言,LLM 在接收到该提示后,将执行以下步骤:

1)评估每个候选项的可能性:LLM 首先会依据先前的分析和上下文信息,对候选集中的每个项目进行评估,包括考虑语义匹配度、上下文相关性和其他可能的评分标准。

2)计算可能性评分:对于每一个候选项,LLM 会计算一个可能性评分。这些评分基于 LLM 的内在算法和提示中隐含的指令,反映了每个候选项成为最优项的概率。

3)筛选出最优项:在排序完成后,LLM 将按照提示中的指令,选择评分最高的前四个候选项作为最终的尾节点。这一选择过程确保了 LLM 只保留可能性最大的项目,从而提高预测的准确性。

另外,为了使 LLM 回答的结果更容易被计算机编程语言所理解,本文设计了包含“(按格式回复:[选项.候选节点])”的提示词模板,使 LLM 的回答按照一定格式输出,更容易被提取。例如,当 LLM 选择 4 个最优项时,它会按照预定格式输出结果,如“选项 1.候选节点 A,选项 2.候选节点 B,选项 3.候选节点 C,选项 4.候选节点 D”,使后续的计算机程序能够直接解析和利用这些信息。

最优项选择提示的引入,使得 LLM 能够综合考虑候选项的各方面因素,从而做出更加准确和合理的预测决策。

4 实验

本章将通过多组实验验证 LMKGC 方法的有效性,首先对实验数据集、评价指标、基线模型与实验设置进行描述,在此基础上进行消融实验,并对实验结果进行分析。

4.1 数据集

如表 1 所列,本实验将采用公开数据集 OpenBG-500^[13]和 NATIONS^[14]。OpenBG-500 数据集源自真实的电商知识图谱,而 NATIONS 数据集则收集了不同国家/地区之间的部分事实关系。这两个数据集均包含丰富的实体和关系类型,具有较高的完整性和真实性,适用于评估具有多元关系的知识图谱补全任务的性能。

表1 数据集统计
Table 1 Dataset statistics

数据集	实体数	关系数	训练集	验证集	测试集
OpenBG-500	24973	500	1242550	5000	5000
NATIONS	14	55	1593	200	202

4.2 评价指标

本文采用知识图谱补全中常用的计算指标 Hits@n 作为评价指标,计算式为:

$$Hits@n = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \mathbb{I}(rank_i \leq n)$$

其中, Q 表示测试样本数量; \mathbb{I} 是指示函数, 当样本 i 的正确关系排名 $rank_i$ 小于等于 n 时取 1, 否则取 0。此公式计算的是在 Q 个测试样本中, 正确关系排名在前 n 位的样本比例。该指标直接反映了模型在测试阶段, 预测正确率在前 n 个推理结果中的比例, 可以反映模型的准确性和表现稳定性。

4.3 基线模型与实验设置

在基线模型的选择上, 本文参考了知识图谱领域中常用的 6 种模型, 大致介绍如下:

TransE^[6]: 通过将实体之间的关系转化为低维线性空间中的平移操作, 实现了实体和关系的联合嵌入表示。

TransH^[7]: TransE 模型的改进版本, 通过引入关系超平面和投影操作, 将实体嵌入投影到关系特定的超平面上, 再进行翻译运算。

TransD^[16]: 一种改进的翻译模型, 通过为每个实体和关系设置独立的映射矩阵, 将它们投影到不同的关系特定超平面上, 再进行翻译操作。

DistMult^[18]: 通过对头实体、关系和尾实体的嵌入向量进行三线性点积运算, 学习实体和关系的分布表示。

ComplEx^[19]: 使用复数嵌入向量来刻画实体和关系, 并采用厄米特点积作为打分函数, 有效地建模了反对称关系。

CausE^[22]: 一种基于因果推理的知识图谱嵌入模型, 它通过引入潜在混杂因素和因果机制, 学习实体和关系的因果表示。

本实验使用单张 NVIDIA GeForce RTX A40 式图形处理器 (GPU), 操作系统为 Ubuntu 20.04 LTS。额外配置 AMD EPYC 7532 32 核中央处理器 (CPU) 以及 128GB 内存。在大语言模型的选取上, 采用了阿里云研发的通义千问-14B (Qwen-14B)^[10] 模型。该模型拥有 140 亿个参数, 预训练 token 数高达 3T, 生成 2048 个 token 的最小显存占用为 13GB。Qwen-14B 在众多自然语言处理任务上展现出卓越的性能, 具有强大的语言理解和生成能力。

4.4 实验结果

本文在 OpenBG-500 和 NATIONS 两个多元关系知识图谱数据集上, 对比评估了采用 LMKGC 方法与不采用该方法的情况下, 6 种基线模型的知识图谱补全性能。如表 2 所列, 实验结果表明大部分模型在使用 LMKGC 方法后, 其评价指标 Hits@1 到 Hits@5 均获得显著提升。值得注意的是, 在 OpenBG-500 数据集上应用 LMKGC 方法后, TransH 模型的 Hits@1 指标从 0.068 提升到 0.205, TransD 模型从 0.07 提升到 0.207, ComplEx 模型从 0.041 提升到 0.151。然而, DistMult 模型的 Hits@3 指标在使用 LMKGC 后出现了下降, 这可能源于不同模型输出候选集质量的差异。

表2 LMKGC 实验结果
Table 2 LMKGC experiment results

模型	方法	OpenBG-500					NATIONS				
		Hits@1	Hits@2	Hits@3	Hits@4	Hits@5	Hits@1	Hits@2	Hits@3	Hits@4	Hits@5
TransE	Base	0.219	0.290	0.326	0.347	0.364	0.007	0.055	0.139	0.204	0.308
	LMKGC	0.243	0.295	0.395	0.364	3.373	0.080	0.102	0.204	0.273	0.324
TransH	Base	0.068	0.162	0.206	0.232	0.249	0.007	0.050	0.129	0.197	0.286
	LMKGC	0.205	0.264	0.265	0.324	0.344	0.070	0.102	0.162	0.247	0.373
TransD	Base	0.07	0.159	0.203	0.229	0.245	0.012	0.075	0.147	0.249	0.323
	LMKGC	0.207	0.267	0.265	0.313	0.340	0.100	0.115	0.192	0.279	0.386
DistMult	Base	0.122	0.175	0.207	0.229	0.244	0.047	0.090	0.160	0.231	0.313
	LMKGC	0.128	0.178	<u>0.161</u>	0.295	0.302	0.073	0.114	0.184	0.232	0.383
ComplEx	Base	0.041	0.115	0.164	0.187	0.206	0.020	0.057	0.117	0.177	0.251
	LMKGC	0.151	0.202	0.191	0.254	0.294	0.085	0.100	0.159	0.264	0.361
CausE	Base	0.107	0.150	0.174	0.190	0.202	0.062	0.151	0.236	0.338	0.428
	LMKGC	0.191	0.213	0.246	0.268	0.291	0.083	0.164	0.267	0.358	0.470

综上所述, LMKGC 方法通过引入外部语义知识, 可以提升大多数知识图谱嵌入模型的性能, 这主要得益于以下几个方面: 首先, LMKGC 方法通过提供外部语义知识, 有效弥补了基线模型本身在语义表征能力上的不足; 其次, 对于较难处理特定关系类型的模型如 TransH, LMKGC 方法在语义指导下能显著改善其效果; 再者, 引入 LMKGC 方法后, 各模型之间的性能差异有所缩小, 表明该方法可以很好地补充不同模型在语义表达上的差异; 最后, LMKGC 方法在两个不同规模的数据集上均取得较为稳定的性能提升, 揭示了其良好的泛化能力。

4.5 消融实验

为了进一步量化思维链提示对 LMKGC 方法整体效果的贡献, 本文设计了一个减弱变体 LMKGC-Lite, 代表去除思维链提示后的 LMKGC 方法。图 2 展示了在 OpenBG-500 数据集上进行的消融实验的结果。

实验结果表明, 无论采用哪一类基线模型, 完整的 LMKGC 方法均显著优于去除思维链提示后的 LMKGC-Lite 方法, 表明思维链提示对单 LMKGC 整体架构具有积极影响。尽管使用 LMKGC-Lite 方法时, 各模型的效果不及完整的 LMKGC, 但部分模型的效果仍优于基线, 说明即使在缺乏

思维链提示的情况下,LMKGC-Lite 通过整合先验知识依然对知识图谱完成任务产生了一定的促进作用。该消融实验

设计初步区分了思维链提示模块与 LMKGC 其他模块的不同作用,揭示了思维链提示模块对整体架构的贡献机理。

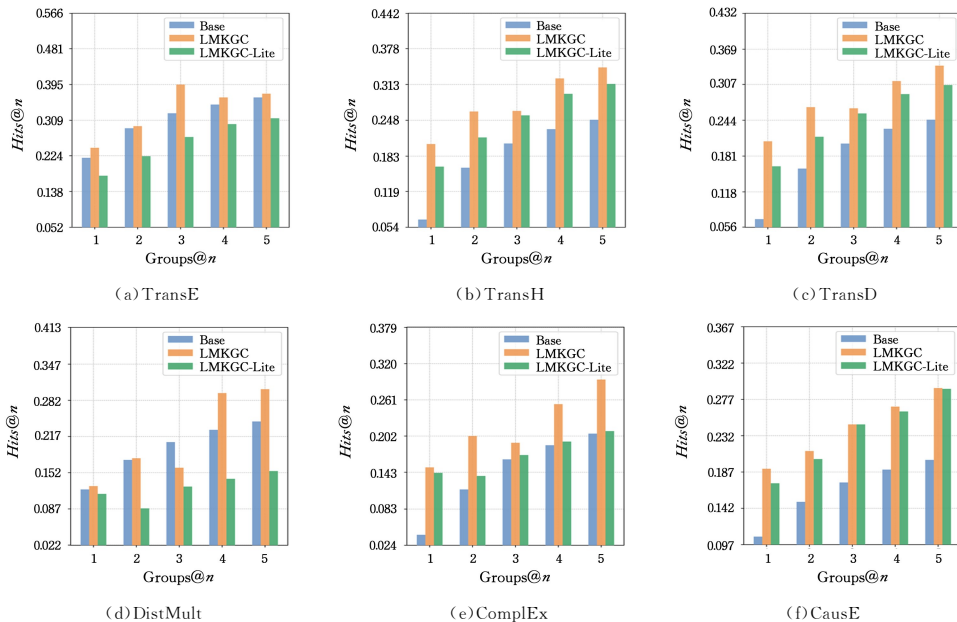


图 2 LMKGC 消融实验

Fig. 2 LMKGC ablation experiment

4.6 理论分析

由于 LMKGC 方法中的各个模块的不可分割性,其他模块无法单独进行消融实验。为此,本文在此提供详细的理论分析,以解释各个模块在整体系统中的作用。

候选集构建在 LMKGC 中起着至关重要的作用。这一模块不仅为模型提供了一个更小、更可控的搜索空间,还极大地减少了计算资源的消耗。通过预先筛选高质量的候选项,LMKGC 能够在更短的时间内找到最优解。通过缩小搜索空间,减少了需要评估的候选项数量,提高了候选集构建的效率,从而提升了整体系统的效率。同时,候选集构建利用预训练的知识图谱补全模型,保证了候选集的高质量,使得后续的推理过程能够在高质量的基础上进行。此外,还降低了大型语言模型在处理全图谱数据时的复杂度,使得处理过程更加简洁和高效。

思维链提示是 LMKGC 的核心创新之一。该模块旨在通过构建逻辑性强的提示词,帮助大型语言模型在推理过程中形成清晰的思维链条。这不仅增强了模型的推理能力,还提高了其决策的透明度。具体来说,思维链提示增强了推理能力,通过逐步引导模型进行逻辑推理,帮助模型更好地理解和分析问题,从而做出更准确的预测;通过要求模型给出详细的理由说明,增加了推理过程的透明度,使每一步的推理结果都有据可循;促进了逻辑思维,通过构建逻辑性强的提示词,培养了模型的逻辑思维能力,使其在处理复杂问题时能够更加得心应手。

最优项选择提示模块利用大型语言模型的知识推理和决策能力,从候选集中选出最优的补全结果。该模块在整个系统中起到了关键决策的作用。最优项选择提示通过计算每个候选项的可能性评分,精确地筛选出最优的补全结果;综合

评估候选项的各个方面因素,如语义匹配度和上下文相关性,确保了决策的全面性和准确性;并通过预定义的输出格式,确保模型的输出结果能够被计算机程序直接解析和利用,提升了系统的实用性。

结合上述各模块的作用,LMKGC 的整体性能得以显著提升。通过候选集构建、思维链提示和最优项选择提示的密切配合,LMKGC 实现了高效、高质量的知识图谱补全。理论分析表明,LMKGC 各模块合理分工,减少了冗余计算,提高了系统的整体效率;通过高质量的候选集和逻辑性强的推理过程,保证了补全结果的准确性和可信度;思维链提示和最优项选择提示的引入,使得整个系统的决策过程透明可追溯,增强了系统的可靠性。

综上所述,LMKGC 通过各模块的有机结合,实现了对复杂知识图谱场景的高效补全,展现了强大的推理和决策能力。

结束语 本文提出了一种利用先进的大语言模型提升知识图谱补全模型性能的新方法。具体而言,设计了一套知识图谱语义增强方法 LMKGC,以实现外部语言知识引导模型学习的机制。为验证该机制的实用性,本文在两个公开知识图谱数据集开展了实证实验。实验结果表明,应用 LMKGC 可以显著且稳定地提升各类基线模型在知识补全任务中的预测性能。此外,通过设计消融实验进一步分析鉴定了思维链提示策略在 LMKGC 整体架构中的重要作用。总体而言,这项工作提出了一种能有效利用 LLM 弥补模型短板的新式知识图谱补全优化方法。本文设计的 LMKGC 方法在处理大规模知识图谱时的计算成本较高,未来将探索更加高效、轻量的链提示生成机制,并设计更加灵活和通用的知识融合策略,实现不同知识源之间的无缝整合,为构建高质量、覆盖面广的大规模知识图谱提供有力的技术支持。

参 考 文 献

- [1] CHEN X, JIA S, XIANG Y. A review: Knowledge reasoning over knowledge graph [J]. *Expert Systems with Applications*, 2020, 141: 112948.
- [2] JI S, PAN S, CAMBRIA E, et al. A survey on knowledge graphs: Representation, acquisition, and applications [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 494-514.
- [3] ANNERVAZ K M, CHOWDHURY S B R, DUKKIPATI A. Learning beyond datasets: Knowledge graph augmented neural networks for natural language processing [C] // *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, Volume 1 (Long Papers)*. New Orleans, Louisiana: Association for Computational Linguistics, 2018: 313-322.
- [4] WANG W J, YU Y F. Automatic completion algorithm for missing links in knowledge graph considering data sparsity [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2022, 52(6): 1428-1433.
- [5] CHEN Z, WANG Y, ZHAO B, et al. Knowledge graph completion: A review [J]. *IEEE Access*, 2020, 8: 192435-192456.
- [6] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating Embeddings for Modeling Multi-relational Data [C] // *Proceedings of Advances in Neural Information Processing Systems*. Red Hook, NY: Curran Associates, Inc., 2013.
- [7] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes [C] // *AAAI'14: Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. Québec City, Québec, Canada: AAAI Press, 2014: 1112-1119.
- [8] WANG L, MA C, FENG X, et al. A survey on large language model based autonomous agents [J]. *Frontiers of Computer Science*, 2024, 18(6): 186345.
- [9] TOUVRON H, MARTIN L, STONE K, et al. Llama 2: Open foundation and finetuned chat models [J]. *arXiv: 2307. 09288*, 2023.
- [10] BAI J, BAI S, CHU Y, et al. Qwen technical report [J]. *arXiv: 2309. 16609*, 2023.
- [11] ZHANG Y, CHEN Z, ZHANG W, et al. Making large language models perform better in knowledge graph completion [J]. *arXiv: 2310. 06671*, 2023.
- [12] LI Q, WANG G, LIU J, et al. Explainability for Large Language Models: A Survey [J]. *ACM Transactions on Intelligent Systems and Technology*, 2024, 15(2): 20.
- [13] DENG S, WANG C, LI Z, et al. Construction and applications of billion-scale pre-trained multimodal business knowledge graph [C] // *2023 IEEE 39th International Conference on Data Engineering (ICDE)*. Anaheim: IEEE Press, 2023: 2988-3002.
- [14] HOYT C T, BERRENDORF M, GALKIN M, et al. A unified framework for rank-based evaluation metrics for link prediction in knowledge graphs [J]. *arXiv: 2203. 07544*, 2022.
- [15] LIN Y, LIU Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. Washington: AAAI Press, 2015.
- [16] JI G, HE S, XU L, et al. Knowledge graph e-embedding via dynamic mapping matrix [C] // *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*. Beijing, China: Association for Computational Linguistics, 2015: 687-696.
- [17] NICKEL M, TRESP V, KRIEDEL H P. A three-way model for collective learning on multi-relational data [C] // *ICML'11: Proceedings of the 28th International Conference on International Conference on Machine Learning*. Madison, WI, USA: Omnipress, 2011: 809-816.
- [18] YANG B, TAU YIH W, HE X, et al. Embedding entities and relations for learning and inference in knowledge bases [J]. *arXiv: 1412. 6575*, 2015.
- [19] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction [C] // *Proceedings of The 33rd International Conference on Machine Learning*. New York, USA: PMLR, 2016: 2071-2080.
- [20] DETTMERS T, MINERVINI P, STENETOR-P P, et al. Convolutional 2d knowledge graph embeddings [C] // *Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence*. New Orleans, LA: AAAI Press, 2018.
- [21] CAO Z, XU Q, YANG Z, et al. Geometry interaction knowledge graph embeddings [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(5): 5521-5529.
- [22] ZHANG Y, ZHANG W. Cause: Towards causal knowledge graph embedding [C] // *Knowledge Graph and Semantic Computing: Knowledge Graph Empowers Artificial General Intelligence*. Singapore: Springer Nature Singapore, 2023: 17- 28.
- [23] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [24] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks [C] // *Proceedings of the 15th International Conference on The Semantic Web; ESWC 2018*. Berlin, Heidelberg: Springer-Verlag, 2018: 593-607.
- [25] VASHISHTH S, SANYAL S, NITIN V, et al. Composition-based multi-relational graph convolutional networks [J]. *arXiv: 1911. 03082*, 2020.
- [26] DAI G, WANG X, ZOU X, et al. Mrgat: Multi-relational graph attention network for knowledge graph completion [J]. *Neural Networks*, 2022, 154: 234-245.
- [27] LI R, CAO Y, ZHU Q, et al. How does knowledge graph embedding extrapolate to unseen data: A semantic evidence view [J].

- Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(5):5781-5791.
- [28] ZHANG X, ZHANG C, GUO J, et al. Graph attention network with dynamic representation of relations for knowledge graph completion [J]. Expert Systems with Applications, 2023, 219: 119616.
- [29] LU X, WANG L, JIANG Z, et al. MMKRL: A robust embedding approach for multi-modal knowledge graph representation learning [J]. Applied Intelligence, 2022, 52(7):7480-7497.
- [30] XIE R, LIU Z, JIA J, et al. Representation learning of knowledge graphs with entity descriptions [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2016.
- [31] YANG B X, LUO X D, SUN K L. Recent Progress on Machine Translation Based on Pre-trained Language Models [J]. Computer Science, 2024, 51(S1):230700112-8.
- [32] GENG M, WANG S, DONG D, et al. Large Language Models are Few-Shot Summarizers: Multi-Intent Comment Generation via In-Context Learning [C] // Proceedings of the IEEE/ACM 46th International Conference on Software Engineering. New York, NY, USA: Association for Computing Machinery, 2024.
- [33] ZHANG Z, HAN X, LIU Z, et al. Ernie: Enhanced language representation with informative entities [J]. arXiv: 1905. 07129, 2019.
- [34] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [J]. arXiv: 1810. 04805, 2019.
- [35] LIU W, ZHOU P, ZHAO Z, et al. K-BERT: Enabling language representation with knowledge graph [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(3):2901-2908.
- [36] YAO L, MAO C, LUO Y. Kg-bert: Bert for knowledge graph completion [J]. arXiv: 1909. 03193, 2019.
- [37] FEI H, REN Y, ZHANG Y, et al. Enriching contextualized language model from knowledge graph for biomedical information extraction [J]. Briefings in Bioinformatics, 2020, 22(3): bbaa110.
- [38] WEI Y, HUANG Q, ZHANG Y, et al. Kicgpt: Large language model with knowledge in context for knowledge graph completion [C] // Findings of the Association for Computational Linguistics: EMNLP 2023. Singapore: Association for Computational Linguistics, 2023: 8667-8683.
- [39] GUAN L, LIN Y, LIN H, et al. Mitigating Large Language Model Hallucinations via Autonomous Knowledge Graph-Based Retrofitting [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2024: 18126-18134.
- [40] YANG L, CHEN H, LI Z, et al. Give us the Facts: Enhancing Large Language Models With Knowledge Graphs for Fact-Aware Language Modeling [J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(7):3091-3110.
- [41] PAN S, LUO L, WANG Y, et al. Unifying large language models and knowledge graphs: A roadmap [J]. arXiv: 2306. 08302, 2024.
- [42] 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. Curran Associates, Inc., 2022: 24824-24837.



LIU Changcheng, born in 1999, master, is a member of CCF(No. U6154G). His main research interests include large language models and data mining.



LI Wei, born in 1969, Ph.D, professor. Her main research interests include software engineering, virtual reality human-computer interaction, and data mining.

(责任编辑:何杨)