



计算机科学

COMPUTER SCIENCE

基于预训练语言模型的知识图谱研究综述

曾泽凡, 胡星辰, 成清, 司悦航, 刘忠

引用本文

曾泽凡, 胡星辰, 成清, 司悦航, 刘忠. 基于预训练语言模型的知识图谱研究综述[J]. 计算机科学, 2025, 52(1): 1-33.

ZENG Zefan, HU Xingchen, CHENG Qing, SI Yuehang, LIU Zhong. [Survey of Research on Knowledge Graph Based on Pre-trained Language Models](#) [J]. Computer Science, 2025, 52(1): 1-33.

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)

[基于层次化视觉注意力的富语义视频对话生成](#)

Generation of Enrich Semantic Video Dialogue Based on Hierarchical Visual Attention
计算机科学, 2025, 52(1): 315-322. <https://doi.org/10.11896/jsjcx.231100107>

[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>

[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 Method
计算机科学, 2025, 52(1): 94-101. <https://doi.org/10.11896/jsjcx.240600170>

[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>

基于预训练语言模型的知识图谱研究综述

曾泽凡^{1,2,3} 胡星辰^{1,2} 成清^{1,2} 司悦航^{1,2} 刘忠^{1,2}

1 国防科技大学系统工程学院 长沙 410073

2 国防科技大学大数据与决策实验室 长沙 410073

3 福建省军区 福州 350001

(zengzefan@nudt.edu.cn)

摘要 大语言模型时代,知识图谱作为一种结构化的知识表示方式,在提升人工智能的可靠性、安全性和可解释性方面发挥着不可替代的作用,具有重要的研究价值和实际应用前景。近年来,凭借在语义理解和上下文学习方面的优越性能,预训练语言模型已经成为了知识图谱研究的主要手段。系统梳理了基于预训练语言模型的知识图谱研究的相关工作,包括知识图谱构建、表示学习、推理、问答等,介绍了相关模型和方法的核心思路,并依据技术路径建立了分类体系,对不同类型方法的优缺点进行了对比分析。此外,对预训练语言模型在事件知识图谱和多模态知识图谱这两种新型知识图谱中的应用现状进行了综述。最后,总结了当前基于预训练语言模型的知识图谱研究面临的挑战,展望了未来的研究方向。

关键词 知识图谱;预训练语言模型;大语言模型;多模态;事件知识图谱

中图分类号 TP182

Survey of Research on Knowledge Graph Based on Pre-trained Language Models

ZENG Zefan^{1,2,3}, HU Xingchen^{1,2}, CHENG Qing^{1,2}, SI Yuehang^{1,2} and LIU Zhong^{1,2}

1 College of Systems Engineering, National University of Defense Technology, Changsha 410073, China

2 Laboratory for Big Data and Decision, National University of Defense Technology, Changsha 410073, China

3 Fujian Provincial Military Command, Fuzhou 350001, China

Abstract In the era of large language models (LLMs), knowledge graphs (KGs), as a structured representation of knowledge, play an irreplaceable role in enhancing the reliability, security, and interpretability of artificial intelligence. With its superior performance in semantic understanding, pre-trained language models (PLMs) have become the main approach in knowledge graph research in recent years. This paper systematically reviews the research works on PLM-based knowledge graphs, including knowledge graph construction, representation learning, reasoning, and question answering. The core ideas of the relevant models and methods are introduced and a classification system is established based on the technological approaches. A comparative analysis of the advantages and disadvantages of different categories of methods is provided. In addition, the application status of pre-trained language models in two new types of knowledge graphs, event knowledge graphs and multimodal knowledge graphs, is reviewed. Finally, the challenges faced by current research on knowledge graphs based on pre-trained language models are summarized, and future research directions are prospected.

Keywords Knowledge graph, Pre-trained language model, Large language model, Multi-modal, Event knowledge graph

1 引言

知识表示和学习是人类认识世界、学习技能和作出决策的必要手段。知识图谱(Knowledge Graph, KG)以结构化的形式描述客观世界中的概念、实体及其关系,将信息表达成更接近人类认知世界的形式,以便于更高效精确地实现互联网海量数据的组织、管理和理解。近年来,随着 WordNet^[1], DBpedia^[2], YAGO^[3], NELL^[4], Probase^[5], CN-DBpedia^[6] 和

zhishi.me^[7]等国内外开放知识库的迅猛增长,知识图谱已被广泛用于支持语义网络的各类实际应用,如信息检索^[8]、问答系统^[9]、智能对话^[10]等。

预训练语言模型(Pre-trained Language Model, PLM)通过在未标记的语料库上进行预训练,学习通用语言学知识,并将其以参数形式嵌入模型网络结构中。通过微调模型参数,PLM可以应用于各种下游自然语言处理(Natural Language Processing, NLP)任务中。2018年,谷歌提出 Transformer

到稿日期:2024-01-12 返修日期:2024-03-07

基金项目:国家自然科学基金面上项目(62376279);目标认知与应用技术重点实验室资助(2023-CXPT-LC-005)

This work was supported by the National Natural Science Foundation of China(62376279).

通信作者:胡星辰(xhu4@ualberta.ca)

架构^[11],奠定了 PLM 算法的基础。随后, BERT^[12], GPT^[13]和 BART^[14]等 PLM 陆续问世,展示出强大的语义理解能力,在各种 NLP 任务中表现出色。随着 OpenAI 先后推出 GPT-3^[15], ChatGPT^[16]和 GPT-4^[17],大语言模型(Large Language Model, LLM)时代正式到来。模型体量的急剧增加赋予了 LLM 前所未有的新能力,为将 LLM 应用于通用人工智能铺平了道路。

尽管 LLM 具备很强的学习和创作等通用能力,但受限于其黑箱模型特性和领域知识缺乏等原因,其可解释性、可信赖性和领域能力都还难以令人满意^[18]。而知识图谱凭借其结构化知识存储的特点,具有较好的可解释性、可溯源性、可信赖性和灵活性,恰好能够有效弥补 LLM 的这些不足^[19]。因此,未来知识图谱仍将是人工智能研究和应用的重要工具。

目前,针对知识图谱构建、补全和应用,已有多篇相关研究综述,这些综述主要集中在知识图谱构建^[20-23]、表示学习^[24-26]、推理^[27-30]和问答^[31-32]等方面。早期,研究者们采用基于逻辑规则^[33]、基于向量计算^[34-36]和基于深度学习^[37-40]等方法来研究知识图谱。然而,这些方法有一个共同缺点,即只关注了知识图谱的结构信息,难以有效捕捉知识图谱中的

语义信息。随着 PLM 技术的发展,利用其在语义理解、内容生成等方面的技术优势,实现对知识图谱全生命周期各环节的增强,提升效率和质量,已经成为学术领域的一个研究热点。此外,事件知识图谱^[41]、多模态知识图谱^[42]等新型知识图谱的研究也逐步兴起,如何基于预训练模型,针对这些不同形式的知识图谱设计算法,也是当前知识图谱研究的聚焦点之一。

本文系统全面地总结梳理了 PLM 在知识图谱的构建、表示学习、推理和问答等核心任务中的研究工作,以及在事件知识图谱、多模态知识图谱中的应用,对相关模型和方法进行分类归纳,并分析面临的挑战,展望未来的研究方向,以期为大语言模型时代的知识图谱研究提供参考借鉴。

本文第 2 章介绍了知识图谱和预训练语言模型、大语言模型相关的基础知识;第 3—8 章全面介绍了基于 PLM 的知识图谱技术,主要包括知识图谱构建、知识图谱表示学习、知识图谱推理、知识图谱问答、事件知识图谱相关技术以及多模态知识图谱相关技术;第 9 章分析了当前基于 PLM 的知识图谱技术存在的问题和面临的挑战,并展望了未来的研究方向;最后总结全文。

图 1 展示了本文的调研内容框架。

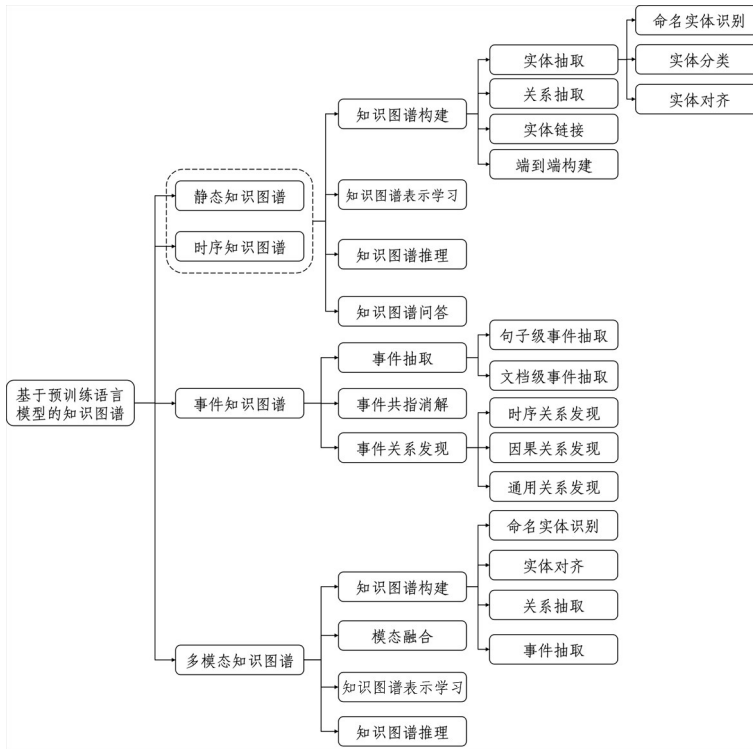


图 1 本文的调研内容框架

Fig. 1 Framework of the survey in this paper

2 预备知识

本章主要介绍知识图谱和预训练语言模型的相关预备知识,明确相关术语和符号表示,理清概念定义,以便于后文中的理解。

2.1 知识图谱

知识图谱是一种表示和组织知识的结构化图形模型,它包含了实体(Entity)及其关系(Relation)和属性(Attribute)信息^[43]。

2.1.1 知识图谱的类型

据实体类型和要素的不同,知识图谱可以分为静态知识图谱(Static Knowledge Graph, SKG)、时序知识图谱(Temporal Knowledge Graph, TKG)、事件知识图谱(Event Knowledge Graph, EKG)和多模态知识图谱(Multi-Modal Knowledge Graph, MMKG)4类。

静态知识图谱^[27]也称为传统知识图谱,指仅包括“实体-关系-属性”元素的知识图谱。其形式上定义为 $SKG = \{E, R, F\}$, E 为实体集合, R 为关系集合, F 为事实集合。 F 通常

以三元组的形式表示,即 $(e_h, r, e_t) \in \mathcal{F}$,其中 $e_h, e_t \in \mathcal{E}$, e_h 称为头实体, e_t 称为尾实体。静态知识图谱是最常见的知识图谱,在很多研究中直接简称为知识图谱。

时序知识图谱^[27]也称为动态知识图谱,指事实中包含时间信息的知识图谱。其形式上定义为 $\mathcal{TKG} = \{\mathcal{E}, \mathcal{R}, \mathcal{F}(t)\}$, $\mathcal{F}(t)$ 表示与时间相关的事实集合,通常用四元组的形式表示,即 $(e_h, r, e_t, t) \in \mathcal{F}(t)$ 。

事件知识图谱^[41]是以事件为中心的知识图谱,包括

事件和实体2种节点和3种关系:“事件-事件”关系包括事件之间的时间关系、因果关系和条件关系等;“事件-实体”关系表示事件的参数或属性;“实体-实体”关系则与传统知识图谱相同。根据上述定义,事件知识图谱可以表示为 $\mathcal{EKG} = \{\mathcal{E}, \mathcal{N}, \mathcal{R}, \mathcal{F}\}$, \mathcal{N} 表示事件集合, $\mathcal{R} = \mathcal{R}_{\text{evt-evt}} \cup \mathcal{R}_{\text{evt-ent}} \cup \mathcal{R}_{\text{ent-ent}}$ 表示3种关系的集合,事实 \mathcal{F} 的表达形式与SKG相同。

图2展示了4种类型的知识图谱示例。

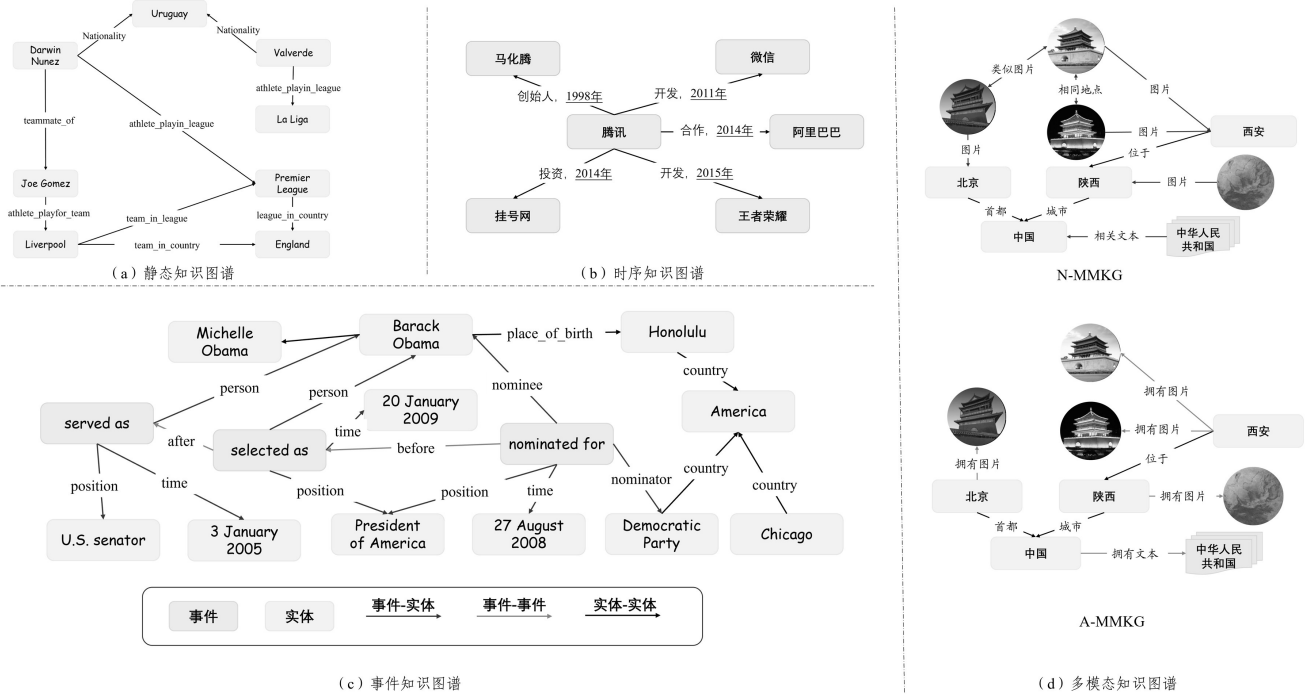


图2 4种不同类型的知识图谱示例

Fig. 2 Examples of four categories of knowledge graphs

根据所包含知识类型的不同,还可以将知识图谱分为百科知识图谱、常识知识图谱和领域知识图谱。

百科知识图谱基于百科全书的知识组织和表示知识,将丰富的知识以结构化的方式表达出来;常识知识图谱是日常工作生活中的概念知识的结构化表示和组织方式;

领域知识图谱是表示领域特定知识知识图谱,此类知识图谱规模相对较小,但更可靠,在领域人工智能应用开发中很重要。

表1列出了包含不同类型知识知识图谱的相关信息,其中带“*”的表示中文知识图谱。

表1 常用的百科知识图谱、常识知识图谱和领域知识图谱的相关信息

Table 1 Information of encyclopedic knowledge graphs, common knowledge graphs, and domain knowledge graphs

名称	机构	内容	类型	名称	机构	内容	类型
Wikidata	维基	通用知识	百科	OMCS	纽约大学	通用常识	常识
Freebase	Metaweb	通用知识	百科	ATOMIC	斯坦福大学	人类行为	常识
DBpedia	柏林自由大学	通用知识	百科	SenticNet	新加坡国立大学	情感常识	常识
YAGO	马克斯普朗克所	通用知识	百科	WordNet	普林斯顿大学	词汇语义	常识
GoogleKG	谷歌	搜索引擎	百科	UMLS	美国卫生研究院	医学	领域
NELL	卡内基梅隆大学	通用知识	百科	MusicBrainz	MB Foundation	音乐	领域
CN-DBpedia*	复旦大学	中文百科	百科	CASIA-KB*	中科院自动化所	多领域	领域
Zhishi, me*	上海交通大学	中文百科	百科	GeoNames	德国地理研究中心	地理	领域
百科	ConceptNet	麻省理工学院	百科	DrugBank	阿尔伯特大学	药品	领域

2.1.2 知识图谱的重要概念

定义1(实体) 指现实世界中独立存在和识别的具体或抽象的事物、对象或概念,包括人、地点、概念等。每个实体在知识图谱中由唯一的标识符表示。

定义2(属性) 与实体相关的特征或描述。

定义3(关系) 不同实体之间的连接或联系,描述了实体之间的某种关联关系。

定义4(实体跨度, Entity Span) 指一个实体在文本中所占据的连续字符范围。对于给定的文本句子,标注者需要标注出其中的实体,并确定它们在文本中的起始位置和结束

位置。起始位置和结束位置之间的字符范围即为实体的跨度。例如,句子“Apple Inc. 是一家总部位于美国的科技公司”,实体“Apple Inc.”的跨度为字符‘A’到字符‘.’。

定义 5(实体指称, Entity Mention) 指在自然语言文本中用于指代实体的词语或短语。在句子“张三是一名医生,他在医院工作”中,“张三”和“他”都是实体“张三”的实体指称。实体将文本与知识图谱中的实体相关联,识别和解析实体指称有助于理解文本中的实体。

定义 6(实体描述文本, Entity Description) 对特定实体的详细描述或解释性文本,提供实体相关的背景信息、属性特征、相关关系等。

2.2 预训练语言模型

预训练语言模型是利用 Transformer 等神经网络模型架构,在大规模文本数据上进行预训练,以学习自然语言的统计规律和语义表示的模型。在预训练阶段,通过下一个句子预测(Next Sentence Prediction, NSP)和掩码语言建模(Mask Language Modeling, MLM)等任务进行无监督学习,捕捉上下文关系,获取丰富的语言知识和语义表示。然后,通过微调或提示学习,将获取的语言知识和语义表示应用到具体任务中。一般来说,根据 PLM 参数数量是否超过 10^7 可以将其

分为标准语言模型(Standard Language Model, SLM)和大语言模型(LLM)。

2.2.1 标准预训练语言模型

SLM 是模型参数小于 10^7 的 PLM,也是大语言模型的雏形。根据模型结构特点,其可以分为 3 类,即编码器型 SLM、解码器型 SLM 和编码器-解码器型 SLM。

编码器型 SLM 是最早被开发的 PLM,这类模型通过编码器来学习编码文本和捕捉语义特征。编码器型 PLM 擅长对文本内容进行分析,在自然语言理解任务中表现出色;其不足之处在于只能生成固定长度的输出,无法直接生成后续词语或句子,且由于输入为固定长度序列,对长文本的处理受到限制。

解码器型 SLM 直接利用解码器生成输出文本。解码器型 SLM 具有更高的训练效率且更容易实现,但对输入序列的前缀和生成序列的完整性有一定的依赖。

编码器-解码器型 SLM 先利用编码器将输入文本转换为隐藏向量,然后利用解码器生成文本。这类 PLM 擅长处理输入和输出序列之间存在复杂映射关系的任务,兼具自然语言理解和生成能力;但通常需要更大的模型参数规模、更长的训练时间和更多的计算资源,其参数数量大多在 5×10^6 以上。表 2 列出了一些经典的 SLM 的相关信息。

表 2 经典的标准预训练语言模型的相关信息

Table 2 Relevant information of classic standard PLMs

名称	发布机构	发布时间	参数规模	所属类型
ELMo	AI2	2018	9.4×10^7	编码器
BERT	谷歌	2018	$1.1 \times 10^8 \sim 3.4 \times 10^8$	编码器
RoBERTa	Facebook AI	2019	$1.25 \times 10^8 \sim 3.55 \times 10^8$	编码器
DistillBERT	Hugging Face	2019	6.6×10^7	编码器
DeBERTa	微软亚洲研究院	2020	$4.4 \times 10^7 \sim 3.04 \times 10^8$	编码器
ALBERT	谷歌	2019	$1.1 \times 10^7 \sim 2.23 \times 10^8$	编码器
BART	Facebook AI	2019	4×10^8	编码器-解码器
GPT-1	OpenAI	2018	1.17×10^8	解码器
GPT-2	OpenAI	2019	1.5×10^9	解码器
XLNet	谷歌	2019	3.4×10^8	解码器

2.2.2 大语言模型

LLM 是指参数数量庞大、结构复杂的 PLM,利用海量的训练数据,采取大规模自监督学习的方法,通过微调适应广泛的下游任务。LLM 具备涌现能力和通用能力,为 NLP 任务提供了强大的基础和工具。与 SLM 类似,根据模型结构

不同,LLM 可以分为编码器-解码器型 LLM 和解码器型 LLM。目前,LLM 以解码器型为主,主要原因是:编码器的双向注意力存在低秩问题,可能会削弱模型的表达能力;此外,解码器型 LLM 更容易训练和投入工程实践。表 3 列出了现有的一些著名 LLM 的相关信息。

表 3 现有部分大语言模型的相关信息

Table 3 Relevant information of some existing LLMs

名称	发布机构	发布时间	参数规模	所属类型	是否开源
T5	Google	2020	$8 \times 10^8 \sim 1.1 \times 10^{10}$	编码器-解码器	是
T0	腾讯	2021	1.1×10^{10}	编码器-解码器	是
PanGu- α	华为	2021	1.3×10^{10}	编码器-解码器	是
Flan-T5	谷歌	2021	1.1×10^{10}	编码器-解码器	是
GLM130B	清华大学	2022	1.3×10^{11}	编码器-解码器	是
UL2	谷歌	2022	21.1×10^{11}	编码器-解码器	是
ST-MoE	谷歌	2022	$4.1 \times 10^9 \sim 2.69 \times 10^{11}$	编码器-解码器	否
PanGu- Σ	华为	2023	2×10^{11}	编码器-解码器	是
GPT-3	OpenAI	2020	1.75×10^{11}	解码器	否
GPT-3.5	OpenAI	2022	1.75×10^{11}	解码器	否
GPT-4.0	OpenAI	2023	—	解码器	否
LaMDA	谷歌	2022	$2 \times 10^9 \sim 1.37 \times 10^{11}$	解码器	否
PaLM	谷歌	2022	5.4×10^{11}	解码器	否
LLaMa	MetaAI	2023	$7 \times 10^9 \sim 6.5 \times 10^{10}$	解码器	是
BLOOM	BigScience	2022	1.76×10^{11}	解码器	是
Alpaca	斯坦福大学	2023	$7 \times 10^9 \sim 1.3 \times 10^{10}$	解码器	是
Bard	谷歌	2023	1.37×10^{11}	解码器	否

2.2.3 预训练语言模型的重要概念

定义 7(标记, token) PLM 处理文本时的最小单位,可以是一个字、一个词或者子词。将文本分割成标记,可以使模型更好地理解 and 处理文本。特殊的标记包括起始标记([CLS])、终止标记([SEP])、掩码标记([MASK])和填充标记([PAD]),其中[CLS]和[SEP]用于标记输入文本的开始和结束,[MASK]用于预测缺失的词,[PAD]用于填充输入序列到相同长度。

定义 8(掩码语言建模, MLM) 一种训练语言模型的方法。随机掩盖或替换一些输入标记,通过让模型预测缺失的标记,促使其学到词语之间的关联性和语法规则,提高模型对文本的理解能力和生成能力。

定义 9(指令微调) 指在下游任务上微调预训练后的 PLM。为了进行指令微调,首先需要收集或构建指令格式的实例,然后使用这些实例以有监督的方式微调 PLM。指令微调后,PLM 可以展现出泛化到新的任务和复杂场景的能力。

定义 10(对齐微调) 指通过标签数据对齐或人类反馈强化学习(Human Feedback Reinforcement Learning, RLHF)的方法,为 PLM 的行为提供反馈信息,指导其训练,使得 PLM 与人类的偏好和价值观或给定的标注数据相一致。

定义 11(提示学习) 一种训练方式,通过给定一组输入提示模板或标签,模型学习从输入中预测下一个词或生成相关的输出。提示学习可以将预训练模型迁移到下游任务中,使任务输入和输出适合原始语言模型,在零样本或少样本的场景中获得良好的任务效果。

2.3 预训练语言模型增强知识图谱

知识图谱在知识理解、知识查询、知识推理、知识溯源和可视化等方面具有明显的优势,但传统的知识图谱构建和应用技术往往忽略了对语义的建模和理解,导致在面对语义歧义、上下文学习、语言常识等问题时缺乏有效的解决办法。同时,由于传统知识图谱构建方法中的语料数据标注、抽取规则还依赖于人工设计,因此效率低下、主观性强、质量不高的问题仍然存在。此外,知识图谱所包含信息的通用性、完备性不足,造成泛化迁移能力较弱,数据规模有限,有效知识稀疏。

预训练语言模型基于大量的语料库学习知识,具有很强的上下文感知、深层语义表示和少样本学习能力,能够有效地弥补传统知识图谱技术的不足。此外,预训练语言模型能够通过微调扩展到多种任务,支持多语言、多模态、多领域的应用,增强知识图谱技术的通用、多模态和泛化能力。

预训练语言模型主要通过如下手段增强知识图谱研究: 1)利用大模型的生成能力,增强知识图谱可用数据;2)利用大模型的上下文学习能力,将其作为编码器增强知识图谱表示;3)将大模型作为解码器、生成器,作用于知识图谱推理、问答;4)利用大模型的深度语义感知能力,辅助事件抽取和关系发现,增强事件知识图谱构建;5)利用大模型的多模态建模和融合能力,增强多模态知识图谱的构建、融合表示和推理。

本文从知识图谱构建、表示学习、推理、问答等层面,全面介绍基于 PLM 的知识图谱研究技术。考虑到事件知识图谱和多模态知识图谱与传统知识图谱的研究体系差异,为了突出其个性特征,本文将它们作为两个独立内容进行梳理和介绍。

3 基于 PLM 的知识图谱构建

知识图谱构建指通过从结构化和非结构化数据中提取知识,将分散的、不同来源的知识整合成一个有机整体的过程。知识图谱构建主要包括实体抽取、关系抽取、实体链接等步骤。相比传统的知识图谱构建方法,PLM 在上下文理解、零样本学习、多模态数据处理和迁移学习能力方面具有显著优势,且具有较强的领域和任务适应性。此外,部分基于 PLM 的方法还可以从文本或模型中直接抽取知识并构建完整的知识图谱,本文将之称为端到端知识图谱构建。图 3 给出了知识图谱构建相关任务的示例,表 4 梳理归纳了基于 PLM 的知识图谱构建的相关方法、文献及其特点。

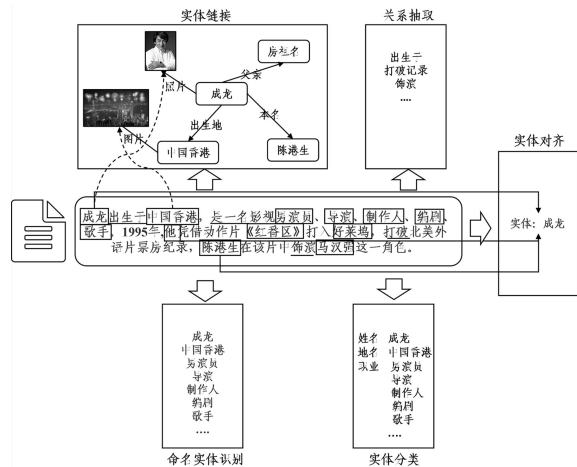


图 3 知识图谱构建示例

Fig. 3 Example of knowledge graph construction

表 4 基于 PLM 的知识图谱构建方法的相关信息

Table 4 Relevant Information of knowledge graph construction methods based on pre-trained language models

功能	分类	方法/任务特点	模型/方法
命名实体识别	非重叠 NER	将命名实体视作一个整体,并将 NER 转化为序列标注问题来识别文本中不重叠的实体,未考虑一个标记属于多个实体的情况	BERT ^[12] , biLM ^[44] , DTPDR ^[45] , P-Tuning v2 ^[46]
	嵌套 NER	考虑一个标记属于多个实体的情况,允许实体嵌套在其他实体之中,并使用嵌套标签来表示,没有考虑实体被分隔的情况	Biaffine ^[48] , BENSC ^[49] , PO-TreeCRFs ^[50] , Lou et al. ^[51] , Yang et al. ^[52]
	非连续 NER	识别在文本中以间隔分隔的实体,可以适应更多样化的实体表示	SoD-NER ^[53] , Yan et al. ^[54] , D-NER ^[55]
实体分类	基于标签对齐	应用于有监督场景,通过对齐模型中间或输出表示和目标任务的标签来进行微调	Denoise-ET ^[56] , Box4Types ^[57] , MLM-ET ^[58] , Liu et al. ^[59] , LITE ^[60] , DenoiseFET ^[61]
	基于提示学习	通过提示学习来适应标签稀缺的无监督和少/零样本场景	Ding et al. ^[62] , Li et al. ^[63] , OntoType ^[64]

(续表)

功能	分类	方法/任务特点	模型/方法
实体对齐		利用 PLM 对 GNN 进行增强,或设计针对实体对齐的下游任务对 PLM 进行微调	BERT-IN ^[65] , MAN and HMAN ^[66] , TEA ^[67] , ERNIE ^[68]
	基于 MLM 的句子级别 RE	将关系抽取建模为掩码语言建模任务并进行微调来抽取句子内关系,更加可靠,但效率较低	TRE ^[69] , Shi et al. ^[70] , SpanBERT ^[71] , MTB ^[72] , Park et al. ^[73] , RECENT ^[74] , CTL-DRP ^[75]
	基于 MLM 的文档级别 RE	将关系抽取建模为掩码语言建模任务并进行微调,抽取文档内跨句子关系,通常采用分层建模、共现汇聚等方式实现	HIN ^[76] , GLRE ^[77] , GAIN ^[78] , SIRE ^[79] , LSR ^[80] , DocuNet ^[81] , ATLOP ^[82]
关系抽取	基于提示学习	将关系抽取任务视为文本生成问题,在提示模板中引入输入句子,利用模板中的附加信息辅助生成过程,更适用于少样本、零样本等受限场景	LPAQA ^[83] , PTR ^[84] , Li 和 Liang ^[85] , Qin et al. ^[86] , KnowPrompt ^[87] , Shin et al. ^[88] , Ma et al. ^[90] , Wei et al. ^[91]
	实体知识增强	将实体编码到 PLM 中,增强 PLM 的语义和知识学习能力,提升关系抽取的性能,扩展性、灵活性强;需要设计多任务联合训练策略和损失函数,训练成本高,且需要规模匹配的知识图谱	CokeBERT ^[92] , Coref-BERT ^[93] , ERICA ^[94] , KnowBERT ^[95] , ERNIE ^[68]
实体链接	基于向量匹配	通过 PLM 或知识增强的 PLM 将实体编码为向量空间中的向量,然后计算匹配分数,计算复杂度高	E-ELMo ^[96] , Jia et al. ^[97] , Broscheit et al. ^[98] , BLINK ^[99] , ELQ ^[100] , E-BERT ^[101] , FAE ^[102] , KnowBERT ^[95] , ERNIE ^[68]
	基于序列分析	将 EL 转化为序列分析问题,通过自回归等方式预测链接,不需要进行逐对遍历匹配,规避了学习大量实体嵌入表示的昂贵成本	Yamada et al. ^[103] , GENRE and mGENRE ^[104] , Cao et al. ^[105] , ReFinED ^[106]
端到端构建	文本-知识图谱	从文本中构建知识图谱	Kumar et al. ^[107] , Melnyk et al. ^[108] , PiVe ^[109] , KGLLM ^[110] , AutoKG ^[111]
	表格-知识图谱	从数据库、网络表格和 CSV 文件等表格数据中提取知识	TURI ^[112] , RPT ^[113] , Starmie ^[114] , Doduo et al. ^[115] , Korini et al. ^[116]
	模型-知识图谱	将模型存储的知识(参数形式)转化为知识图谱	Kazemi et al. ^[117] , COMET ^[118] , BERTNet and RoBERTaNet ^[119] , Liu et al. ^[120] , West et al. ^[121]

3.1 实体抽取

实体抽取是知识图谱构建的第一步,其主要目的是从文本中识别和提取出具有特定意义的实体。实体发现通常包括 3 个子任务:命名实体识别、实体分类和实体对齐。

3.1.1 命名实体识别

命名实体识别(Named Entity Recognition, NER)旨在从文本中识别和提取出具有特定意义的实体,如人名、地名、组织机构等,并将其分类为预定义类别。PLM 通常通过预训练来学习实体的特征和上下文信息,然后在下游的分类器上进行微调,以获取完成 NER 任务的能力。根据识别实体的跨度类型,NER 可以分为非重叠 NER、嵌套 NER 和非连续 NER^[18]。本文根据这 3 种类型任务对 PLM 的相关应用进行介绍。

非重叠 NER 是最传统的 NER 任务,将命名实体视作一个整体,然后将 NER 转化为序列标注问题,利用 PLM 编码和识别文本中不重叠的实体。BERT 可以结合条件随机场(Conditional Random Field, CRF)进行序列标注,通过微调执行实体识别推理。biLM^[44]建立深度双向语言模型,对句法、语义及其多义性进行建模。DTPDR^[45]和 P-Tuning v2^[46]利用提示调优方法替代微调,针对固定的 PLM 调整连续的提示词来实现高效快速的 NER。Fu 等^[47]对 4 种基于 PLM 的 NER 方法进行了比较,证明了 BERT 这类 PLM 可以在较低的成本下实现更好的性能。

嵌套 NER 考虑了一个标记属于多个实体的情况,相比非重叠 NER,可以识别出更复杂的实体结构。它允许实体嵌套在其他实体之中,并使用嵌套标签来表示这种结构。PLM 通常需要通过增强文本跨度学习或结合组成树建模来实现嵌套 NER。Biaffine^[48]借鉴基于图的依存句法分析思想,建立双仿射语言模型对句子中的起始和结束标记对进行打分,以探索所有可能的跨度,预测命名实体。针对子序列分类计算

成本高、效率低的问题, BENS^[49]使用 BERT 作为编码器,并引入额外的边界检测任务来增强跨度表示。PO-TreeCRFs^[50]将嵌套 NER 视为具有部分观测树的组成解析,使用 BERT 编码文本,利用基础双仿射评分架构预测跨度得分,然后将嵌套 NER 视为具有观测树的组成解析,使用 CRF 进行建模。Lou 等^[51]对 PO-TreeCRFs 进行改进,利用词头作为注释的词汇化组成树来建模嵌套实体,加入词头正则化损失和词头感知标签损失以增强 PLM 的性能。Yang 等^[52]同样采用组成分析的思想,按照后序遍历的方式遍历组成树,通过两个跨度的共享边界来执行 NER,利用观测树的子树特征降低计算复杂度。

非连续 NER 可以识别在文本中以间隔分隔的实体,可以适应更多样化的实体表示。SoD-NER^[53]使用 BERT 进行词汇表示,然后引入一种注意力引导的图卷积网络(Graph Convolutional Network, GCN)增强文本跨度表示,最后通过遍历文本跨度和关系分类这两个步骤,同时识别重叠和不连续的实体。Yan 等^[54]使用 BART^[14]作为实体嵌入表示学习的编码器,将不同类型的 NER 子任务构建为实体跨度序列生成任务,并通过统一的序列到序列框架来解决。

最近, D-NER^[55]引入了动态 NER 任务,并利用 BERT 的不同版本进行了任务测试。该任务的目的是应对复杂文本中 NER 的上下文信息和限制记忆效应,更充分利用句子上下文信息来处理未见过的实体,提升模型的可迁移性。

3.1.2 实体分类

实体分类(Entity Typing, ET)旨在为已经识别出的实体赋予适当的类型标签,可以被视为“细粒度的命名实体识别”。PLM 通常通过微调来完成 ET 任务。根据 ET 任务监督场景的不同,基于 PLM 的 ET 方法可分为基于标签对齐的方法和基于提示学习的方法。

1) 基于标签对齐的方法。此类方法主要应用于有监督的

实体识别和分类任务,通过对齐模型的中间表示/输出表示和目标任务的标签来进行微调。Denoise-ET^[56]以 ELMo 模型为基础,添加指称编码器和类型编码器对训练数据进行去噪,并将去噪后的远程数据用于实体识别和分类的监督训练。Box4Types^[57]基于 BERT 模型,将概念嵌入为 d 维超矩形,以捕捉实体类型层次结构。MLM-ET^[58]利用 BERT 预测 MLM 指称的上位词,以用作实体类型的标签。针对相互依赖、长尾和细粒度的实体分类问题,Liu 等^[59]通过发现和利用数据中蕴含的标签依赖知识,顺序推理细粒度的实体标签。为缓解注释数据稀缺问题,LITE^[60]将实体识别和分类任务转化为自然语言推理,利用其间接监督推断类型信息,并利用排序目标来避免预定义类型集。DenoiseFET^[61]根据模型输出得分估计标签为正或负的后验概率,以去除噪声标签;然后对剩余的标签进行训练,以重新标记候选噪声标签,可以在不使用外部资源的情况下自动纠正实体识别和分类中的噪声标签。

2)基于提示学习的方法。此类方法通过提示学习来适应标签稀缺的无监督和少/零样本的实体识别和分类场景。Ding 等^[62]利用提示学习构建面向实体的命名方法和模板,并进行掩码语言建模,然后采用自监督策略以应对零样本的情况。Li 等^[63]引入了类型抽象的概念,通过提示进行泛化并对类型进行命名,然后利用推断的类型名称之间的相似性来诱导聚类。OntoType^[64]利用本体语言提供的语义丰富的层次结构的框架,将多个预训练语言模型的提示结果集成为一组候选类型,然后使用自然语言推理模型在本地上下文中对类型进行细化解析。

3.1.3 实体对齐

实体对齐(Entity Alignment,EA)包括共指消解和实体消歧,是将不同数据源(知识图谱)中的实体进行匹配和对应。实体对齐需要考虑实体的属性、上下文信息、语义相似性等因素,通过比较实体之间的相似度或相关性来确定是否相匹配。目前主流的实体对齐方法以基于图神经网络(Graph Neural Network,GNN)的方法为主,但这类方法语义学习能力不足,因此研究者们尝试使用 PLM 进行增强。此外,部分方法通过设计针对实体对齐的下游任务对 PLM 进行微调。

1)PLM 增强 GNN 的方法。此类方法利用 PLM 的上下文理解能力解决 GNN 邻居/属性聚合导致的噪声问题。BERT-INT^[65]利用实体和邻居的名称/描述以及实体的属性等附加信息,捕捉邻居之间的细粒度的确切语义匹配,缓解不相似邻居的负面影响。MAN 和 HMAN^[66]用于跨语言 EA 任务,集成了 GCN 和 BERT。GCN 用于结合实体的拓扑连接、关系和属性;BERT 将实体对齐任务形式化为文本匹配任务,对所有实体对进行语义匹配,并编码实体文字描述作为跨语言文本嵌入,以测量实体对之间的距离。

2)微调 PLM 的方法。此类方法设计针对 PLM 的微调来完成 EA。TEA^[67]将关系三元组和属性三元组转换为统一的文本序列输入 PLM 中,将序列之间的蕴含概率建模为实体之间的相似度,以捕捉实体之间信息的统一关联模式。ERNIE^[68]将 MLM 任务修改为专用于学习实体知识的实体去噪自编码任务,针对实体对齐进行随机掩码,并且要求模型

参考实体描述来判断对应的实体 ID。

3.2 关系抽取

关系抽取(Relation Extraction,RE)旨在从文本中识别和提取出实体之间的关系。经过在大量文本数据上进行预训练,PLM 能很好地理解词语和句子的含义和上下文,充当关系抽取模型中的特征编码器,为关系抽取任务提供丰富的语义知识。根据 PLM 理解和抽取关系方法的不同,本文将相关方法分为基于 MLM 的方法、基于提示学习的方法和实体知识增强的方法。

3.2.1 基于 MLM 的方法

这类方法通过将关系抽取建模为掩码语言建模任务进行预训练,然后添加关系分类器等任务特定层进行微调。此类方法早期的工作主要针对句子级别关系抽取,近两年的相关工作则主要面向文档级别的关系抽取。

句子级别关系抽取分析和提取单个句子中的实体之间的关系。TRE^[69]首次使用 PLM 完成 RE 任务,利用 Transformer 进行关系抽取。Shi 和 Lin^[70]将 BERT 用于 RE 中,证明 BERT 能在不使用任何外部特征的情况下独立完成关系抽取。Span-BERT^[71]通过对实体的上下文进行建模和引入跨度级别的训练目标来处理实体之间的关系。MTB^[72]利用 BERT 进行空白匹配训练,然后设计关系抽取目标,在标记数据上进行微调。Park 和 Kim^[73]提出了一种基于课程学习的 RE 方法,模拟人类由简到繁的学习过程,快速学习简单数据并解决局部优化问题,然后再逐步增加难度。RECENT^[74]集成了 SpanBERT 和 GCN,考虑实体类型对候选关系的限制,以减少不恰当关系的出现。CTL-DRP^[75]引入对比学习方法,同时考虑实体信息、关系知识和实体类型限制。

文档级别关系抽取从整个文档中提取出实体间的关系,需要综合考虑文档中的多个句子、段落或文本片段,并分析其关联关系。PLM 通常首先对文本进行编码,然后采用分层建模、共现汇聚等方式来实现文档级别关系抽取。HIN^[76]构建层次推理网络来聚合实体级别、句子级别和文档级别的信息。GLRE^[77]将文档信息编码为实体全局表示、实体局部表示以及上下文关系表示,对文档中的实体指称和关系进行复杂推理。GAIN^[78]构建异构指称级别图和实体级别图,前者捕捉不同指称之间的复杂交互,后者聚合同一实体的底层指称。SIRE^[79]聚合所有共现句子的关系表示,并使用 GAIN 进行文档级别的建模。LSR^[80]自动诱导潜在的文档级别图,基于图逐层执行句间关系推理。DocuNet^[81]利用编码器模块来捕捉实体的上下文信息,并在图像风格的特征图上通过 U 型分割来捕捉三元组间的全局依赖关系。ATLOP^[82]使用自适应阈值和局部上下文汇聚来解决多标签和多实体问题。

3.2.2 基于提示学习的方法

关系抽取任务通常具有不同的目标形式,因此微调方式的效率相对较低,且效果受训练数据和质量的影响较大。提示学习可以弥合预训练任务和关系抽取任务之间的格式差距,有效地利用 PLM 中编码的知识,且适用于句子和文档级别的关系抽取。提示学习将关系抽取任务视为文本生成问题,在提示模板中引入输入句子,利用模板

中的附加信息辅助生成过程。

LPAQA^[83]通过联合基于挖掘和基于释义的方法来自动生成高质量且多样化的提示,并集成来自不同提示的答案。PTR^[84]通过将设计的子提示与逻辑规则组合构建提示,帮助PLM利用预训练期间学到的通用语言表示和关系抽取能力。Li和Liang^[85]基于提示学习提出了前缀微调,使用子序列标记来引导PLM进行关系抽取,只学习0.1%左右的参数,微调的成本较低。Qin和Eisner^[86]提出将提示建模为由多个提示组成的连续向量来指导关系抽取。KnowPrompt^[87]将关系标签之间的知识融入到提示中,把关系抽取转化为恢复掩码单词的任务来提示PLM。为了减小构建提示的工作量,Shin等^[88]设计了AutoPrompt,通过梯度引导搜索自动生成提示。

上述RE方法都是基于SLM的。Gutiérrez等^[89]和Ma等^[90]的研究表明,在标注有限的情况下,LLM在关系抽取中的性能优于SLM。Wei等^[91]探索了ChatGPT在关系抽取任务中的性能,通过提示ChatGPT,将零样本信息抽取任务转化为多轮问答问题。Ma等^[90]提出了一种先过滤再重新排序的范式,结合了LLM和SLM的优势,其中LLM可以很好地补充SLM,并有效处理SLM难以处理的复杂样本。

3.2.3 实体知识增强的方法

此类方法以PLM为基线模型,将实体编码到PLM中,增强PLM的语义和知识学习能力,提升关系抽取的性能。除了知识图谱相关任务,实体知识增强还能提升PLM在其他任务中的性能。这类方法通常需要设计自然语言理解和事实知识(三元组)学习的双重任务联合训练策略和损失函数,帮助PLM同时学习两个方面的知识。

CokeBERT^[92]引入背景信息的动态选择机制,构建包含实体背景信息的知识表示学习模块,以更好地理解和学习关系并捕捉和表示共指信息。Coref-BERT^[93]引入指称参考预测任务,应用指称引用屏蔽策略来屏蔽一个或多个指称,并要求模型预测被屏蔽指称的对应引用。ERICA^[94]基于对比学习方法,通过使用文档级远程监督构建实体对,以隐式的方式考虑复杂的关系推理链,提高了关系的理解能力。KnowBERT^[95]使用集成的实体链接器来检索相关的实体嵌入,利用词到实体的注意力来更新上下文词表示,增强对实体之间关系的语义理解,并最终联合训练实体链接器和自监督语言建模目标。此外,ERNIE模型也同样适用于关系抽取。

总的来说,对比3种基于PLM的关系抽取方法,基于MLM的方法更加可靠,但需要有监督微调,效率较低;基于提示学习的方法效率和精度最高,但受提示形式和语言模型自身性能的影响较大;实体知识增强的方法扩展性和灵活性较强,但往往需要有与知识图谱规模相匹配的高质量实体知识才能起到性能提升作用。

3.3 实体链接

实体链接(Entity Linking, EL)指将文本中的实体链接到一个或多个知识图谱中的对应实体的过程。PLM可以对实体进行编码或解码,学习其恰当的语义表示,以实现更精确的链接。根据不同的链接方式,将基于PLM的EL分为基于向量匹配的方法和基于序列分析的方法。

3.3.1 基于向量匹配的方法

此类方法主要通过PLM将实体编码为向量空间中的向量,然后计算匹配分数(概率)来完成EL。E-ELMo^[96]将指称定义为整个段落的函数,然后预测引用实体来执行链接。Jia等^[97]将潜在实体类型信息注入到基于预训练BERT的实体嵌入,并把基于BERT的实体相似度分数集成到本地上下文模型中,以更好地捕捉实体类型信息。Broscheit等^[98]提出的基于BERT编码器的端到端EL方法,可以同时发现和链接实体。BLINK^[99]使用一种两阶段的零样本链接算法,第一阶段在双编码器定义的稠密空间中进行检索,第二阶段使用交叉编码器对每个候选进行重新排名。ELQ^[100]是一种端到端的EL方法,使用双编码器在一次处理中共同执行指称检测和实体链接。

还有部分此类方法将知识图谱作为外部知识增强到原有的PLM中,提升PLM的语义理解能力。E-BERT^[101]把实体嵌入拼接到文本中对应实体指称的前方,将实体向量与PLM的原生词向量空间对齐,利用对齐的实体向量作为词向量。FAE^[102]以键值对的形式存储知识图谱中的三元组嵌入编码,使用上下文编码的[MASK]作为查询来访问事实内存,根据知识图谱中的属性检索实体,执行实体链接。此外,KnowBERT和ERNIE等知识增强模型也在EL任务中有较好的表现。

3.3.2 基于序列分析的方法

针对向量匹配方法的计算复杂度较高的缺陷,此类方法将EL转化为序列分析问题,通过基于PLM的自回归等方式预测链接,无需逐对遍历匹配,可规避学习大量实体嵌入表示成本昂贵的问题。

Yamada等^[103]提出基于单词和实体上下文信息嵌入的全局EL模型,通过引入屏蔽实体预测任务来训练模型,并将EL视作顺序决策任务来扩展模型。mGENRE^[104]通过自回归直接捕捉上下文和实体名称之间的关系,并进行交叉编码,编码器和解码器不与实体数量成正比,占用的内存大大减小。针对自回归方法无法并行解码导致效率较低的问题,Cao等^[105]对所有潜在指称进行并行自回归链接,使用了浅层和高效的解码器。ReFin-ED^[106]是一种高效的具备端到端零样本能力的EL模型,利用细粒度的实体类型和实体描述,在单次前向传递中对文档中的所有指称进行指称检测、细粒度实体分类和实体链接,具有较高的效率。

3.4 端到端知识图谱构建

端到端知识图谱构建将“原始数据-知识图谱”的构建过程整合在一起,旨在自动化地从非结构或半结构化的文本数据中提取出实体、关系和属性,并将其组织成知识图谱。根据原始数据类型的不同,将基于PLM的端到端知识图谱构建方法分为3类:文本-知识图谱构建、表格-知识图谱构建和模型-知识图谱构建。

3.4.1 文本-知识图谱构建

此类方法直接从文本中提取实体、关系和属性,并利用PLM的语义理解和推理能力将其组织为知识图谱。

Kumar等^[107]利用实体感知的BERT分类器构建端到端

的实体关系提取系统。BERT 首先利用标签数据微调分类器学习实体识别能力,然后又作为关系分类器和方向分类器来提取关系。Melnyk 等^[108]提出一种端到端多阶段图生成系统 Grapher,首先使用 PLM 生成图节点,然后利用边构建模块从文本描述中提取知识图谱。PiVe^[109]训练一个 SLM 作为 LLM 输出的验证模块,然后迭代地利用细粒度的纠正指令改进提示信息,提升 LLM 的知识图谱抽取性能。KG-LLM^[110]将图编码器作为知识编码器,利用注意力机制设计知识融合模块,然后通过多任务学习策略提高 LLM 对文本中事实知识的学习能力。Zhu 等^[111]对比了 LLM 与一些微调的最优方法在知识图谱构建上的能力,发现尽管 LLM 的构建性能与微调后的最优方法稍有差距,但其构建的效率明显更高。Zhu 等还提出了 AutoKG,基于 ChatGPT 和 GPT-4.0 为知识图谱构建中的不同子任务设计了针对性的高效提示,直接从文本中提取事实知识以构建知识图谱。

3.4.2 表格-知识图谱构建

从数据库、网络表格和 CSV 文件这样的表格数据中提取知识也是构建知识图谱的常见方法。传统的方法通过定义并使用启发式规则将表格数据转化为知识图谱。然而,现实世界的表格中的语义往往不明确,重要的元信息(例如表名和列标题)定义缺失,而 PLM 可以学习表格的向量表示,使表格中的语义更加清晰,向量还可以作为其他预测任务的基础。

TURL^[112]使用 BERT 进行单元填充、列类型注释和关系抽取。RPT^[113]使用 BERT 和 GPT 预训练表格表示模型。Starmie^[114]使用模板将表格的列转化为序列,并以可合并和不可合并的列对作为样本,通过对比学习对 BERT 进行微调。Doduo 等^[115]将表格序列化为一系列的标记,并使用 BERT 来预测列类型和列之间的关系,以补充知识图谱。Korini 等^[116]使用 ChatGPT 来注释语义表格的列类型。

3.4.3 模型-知识图谱构建

此类方法直接提取出 PLM 中以模型参数知识存储的知识,并将其组织起来转化为知识图谱。

Kazemi 等^[117]研究了从 PLM 的参数中提取知识的方法,

并针对利用事实知识进行微调导致的过度预测和欠预测问题,设计了模型混合和预训练任务混合微调两种策略。COMET^[118]使用带有多头自注意力的 Transformer 来编码三元组,通过设计知识图谱补全相关的训练任务,把 PLM 的隐式知识转移到常识知识图谱中生成显式知识。BERTNet 和 RoBERTaNet^[119]从 PLM 中收集符号知识,通过自动创建多样化的加权提示来提供三元组关系的整体语义,并结合简单的示例对来消除歧义。Liu 等^[120]集成常识和领域知识,采用“双向学习”方法对 DialoGPT 进行微调,使知识和句子对之间建立双向关系,进而从对话模型中生成更符合背景的潜在三元组。West 等^[121]借鉴知识蒸馏方法提出了符号知识蒸馏框架,将知识以神经模型的形式蒸馏,并以文本的形式符号化,然后从 LLM(教师模型)中蒸馏出常识知识来微调一个 SLM(学生模型),最后利用这个 SLM 来生成常识知识。

4 基于 PLM 的知识图谱表示学习

知识图谱表示学习(Knowledge Graph Representation Learning, KGRL)又称为知识图谱嵌入(Knowledge Graph Embedding, KGE),旨在将知识图谱中的实体和关系表示为低维向量空间中的连续向量,使得实体和关系能够映射到向量空间中进行操作和计算。KGRL 是实现大规模知识图谱分析和处理的关键技术。

传统的 KGRL 方法主要包括基于张量分解的方法和基于传递模型的方法等^[24],利用知识图谱的结构信息来优化基于嵌入向量/矩阵的评分函数。然而,这些方法受限于知识图谱的结构,且难以表示未知实体和长尾关系。此外,传统方法难以捕捉高层次的语义知识,对少样本和零样本学习的能力较差。利用 PLM 作为知识图谱嵌入的文本和图结构编码器,能够解决结构连通性有限的问题,提升知识表示的能力。根据 PLM 在表示学习中发挥的作用不同,可以将基于 PLM 的 KGRL 方法分为两类,即 PLM 作为知识编码器和 PLM 作为联合编码器的方法。表 5 梳理归纳了这些方法的相关信息。

表 5 基于 PLM 的知识图谱表示学习方法的相关信息

Table 5 Relevant Information of knowledge graph representation learning methods based on PLMs

类型	模型/方法	嵌入方式	方法特点
PLM 作为知识编码器	Pretrain-KGE ^[122]	利用 PLM 将文本嵌入向量转化为实体和关系的初始化嵌入	
	KEPLER ^[123] 和 Alam et al. ^[124]	利用 PLM 的文本嵌入向量初始化	优点:训练成本低 缺点:对实体和关系的语义学习不充分
	KALA ^[127]	实体使用 PLM 的文本嵌入向量初始化,关系编码随机初始化	
	Nayyeri et al. ^[128]	使用 PLM 将实体和关系嵌入到四维超复数的二面体空间中	
PLM 作为联合编码器	K-BERT ^[129]	将原始文本扩展为树形结构再压缩回文本序列重排。三元组被插入文本对应实体的后方,后方原有文本依次后移	
	CoLAKE ^[130]	文本中的句子建模为全连接图,然后将相关的三元组直接链接到图中。训练时,相关的关系和实体被拼接在文本后方	
	LUKE ^[103]	将实体的嵌入表示拼接在文本嵌入的后方,加入了位置嵌入和实体类型嵌入	优点:能够更充分地学习实体、关系及其语义
	kNN-KGE ^[131]	将其实体描述文本嵌入表示拼接在实体嵌入表示的后面;将关系视为特殊的 token	缺点:训练成本较高,且容易引入噪声
	LMKE ^[132]	将所有三元组的头实体、关系、尾实体和对应的描述文本作为输入,并且将尾实体替换为[MASK]	
	KECP ^[134]	与 K-BERT 相似的嵌入方法	
	Bondarenko et al. ^[133]	在 BERT 的上层融入知识图谱嵌入表示	
GilBERT ^[135]	创建一个嵌入空间,将知识图谱中关于实体或关系的信息聚类		

4.1 PLM 作为知识编码器

这类方法直接用 PLM 从描述文本中学习到的词嵌入

向量作为对应的实体和关系的初始嵌入向量,然后通过训练对嵌入表示进行更新。其基本原理如图 4 所示。

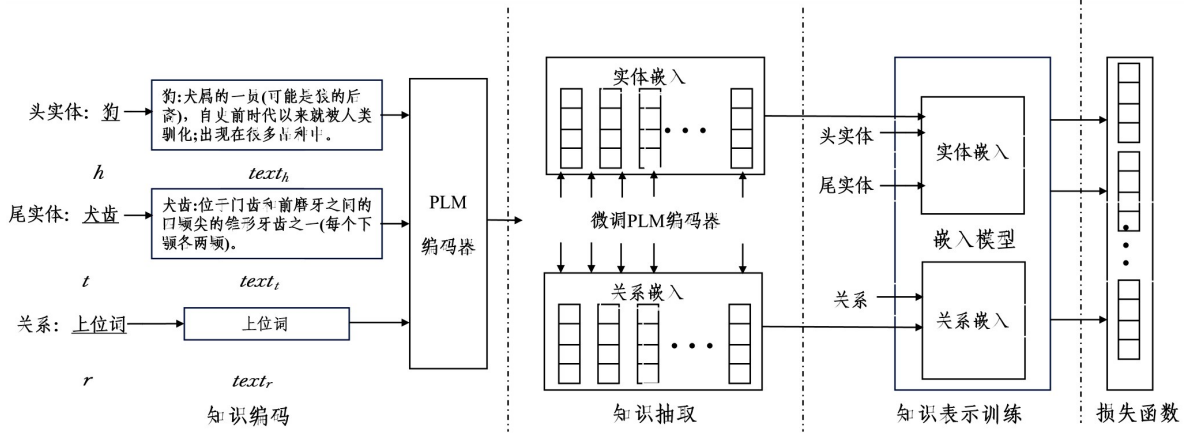


图 4 PLM 作为知识编码器的模型框架

Fig. 4 Model framework of PLM as knowledge encoder

Pretrain-KGE^[122]是最早使用 PLM 进行 KGRL 的方法。该方法使用 BERT 作为编码器来编码实体和关系,然后利用实体和关系的嵌入向量初始化其表示,即:

$$Enc_e(e) = \sigma(W_e BERT(text_e) + b_e) \quad (1)$$

$$Enc_r(r) = \sigma(W_r BERT(text_r) + b_r) \quad (2)$$

$$e_h, e_r, e_t = Enc_e(h), Enc_e(r), Enc_e(t) \quad (3)$$

其中, $text_e$ 和 $text_r$ 是实体和关系的语义描述; Enc_e 和 Enc_r 代表实体和关系编码器; W_e, W_r, b_e, b_r 是可学习的参数; e_h, e_r, e_t 是头实体、关系和尾实体的嵌入表示。在训练阶段,定义如下损失函数来优化嵌入模型:

$$\mathcal{L} = \max\{\gamma + f(e_h, e_r, e_t) - f(e_h', e_r', e_t'), 0\} \quad (4)$$

其中, $\{e_h', e_r', e_t'\}$ 表示随机替换后三元组的负实例, γ 表示边际量。通过将 PLM 编码的向量作为实体和关系的初始化表示,可以有效融合上下文语义信息,捕捉更高层的知识,从而学习到更好的嵌入表示。

与 Pretrain-KGE 不同, KEPLER^[123] 直接将知识图谱中的实体和关系的描述文本作为初始输入,即:

$$e_h, e_r, e_t = Enc(text_h), Enc(text_r), Enc(text_t) \quad (5)$$

然后,定义嵌入表示损失函数:

$$\mathcal{L}_{KE} = -\log \sigma(\gamma - d_r(e_h, e_t)) - \sum_{i=1}^n \frac{1}{n} \log \sigma(d_r(e_{h,i}, e_{t,i}) - \gamma) \quad (6)$$

其中, n 表示负实例的数量, $d_r(e_h, e_t) = \|e_h + e_r - e_t\|$ 。KEPLER 将嵌入损失函数 \mathcal{L}_{KE} 和 MLM 损失函数 \mathcal{L}_{MLM} 相加,计算联合训练的损失,并允许多个知识图谱同时与 PLM 进行联合训练。

Alam 等^[124] 提出一种 PLM 引导的 KGRL 方法,其采用与 KEPLER 相同的嵌入方式,将知识图谱相关的文本信息引入 KGE 模型中。他们利用 Sentence-BERT^[125] 和 FastText^[126] 获取相关文本信息的嵌入,并将其注入到一个与模型无关的损失函数中,以便其与各种不同的 KGE 模型相结合。

KALA^[127] 根据实体及其在文本中的指称,初始化其

嵌入向量,即:

$$e_h^{init}, e_r^{init}, e_t^{init} = Enc(text_h), e_{rand}, Enc(text_t) \quad (7)$$

然后将所有实体的嵌入向量以键值对的形式存储到一个实体内存库中。引入知识特征调制层,将实体嵌入表示转化为线性变换的参数,并对嵌入表示进行更新。与 Pretrain-KGE 和 KEPLER 不同, KALA 中的关系嵌入是随机初始化的。关系嵌入来源于基于 GNN 的目标实体聚合,在训练中随实体嵌入表示的更新而更新。

知识图谱中包含了结构化和文本化知识。为同时集成和推理这两种类型的知识, Nayyeri 等^[128] 利用超复数代数来表示不同模态之间的交互及其知识表示方式。嵌入向量通过 Hamilton 和 Dihe-dron 乘积进行学习,从而模拟不同类型知识间的成对交互。在四维超复数的二面体空间中,实体和关系表示为:

$$e = s_e + x_e^{\mathcal{T}_1} i + y_e^{\mathcal{T}_2} j + z_e^{\mathcal{T}_3} k \quad (8)$$

$$r = \frac{s_r + x_r^{\mathcal{T}_1} i + y_r^{\mathcal{T}_2} j + z_r^{\mathcal{T}_3} k}{\sqrt{s_r^2 + x_r^{\mathcal{T}_1} + y_r^{\mathcal{T}_2} + z_r^{\mathcal{T}_3}}} \quad (9)$$

其中, s 表示超复数的实部; i, j, k 表示 3 个虚部的单位向量; x, y, z 表示 3 个方向上的“长度”; \mathcal{T}_i 可以从集合 $\{_, \text{Word2Vec}, \text{Fasttext}, \text{Sentence Transformer}, \text{Doc2Vec}\}$ 中选择,分别代表结构化知识图嵌入、词级表示、句级表示和文档级表示这 4 种类型。

4.2 PLM 作为联合编码器

这类方法将实体的嵌入表示和 PLM 中与实体对应的描述文本的嵌入表示同时作为输入,然后通过 MLM 和下游任务微调等方式来训练模型和更新参数,其基本原理如图 5 所示。相比 PLM 作为知识编码器的方法,此类方法能够更充分地学习实体、关系及其语义,但训练的成本较高,且容易引入噪声。

K-BERT^[129] 把知识图谱中的三元组直接插入文本中,然后使用 PLM 在微调阶段进行训练。KBERT 首先将原始文本扩展为树形结构,然后再压缩回文本序列进行重排。三元组

被插入文本中对应实体的后方,后方原有文本则依次后移。K-BERT 还引入了软置索引和可视矩阵,防止句子丢失原有结构信息。CoLaKE^[130]将文本中的句子建模为全连接图,相关的三元组直接链接到图中。训练时,关系和实体被拼接在文本后方,采用与 K-BERT 类似的软位置编码方法,还添加了类型编码。不同于 K-BERT,CoLaKE 在预训练阶段注入知识图谱嵌入。LUKE^[103]采用与 CoLaKE 类似的策略,将实体的嵌入表示拼接到文本嵌入的后方,并加入位置嵌入和实体类型嵌入。图 6 展示了这 3 种方法的联合编码策略对比,其中黄色字体表示实体描述文本嵌入,绿色字体表示关系描述文本嵌入,蓝色字体表示实体和关系嵌入。

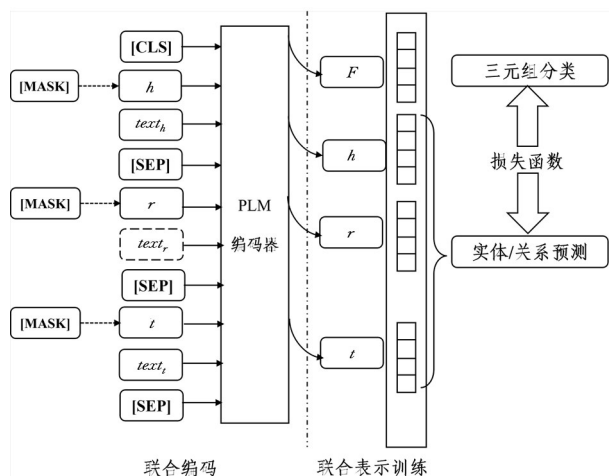


图 5 PLM 作为联合编码器的模型框架

Fig. 5 Model framework of PLM as joint encoder

针对可能存在的“看不见”(未在训练集中出现)的实体, kNN-KGE^[131]根据知识图谱中实体嵌入空间的距离计算近邻,然后利用 PLM 通过线性插值将其实体分布与 k 个最近邻相结合。对于每个实体,将其对应描述文本中的嵌入表示拼接接到实体嵌入表示的后面;而对于关系,则将其视为一个特殊的标记,不拼接相关描述文本。

前述方法需要进行负采样,训练成本高且效率较低。针对该问题,LMKE^[132]采用对比学习框架,将三元组和对应的描述文本作为输入,将尾实体替换为[MASK],其输入的标记序列为:

$$x = [\text{CLS}] h \text{ text}_h r \text{ text}_r [\text{MASK}] [\text{SEP}] \quad (10)$$

然后,经过 PLM 输出的[CLS]代表三元组的嵌入, $e(\text{triple})$ 通过分类任务进行微调;而对于输出的尾实体预测结果,则使用一个 MLP 进行相似度计算,以应对负样本不足的情况。

针对嵌入学习中标注数据少的问题,研究者们基于对比学习或聚类提出了一系列对策。Bondarenko 等^[133]集成了多种对比学习方法,在 BERT 的上层融入知识图谱嵌入表示,然后依据对比学习训练任务重塑损失函数。KECP^[134]将文本嵌入向量与实体、关系嵌入向量拼接作为输入,然后使用相似且混淆的语义采样负跨度文本,最后通过对比学习优化嵌入表示。GiBERT^[135]采用基于 Transformer 的三元组网络创建嵌入空间,将知识图谱中关于实体或关系的信息聚类,然后从事实中创建文本序列,对三元组网络进行微调。




图 6 K-BERT,CoLaKe 和 LUKE 的联合编码策略对比(电子版为彩图)

Fig. 6 Comparison of joint encoding strategies in K-BERT,CoLaKe and LUKE

5 基于 PLM 的知识图谱推理

知识图谱推理(Knowledge Graph Reasoning, KGR)是从现有的知识出发,运用推理方法获取所蕴含的隐藏事实。其本质是通过推导或归纳,将个体知识推广到一般性知识的过程。根据对象三元组是否完整,可以将知识图谱推理任务分为知识图谱去噪(Knowledge Graph Denoising, KGD)和知识图谱补全(Knowledge Graph Completion, KGC)两类,前者是对现有完整三元组正确与否进行判断,而后者是对缺失实体或关系进行预测。

早期的 KGR 方法大多从知识图谱的结构出发,采用图的演绎、归纳和路径搜索等方法进行推理,对知识图谱相关的文本、语料应用不够,对语义知识的挖掘不深。针对该问题,近年来基于 PLM 的 KGR 方法不断涌现。在这些研究中,PLM 主要是作为编码器或解码器来实现推理。根据 PLM 发挥作用的不同,相关方法可以分为 PLM 作为文本编码器、PLM 作为文本生成器和 PLM 作为路径编码器。

表 6 梳理归纳了基于 PLM 的知识图谱推理方法的相关信息。

表 6 基于 PLM 的知识图谱推理方法的相关信息

Table 6 Relevant Information of knowledge graph reasoning methods based on PLMs

PLM 作用	分类	特点	模型/方法	优缺点
文本编码器	基于相似度排序	基于输出序列中的[CLS]向量进行评分,得出所有潜在推理结果的概率(相似度),然后通过排序选择最终结果	KG-BERT ^[136] , Kim et al. ^[137] , iHT ^[138] , SimKGC ^[139] , Lv et al. ^[140] , CSProm-KG ^[141]	优点:单次推理高效 缺点:需要微调,需要逐个评分排序,无法适用于未见实体,适应性不强,无法用于闭源 PLM
	基于掩码预测	基于 MLM 来对三元组及其描述文本进行编码,通过预测结果的评分构造损失函数,对掩码预测模型进行训练,以学习知识图谱补全能力	MEM-KGC ^[142] , OpenWorld KGC ^[144] , MLMML ^[143] , Bi-Link ^[145] , TAGREAL ^[146] , SSTBERT ^[147] , PPT ^[148] , LP-BERT ^[149]	
文本生成器		将 PLM 作为解码器或编码器-解码器,根据输入的缺失的三元组直接生成完整三元组	KG-T5 ^[150] , GenKGC ^[151] , KG-S2S ^[152] , AutoKG ^[111]	优点:对负实例的要求较低;可以扩展到“看不见”的实体;适应性强,可以和各种 PLM 结合 缺点:单次推理慢,未见实体可信度难保证
结构编码器		利用 PLM 对知识图谱中的结构(图、路径)进行编码,通过对编码的路径进行评分和排序来完成知识图谱推理	BERT-RL ^[153] , KGLM ^[154] , Lan et al. ^[155] , StAR ^[156] , LASS ^[157] , MoCo-SA ^[158]	优点:捕捉结构和语义信息,可解释性强 缺点:成本高,噪声和信息损耗大

5.1 PLM 作为文本编码器

此类方法将 PLM 作为编码器对知识图谱及其描述文本进行编码,然后利用评分函数对[CLS]或[MASK]对应的嵌入向量进行处理,转化为概率分数,判断三元组的可能性,并选择最有可能的实体/关系进行补全。根据推理所利用的标记不同,此类方法可以分为基于相似度排序的方法(使用[CLS])和基于掩码预测的方法(使用[MASK])。

5.1.1 基于相似度排序的方法

此类方法基于输出序列中的[CLS]向量进行评分,得出所有潜在推理结果的概率(即与正确答案的相似度),然后通过排序选择最终结果。将三元组经过 PLM 后[CLS]输出的隐藏向量记为 \mathbf{C} ,通过定义评分函数 $f(\mathbf{C})$ 计算概率分数。

KG-BERT^[136]是一种典型的 PLM 作为文本编码器的推理方法,其原理如图 7 所示。该方法将三元组的实体和关系描述输入 BERT 中。对于知识图谱去噪任务(见图 7(a)),假设 Transformer 隐藏层维度为 H ,根据 $\mathbf{C} \in \mathbb{R}^H$ 和参数 $\mathbf{W} \in \mathbb{R}^{2 \times H}$ 计算分数,即:


$$s = f(\mathbf{C}) = \text{sigmoid}(\mathbf{C}\mathbf{W}^T) \quad (11)$$

得到的分数是一个长度为 2 的向量,其两个数值分别代表正实例和负实例的分数,然后再通过交叉熵损失函数进行训练和优化。对于知识图谱补全任务(见图 7(b)),根据 $\mathbf{C} \in \mathbb{R}^H$ 和参数 $\mathbf{W} \in \mathbb{R}^{|\mathcal{R}| \times H}$ 计算所有关系的概率分数,然后采用相同的训练方式, $|\mathcal{R}|$ 表示关系的数量。

Kim 等^[137]针对 KG-BERT 无法充分学习关系信息和难以从词汇相似的候选项中选择出正确答案的问题,在 KG-BERT 基础上提出了一种多任务学习方法,将关系预测、相关性排序任务和链接预测结合起来,以学习更多关系属性,识别相似的词汇。iHT^[138]采用与 KG-BERT 类似的推理方法,并以 Transformer 作为评分函数,改进了 KG-BERT 的归纳式推理性能。

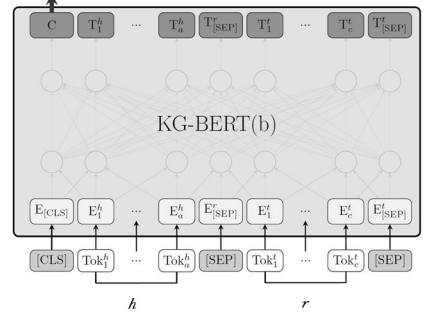
SimKGC^[139]采用对比学习训练三元组评分模型,并引入了 3 种类型的负实例,以增强对比学习的训练数据,防止 PLM 为高度重叠的头实体分配过高的分数;然后,使用 KG-BERT 进行编码,通过最大化三元组与正实例嵌入表示的相似度并最小化三元组与负实例表示的相似度来训练模型。

三元组标签 $\{0, 1\}$



(a) 用于知识图谱去噪的 KG-BERT

关系标签 $\{1, 2, \dots, R\}$



(b) 用于知识图谱补全的 KG-BERT

图 7 KG-BERT 的两类模型框架

Fig. 7 Two types of model architecture of KG-BERT

传统的 KGR 评估大多在封闭世界假设情况下运行,评估数据集的有限性导致对方法性能的评估不准。针对该问题, Lv 等^[140]提出了一种在开放世界假设下进行 KGR 性能评估的方法,并开发了基于提示学习的知识图谱推理方法 PKGC。该方法根据模板将三元组转化为提示句子,克服了直接将实体和关系拼接导致的不连贯和语义偏差。他们还证明了 PLM 对 KGR 方法带来的性能提升并不只是因为知识的增加,更重要的是推理能力的提升。

CSProm-KG^[141]也是一种基于提示学习的 KGR 方法。该方法根据三元组进行条件软提示,然后在一个冻结的 PLM 中将提示与文本充分交互,最后将输出传入基于图的 KGR 模型 ConvE^[35]中进行训练。此外, CSProm-KG 还提出了一种

局部对抗正则化方法来提取文本相似的实体用于训练。

5.1.2 基于掩码预测的方法

此类方法基于 MLM 来对三元组及其描述文本进行编码,通过预测结果的评分构造损失函数,基于[MASK]对掩码预测模型进行训练,以学习知识图谱补全能力。其原理如图 8 所示。相比基于相似度排序的方法,此类方法对负实例的要求较低,计算复杂度更小。




图 8 基于掩码预测的知识图谱推理模型框架

Fig. 8 Framework of knowledge graph reasoning model based on mask prediction

MEM-KGC^[142]使用掩码实体模型(Masked Entity Model, MEM)分类机制来预测三元组的掩码实体,引入实体预测和超类预测两种任务。对于实体预测(Entity Prediction, EP),输入文本的形式同式(10);对于超类预测(Superclass Prediction, SP),为应对看不见的实体,进行归纳推理,MEM-KGC将三元组转化成如下输入序列:

$$x_{sp} = [\text{CLS}] [\text{MASK}] [\text{SEP}] \text{text}_h [\text{SEP}] \quad (12)$$

分别根据[MASK]和[CLS]计算 EP 和 SP 的输出评分。

假设三元组经过 PLM 编码后[MASK]的输出向量为 \mathbf{M} , [CLS]的输出向量为 \mathbf{C} ,那么 EP 和 SP 中的三元组的概率分数可以分别写成:

$$s_{ep} = \text{softmax}(\mathbf{M}\mathbf{W}_1^T) \quad (13)$$

$$s_{sp} = \text{softmax}(\mathbf{C}\mathbf{W}_2^T) \quad (14)$$

其中, \mathbf{W}_1 和 \mathbf{W}_2 为可训练参数。最后根据概率分数计算损失函数,进行联合训练。MEM-KGC 不需要训练负样本,可以最小化采样方法的影响,显著减少训练时间。

MLMLM^[143]以 RoBERTa 为基座,采取与 MEM-KGC 相同的编码方式,首先比较从 MLM 中采样得到的具有不同长度文本的可能性,然后使用平均可能性抽样重新排序所有可能的实体。

OpenWorld KGC^[144]将 MEM-KGC 模型扩展到开放世界中,同样定义了两个任务:实体描述预测任务用于预测给定文本描述的对应该实体;不完整三元组预测任务用于预测缺失三元组($h, r, ?$)的尾实体。首先使用式(12)对三元组进行编码并生成最终隐藏状态,然后将其作为式(10)中头实体的嵌入进行不完整三元组预测。

还有一些研究使用提示学习来增强基于 MLM 的 KGR 方法。Bi-Link^[145]基于 Transformer 编码器,采用双向预测的策略从两个方向理解三元组,以理解对称关系。在正向和反向预测中,输入序列分别为:

$$x_f = [\text{CLS}] \text{text}_h \text{prompt } r [\text{MASK}] \quad (15)$$

$$x_b = [\text{CLS}] \text{text}_t \text{prompt } r [\text{MASK}] \quad (16)$$

其中,prompt 表示基于规则的提示文本。然后,通过对比学习将相同三元组的头尾实体拉近,将负实例的批次分开。

TAGREAL^[146]借助于 PLM 捕捉的事实来辅助开放式知识图谱补全,通过引入提示生成和信息检索方法,自动生成高质量的用于 PLM 知识探索的提示,并搜索支持信息,提供领域知识。

针对时序知识图谱补全(TKGC)问题,SST-BERT^[147]将结构化句子与时序增强的 BERT 相结合,通过编码结构化句子来获取实体历史,并在语义空间中学习隐式规则,提升灵活性。此外,SSTBERT 引入时间 MLM 任务,以在包含时间信息的语料库中预训练 BERT,增强时间敏感性。PPT^[148]将 TKG 中采样的四元组转换为 PLM 的输入,并将时间戳的间隔转换为不同的提示,以形成具有隐含语义信息的连贯句子;然后将 TKGC 任务转换为掩码标记预测任务,用掩码策略训练模型。

LP-BERT^[149]包括多任务预训练和知识图谱微调两个阶段。在多任务预训练阶段,使用 MLM 来学习上下文语料库的知识,并引入 MEM 和掩码关系模型(Masked Relation Model, MRM),通过预测基于语义的实体和关系来学习三元组的关系信息。在微调阶段,利用 BERT 对“头实体+关系”和尾实体两个部分进行编码,将每个三元组分成两个不对称的部分 \tilde{x}^h 和 x^t ,即:

$$\tilde{x}^h = [\text{CLS}] h [\text{SEP}] r [\text{SEP}] \quad (17)$$

$$x^t = [\text{CLS}] t [\text{SEP}] \quad (18)$$

最后,在样本批次中进行三元组的负采样,增加了负采样的比例。

5.2 PLM 作为文本生成器

此类方法将 PLM 作为解码器或编码器-解码器,把 KGR 建模为序列-序列生成问题。通过 PLM 对输入的缺失三元组进行处理,直接对缺失部分进行补全,生成完整三元组,其原理如图 9 所示。




图 9 PLM 作为文本生成器的知识图谱推理模型框架

Fig. 9 Framework of knowledge graph reasoning model with PLMs as text generator

KGT5^[150]是最早将 PLM 作为文本生成器执行 KGR 的模型。KGT5 使用编码器-解码器型 Transformer,以知识图谱链接预测和问答作为序列-序列生成任务。在推理的训练过程中,使用自回归解码进行三元组评分,通过链接预测任务执行预训练,最后在问答任务上进行微调。该模型量级和计算复杂度较小,推理性能优于 T5 模型。

GenKGC^[151]将实体和关系表示为输入序列,并以 BART 作为编码器-解码器生成缺失的实体。首先,将目标知识图谱转化为元组 $G = (\mathcal{E}, \mathcal{R}, \mathcal{T}, \mathcal{C}, \mathcal{D})$,其中 \mathcal{C} 是实体类型, \mathcal{D} 是实体描述。然后,构建关系引导的提示模板,根据目标关系 r_j 的指导,从训练集中抽样具有相同关系的输入示例作为演示。

输入序列为:

$$x = [\text{CLS}] P(r_j) [\text{SEP}] \text{text}_h \text{text}_r [\text{SEP}] \quad (19)$$

其中, $P(r_j)$ 表示关系 r_j 的演示示例。最后, 使用实体感知的分层解码方法, 通过自回归公式计算概率, 对实体进行排序。这种分解方式避免了采样负实例的计算成本。

KG-S2S^[152] 将不同的文本化图结构表示为统一的文本形式, 适用于静态、时序和少样本的 KGC 任务。该方法将知识图谱中的事实定义成一个四元组 (h, r, t, m) , 其中 m 表示额外的“条件”元素。为了将不同类型的 KGR 任务统一到相同模板中而不丢失结构信息, KG-S2S 采用 3 种策略改进实体和关系的输入表示, 包括: 1) 引入额外的实体描述来丰富实体的上下文信息; 2) 为特定实体和关系添加额外的可训练提示; 3) 使用 Dropout 技术, 在注意力模块随机选择并屏蔽一定比例的输入标记。

此外, AutoKG^[111] 针对闭源的大模型 Chat-GPT 和 GPT-4.0, 使用基于提示学习的方法来完成 KGR, 通过设计指令、提供示例和反馈学习, 指导大模型进行自动推理, 如图 10 所示。AutoKG 特别适用于少样本和零样本的情况, 为利用闭源大模型完成知识图谱相关任务提供了借鉴。

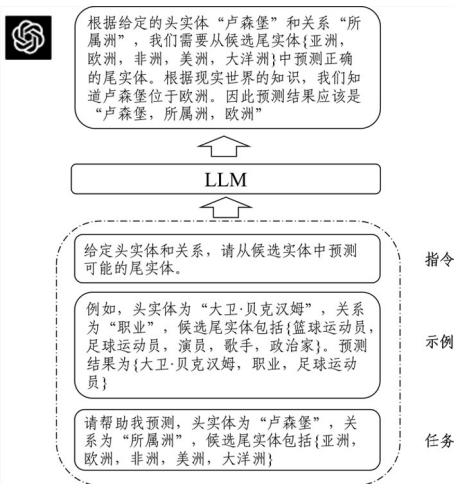


图 10 AutoKG 执行知识图谱推理示例

Fig. 10 Example of KGR executed by AutoKG

相比 PLM 作为文本编码器的方法, PLM 作为文本生成器的方法有如下优点: 1) 对负实例的需求较少; 2) 可以扩展到“看不见”的实体; 3) 适用性强, 可以推广到各种不同的 PLM 框架, 包括闭源的 LLM。但此类方法也存在如下缺点: 1) 单次推理时间通常较长, 计算效率不高; 2) 生成的“新实体”的可信性难以保证。

5.3 PLM 作为结构编码器

此类方法首先通过线性化将图结构或路径线性化为输入序列, 然后利用 PLM 对知识图谱中的结构(图、路径)进行编码, 并对编码的路径进行评分和排序以完成知识图谱推理。其原理如图 11 所示。此外, 最近的研究将 PLM 同时用作文本和结构编码器, 以理解和捕获不同类型知识。

BERT-RL^[153] 将 PLM 与关系学习相结合, 首先对知识图谱进行线性化处理并将其作为 BERT 的有效输入, 然后建立 BERT 模型对推理路径进行编码, 最后聚合三元组路径和推理路径的评分。

KGLM^[154] 引入一个新的实体/关系嵌入层来区分实体和关系类型, 帮助模型学习知识图谱的潜在结构。模型首先从知识图谱中提取正向和逆向的三元组来预训练, 然后利用 MLM 训练目标, 对添加了额外实体/关系类型嵌入层的 RoBERTa 进行预训练, 将输入标记与其对应的实体/关系类型连接在一起形成结构嵌入。

Lan 等^[155] 针对稀疏性导致推理难度大的问题, 提出了两种基于路径的推理方法来解决实体和路径稀疏性问题。第一种方法是 BERT 增强的实体表示, 采用类似于 Pretrain KGE 的方法增强实体的嵌入表示; 第二种方法使用模板将路径表示为文本描述, 将实体对 (e_s, e_t) 的路径文本描述表示为集合 $P = \{\pi_1, \pi_2, \dots, \pi_n\}$, 其中 $\pi_i \in \mathbb{R}^d$ 表示路径。最后使用 BERT 编码, 将最后隐藏层的 [CLS] 输出表示作为路径序列嵌入。

StAR^[156] 针对 KG-BERT 需要对所有的潜在三元组进行评分及计算复杂度较高的问题, 将文本嵌入和图嵌入技术相结合, 采取与 LP-BERT 类似的不对称编码方式, 然后使用两个带有池化层的 Transformer 编码器进行编码, 并设计了一个三元组二分类任务和一个对比学习任务, 分别学习文本化知识和结构化知识。

LASS^[157] 也同时学习了文本嵌入和图结构嵌入。与 StAR 的不同之处在于, LASS 将结构信息也嵌入到三元组的文本描述中, 然后通过最小化结构化损失来重构语义嵌入中的结构信息。

MoCoSA^[158] 利用对比学习方法, 设计了自适应的结构编码器, 使 PLM 能够感知结构信息。该方法独立地对文本和结构表示进行编码, 然后利用文本编码器进行融合。通过在文本中编码结构信息, 平衡文本和结构信息的学习。编码的结构信息还能学习一个共享的维度空间, 通过负采样策略匹配嵌入, 以发现更多有信息量的样本。此外, 引入了两类负实例来提高对比学习的效率。

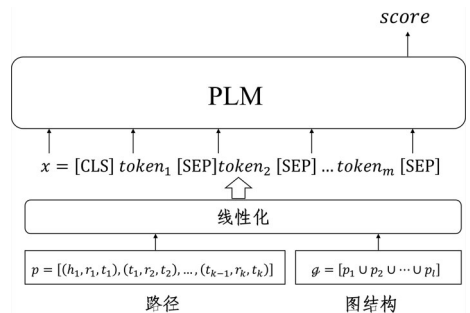


图 11 PLM 作为结构编码器的知识图谱推理模型框架

Fig. 11 Framework of knowledge graph reasoning model with PLMs as architecture encoder

相比对文本进行编码或编码-解码的 KGR 方法, 此类方法融合了结构化知识, 具有更强的可解释性, 但对路径进行编码和处理也需要更高的成本, 且面临着更多的噪声和信息损耗。

6 基于 PLM 的知识图谱问答

知识图谱问答 (Knowledge Graph Question Answering,

KGQA)是以知识图谱为依据,通过理解用户提出的问题,从知识图谱中获取相关信息,查找准确的答案。传统的 KGQA 方法往往难以捕捉知识图谱中的语义信息。利用 PLM 抽取自然语言问题中的实体、关系,进入结构化的知识图谱寻找问题答案,再通过 PLM 组合答案,并结合其自身知识将

答案以自然语言的方式输出,能够有效增强知识图谱问答的广度、自然性和准确性。根据 PLM 在问答中发挥的作用不同,可以分为 PLM 作为信息编码器和 PLM 作为推理器的方法。表 7 梳理归纳了基于 PLM 的知识图谱推理方法的相关信息。

表 7 基于 PLM 的知识图谱问答方法的相关信息

Table 7 Relevant information of KGQA based on PLM

PLM 的作用	分类	模型/方法	方法特点
PLM 作为语义编码器	基于匹配评分	KagNet ^[159] , Lukovnikov et al. ^[160] , Luo et al. ^[161]	利用 PLM 作为编码器,对知识图谱和文本的分离或联合编码,再通过向量匹配评分和下游任务基于微调等方式训练问答模型 优点:模型相对简单,编码策略灵活 缺点:归纳推理能力差
	基于微调	EAE ^[162] , TMA ^[163] , Petroni et al. ^[164]	
PLM 作为信息编码器	PLM 作为路径编码器	Zhang et al. ^[165] , MHGRN ^[166] , Misra et al. ^[167]	使用 PLM 编码路径,然后计算路径的概率分数,选择最优路径查询答案 优点:可解释性强 缺点:路径编码可能导致信息损失和噪声
PLM 作为推理器	PLM 独立推理	DEKCOR ^[168] , DRLK ^[169] , RECKONING ^[170] , KBQARL ^[171] , UniKGQA ^[172]	根据知识图谱和问题查询,使用 PLM 作为主推理引擎进行独立推理、增强推理或联合推理 优点:模型复杂 缺点:归纳推理能力更强,适用于少样本和无监督场景
	外接模块增强	K-Adapter ^[173] , OreLM ^[174]	
	PLM 推理	KAPING ^[175] , StructGPT ^[176]	
	多模块联合推理	QA-GNN ^[177] , JointLK ^[178] , GreaseLM ^[179] , ReLMKG ^[180]	

6.1 PLM 作为信息编码器

此类方法依靠 PLM 从知识图谱中提取实体和关系,通过编码的方式学习它们的嵌入表示,然后通过对接入向量的计算来检索答案。

6.1.1 PLM 作为语义编码器

此类方法利用 PLM 作为编码器,对知识图谱和文本的分离或联合编码,学习其语义的嵌入表示,然后再通过向量匹配、评分和下游任务微调等方式训练问答模型。

1)基于匹配评分的方法。此类方法基于对 PLM 编码的嵌入向量计算问题和答案的匹配评分 $score(q, a) = f(Enc(q), Enc(a))$,其中 q 表示问题, a 表示答案。KagNet^[159]提出一种联合编码框架,首先利用 PLM 将问题-答案编码到语义空间,然后将问题-答案对映射到基于知识的符号空间作为模式图,最后利用图表示对答案进行评分。Lukovnikov 等^[160]使用 BERT 识别问题中的跨度并预测使用的关系,然后通过倒序索引来检索与预测跨度相似的标签实体,最后按照字符相似度及关系数量进行排序得到答案。为了弥合问题与知识图谱事实之间的语义差距, Luo 等^[161]提出一种基于 PLM 的关系感知注意力模型,将问题-答案对构造为 PLM 的输入,以保留原始的交互信息,并使用关系感知注意力网络来增强候选答案的表示,最后对 PLM 编码的向量进行相似度匹配来查询候选答案。

2)基于微调的方法。此类方法通过下游 QA 任务对 PLM 进行微调,以适应 QA 的目标。EAE^[162]文本中学习实体的表示,首先用 PLM 预测文本中实体指称的边界,然后从实体存储器中检索实体嵌入,并将其添加到下一个 Transformer 层的输入,将最后一个 Transformer 块的输出与问答任务的头部相连接,进行有监督微调。TMA^[163]使用 Sentence-BERT 对时序知识图谱中的主谓宾结构进行预训练,

学习其嵌入表示,然后将预训练的知识图谱嵌入和问题嵌入一起输入到 MLP 中生成预测和执行有微调训练。Petroni 等^[164]采用纯无监督的方式,通过 BERT 的 NSP 任务将检索系统的信息与 PLM 集成在一起,利用 PLM 编码的相关上下文来增强查询,并使用启发式算法来减少候选答案中的噪声。

6.1.2 PLM 作为路径编码器

为了加强对结构化知识的建模,提升模型的可解释性,部分研究使用 PLM 进行路径建模,然后通过计算每一条路径对应的概率分数 $score(q, p) = f(Enc(q), Enc(p))$ 选择最可能路径查询答案,其中 p 和 p 表示路径和嵌入。

Zhang 等^[165]提出了一种基于 PLM 的路径检索器,通过逐跳检索问题相关关系并构建多条路径,将检索到的关系和路径作为上下文知识来提升答案推理器的性能。MHGRN^[166]在 KagNet 的基础上,将基于路径的推理方法和 GNN 相结合,使用 PLM 进行路径编码,通过联合多跳关系推理模块,在从知识图谱中提取的子图上进行多跳、多关系的推理,具有更好的可解释性和可扩展性。Misra 等^[167]以知识增强的 T5 模型为基座,对知识图谱的多条路径进行编码,通过训练软提示,在结构化知识上进行随机游走,并设计了两种策略:PATH 策略设计两种软提示,用于从问题中解析事实和生成答案路径; MIXHOP 策略在混合任务中训练单个提示,将 QA 任务与随机游走相结合。

6.2 PLM 作为推理器

此类方法根据知识图谱和问题查询,使用 PLM 作为主推理引擎直接生成答案,还可以通过外接提示、插件进行增强推理,或者结合其他模块(如 GNN)进行联合推理。其基本原理如图 12 所示。相比 PLM 作为信息编码器的方法,此类方法的模型更为复杂,但具有更强的归纳推理能力,更适合于少样本和无监督的问答场景。

表 8 基于 PLM 的事件知识图谱研究方法的相关信息

Table 8 Relevant information on the research methods of event knowledge graph based on PLMs

任务	分类	方法特点	模型/方法
句子级 事件抽取	基于分类	使用 PLM 对句子进行编码,然后通过分类器进行事件提取	Yang et al. ^[182] ,OntoED ^[183] ,DyGIE ^[184]
	基于任务 转换	将 EE 转化为问答或翻译任务,然后使用经过相关任务微调的 PLM 提取事件	RCEE ^[185] , ONEIE ^[187] , Lyu 等 ^[188] , TANL ^[186]
文档级 事件抽取	端到端生成	使用 PLM 作为编码-解码器(即生成器),直接从文本中提取事件	Text2Event ^[189] , Gen-Arg ^[190] , UIE ^[191] , EA2E ^[192] , PAIE ^[193] , Memory-DocIE ^[194]
	编码+微调 方法	用 PLM 作为编码器,学习输入文本的嵌入表示,然后通过任务微调来训练提取模型	PoKE ^[195] , TSAR ^[196] , Procnnet ^[197] , TARA ^[198]
事件时序 关系发现	基于 SLM	利用规模较小的开源 PLM 作为编码器来学习语义特征,再通过嵌入匹配和微调等方式发现时序关系,需要访问 PLM 结构	Su et al. ^[199] , Wang et al. ^[200] , Bayesian-Trans ^[201] , MulCo ^[202] , Unified-ETRD ^[203]
	基于 LLM	通过为 LLM 提供提示模板来实现端到端的事序关系发现,相比基于 SLM 的方法更加简便高效,且可以对各类 LLM 即插即用,无需访问模型内部架构	Yuan et al. ^[204] , IncSchem ^[205] , AutoG-PT ^[206]
事件因果 关系发现	关系发现 模型	设计基于 PLM 的因果关系发现模型	Liu et al. ^[207] , SemSIn ^[208] , DA-Prompt ^[209] , Gao et al. ^[210]
	外部知识 增强	利用 PLM 引入外部知识,提供用于增强因果关系发现能力的表示或数据	KnowDis ^[211] , LearnDA ^[212] , CauSe-RL ^[213] , LSIN ^[214] , ERGO ^[215]
事件共指 消解	基于事件配对	利用 PLM 对事件对进行上下文建模,然后对学习的嵌入表示进行处理,采用二值分类器作为评分器,为每个事件对分配一个共指概率	Barhom et al. ^[216] , Choubey et al. ^[217] , EPASE ^[218] Ahmed et al. ^[219]
	基于先行词 排序	利用 PLM 进行编码,并行处理先行事件,然后为每个给定事件的第一个共指先行词进行排序,相比基于事件配对的方法具有更高的效率	E3C ^[220] , Lu et al. ^[221] Lu et al. ^[222] , Tran et al. ^[223] , Ravi et al. ^[224] , Horwood ^[225]

7.1 事件抽取

事件抽取(Event Extraction, EE)是从文本中提取结构化的事件信息,主要包括两个子任务,即触发词检测和论元提取。早期的事件抽取大多通过机器学习和神经网络实现,而 PLM 能根据文本呈现的上下文动态地对句子中的单词进行编码,在事件抽取中有明显的优势。

7.1.1 句子级事件抽取

句子级事件抽取(Sentence-level Event Extraction, SEE)指从一个句子中抽取触发词和参数。根据提取事件方式的不同,基于 PLM 的 SEE 方法可分为基于分类的方法和基于任务转换的方法。

基于分类的方法使用 PLM 对句子进行编码,然后利用分类器进行事件提取。Yang 等^[182]在 BERT 上添加一个多分类器和多组二值分类器,分别用于触发词检测和论元提取。OntoED^[183]利用事件-事件关系丰富事件模式,以改进基于 BERT 的分类器触发词检测。DyGIE^[184]利用 BERT 对句子进行编码,然后列举文本跨度,构造跨度图,通过整合相邻嵌入来更新跨度嵌入,最后将其传递给分类器。

基于任务转换的方法将 EE 转化为问答或翻译任务,然后利用经过相关任务微调的 PLM 提取事件。RCEE^[185]提出了基于 BERT 的机器阅读理解框架,通过问答的方式抽取事件。TANL^[186]将 EE 转换成翻译任务,把结构化信息作为输入/输出的一部分,利用 PLM 进行编码,并使用一种鲁棒的对齐方法以确保提取的结构与原句子的正确部分匹配。ONEIE^[187]利用 BERT 所学的嵌入和基于全连接卷积网络的分类器计算所有候选触发器、实体及其成对链接的局部分数,然后使用波束搜索解码器来搜索全局最优结果。Lyu 等^[188]将 EE 作为一组文本蕴涵和问答查询(如“一个城市遭到了袭击”蕴含着“发生了一次袭击”)来进行零样本事件抽取,利用

微调过的 PLM 直接执行抽取。

7.1.2 文档级事件抽取

文档级事件抽取(Document-level Event Extraction, DEE)指从分散在文档中的多个句子中提取触发词和参数。根据 PLM 在 DEE 中发挥作用的不同,将此类方法分为端到端生成方法和编码+微调方法。

端到端生成的方法使用 PLM 作为编码-解码器(即生成器),直接从文本中提取事件。Text2Event^[189]以 T5 模型为基座,设计了“序列→结构”网络用于事件抽取,并使用约束解码算法在推理过程中注入事件知识。Gen-Arg^[190]使用 BART 作为生成器,将 EE 任务转换为根据事件模板进行条件生成,在给定未填充模板和上下文的情况下,生成一个填充参数的模板以提取事件。UIE^[191]利用结构化抽取语言,使用 PLM 统一编码不同的抽取结构,通过基于模式的提示机制自适应地生成抽取目标,执行通用事件抽取。EA2E^[192]将事件参数的一致性问题定义为文档级设置下事件间关系的约束,引入了事件感知参数抽取模型,并通过增强的上下文进行训练和推理。PAIE^[193]引入了基于提示的跨度选择器来选择输入文本中每个目标的起始/结束标记,然后使用 BART 作为生成器捕捉参数间的相互作用。Memory-DocIE^[194]通过 PLM 构建文档记忆存储器来记录上下文事件信息,并利用它在隐式和显式上下文中帮助解码后续事件的参数。

编码+微调方法使用 PLM 作为编码器,学习输入文本的嵌入表示,然后通过任务微调来训练提取模型。PoKE^[195]使用联合触发器来融合描述理解和交互建模这两个任务,通过建模不同触发器或参数之间的交互作用,激发嵌入在 PLM 中的知识。TSAR^[196]引入抽象意义表示(Abstract Meaning Representation, AMR)引导的交互模块,基于局部和全局构建的 AMR 语义图来捕捉句内和句间特征。Procnnet^[197]使用

BERT 作为序列标注器,在句子级别上检测实体,通过对实体组成标记的隐藏状态进行平均来得到其表示,然后使用事件代理节点和距离最小化方法进行文档级多事件抽取。TARA^[198]通过添加基于 AMR 的文本对齐器和稀疏器集成跨度信息,突出显示同一文档中周围的事件,并使用 GNN 作为链接预测模型来查找事件。

7.2 事件关系发现

事件关系发现(Event Relation Discovery, ERD)指发现事件中各种类型的关系,包括时序关系和因果关系等。相比传统知识图谱,事件知识图谱中的关系发现更为复杂,需要适应复杂的语义和表示模式。本文重点调研了基于 PLM 的时序关系发现和因果关系发现的相关文献。

7.2.1 时序关系发现

事件时序关系发现(Event Temporal Relation Discovery, ETRD)是对事件之间先后顺序的描述。早期的时序关系发现基于人工设计的语法和语义特征,把时序关系发现转化为分类问题。近几年,越来越多的学者将 PLM 用于时序关系发现任务中。这些方法主要是利用 SLM 作为编码器从文本中学习语义表示,进而提取关系,或者通过提示学习将 LLM 作为端到端的关系发现工具。

1)基于 SLM 的方法。利用规模较小的开源 PLM 作为编码器来学习语义特征,再通过嵌入匹配和微调等方式发现时序关系。这种方法通常需要访问 PLM 的结构。Su 等^[199]提出一种基于深度双射注意力时间信息提取模型,利用 BERT 学习到的文本嵌入来提取非结构化文本中的事件时间关系。Wang 等^[200]利用 PLM 作为编码器,添加了反事实分析和不确定性估计两种策略来提升 ETRD 的准确性和可信度。Bayesian-Trans^[201]使用 BART 作为编码器,将事件时间关系表示建模为隐变量,并通过贝叶斯推断和转移函数来推断其值,具有较强的不确定性编码和表达能力。MulCo^[202]利用 BERT 来编码局部上下文,使用 GNN 来表示全局文档级的句法和时间特征,然后通过多尺度对比学习目标共同训练两个模块,实现协同参数化。Unified-ETRD^[203]使用 PLM 作为编码器,将时序关系转化为时间点的逻辑表达式,并通过预测时间点对之间的关系来完成 ETRD,该方法可以适应低数据场景和不同的关系定义。

2)基于 LLM 的方法。这类方法通过为 LLM 提供提示模板来实现端到端的时序关系发现,相比基于 SLM 的方法更加简便高效,且对各类 LLM 可以即插即用,无需访问模型的内部架构。Yuan 等^[204]研究了 ChatGPT 在零样本 ETRD 中的能力,设计了 3 种提示技术来分解任务并评估 ChatGPT,证明了相对于监督方法,ChatGPT 能够更准确地推断出更多的稀有关系类别。IncSchema^[205]将事件模式视为一种可以从 LLM 中派生的常识知识形式,以简化模式归纳过程,直接处理事件之间的层次和时间关系。此外,还引入了一种增量提示和验证方法以适应复杂模式事件。AutoGPT^[206]通过提供少样本和提示词来利用 LLM 进行事件时序关系的发现。

7.2.2 因果关系发现

事件因果关系发现(Event Causality Discovery, ECD)指从文本数据中提取出描述事件之间因果关系的信息。当前,

基于 PLM 的事件因果关系发现研究主要包括两个方面的内容,即设计基于 PLM 的因果关系发现模型,以及利用 PLM 引入外部知识来增强用于因果关系发现的嵌入表示或训练数据。

1)基于 PLM 的因果关系发现模型。通过 PLM 来编码和学习上下文关系,进而推理因果关系。Liu 等^[207]引入基于 PLM 的知识感知推理器和掩码推理器进行事件因果关系的发现。知识感知推理器使用知识增强的 BERT 对句子进行建模,学习表达性事件嵌入;掩码推理器同样使用 BERT,但事件指称被[MASK]符号取代,以挖掘事件不可知模式和特定于上下文的模式。SemSin^[208]以 BERT 为语境编码器,分别使用 GNN 和 BiLSTM 对以事件为中心的结构和与事件相关的结构进行显示语义建模,以发现事件间的因果关系。DAPrompt^[209]使用确定性假设提示学习模型,为发现因果关系设计提示模板,并与输入事件对进行拼接来计算预测事件的概率,判定因果关系。Gao 等^[210]对 ChatGPT 的文本因果推理能力进行了首次全面评估,并证明 ChatGPT 并不是一个很好的因果推理器,而是一个很好的因果解释器。

2)基于 PLM 的外部知识增强数据。通过 PLM 引入外部知识来解决因果关系提取所需数据缺乏的问题。KnowDis^[211]基于词汇知识提取因果事件对用于远程标注句子,然后利用因果常识知识进一步优化标注,最后利用远程标记句子来训练基于 BERT 编码器的因果关系发现模型。LearnDA^[212]是一种知识引导的数据增强框架,将因果关系发现和句子生成视为双重任务,使用 BERT 进行编码和解码,并通过双向学习建模其相互关系,实现数据交互增强。CauSERL^[213]从外部因果陈述中学习特定上下文的因果模式,然后采用对比传递策略将学习到的模式数据融入到基于 BERT 的目标因果关系提取模型中。LSIN^[214]将来自事件句子的 BERT 上下文信息嵌入以及来自外部知识事件的 GCN 嵌入进行拼接,将拼接后的增强嵌入传递给分类器。ERGO^[215]通过构建事件关系图将 ECD 转化为节点分类问题,整合事件对关系分类和全局推断,最后利用关系图 Transformer 捕获潜在的因果链。

7.3 事件共指消解

文档中可能有许多文本描述相同的事件,需要将引用相同现实事件的事件分组到相同的簇中,即事件共指消解(Event Coreference Resolution, ECR)。基于 PLM 的事件共指消解方法主要是利用 PLM 学习事件文本的嵌入表示,然后采取计算匹配评分或共指先行事件排序的方法进行共指消解。

7.3.1 基于事件配对的方法

此类方法利用 PLM 对事件对进行上下文建模,然后对学习的嵌入表示进行处理,采用二分类器作为评分器,为每个事件对分配一个共指概率。

Barhom 等^[216]提出一种用于跨文档共指解析的模型,使用 ELMo 进行上下文建模,发掘词汇跨度、周围上下文以及与事件指称之间的关系,通过谓词-论元结构来表示事件指称。Choubey 和 Huang^[217]使用 BERT 作为文本的编码器,将学习到的嵌入向量输入到最大化池层后进行多次线性变换,得到预测标签。EPASE^[218]使用 BERT 进行上下文建模,

设计了释义识别模块和特殊标记[COREF]来帮助BERT捕捉事件特定的释义关系,通过语义注意机制将语义的角色标签嵌入和标记嵌入整合为事件的共指得分。Ahmed等^[219]使用跨文档语言模型CDLM对事件文本进行编码,利用启发式方法过滤大量非指代关系,并在一组平衡的指代和非指代关系的指称对上进行训练。

7.3.2 基于先行事件排序的方法

此类方法并行处理给定事件之前提到的所有事件,即先行事件,然后利用对先行事件的训练,为每个给定事件的一个共指先行事件进行排序。相比基于事件配对的方法,此类方法具有更高的效率。

E3C^[220]是一种端到端ECR方法,利用BERT进行词的上下文信息嵌入,通过联合建模EE和ECR任务,从原始文本中提取特征,并使用类型引导的事件指代机制以应对多样化指称。Lu和Ng^[221]基于SpanBERT提出基于跨度的模型进行ECR,证明了实体指代信息能够有效辅助完成ECR任务。同期,Lu和Ng^[222]还提出了基于约束多任务学习的ECR方法,将事件指代与5个任务进行联合训练,并将跨任务

一致性约束作为软约束引入到学习过程中,以指导模型学习。Tran等^[223]使用BERT编码获取词表示、实体指表示和事件指称表示,然后在文档结构中引入多样知识源创建文档结构图,最后通过端到端解析和簇一致正则化得到事件的共指集群。Ravi等^[224]使用PLM作为跨度编码器,在ECR模型中增加了一个常识推理引擎,提升了ECR模型的性能。Hsu和Horwood^[225]提出一种基于对比表示学习的跨文档ECR的方法,以RoBERTa作为编码器,并利用神经网络微调,最后使用“黄金指称”替代预测的指称进行训练和评估。

8 基于PLM的多模态知识图谱技术

多模态知识图谱(MMKG)研究尚处于早期阶段,目前,相关的研究主要集中在命名实体识别、实体对齐、关系抽取、事件抽取、模态融合、表示学习和推理这7个方面,其中前4个方面属于MMKG的构建^[226-227]。利用PLM对多类型数据统一处理的能力,可以赋能多模态知识图谱的构建、表示、推理和应用的全流程。表9梳理归纳了基于PLM的多模态知识图谱研究方法的相关信息。

表9 基于PLM的多模态知识图谱研究方法的相关信息

Table 9 Relevant information on the research methods of MMKG based on PLM

任务	模型/方法	PLM的作用
命名实体识别	UMT ^[228] , FMIT ^[229] , BFCL ^[230] , ITA ^[231] , MAF ^[232] , TISGF ^[233] , MGICL ^[234]	作为统一编码器对不同模态的数据进行处理,弥合表示差距,减小视觉噪声
实体对齐	MEaformer ^[233] , UMAEA ^[234] , Oscar ^[235] , Knowledge-CLIP ^[236]	作为编码器将不同模态数据投射到同一个语义空间,统一向量维度和表示方法
关系抽取	HVPNeT ^[239] , DGF-PT ^[242] , MoRe ^[241]	同“命名实体识别”
事件抽取	CAMEL ^[242] , VM ² E ² ^[243] , Multimedia-EE ^[244] , CLIP-Event ^[245] , VF-Event ^[246] , TSEE ^[247]	作为编码器来对齐文本和视觉数据的表示
模态融合	ViLBERT ^[248] , Visual-BERT ^[249] , LXMERT ^[250] , VL-BERT ^[251] , PixelBERT ^[252] , Inter-BERT ^[253] , Unicoder-VL ^[254]	在模态融合中作为编码器对不同模态数据信息进行融合处理
表示学习	Han et al. ^[255] , ERNIE-ViL ^[256] , ROSITA ^[257] , UNIMO ^[258] , Sun et al. ^[259] , Huang et al. ^[260] , RECipe ^[262] , VPT ^[264]	作为统一编码器学习相同形式的嵌入表示,捕捉多模态语义信息
推理	MarT ^[265] , MKGformer ^[266] , KVQA ^[267] , SGMPT ^[268] , VBKGC ^[269] , MACO ^[270]	作为融合编码器,充当事实推理之前的多模态知识融合模块

8.1 知识图谱构建

8.1.1 命名实体识别

多模态命名实体识别(Multi-modal Named Entity Recognition, MNER)旨在从图像中检测和定位目标视觉对象,然后在知识图谱中用实体(或概念)符号标记这些对象。PLM在MNER中通常作为统一的编码器对不同模态的数据进行处理,弥合它们之间的表示差距,减小视觉噪声。

UMT^[228]以BERT为基座模型,通过添加两个额外的Transformer层分别编码和融合文本和视觉信息。FMIT^[229]利用多模态交互Transformer将视觉和文本的细粒度语义表示转化为统一的格点结构,并设计相对位置编码来匹配不同模态。BFCL^[230]提出一种基于Transformer的瓶颈融合机制来限制噪声传播,并利用图像-文本对比损失对齐单模态表示。ITA^[231]将图像与文本连接作为跨模态嵌入输入到PLM中,对不同模态视图预测的输出分布进行对齐,提高对图像噪声的鲁棒性。MAF^[232]使用跨模态匹配模块来计算文本和图像间的相似度得分,以确定应保留的视觉信息比例,并利用跨模态对齐模块弥合两种模态的表示差距。TISGF^[233]构建视觉和文本场景图,使用BERT对这两个场景图分别进行

编码,获得对象级和关系级的跨模态特征。MGICL^[234]将数据切分为不同粒度,即文本的句子级/词级和图像的图像级/对象级,然后使用PLM进行统一编码和抽取,缩小模态间的特征空间差距。

8.1.2 实体对齐

MMKG的实体对齐(Multi-Modal Entity Alignment, MMEA)将来自不同模态的信息进行对齐,以建立其对应关系,从而直接应用于一些多模态任务,如视觉问答、视频摘要等,或作为视觉-语言预训练模型的预训练任务。PLM可以作为编码器将不同模态的数据投射到同一个语义空间,统一其表示模式,以便进行对齐。

Chen等^[233]提出了一种用于元模态混合的多模态实体对齐模型MEaformer,其以Transformer为基本单元,通过动态地预测模态之间的相互关系数来执行细粒度的实体级模态融合和对齐。为解决不确定缺失和模糊视觉模态问题,UMA EA^[234]对MEaformer进行改进,使用GNN进行多模态知识嵌入,嵌入经过全局模态整合后,使用基于Transformer的多头跨模态自注意机制进行融合,将嵌入表示用于实体对齐。Oscar^[235]将词符、对象标签、区域特征输入到多层

Transformer 中,利用图像中检测到的对象标签作为锚点,在一个共享的语义空间中对齐图像和语言模态。Knowledge-CLIP^[236]将语义信息注入到 CLIP 模型中,通过在预训练过程中引入基于知识的目标,并利用不同类型的知识图谱作为训练数据实现高质量的视觉-语言语义对齐,学习跨场景和跨模态的推理能力。

8.1.3 关系抽取

多模态关系抽取 (Multi-Modal Relation Extraction, MMRE)旨在识别图像中检测到的视觉实体(或概念)之间的语义关系,然后使用知识图谱中的关系对它们进行标注。MMRE 可以被视为 MNER 的后续任务,尽管两个任务的目的不同,但其研究方法趋于一致,许多研究采用相同模型来完成这两项任务。

HVPNeT^[239]将视觉表示视为可插拔的视觉前缀,引导文本表示进行具有误差抵抗性的预测决策,并设计了一种动态门控聚合策略,以解决不相关的图像与文本结合时的错误敏感性问题。DGF-PT^[242]使用 GPT-2 作为词汇编码器,提出基于提示的自回归编码器,通过面向实体和面向对象的前缀,分别建立与任务相关的模态内和模态间的特征关联。此外,设计了双门控融合模块来整合有用的视觉信息,丰富文本表示。MoRe^[241]使用 XLM-RoBERTa 和 CLIP 作为文本和图像编码器,通过将知识库中检索到的文本和图像知识分别发送到文本和视觉模型进行预测,可以同时完成 MNER 和 MMRE 任务。

8.1.4 事件抽取

多模态事件抽取 (Multi-Modal Event Extraction, MMEE)任务与常规的事件抽取任务内容基本一致,但需要同时处理文本和视觉数据。这项任务本质上是 MNER 和 MMRE 的组合。PLM 在 MMEE 中同样作为编码器来对齐文本和视觉数据的表示。

CAMEL^[242]使用两个 Transformer 分别作为文本和图像编码器,利用图像生成器像字幕生成器那样来生成缺失的模态,并设计迭代和逐步训练策略来学习跨领域的鲁棒特征。VM²E^[243]同样使用 Transformer 来编码不同的模态信息,构建自监督多模态事件共指模型来实现零样本的共指消解,并使用多模态 Transformer 从视频和文本文档中提取结构化的事件信息。Multimedia-EE^[244]的编码形式与前两种方法类似,利用对比学习来改进文本和图像的相似表示,可用于无标注的零样本场景。CLIP-Event^[245]基于视觉-语言预训练模型 CLIP,使用多个提示函数,通过操作事件结构来对比困难的负面描述,强制理解事件及其相关论元角色。VF-Event^[246]采用预训练的 CLIP 模型,利用领域特定的视觉想象器来从文本中合成图像,还设计了一种领域自适应的视觉融合事件检测方法。TSEE^[247]使用 PLM 和预训练的视觉模型,将光流特征与视频外观特征和文本序列特征相结合,通过多层次事件对比学习,对光流特征与事件触发词、事件触发词与类型之间的嵌入空间进行对齐。

8.2 模态融合

模态融合旨在通过跨模态融合,更好地利用不同模态之间的互补性,提供更准确的知识表示和推理。

ViLBERT^[248]通过共注意力的 Transformer 层分别处理视觉和文本输入,并利用这些层进行交互。Visual-BERT^[249]将文本和图像同时输入模型,通过自注意力隐式地对输入文本和相关联图像中的区域进行对齐。不同于 ViLBERT 的双流模型,该模型为单流模型,更加简单。LXMERT^[250]以 ViLBERT 为基座,在跨模态注意力层后添加全连接层,以融合图像和文本信息,并添加了跨模态掩码预训练任务。VL-BERT^[251]在视觉语言和纯文本数据集上进行融合预训练,输入元素可以是文本的单词或图像中感兴趣的区域。Pixel-BERT^[252]同样采用多模态 Transformer 学习视觉和语言融合表示,通过在像素和文本级别上对齐语义连接,突破视觉表示局限性,降低注释的成本,解决了视觉任务和语义之间标签不平衡的问题。Inter-BERT^[253]融合了单流和双流模块,提出掩码片段建模、掩码区域建模和图像-文本匹配 3 个预训练任务,并在一系列视觉和语言下游任务上对模型进行微调。Unicoder-VL^[254]将视觉和语言信息同时输入一个多层 Transformer 中进行跨模态预训练,并使用了包括掩码语言建模、掩码对象分类和视觉-语言匹配 3 个任务,以学习文本和图像的融合表示。

8.3 表示学习

多模态知识图谱表示学习旨在学习一个能够捕捉不同模态之间关联性的嵌入表示,使得这些表示能够有效地表达和推理出实体之间的关系。相比模态融合,表示学习更注重学习合理的嵌入向量,增强知识图谱的语义表达能力和应用效果。PLM 可以充当不同模态的统一编码器,通过学习到相同形式的嵌入表示捕捉多模态语义信息。

Han 等^[255]提出了一种端到端的自适应阈值多模态表示学习方法,使用双流网络分别提取多模态实体嵌入和阈值嵌入,使用 Transformer 和 RoBERTa 分别编码图像和文本信息,然后将它们拼接在一起以获得实体表示。ERNIE-ViL^[256]是 ERNIE 的一种变体,利用视觉场景图,在预训练阶段构建场景图预测任务,然后从场景图中获取结构化知识,进而学习视觉-语言的联合表示。ROSITA^[257]引入结构化知识掩码策略,利用场景图结构作为先验知识进行掩码语言建模,通过消除模态内和模态间的干扰信息来减小语义差异。UNIMO^[258]利用大量的开放域文本语料和图片集来提高视觉和文本理解能力,采用跨模态对比学习方法将大量文本和视觉信息映射到统一的语义空间。Sun 等^[259]提出一种“联合预训练和本地重新训练”框架,在链接的多模态知识图谱上预训练一个大型的嵌入模型,并通过知识蒸馏转移到特定任务的学生模型中进行训练。Huang 等^[260]外部知识库 Visual-Sem^[261]与 BERT 相结合,使用下游任务进行句子查询,学习多模态知识图谱的嵌入。RECipe^[262]从 MPNet^[263]中获取文本实体的嵌入表示,并使用知识图谱引导的变分自编码器来学习图像的潜在表示,对两个表示模型进行联合训练。VPT^[264]基于 Flan-T5 架构,通过建立自回归因果语言模型,预测 YouTube 视频中的语音单词,将视频转化为紧凑的嵌入表示。

8.4 推理

相比传统知识图谱推理,由于 MMKG 中的实体存在于

多个模态中,其推理通常需要在事实推理之前进行不同模态的额外知识融合,而 PLM 能够很好地充当融合编码器。由于 Transformer 在多模态场景中具有良好的性能,近年来学者们提出了多种通用的多模态预训练 Transformer 模型用于多模态知识图谱推理。

MarT^[265]利用稀疏知识图谱对模型进行预训练,以获取实体和关系的表示,然后通过专门的数据集提供基于提示的类比推理。MarT 可以与多种不同的 MPT 相结合,有效提升推理性能。MKGformer^[266]引入模态编码器 M-Encoder,然后在其中添加一个粗粒度的前缀引导交互模块,以减少下一步的模态异质性。此外,M-Encoder 还引入相关性感知融合模块来获得细粒度的图像-文本表示,减轻不相关图像的错误影响。KVQA^[267]将模型分解为一系列基于记忆的推理步骤,每个步骤由一个图形化的读取、更新和控制模块执行,该模块在视觉和语义信息上进行并行推理。SGMPT^[268]使用图结构编码器进行结构特征编码,并设计了结构引导的融合模块,将结构信息注入到文本和视觉特征中。VBKGC^[269]使用 VisualBERT 作为多模态编码器,将实现模态对齐和融合的知识隐含地存储在模型的参数中,以用于推理。模型将包含的文本知识和视觉信息作为输入,然后将输出传送到投影和评分模块进行整合,以获取深度多模态特征。MACO^[270]通过对抗训练生成器和判别器来生成缺失的模态特征,将特征融入到 MMKG 推理模型中,并使用了一种跨模态对比损失来改进生成器的性能。

9 挑战和未来研究方向

尽管基于 PLM 的知识图谱技术已经逐步发展完善,在多样化的知识图谱任务中表现出优异的性能,但由于知识图谱的语义和结构复杂性,以及 PLM 自身的缺陷,基于 PLM 的知识图谱技术仍面临着很多亟待解决的问题。此外,随着 LLM 的兴起,如何发挥其强大的生成和涌现能力来提升知识图谱技术的性能也是一个重要的研究方向。

9.1 挑战

结合当前预训练语言模型和知识图谱的研究现状,基于预训练语言模型的知识图谱技术还存在如下 7 个方面的挑战。

1)应对大模型幻觉。大语言模型的幻觉(Hallucination)指模型生成的文本不符合事实或无法从源内容中验证,主要原因是数据质量不高(如重复、内在差异)或模型的性能不足(如不完善的表示学习和解码错误等)。尽管已经有研究针对幻觉提出了改进措施^[271-272],但在生成式大模型中,幻觉依然是很难避免的。而幻觉造成的错误很可能在知识图谱的链式结构中不断传播扩散,产生负面的影响。

2)处理长尾实体。长尾实体指在一个给定的领域或数据集中出现频率较低的实体。长尾实体在预训练语料库中出现的频率较低,导致预训练语言模型对有关知识的记忆、学习和语义理解也明显不足,难以有效挖掘相关信息。

3)纠正语义偏差。大多预训练语言模型是以单词为基本单元进行语义学习的,因此在应用到知识图谱中时,若遇到一词多义或一义多词等情况,可能会造成混淆和偏差。此外,

实体引用方式的多样性和未见实体的消歧也是使用 PLM 进行知识图谱构建的一大难点。

4)结构化知识学习。基于纯文本数据训练的预训练语言模型往往难以捕捉结构信息。已有的方法通过一种简单的方法将结构化数据线性化为预训练语言模型可以理解的句子,但这种方法可能造成信息的损失,且在大规模知识图谱中无法适用。

5)评估模型推理性能。目前基于预训练语言模型的知识图谱推理的评估依然沿用传统的评价指标,如准确率、召回率、Hit@k、MRR^[29]等。但由于预训练语言模型是基于大量语料库进行训练的,这些语料库可能与知识库(如 Wikidata)重叠,因此如何区分并评估模型的事实记忆和推理能力也需要有系统的评价指标体系。

6)多种模态融合。尽管最近多模态预训练模型已经在多模态融合、实体对齐等方面取得了一定的进展,但不同模态知识的编码和弥合依然还难以达到令人满意的程度。此外,模态数据的不平衡、融合策略的选择和大规模数据的效率等问题都需要进一步研究。

7)知识动态更新。世界上的知识是不断更新的,这要求知识图谱和预训练语言模型都随之更新,而 PLM 参数规模庞大,模型框架复杂,更新往往是非常耗时且成本昂贵的。因此,如何使用高效、低成本的方法完成知识图谱和预训练语言模型的更新,都是亟待解决的问题。

9.2 未来研究方向

综合分析基于预训练语言模型的知识图谱技术研究现状、现存问题和挑战,以及大语言模型的发展趋势,下一步,基于预训练语言模型的知识图谱技术应重点从以下方面展开研究和探索。

9.2.1 知识图谱构建

1)构建新型知识图谱。最近,除了现有的 4 种主流知识图谱,决策知识图谱^[273]和因果知识图谱^[274-276]等新型知识图谱的相关研究也逐渐兴起。因果知识图谱与现有的因果学习研究类似,更加聚焦由因及果和由果溯因的推理,注重从感知到认知的进化;决策知识图谱则在事件知识图谱的基础上添加了“决策”维度,着重关注事件知识图谱如何直接指导实践中的决策。这些新型知识图谱涉及复杂语义和逻辑线索,必然需要以 LLM 强大的语言理解和推理能力为支撑。

2)提升知识图谱质量。考虑到知识图谱的结构化存储优势,利用知识图谱消除 LLM 幻觉很可能是一个潜在的研究方向。通过知识图谱的反馈强化学习消除 LLM 的幻觉,反过来再利用更可信赖的 LLM 来增强知识图谱研究,可以形成可靠性增强的正反馈,提升图谱的质量。此外,LLM 还可以利用固有的知识和推理能力,通过语义一致性检查、知识完整性评估、事实验证、异常检测等方法,评估知识图谱的质量,为更好地改进知识图谱提供判据。

9.2.2 知识图谱表示学习

1)上下文感知的动态嵌入。传统的知识图谱嵌入方法往往生成静态的向量表示,忽略了实体和关系在不同上下文中的多样性。未来可以基于 LLM 开发上下文感知的动态嵌入技术,根据不同的查询上下文动态调整实体和关系的嵌入

表示。这种方法可以更精确地反映实体在不同情境下的语义变化,提高知识图谱在特定任务上的灵活性、适应性和准确性。

2)跨语言知识图谱嵌入。知识图谱往往包含多种语言的信息,尤其是在全球化的背景下,跨语言的知识表示和检索变得尤为重要。很多LLM在多语言的大规模语料库中进行了预训练,可以在保持不同语言知识等价性的同时,避免受到特定语言偏见的影响^[277]。因此,可以通过基于多语言任务的LLM微调,使其无缝处理多语言信息,并支持跨语言的知识检索和应用。

9.2.3 知识图谱推理

1)大规模知识图谱推理。工业级知识图谱通常是大规模的^[27],因此现有的神经网络模型和小规模预训练模型的体量无法高效地完成推理,需要将大规模图进行切分,通过牺牲精度来换取效率。LLM已经被证明在大规模图结构上也具有较强的能力^[278-279]。未来应探索如何通过低成本微调、提示学习等手段,充分利用和转化LLM的能力,实现高效、准确的大规模知识库推理。

2)可解释推理。LLM利用大量深度神经网络对知识进行隐式建模,知识图谱则以图的形式对知识进行显式建模。LLM效率高,深度语义理解能力强,但不可解释,而知识图谱则能够通过图检索提供溯因能力,为推理提供解释。尽管已经有不少研究对两者的联合推理进行了尝试,但如何权衡速度、精度和可解释性仍需要探索LLM和知识谱的恰当融合方式,以充分发挥两者的优点。

9.2.4 知识图谱问答

1)领域知识问答。知识图谱具有图结构的领域知识支持,易于理解和推理,但其网络稀疏性和低效率成为了制约其领域应用的瓶颈。因此,需要充分利用LLM的通用知识和快速响应能力来弥补知识图谱的缺陷,从而使知识图谱以更便捷可靠的方式推广到不同的领域中^[280-281]。使用LLM来自动高效地检索知识图谱,检索到的知识反过来增强LLM,不仅可以提升LLM的灵活性,也可以降低微调和重训练的成本。

2)基于知识的决策。在复杂问题中,特别是在决策背景下,知识问答需要充分整合与运用现有知识,通过多步骤的逻辑推导,推理和预测出潜在的结果以及发展的趋势,并以流畅和易读的语言给出决策建议^[282]。这些任务的完成都离不开基于LLM和知识图谱的联合问答。未来,需要基于LLM和知识库开发决策助手,构建能够适应多任务、多领域的决策大模型,实现基于认知的决策智能。

9.2.5 事件知识图谱

1)少样本/零样本的事件知识图谱构建。实践中,标注数据稀缺制约了事件知识图谱的高效构建。LLM拥有丰富的知识和推理能力,在少样本和零样本场景下展现出一定的优势^[283-284],可以泛化到未见过的事件和关系类型中。此外,LLM还具备很强的生成能力,能够根据事件的模式举一反三地生成多样化的事件样本。因此,还可以利用LLM扩展训练数据,并利用这些数据精调小规模的事件抽取、关系发现和共指消解模型,在特定数据集上达到更优越的性能。

2)事件知识图谱动态关联和更新。随着时间的推移,

新的事件不断发生,现有事件的知识也可能发生变化,但当前还没有较好的方法来更新、关联和适应新的事件类型。未来,需要利用LLM的持续学习能力,设计高效、低成本的迁移学习方法,不断学习、记录和分析事件的动态发展,适应新的任务和背景,保持构建的事件知识图谱的时效性和准确性。

9.2.6 多模态知识图谱

1)基于多模态大模型的多模态知识图谱构建。多模态大模型利用预训练的视觉-语言模型来执行多模态任务,是近年兴起的一个新的研究热点。利用多模态大模型的多模态指令调整、多模态上下文学习、多模态思维链和LLM辅助视觉推理模型来构建、完善和利用多模态知识图谱^[285],是非常有前景的研究方向。

2)知识图谱跨模态转化。随着多模态知识图谱的增加,基于视觉信息的问答将成为越来越重要的一个研究方向。2023年下半年以来,GPT-4V,Vedio-ChatGPT和Sora等多个强大的多模态大模型陆续被开发出来,LLM展现出其强大的跨模态理解和生成能力。未来,通过具备文本-图像/视频、视频/图像-文本转化能力的LLM实现各种知识图谱的跨模态转化和生成,提升其适应性和多样性,也将成为下一阶段的研究热点。

结束语 本文全面综述了基于预训练语言模型的知识图谱技术,系统介绍了基于预训练语言模型的知识图谱构建、表示学习、推理、问答以及事件知识图谱、多模态知识图谱相关技术。随着大模型时代的到来,部分研究者认为知识图谱的价值将减小。但是,科学研究范式的转变并不意味着知识图谱已经被淘汰,相反,对于那些关注可靠性、安全性和可解释性的研究领域,知识图谱这样的结构化知识依然是不可或缺的。知识图谱和LLM的融合,可以有效提升LLM的运行效率、知识实时性、可解释性、推理能力,进而实现深度认知,提升智能决策的速度和可信赖性。因此,知识图谱在大模型时代仍将大有可为,需要在构建、完善和应用算法中进行更加深入的研究。利用LLM与知识图谱相互增强,发挥LLM和知识图谱两者的技术优势,充分统一知识表征、动态协同知识推理等技术手段,将有力推动认知决策智能水平的升级发展。

参考文献

- [1] GEORGE M. WordNet: A Lexical Database for English [J]. Communications of the ACM, 1995, 38(11): 39-41.
- [2] AUER S, BIZER C, KOBILAROV G, et al. DBpedia: A Nucleus for a Web of Open Data [C] // Proceedings of the 6th International Semantic Web Conference, 2nd Asian Semantic Web Conference. Berlin, German: Springer, 2007: 722-735.
- [3] SUCHANEK F M, KASNECI G, WEIKUM G, YAGO: A Large Ontology from Wikipedia and WordNet [J]. Journal of Web Semantics, 2008, 6(3): 203-217.
- [4] CARLSON A, BETTERIDGE J, KISIEL B, et al. Toward an architecture for never-ending language learning [C] // Proceedings of the Twenty-Fourth AAAI Conference on Artificial Intelligence (AAAI'10). Atlanta, USA: AAAI, 2010: 1306-1313.
- [5] WU W, LI H, WANG H et al. Probbase: a probabilistic taxonomy

- for text understanding[C]//Proceedings of the 2012 ACM SIGMOD International Conference on Management of Data. New York, USA; ACM, 2012; 481-492.
- [6] XU B, XU Y, LIANG J, et al. CN-DBpedia: A Never-Ending Chinese Knowledge Extraction System [C] // Proceedings of 2017 the International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems. Berlin, Germany; Springer, 2017; 428-438.
- [7] NIU X, SUN X, WANG H, et al. Zhishi. me-Weaving Chinese Linking Open Data [C] // Proceedings of 10th International Semantic Web Conference. Berlin, Germany; Springer, 2011; 23-27.
- [8] ZHOU S, DAI X, CHEN H, et al. Interactive Recommender System via Knowledge Graph-enhanced Reinforcement Learning [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'20). New York, NY, USA; Association for Computing Machinery, 2020; 179-188.
- [9] CUI H, PENG T, FENG L, et al. Simple Question Answering over Knowledge Graph Enhanced by Question Pattern Classification [J]. Knowledge and Information Systems, 2021, 63(2): 2741-2761.
- [10] MA Y, CROOK P, SARIKAYA R, et al. Knowledge Graph Inference for spoken dialog systems [C] // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane, Australia; IEEE, 2015; 5346-5350.
- [11] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). Red Hook, NY, USA; ACM, 2017; 6000-6010.
- [12] DEVLIN J, CHANG M, LEE K, et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Minneapolis, Minnesota. ACL, 2019; 4171-4186.
- [13] RADFORD A, NARASIMHAN K, SALIMANS T, et al. Improving language understanding by generative pre-training [EB/OL]. [2023-9-20] <https://openai.com/blog/language-unsupervised>.
- [14] LEWIS M, LIU Y, GOYAL N, et al. BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension [C] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. ACL, 2020; 7871-7880.
- [15] WINATA G, MADOTTO A, LIN Z, et al. Language Models are Few-shot Multilingual Learners [C] // Proceedings of the 1st Workshop on Multilingual Representation Learning, Punta Cana, Dominican Republic. Association for Computational Linguistics, 2021; 1-15.
- [16] Introducing ChatGPT [EB/OL]. [2023-09-20] <http://openai.com/blog/chatgpt>.
- [17] OpenAI, GPT-4 Technical Report [J]. arXiv:2303.08774, 2023.
- [18] PAN S, LUO L, WANG Y, et al. Unifying Large Language Models and Knowledge Graphs: A Roadmap [J]. arXiv: 2306.08302, 2023.
- [19] PAN J, RAZNIEWSKI S, KALO J, et al. Large Language Models and Knowledge Graphs: Opportunities and Challenges [J]. arXiv:2308.06374, 2023.
- [20] LI J, SUN A, HAN J, LI C. A Survey on Deep Learning for Named Entity Recognition [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(1): 50-70.
- [21] WANG H, LU G, YIN J, et al. Relation Extraction: A Brief Survey on Deep Neural Network Based Methods [C] // Proceedings of the 2021 4th International Conference on Software Engineering and Information Management (ICSIM'21). New York, NY, USA; Association for Computing Machinery, 2021; 220-228.
- [22] SHEN W, LI Y, LIU Y, et al. Entity Linking Meets Deep Learning [J]. Techniques and Solutions. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(3): 2556-2578.
- [23] ZHONG L, WU J, LI Q, et al. A Comprehensive Survey on Automatic Knowledge Graph Construction [J]. arXiv:2302.05019, 2023.
- [24] CAI H, ZHENG V, CHANG K. A Comprehensive Survey of Graph Embedding: Problems, Techniques, and Applications [J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(9): 1616-1637.
- [25] CAO J, FANG J, MENG Z, et al. Knowledge Graph Embedding: A Survey from the Perspective of Representation Spaces [J]. arXiv:2211.03536, 2022.
- [26] XU Y, ZHAO J, WANG Y, et al. Temporal Knowledge Graph Representation Learning [J]. Chinese Journal of Computer Science, 2022, 49(9): 162-171.
- [27] LIANG K, MENG L, LIU M, et al. Reasoning over Different Types of Knowledge Graphs: Static, Temporal and Multi-Modal [J]. arXiv:2212.05767, 2022.
- [28] XIA Y, LAN M, CHEN X, et al. Survey on explainable knowledge graph reasoning methods [J]. Chinese Journal of Network and Information Security, 2022, 8(5): 1-25.
- [29] MA R, LI Z, CHEN Z, et al. Survey on Knowledge Graph Reasoning [J]. Chinese Journal of Computer Science, 2022, 49(S1): 74-85.
- [30] FENG H, DUAN L, ZHANG B. Overview on Knowledge Reasoning for Knowledge Graph [J]. Chinese Journal of Computer Systems & Applications, 2021, 30(10): 21-30.
- [31] HUANG X, ZHANG J, LI D, et al. Knowledge Graph Embedding Based Question Answering [C] // Proceedings of the 12th ACM International Conference on Web Search and Data Mining (WSDM'19). New York, NY, USA; ACM, 2019; 105-113.
- [32] SA R, LI Y, LIN M. Survey of Question Answering Based on Knowledge Graph Reasoning [J]. Chinese Journal of Frontiers of Computer Science and Technology, 2022, 16(8): 1727-1741.
- [33] ZHANG W, CHEN J, LI J, et al. Knowledge Graph Reasoning with Logics and Embeddings: Survey and Perspective [J]. arXiv:2202.07412.
- [34] BORDES A, USUNIER N, GARCIA-DURÁN A, et al. Translating embeddings for modeling multi-relational data [C] // Proceedings of the 26th International Conference on Neural Information Processing Systems. Red Hook, NY, USA; Curran Asso-

- ciates Inc. ,2013;2787-2795.
- [35] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2D knowledge graph embeddings[C]// Proceedings of the 32nd AAAI Conference on Artificial Intelligence and 30th Innovative Applications of Artificial Intelligence Conference and 8th AAAI Symposium on Educational Advances in Artificial Intelligence. New Orleans, Louisiana, USA; AAAI, 2018; 1811-1818.
- [36] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[C]// Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence (AAAI'14). Quebec City, Canada; AAAI, 2014; 1112-1119.
- [37] YU C, WANG F, LIU Y, et al. Research on knowledge graph alignment model based on deep learning [J]. Expert Systems with Applications, 2021, 186; 115768.
- [38] SU M, SU H, ZHENG H, et al. Deep Learning For Knowledge Graph Completion With XLNET[C]// Proceedings of the 2021 5th International Conference on Deep Learning Technologies (ICDLT'21). New York, NY, USA; ACM, 2021; 13-19.
- [39] ZHU Z, GALKIN M, ZHANG Z, et al. Neural-Symbolic Models for Logical Queries on Knowledge Graphs [J]. arXiv; 2205.10128, 2022.
- [40] ZHANG J, CHEN B, ZHANG L, et al. Neural, symbolic and neural-symbolic reasoning on knowledge graphs [J]. AI Open, 2021, 2; 14-35.
- [41] GUAN S, CHENG X, BAI L, et al. What is Event Knowledge Graph; A Survey [J]. IEEE Transactions on Knowledge and Data Engineering, 2015, 35(7); 7569-7589.
- [42] ZHU X. , LI Z, WANG X, et al. Multi-Modal Knowledge Graph Construction and Application; A Survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(1); 1-15.
- [43] FENSEL D., SIMSEK U, ANGELE K, et al. Introduction; What Is a Knowledge Graph? [M]// Knowledge Graphs. Cham; Springer, 2020; 1-10.
- [44] PETERS M E, NEUMANN M, IYYER M, et al. Deep Contextualized Word Representations [C]// Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. New Orleans, Louisiana; ACL, 2018; 2227-2237.
- [45] TANG Z, WANG B, YAO T. DPTDR; Deep Prompt Tuning for Dense Passage Retrieval[C]// Proceedings of the 29th International Conference on Computational Linguistics. Gyeongju, Republic of Korea; International Committee on Computational Linguistics. 2022; 1193-1202.
- [46] LIU X, JI K, FU Y, et al. P-Tuning; Prompt Tuning Can Be Comparable to Fine-tuning Across Scales and Tasks[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin, Ireland; ACL, 2022; 61-68.
- [47] FU J, FENG L, ZHANG Q, et al. Larger-Context Tagging: When and Why Does It Work? [C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. ACL, 2021; 1463-1475.
- [48] YU J, BOHNET B, POESIO M. Named Entity Recognition as Dependency Parsing[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. ACL, 2020; 6470-6476.
- [49] TAN C, QIU W, CHEN M, et al. Boundary Enhanced Neural Span Classification for Nested Named Entity Recognition[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, California USA; AAAI, 2020; 9016-9023.
- [50] YAO F, TAN C, CHEN M, et al. Nested Named Entity Recognition with Partially-Observed TreeCRFs[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver, Canada; AAAI, 2021; 12839-12847.
- [51] LOU C, YANG S, TU K. Nested Named Entity Recognition as Latent Lexicalized Constituency Parsing[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin, Ireland; ACL, 2022; 6183-6198.
- [52] YANG S, TU K. Bottom-Up Constituency Parsing and Nested Named Entity Recognition with Pointer Networks[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin, Ireland; ACL, 2022; 2403-2416.
- [53] LI F, LIN Z, ZHANG M, et al. A Span-Based Model for Joint Overlapped and Discontinuous Named Entity Recognition[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 4814-4828.
- [54] YAN H, GUI T, DAI J, et al. A Unified Generative Framework for Various NER Subtasks[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 5808-5822.
- [55] LUIGGI T, GUIGUE V, SOULIER L, et al. Dynamic Named Entity Recognition[C]// Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing. New York, NY, USA; ACM, 2023; 890-897.
- [56] ONOE Y, DURRETT G. Learning to Denoise Distantly-Labeled Data for Entity Typing[C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. Minneapolis, Minnesota, USA; ACL, 2019; 2407-2417.
- [57] ONOE Y, BORATKO M, MCCALLUM A, et al. Modeling Fine-Grained Entity Types with Box Embeddings[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 2051-2064.
- [58] DAI H, SONG Y, WANG H. Ultra-Fine Entity Typing with Weak Supervision from a Masked Language Model[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 1790-1799.
- [59] LIU Q, LIN H, XIAO X, et al. Fine-grained Entity Typing via Label Reasoning[C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Online and

- Punta Cana, Dominican Republic; ACL, 2021; 4611-4622.
- [60] LI B, YIN W, CHEN M. Ultra-fine Entity Typing with Indirect Supervision from Natural Language Inference [J]. Transactions of the Association for Computational Linguistics, 2022, 10: 607-622.
- [61] PAN W, WEI W, ZHU F. Automatic Noisy Label Correction for Fine-Grained Entity Typing [C] // Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence. Messe Wien, Vienna, Austria; International Joint Conferences on Artificial Intelligence Organization, 2022; 4317-4323.
- [62] DING N, CHEN Y, HAN X, et al. Prompt-learning for Fine-grained Entity Typing [C] // Findings of the Association for Computational Linguistics; EMNLP 2022. Abu Dhabi, United Arab Emirates; ACL, 2022; 6888-6901.
- [63] LI S, JI H, HAN J. Open Relation and Event Type Discovery with Type Abstraction [C] // Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi, United Arab Emirates; ACL, 2022; 6864-6877.
- [64] KOMARLU T, JIANG M, WANG X, et al. OntoType: Ontology-Guided Zero-Shot Fine-Grained Entity Typing with Weak Supervision from Pre-Trained Language Models [J]. arXiv: 2305.12307, 2023.
- [65] TANG X, ZHANG J, CHEN B, et al. BERTINT: a BERT-based interaction model for knowledge graph alignment [C] // Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence. Yokohama, Japan; International Joint Conferences on Artificial Intelligence Organization, 2020; 3174-3180.
- [66] YANG H W, ZOU Y, SHI P, et al. Aligning Cross-Lingual Entities with Multi-Aspect Information [C] // Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China; ACL, 2019; 4431-4441.
- [67] LIU Y, HUA W, XIN K, et al. TEA: Timeaware Entity Alignment in Knowledge Graphs [C] // Proceedings of the ACM Web Conference 2023. New York, NY, USA; ACM, 2023; 2591-2599.
- [68] ZHANG Z, HAN X, LIU Z, et al. ERNIE: Enhanced Language Representation with Informative Entities [C] // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy; ACL, 2019; 1441-1451.
- [69] ALT C, HÜBNER M, HENNIG L. Improving Relation Extraction by Pre-trained Language Representations [J]. arXiv: 1906.03088, 2019.
- [70] SHI P, LIN J. Simple BERT Models for Relation Extraction and Semantic Role Labeling [J]. arXiv: 1904.05255, 2019.
- [71] JOSHI M, CHEN D, LIU Y, et al. SpanBERT: Improving Pre-training by Representing and Predicting Spans [J]. Transactions of the Association for Computational Linguistics, 2020, 8: 64-77.
- [72] SOARES L B, FITZGERALD N, LING J, et al. Matching the Blanks; Distributional Similarity for Relation Learning [C] // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy; ACL, 2019; 2895-2905.
- [73] PARK S, KIM H. Improving Sentence-Level Relation Extraction through Curriculum Learning [J]. arXiv: 2107.09332, 2021.
- [74] LYU S, CHEN H. Relation Classification with Entity Type Restriction [C] // Findings of the Association for Computational Linguistics, 2021; 390-395.
- [75] ZHENG J, CHEN Z. Sentence-Level Relation Extraction via Contrastive Learning with Descriptive Relation Prompts [J]. arXiv: 2304.04935, 2023.
- [76] TANG H, CAO Y, ZHANG Z, et al. HIN: Hierarchical Inference Network for Document-Level Relation Extraction [C] // Proceedings of Advances in Knowledge Discovery and Data Mining: 24th Pacific-Asia Conference. Berlin, Germany; Springer-Verlag, 2020; 197-209.
- [77] WANG D, HU W, CAO E, et al. Global-to-Local Neural Networks for Document-Level Relation Extraction [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 3711-3721.
- [78] ZENG S, XU R, CHANG B, et al. Double Graph Based Reasoning for Document-level Relation Extraction [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 1630-1640.
- [79] ZENG S, WU Y, CHANG B. SIRE: Separate Intra- and Intersentential Reasoning for Document-level Relation Extraction [C] // Findings of the Association for Computational Linguistics. ACL, 2021; 524-534.
- [80] NAN G, GUO Z, SEKULIC I, et al. Reasoning with Latent Structure Refinement for Document-Level Relation Extraction [C] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. ACL, 2020; 1546-1557.
- [81] ZHANG N, CHEN X, XIE X, et al. Document-level Relation Extraction as Semantic Segmentation [C] // Proceedings of the 30th International Joint Conference on Artificial Intelligence, 2021; 3999-4006.
- [82] ZHOU W, HUANG K, MA T, et al. Document-Level Relation Extraction with Adaptive Thresholding and Localized Context Pooling [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver, Canada; AAAI, 2021; 14612-14620.
- [83] JIANG Z, XU F, ARAKI J, et al. How Can We Know What Language Models Know? [J] Transactions of the Association for Computational Linguistics, 2020, 8: 423-438.
- [84] HAN X, ZHAO W, DING N, et al. PTR: Prompt Tuning with Rules for Text Classification [J]. AI Open, 2022, 3: 182-192.
- [85] LI X L, LIANG P. Prefix-Tuning: Optimizing Continuous Prompts for Generation [C] // Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 4582-4597.
- [86] QIN G, EISNER J. Learning How to Ask; Querying LMs with Mixtures of Soft Prompts [C] // Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. ACL, 2021; 5203-5212.
- [87] CHEN X, ZHANG N, XIE X, et al. KnowPrompt: Knowledge-aware Prompt-tuning with Synergistic Optimization for Relation

- Extraction [C]//Proceedings of the ACM Web Conference 2022 (WWW'22). New York, NY, USA: ACM, 2022; 2778-2788.
- [88] SHIN T, RAZEGHI Y, LOGAN IV R L, et al. AutoPrompt: Eliciting Knowledge from Language Models with Automatically Generated Prompts[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 4222-4235.
- [89] GUTIERREZ B J, MCNEAL N, WASHINGTON C, et al. Thinking about GPT-3 In-Context Learning for Biomedical IE? Think Again [C] // Findings of the Association for Computational Linguistics; EMNLP 2022. Abu Dhabi, United Arab Emirates; ACL, 2022; 4497-4512.
- [90] MA Y, CAO Y, HONG Y, et al. Large language model is not a good few-shot information extractor, but a good reranker for hard samples[J]. arXiv; 2303. 08559, 2023.
- [91] WEI X, CUI X, CHENG N, et al. Zero-Shot Information Extraction via Chatting with ChatGPT[J]. arXiv; 2302. 10205, 2023.
- [92] SU Y, HAN X, ZHANG Z, et al. Coke-BERT: Contextual knowledge selection and embedding towards enhanced pre-trained language models[J]. AI Open, 2021, 2; 127-134.
- [93] YE D, LIN Y, DU J, et al. Coreferential Reasoning Learning for Language Representation[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 7170-7186.
- [94] QIN Y, LIN Y, TAKANOBU R, et al. ERICA: Improving Entity and Relation Understanding for Pre-trained Language Models via Contrastive Learning[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 3350-3363.
- [95] PETERS ME, NEUMANN M, LOGAN R, et al. Knowledge Enhanced Contextual Word Representations [C] // Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China; ACL, 2019; 43-54.
- [96] HE Z, LIU S, LI M, et al. Learning Entity Representation for Entity Disambiguation [C] // Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics. Sofia, Bulgaria; ACL, 2013; 30-34.
- [97] JIA C, SHI Y, YANG Q, et al. Entity Enhanced BERT Pre-training for Chinese NER[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 6384-6396.
- [98] BROSCHEIT S. Investigating Entity Knowledge in BERT with Simple Neural End-To-End Entity Linking[C]//Proceedings of the 23rd Conference on Computational Natural Language Learning (CoNLL). Hong Kong, China; ACL, 2019; 677-685.
- [99] WU L, PETRONI F, JOSIFOSKI M, et al. Scalable Zero-shot Entity Linking with Dense Entity Retrieval[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 6397-6407.
- [100] LI B Z, MIN S, IYER S, et al. Efficient One-Pass End-to-End Entity Linking for Questions [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 6433-6441.
- [101] POERNER N, WALTINGER U, SCHÜTZE H. E-BERT: Efficient-Yet-Effective Entity Embeddings for BERT[C]//Findings of the Association for Computational Linguistics; EMNLP 2020. ACL, 2020; 803-818.
- [102] VERGA P, SUN H, BALDINI S L, et al. Adaptable and Interpretable Neural Memory Over Symbolic Knowledge[C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Online; ACL, 2021; 3678-3691.
- [103] YAMADA I, ASAI A, SHINDO H, et al. LUKE: Deep Contextualized Entity Representations with Entity-aware Self-attention [C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL, 2020; 6442-6454.
- [104] CAO N, WU L, POPAT K, et al. Multilingual Autoregressive Entity Linking[J]. Transactions of the Association for Computational Linguistics, 2022, 10; 274-290.
- [105] CAO N, IZACARD G, RIEDEL S, et al. Autoregressive Entity Retrieval[C]//Proceedings of the 8th International Conference on Learning Representations. 2020.
- [106] AYOOLA T, TYAGI S, FISHER J, et al. ReFinED: An Efficient Zero-shot-capable Approach to End-to-End Entity Linking [C]//Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics. ACL, 2022; 209-220.
- [107] KUMAR A, PANDEY A, GADIA R, et al. Building Knowledge Graph using Pre-trained Language Model for Learning Entity-aware Relationships [C] // 2020 IEEE International Conference on Computing, Power and Communication Technologies (GUCON). Greater Noida, India, 2020; 310-315.
- [108] MELNYK I, DOGNIN P, DAS P. Grapher: Multi-Stage Knowledge Graph Construction using Pretrained Language Models [C]//NeurIPS 2021 Workshop on Deep Generative Models and Downstream Applications. 2021.
- [109] HAN J, COLLIER N, BUNTINE W. PiVe: Prompting with Iterative Verification Improving Graph-based Generative Capability of LLMs[J]. arXiv; 2305. 12392, 2023.
- [110] YANG L, CHEN H, LI Z, et al. ChatGPT is not Enough; Enhancing Large Language Models with Knowledge Graphs for Fact-aware Language Modeling[J]. arXiv; 2306. 11489, 2023.
- [111] ZHU Y, WANG X, CHEN J, et al. LLMs for Knowledge Graph Construction and Reasoning: Recent Capabilities and Future Opportunities[J]. arXiv; 2305. 13168, 2023.
- [112] DENG X, SUN H, LEES A, et al. TURL: Table Understanding through Representation Learning[J]. ACM SIGMOD Record, 2022, 51(1); 33-40.
- [113] TANG N, FAN J, LI F, et al. RPT: Relational Pre-Trained Transformer is Almost All You Need towards Democratizing Data Preparation[C]//Proc. VLDB Endow. 2021; 1254-1261.
- [114] FAN G, WANG J, LI Y, et al. Semantics-Aware Dataset Discovery from Data Lakes with Contextualized Column-Based Representation Learning[C]//Proc. VLDB Endow. 2023; 1726-1739.
- [115] SUHARA Y, LI J, LI Y, et al. Annotating Columns with Pre-

- trained Language Models[C]//Proceedings of the 2022 International Conference on Management of Data (SIGMOD'22). New York, NY, USA: ACM, 2022: 1493-1503.
- [116] KORINI K, BIZER C. Column Type Annotation using ChatGPT [J]. arXiv:2306.00745, 2023.
- [117] KAZEMI M, MITTAL S, RAMACHAN-DRAN D. Understanding Finetuning for Factual Knowledge Extraction from Language Models[J]. arXiv:2301.11293, 2023.
- [118] BOSSELUT A, RASHKIN H, SAP M, et al. COMET: Commonsense Transformers for Automatic Knowledge Graph Construction[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy: ACL, 2019: 4762-4779.
- [119] HAO S, TAN B, TANG K, et al. BertNet: Harvesting Knowledge Graphs with Arbitrary Relations from Pretrained Language Models[C]//Findings of the Association for Computational Linguistics. Toronto, Canada: ACL, 2023: 5000-5015.
- [120] LIU Y, MAIER W, MINKER W, et al. ConceptNet infused DialogPT for Underlying Commonsense Understanding and Reasoning in Dialogue Response Generation[J]. arXiv:2209.15109, 2022.
- [121] WEST P, BHAGAVATULA C, HESSEL J, et al. Symbolic Knowledge Distillation: from General Language Models to Commonsense Models[C]//Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Seattle, United States: ACL, 2022: 4602-4625.
- [122] ZHANG Z, LIU X, ZHANG Y, et al. Pretrain-KGE: Learning Knowledge Representation from Pretrained Language Models [C]//Findings of the Association for Computational Linguistics; EMNLP 2020. ACL, 2020: 259-266.
- [123] WANG X, GAO T, ZHU Z, et al. KEPLER: A Unified Model for Knowledge Embedding and Pre-trained Language Representation[J]. Transactions of the Association for Computational Linguistics. 2021, 9: 176-194.
- [124] ALAM M, RONY M, NAYYERI M, et al. Language Model Guided Knowledge Graph Embeddings[J]. IEEE Access, 2022, 10: 76008-76020.
- [125] REIMERS N, GUREVYCH I. Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China: ACL, 2019: 3982-3992.
- [126] FastText: Library for efficient text classification and representation learning [EB/OL]. [2023-09-21]. <https://fasttext.cc>.
- [127] KANG M, BAEK J, HWANG S J. KALA: Knowledge-Augmented Language Model Adaptation[C]//Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Seattle, United States: ACL, 2022: 5144-5167.
- [128] NAYYERI M, WANG Z, AKTER M M, et al. Integrating Knowledge Graph embedding and pretrained Language Models in Hypercomplex Spaces[J]. arXiv:2208.02743, 2022.
- [129] LIU W, ZHOU P, ZHAO Z, et al. K-BERT: Enabling Language Representation with Knowledge Graph[C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2020: 2901-2908.
- [130] SUN T, SHAO Y, QIU X, et al. CoLAKE: Contextualized Language and Knowledge Embedding[C]//Proceedings of the 28th International Conference on Computational Linguistics. Barcelona, Spain: International Committee on Computational Linguistics, 2020: 3660-3670.
- [131] WANG P, XIE X, WANG X, et al. Reasoning Through Memorization: Nearest Neighbor Knowledge Graph Embeddings [J]. arXiv:2201.05575, 2022.
- [132] WANG X, HE Q, LIANG J, et al. Language Models as Knowledge Embeddings[C]//Proceedings of the 31st International Joint Conference on Artificial Intelligence. Vienna, Austria: International Joint Conferences on Artificial Intelligence Organization, 2022: 2291-2297.
- [133] BONDARENKO D A, FERROD R, DI CARO L. Combining Contrastive Learning and Knowledge Graph Embeddings to develop medical word embeddings for the Italian language[J]. arXiv:2211.05035.
- [134] WANG J, WANG C, QIU M, et al. KECP: Knowledge Enhanced Contrastive Prompting for Few-shot Extractive Question Answering[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi, United Arab Emirates: ACL, 2022: 3152-3163.
- [135] NASSIRI A K, PERNELLE N, SAIS F, et al. Knowledge Graph Refinement based on Triplet BERT-Networks[J]. arXiv: 2211.10460.
- [136] YAO L, MAO C, LUO Y. KG-BERT: BERT for Knowledge Graph Completion[J]. arXiv:1909.03193, 2019.
- [137] KIM B, HONG T, KO Y, et al. Multi-Task Learning for Knowledge Graph Completion with Pre-trained Language Models [C]//Proceedings of the 28th International Conference on Computational Linguistics, Barcelona, Spain: International Committee on Computational Linguistics, 2020: 1737-1743.
- [138] CHEN S, CHENG H, LIU X, et al. Pre-training Transformers for Knowledge Graph Completion[J]. arXiv:2303.15682, 2023.
- [139] WANG L, ZHAO W, WEI Z, et al. SimKGC: Simple contrastive knowledge graph completion with pre-trained language models [C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin, Ireland: ACL, 2022: 4281-4294.
- [140] LV X, LIN Y, CAO Y, et al. Do Pre-trained Models Benefit Knowledge Graph Completion? A Reliable Evaluation and a Reasonable Approach[C]//Proceedings of the Findings of the Association for Computational Linguistics. Dublin, Ireland: ACL, 2022: 3570-3581.
- [141] CHEN C, WANG Y, SUN A, et al. Dipping PLMs Sauce: Bridging Structure and Text for Effective Knowledge Graph Completion via Conditional Soft Prompting[C]//Proceedings of the Findings of the Association for Computational Linguistics. Toronto, Canada: ACL, 2023: 11489-11503.
- [142] CHOI B, JANG D, KO Y. MEM-KGC: Masked Entity Model for

- Knowledge Graph Completion With Pre-Trained Language Model[J]. *IEEE Access*, 2021, 9: 132025-132032.
- [143] CLOUATRE L, TREMPE P, ZOUAQ A, et al. MLMLM: Link Prediction with Mean Likelihood Masked Language Model[C]// *Proceedings of the Findings of the Association for Computational Linguistics*. ACL, 2021: 4321-4331.
- [144] CHOI B, KO Y. Knowledge graph extension with a pre-trained language model via unified learning method. *Knowledge-Based Systems*[J]. *Knowledge-Based Systems*, 2023, 262: 110245.
- [145] PENG B, LIANG S, ISLAM M. Bi-Link: Bridging Inductive Link Predictions from Text via Contrastive Learning of Transformers and Prompts[J]. *arXiv*: 2210. 14463, 2022.
- [146] JIANG P, AGARWAL S, JIN B, et al. Text-Augmented Open Knowledge Graph Completion via Pre-Trained Language Models [J]. *arXiv*: 2305. 15597, 2023.
- [147] CHEN Z, XU C, SU F, et al. Incorporating Structured Sentences with Time-enhanced BERT for Fully-inductive Temporal Relation Prediction[J]. *arXiv*: 2304. 04717, 2023.
- [148] XU W, LIU B, PENG M, et al. Pre-trained Language Model with Prompts for Temporal Knowledge Graph Completion[J]. *arXiv*: 2305. 07912, 2023.
- [149] LI D, YANG S, XU K, et al. Multi-task Pre-training Language Model for Semantic Network Completion [J]. *arXiv*: 2201. 04843, 2022.
- [150] SAXENA A, KOCHSIEK A, GEMULLA R. Sequence-to-Sequence Knowledge Graph Completion and Question Answering [C]// *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*. Dublin, Ireland; ACL, 2022: 2814-2828.
- [151] XIE X, ZHANG N, LI Z, et al. From Discrimination to Generation: Knowledge Graph Completion with Generative Transformer[C]// *Proceedings of the Web Conference 2022(WWW 22)*. New York, NY, USA; ACM, 2022: 162-165.
- [152] CHEN C, WANG Y, LI B, et al. Knowledge Is Flat: A Seq2Seq Generative Framework for Various Knowledge Graph Completion[C]// *Proceedings of the 29th International Conference on Computational Linguistics*, Gyeongju, Republic of Korea; International Committee on Computational Linguistics, 2022: 4005-4017.
- [153] ZHA H, CHEN Z, YAN X. Inductive Relation Prediction by BERT[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. Vancouver, Canada; AAAI, 2022: 5923-5931.
- [154] LOGAN R, LIU N F, PETERS M E, et al. Barack's Wife Hillary: Using Knowledge Graphs for Fact-Aware Language Modeling[C]// *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Florence, Italy; ACL, 2019: 5962-5971.
- [155] LAN Y, HE S, LIU K, et al. Path-based knowledge reasoning with textual semantic information for medical knowledge graph completion[J]. *BMC Medical Informatics and Decision Making*, 2021, 21(S9): 1-12.
- [156] WANG B, SHEN T, LONG G, et al. Structure-Augmented Text Representation Learning for Efficient Knowledge Graph Completion[C]// *Proceedings of the Web Conference 2021(WWW 21)*. New York, NY, USA; ACM, 2021: 1737-1748.
- [157] SHEN J, WANG C, GONG L, et al. Joint Language Semantic and Structure Embedding for Knowledge Graph Completion [C]// *Proceedings of the 29th International Conference on Computational Linguistics*. Gyeongju, Republic of Korea; International Committee on Computational Linguistics, 2022: 1965-1978.
- [158] HE J, JIA L, WANG L, et al. MoCoSA: Momentum Contrast for Knowledge Graph Completion with Structure-Augmented Pre-trained Language Models[J]. *arXiv*: 2308. 08204, 2023.
- [159] LIN B Y, CHEN X, CHEN J, et al. KagNet: Knowledge-Aware Graph Networks for Commonsense Reasoning[C]// *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*. Hong Kong, China; ACL, 2019: 2829-2839.
- [160] LUKOVNIKOV D, FISCHER A, LEHMAN J. Pretrained Transformers for Simple Question Answering over Knowledge Graphs[C]// *Proceedings of the 18th International Semantic Web Conference (ISWC 2019)*. Auckland, New Zealand; Springer, 2019: 470-486.
- [161] LUO D, SU J, YU S. A BERT-based Approach with Relation-aware Attention for Knowledge Base Question Answering[C]// *Proceedings of the 2020 International Joint Conference on Neural Networks (IJCNN)*. Glasgow, UK; IEEE, 2020: 1-8.
- [162] FÉVRY T, SOARES LB, FITZGERALD N, et al. Entities as Experts: Sparse Memory Access with Entity Supervision[C]// *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. ACL, 2020: 4937-4951.
- [163] LIU Y, LIANG D, FANG F, et al. Time-Aware Multiway Adaptive Fusion Network for Temporal Knowledge Graph Question Answering[C]// *Proceedings of 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Rhodes Island, Greece; IEEE, 2023: 1-5.
- [164] PETRONI F, ROCKTÄSCHEL T, RIEDEL S, et al. Language Models as Knowledge Bases? [C]// *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*. Hong Kong, China; ACL, 2019: 2463-2473.
- [165] ZHANG J, ZHANG X, YU J, et al. Subgraph retrieval enhanced model for multi-hop knowledge base question answering[C]// *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*. Dublin, Ireland; ACL, 2022: 5773-5784.
- [166] FENG Y, CHEN X, LIN B Y, et al. Scalable Multi-Hop Relational Reasoning for Knowledge-Aware Question Answering[C]// *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. ACL, 2020: 1295-1309.
- [167] MISRA K, SANTOS C N, SHAKERI S. Triggering Multi-Hop Reasoning for Question Answering in Language Models using Soft Prompts and Random Walks[J]. *arXiv*: 2306. 04009, 2023.
- [168] XU Y, ZHU C, XU R, et al. Fusing Context Into Knowledge

- Graph for Commonsense Question Answering[C]// Findings of the Association for Computational Linguistics. ACL,2021:1201-1207.
- [169]ZHANG M,DAI R,DONG M,et al. DRLK:Dynamic Hierarchical Reasoning with Language Model and Knowledge Graph for Question Answering[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi,United Arab Emirates;ACL,2022;5123-5133.
- [170]ZHANG Y,YAO Q. Knowledge Graph Reasoning with Relational Digraph[C]// Proceedings of the ACM Web Conference 2022(WWW '22). New York,NY,USA;ACM,2022;912-924.
- [171]YAN Y,LI R,WANG S,et al. Large-Scale Relation Learning for Question Answering over Knowledge Bases with Pre-trained Language Models[C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. ACL,2021:3653-3660.
- [172]JIANG J,ZHOU K,ZHAO X,et al. UniKGQA: Unified Retrieval and Reasoning for Solving Multi-hop Question Answering Over Knowledge Graph[C]// Proceedings of the 11st International Conference on Learning Representations. Kigali,Rwanda,2023.
- [173]WANG R,TANG D,DUAN N,et al. K-Adapter: Infusing Knowledge into Pre-Trained Models with Adapters[C]// Findings of the Association for Computational Linguistics. ACL,2021:1405-1418.
- [174]HU Z,XU Y,YU W,et al. Empowering Language Models with Knowledge Graph Reasoning for Open-Domain Question Answering[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi, United Arab Emirate;ACL,2022;9562-9581.
- [175]BAEK J,AJI A F,SAFFARI A. Knowledge-Augmented Language Model Prompting for Zero-Shot Knowledge Graph Question Answering[C]// Proceedings of the 1st Workshop on Natural Language Reasoning and Structured Explanations(NLRSE). Toronto,Canada;ACL,2023;78-106.
- [176]JIANG J,ZHOU K,DONG Z,et al. StructGPT:A General Framework for Large Language Model to Reason over Structured Data[J]. arXiv:2305.09645,2023.
- [177]YASUNAGA M,REN H,BOSELUT A,et al. QA-GNN: Reasoning with Language Models and Knowledge Graphs for Question Answering[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. ACL,2021:535-546.
- [178]SUN Y,SHI Q,QI L,et al. JointLK:Joint Reasoning with Language Models and Knowledge Graphs for Commonsense Question Answering[C]// Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics. United States;ACL,2022;5049-5060.
- [179]ZHANG X,BOSELUT A,YASUNAGA M,et al. GreaseLM: Graph REASONing Enhanced Language Models for Question Answering[C]// Proceedings of the 10th International Conference on Learning Representations. 2022.
- [180]CAO X,LIU Y. ReLMKG: reasoning with pre-trained language models and knowledge graphs for complex question answering [J]. Applied Intelligence,2023,53(10):12032-12046.
- [181]HU N,WU Y,QI G,et al. An empirical study of pre-trained language models in simple knowledge graph question answering [J]. arXiv:2303.10368,2023.
- [182]YANG S,FENG D,QIAO L,et al. Exploring Pre-trained Language Models for Event Extraction and Generation[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy; ACL,2019:5284-5294.
- [183]DENG S,ZHANG N,LI L,et al. OntoED:Low-resource Event Detection with Ontology Embedding[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL,2021:2828-2839.
- [184]WADDEN D,WENBERG U,LUAN Y,et al. Entity,Relation,and Event Extraction with Contextualized Span Representations[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong,China;ACL,2019;5784-5789.
- [185]LIU J,CHEN Y,LIU K,et al. Event Extraction as Machine Reading Comprehension[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). ACL,2020:1641-1651.
- [186]PAOLINI G,ATHIWARATKUN B,KRONE J,et al. Structured Prediction as Translation between Augmented Natural Languages[C]// Proceedings of the 9th International Conference on Learning Representations. 2021.
- [187]LIU X,HUANG H,SHI G,et al. Dynamic Prefix-Tuning for Generative Template-based Event Extraction[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin,Ireland;ACL,2022;5216-5228.
- [188]LYU Q,ZHANG H,SULEM E,et al. Zero-shot Event Extraction via Transfer Learning: Challenges and Insights[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL,2021;322-332.
- [189]LU Y,LIN H,XU J,et al. Text2Event:Controllable Sequence-to-Structure Generation for End-to-end Event Extraction[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL,2021:2795-2806.
- [190]LI S,JI H,HAN J. Document-Level Event Argument Extraction by Conditional Generation[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics. ACL,2021;894-908.
- [191]LU Y,LIU Q,DAI D. Unified Structure Generation for Universal Information Extraction[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin,Ireland;ACL,2022;5755-5772.
- [192]ZENG Q,ZHAN Q,JI H. EA2E:Improving Consistency with Event Awareness for Document-Level Argument Extraction

- [C]//Findings of the Association for Computational Linguistics: NAACL 2022, Seattle, United States; ACL, 2022; 2649-2655.
- [193]MA Y,WANG Z,CAO Y. Prompt for Extraction? PAIE: Prompting Argument Interaction for Event Argument Extraction[C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, Dublin, Ireland; ACL, 2022;6759-6774.
- [194]DU X,LI S,JI H. Dynamic Global Memory for Document-level Argument Extraction [C] // Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, Dublin, Ireland; ACL, 2022;5264-5275.
- [195]LIN J,CHEN Q. PoKE: A Prompt-based Knowledge Eliciting Approach for Event Argument Extraction [J]. arXiv: 2109.05190,2021.
- [196]XU R,WANG P,LIU T. A Two-Stream AMR-enhanced Model for Document-level Event Argument Extraction [C] // Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics, Seattle, United States; ACL, 2022;5025-5036.
- [197]WANG X,GUI L,HE Y. Document-Level Multi-Event Extraction with Event Proxy Nodes and Hausdorff Distance Minimization[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Toronto, Canada; ACL, 2023;10118-10133.
- [198]YANG Y,GUO Q,HU X,et al. An AMR-based Link Prediction Approach for Document-level Event Argument Extraction[J]. arXiv:2305.19162,2023.
- [199]SU B,HSU S,LAI K. Temporal Relation Extraction with a Graph-Based Deep Biaffine Attention Model [J]. arXiv: 2201.06125,2022.
- [200]WANG H,ZHANG H,DENG Y. Extracting or Guessing? Improving Faithfulness of Event Temporal Relation Extraction [C]//Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics, Dubrovnik, Croatia; ACL, 202;541-553.
- [201]TAN X,PERGOLA G,HE Y. Event Temporal Relation Extraction with Bayesian Translational Model[J]. arXiv:2302.04985, 2023.
- [202]YAO H,BREITFELLER L,NAIK A. Multi-Scale Contrastive Co-Training for Event Temporal Relation Extraction[J]. arXiv: 2209.00568,2022.
- [203]HUANG Q,HU Y,ZHU S. More than Classification: A Unified Framework for Event Temporal Relation Extraction [C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Toronto, Canada; ACL, 2023; 9631-9646.
- [204]YUAN C,XIE Q,ANANIADOU S. Zero-shot Temporal Relation Extraction with ChatGPT[J]. arXiv:2304.05454,2023.
- [205]LI S,ZHAO R,LI M. Open-Domain Hierarchical Event Schema Induction by Incremental Prompting and Verification [C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Toronto, Canada; ACL, 2023; 5677-5697.
- [206]AutoGPT: the heart of the open-source agent ecosystem [EB/OL]. [2023-09-22] <https://github.com/Significant-Gravitas/Auto-GPT>.
- [207]LIU J,CHEN Y,ZHAO J. Knowledge enhanced event causality identification with mention masking generalizations [C] // Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence (IJCAI'20). ACL, 2021;3608-3614.
- [208]HU Z,LI Z,JIN X. Semantic Structure Enhanced Event Causality Identification [C] // Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Toronto, Canada; ACL, 2023;10901-10913.
- [209]XIANG W,ZHAN C,WANG B. DAPrompt: Deterministic Assumption Prompt Learning for Event Causality Identification [J]. arXiv:2307.09813,2023.
- [210]GAO J,XIAO D,QIN B,et al. Is ChatGPT a Good Causal Reasoner? A Comprehensive Evaluation [C]//Findings of the Association for Computational Linguistics; EMNLP 2023, Singapore, ACL, 2023;11111-11126
- [211]ZUO X,CHEN Y,LIU K,et al. KnowDis: Knowledge Enhanced Data Augmentation for Event Causality Detection via Distant Supervision [C] // Proceedings of the 28th International Conference on Computational Linguistics, Barcelona, Spain; International Committee on Computational Linguistics, 2020; 1544-1550.
- [212]ZUO X,CAO P,CHEN Y,et al. LearnDA: Learnable Knowledge-Guided Data Augmentation for Event Causality Identification [C] // Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 3558-3571.
- [213]ZUO X,CAO P,CHEN Y,et al. Improving Event Causality Identification via Self-Supervised Representation Learning on External Causal Statement [C] // Findings of the Association for Computational Linguistics. ACL, 2021;2162-2172.
- [214]CAO P,ZUO X,CHEN Y,et al. Knowledge-Enriched Event Causality Identification via Latent Structure Induction Networks [C] // Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 4862-4872.
- [215]CHEN M,CAO Y,DENG K,et al. ERGO: Event Relational Graph Transformer for Document-level Event Causality Identification [C] // Proceedings of the 29th International Conference on Computational Linguistics, Gyeongju, Republic of Korea; International Committee on Computational Linguistics, 2022; 2118-2128.
- [216]BARHOM S,SHWARTZ V,EIREW A,et al. Revisiting Joint Modeling of Cross-document Entity and Event Coreference Resolution [C] // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, Florence, Italy; ACL, 2019;4179-4189.
- [217]CHOUBEY P K,HUANG R. Event Coreference Resolution by Iteratively Unfold Inter-dependencies among Events [C] // Proceedings of the 2017 Conference on Empirical Methods in Natu-


- ral Language Processing. Copenhagen, Denmark; ACL, 2017; 2124-2133.
- [218] ZENG Y, JIN X, GUAN S, et al. Event Coreference Resolution with their Paraphrases and Argument-aware Embeddings[C]// Proceedings of the 28th International Conference on Computational Linguistics, Barcelona, Spain (Online); International Committee on Computational Linguistics, 2020; 3084-3094.
- [219] CACIULARU A, COHAN A, BELTAGY I, et al. CDLM: Cross-Document Language Modeling[C]// Findings of the Association for Computational Linguistics; EMNLP 2021. Punta Cana, Dominican Republic; ACL, 2021; 2648-2662.
- [220] LU Y, LIN H, TANG J, et al. End-to-end neural event coreference resolution[J]. Artificial Intelligence, 2022, 303: 103632.
- [221] LU J, NG V. Span-Based Event Coreference Resolution[C]// Proceedings of the AAAI Conference on Artificial Intelligence, AAAI, 2021; 13489-13497.
- [222] LU J, NG V. Constrained Multi-Task Learning for Event Coreference Resolution[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics, ACL, 2021; 4504-4514.
- [223] TRAN H M, PHUNG D, NGUYEN T H. Exploiting Document Structures and Cluster Consistencies for Event Coreference Resolution[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, ACL, 2021; 4840-4850.
- [224] RAVI S, TANNER C, NG R, et al. What happens before and after: Multi-Event Commonsense in Event Coreference Resolution [C] // Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics, Dubrovnik, Croatia; ACL, 2023; 1708-1724.
- [225] HSU B, HORWOOD G. Contrastive Representation Learning for Cross-Document Coreference Resolution of Events and Entities[C] // Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics, Seattle, United States; ACL, 2022; 3644-3655.
- [226] CHEN Z, ZHANG Y, FANG Y, et al. Knowledge Graphs Meet Multi-Modal Learning: A Comprehensive Survey [J]. arXiv: 2402. 05391.
- [227] ZHU X, LI Z, WANG X, et al. Multi-Modal Knowledge Graph Construction and Application: A Survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(2): 715-735.
- [228] YU J, JIANG J, YANG L, et al. Improving multimodal named entity recognition via entity span detection with unified multimodal transformer[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, ACL, 2020; 3342-3352.
- [229] LU J, ZHANG D, ZHANG J, et al. Flat multi-modal interaction transformer for named entity recognition. [C]// Proceedings of the 29th International Conference on Computational Linguistics, Gyeongju, Republic of Korea. International Committee on Computational Linguistics, 2022; 2055-2064.
- [230] WANG P, CHEN X, SHANG Z, et al. Multimodal Named Entity Recognition with Bottleneck Fusion and Contrastive Learning [J]. IEICE Transactions on Information and Systems, 2023, 106(4): 545-555.
- [231] WANG X, GUI X, JIANG Y, et al. ITA: Image-Text Alignments for Multi-Modal Named Entity Recognition [C] // Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, Seattle, United States, ACL, 2022; 3176-3189.
- [232] XU B, HUANG S, SHA C, et al. MAF: A General Matching and Alignment Framework for Multimodal Named Entity Recognition[C]// Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York, NY, USA; ACM, 2022; 1215-1223.
- [233] CHENG J, LONG K, ZHANG S, et al. Text-Image Scene Graph Fusion for Multi-Modal Named Entity Recognition [J]. IEEE Transactions on Artificial Intelligence, 2022, 5(6): 2828-2839.
- [234] GUO A, ZHAO X, TANZ, et al. MGICL: Multi-Grained Interaction Contrastive Learning for Multimodal Named Entity Recognition[C]// Proceedings of the 32nd ACM International Conference on Information and Knowledge Management, Birmingham, United Kingdom; ACM, 2023; 639-648.
- [235] CHEN Z, CHEN J, ZHANG W, et al. MEAformer: Multi-modal Entity Alignment Transformer for Meta Modality Hybrid [J]. arXiv: 2212. 14454, 2022.
- [236] CHEN Z, GUO L, FANG Y, et al. 2023. Rethinking Uncertainly Missing and Ambiguous Visual Modality in Multi-Modal Entity Alignment [J]. arXiv: 2307. 16210, 2023.
- [237] LI X, YIN X, LI C, et al. Oscar: Object-Semantics Aligned Pre-training for Vision-Language Tasks [C] // Proceedings of the 16th European Conference on Computer Vision (ECCV). Glasgow, UK, Springer, 2020; 121-137.
- [238] PAN X, YE T, HAN D, et al. Contrastive Language-Image Pre-Training with Knowledge Graphs [C] // Proceedings of the 36th Conference on Neural Information Processing Systems (NeurIPS). New Orleans, Louisiana, USA; Morgan Kaufmann, 2022; 22895-22910.
- [239] CHEN X, ZHANG N, LI L, et al. Good Visual Guidance Make A Better Extractor: Hierarchical Visual Prefix for Multimodal Entity and Relation Extraction [C] // Findings of the Association for Computational Linguistics; NAACL 2022. Seattle, United States; ACL, 2022; 1607-1618.
- [240] LI Q, GUO S, JI C, et al. Dual-Gated Fusion with Prefix-Tuning for Multi-Modal Relation Extraction [C] // Findings of the Association for Computational Linguistics, Toronto, Canada; ACL 2023; 8982-8994.
- [241] WANG X, CAI J, JIANG Y, et al. Named Entity and Relation Extraction with Multi-Modal Retrieval [C] // Findings of the Association for Computational Linguistics; EMNLP 2022. Abu Dhabi, United Arab Emirates. ACL, 2022; 5925-5936.
- [242] DU Z, LI Y, GUO X, et al. Training Multimedia Event Extraction with Generated Images and Captions [C] // Proceedings of the 31st ACM International Conference on Multimedia. New York, NY, USA; ACL, 2023; 5504-5513.
- [243] CHEN B, LIN X, THOMAS C, et al. Joint Multimedia Event

- Extraction from Video and Article[C]// Findings of the Association for Computational Linguistics: EMNLP 2021. Punta Cana, Dominican Republic, ACL, 2021; 74-88.
- [244] LIU J, CHEN Y, XU J. Multimedia Event Extraction from News With a Unified Contrastive Learning Framework[C]// Proceedings of the 30th ACM International Conference on Multimedia. New York, NY, USA: ACM, 2022; 1945-1953.
- [245] LI M, XU R, WANG S, et al. CLIP-Event: Connecting Text and Images with Event Structures[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA: IEEE, 2022; 16399-16408.
- [246] MOGHIMIFAR F, SHIRI, F, HAFFARI R, et al. Few-shot Domain-Adaptative Visually-fused Event Detection from Text [C]// 2023 26th International Conference on Information Fusion (FUSION). Charleston, SC, USA: IEEE, 2023; 1-8.
- [247] LI J, ZHANG C, DU M, et al. Three Stream Based Multi-level Event Contrastive Learning for Text-Video Event Extraction [C]// Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing, Singapore. ACL, 2023; 1666-1676.
- [248] LI H, YATSKAR M, YIN D, et al. VisualBERT: A Simple and Performant Baseline for Vision and Language[J]. arXiv: 1908.03557, 2019.
- [249] LI H, YATSKAR M, YIN D, et al. Visual-BERT: A Simple and Performant Baseline for Vision and Language[J]. arXiv: 1908.03557, 2019.
- [250] TAN H, BANSAL M. LXMERT: Learning Cross-Modality Encoder Representations from Transformers[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Hong Kong, China: ACL, 2019; 5100-5111
- [251] SU W, ZHU X, CAO Y, et al. VL-BERT: Pre-training of Generic Visual-Linguistic Representations[C]// Proceedings of the 8th International Conference on Learning Representations. 2020.
- [252] HUANG Z, ZENG Z, LIU B, et al. Pixel-BERT: Aligning Image Pixels with Text by Deep Multi-Modal Transformers[J]. arXiv: 2004.00849, 2020.
- [253] LIN J, YANG A, ZHANG Y, et al. InterBERT: Vision-and-Language Interaction for Multi-modal Pretraining[J]. arXiv: 2003.13198, 2020.
- [254] LI G, DUAN N, FANG Y, et al. Unicoder-VL: A Universal Encoder for Vision and Language by Cross-Modal Pre-Training [C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2020; 11336-11344.
- [255] HAN C, JIA H. Multi-modal Representation Learning with Self-adaptive Threshold for Commodity Verification [C]// Proceedings of the China Conference on Knowledge Graph and Semantic Computing (CCKS). Singapore: Springer, 2022; 172-179.
- [256] YU F, TANG J, YIN W, et al. ERNIE-ViL: Knowledge Enhanced Vision-Language Representations through Scene Graphs [C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2021; 3208-3216.
- [257] CUI Y, YU Z, WANG C, et al. ROSITA: Enhancing Vision-and-Language Semantic Alignments via Cross-and Intra-modal Knowledge Integration[J]. arXiv: 2108.07073, 2021.
- [258] LI W, GAO C, NIU G, et al. UNIMO: Towards Unified-Modal Understanding and Generation via Cross-Modal Contrastive Learning[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. ACL, 2021; 2592-2607.
- [259] SUN Z, HUANG J, LIN J, et al. Joint Pre-training and Local Re-training: Transferable Representation Learning on Multi-source Knowledge Graphs[J]. arXiv: 2306.02679, 2023.
- [260] HUANG N, DESHPANDE Y R, LIU Y, et al. Endowing Language Models with Multimodal Knowledge Graph Representations[J]. arXiv: 2206.13163, 2022.
- [261] ALBERTS H, HUANG N, DESHPANDE Y, et al. VisualSem: A High-Quality Knowledge Graph for Vision and Language [C]// Proceedings of the 1st Workshop on Multilingual Representation Learning. Punta Cana, Dominican Republic: ACL, 2021; 138-152.
- [262] PESARANGHADER A, SAJED T. RECipe: Does a Multi-Modal Recipe Knowledge Graph Fit a Multi-Purpose Recommendation System[J]. arXiv: 2308.04579, 2023.
- [263] SONG K, TAN X, QIN T, et al. MPNet: Masked and Permuted Pre-training for Language Understanding[C]// Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS'20). Red Hook, NY, USA: Curran Associates Inc, 2020; 16857-16867.
- [264] DAY K, CHRISTL D, SALVI R, et al. Video Pre-trained Transformer: A Multimodal Mixture of Pre-trained Experts[J]. arXiv: 2304.10505, 2023.
- [265] ZHANG N, LI L, CHEN X, et al. Multimodal Analogical Reasoning over Knowledge Graphs[C]// Proceedings of the 11th International Conference on Learning Representations. Kigali Rwanda, 2023.
- [266] CHEN X, ZHANG N, LI L, et al. Hybrid Transformer with Multi-level Fusion for Multimodal Knowledge Graph Completion[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'22). New York, NY, United States: ACM, 2022; 904-915.
- [267] YU J, ZHU Z, WANG Y, et al. Cross-modal knowledge reasoning for knowledge-based visual question answering[J]. Pattern Recognition, 2020, 108, Article No. 107563.
- [268] LIANG K, ZHOU S, LIU Y, et al. Structure Guided Multi-modal Pre-trained Transformer for Knowledge Graph Reasoning [J]. arXiv: 2307.03591, 2023.
- [269] ZHANG Y, ZHANG W. Knowledge Graph Completion with Pre-trained Multimodal Transformer and Twins Negative Sampling[J]. arXiv: 2209.07084, 2022.
- [270] ZHANG Y, CHEN Z, ZHANG W. MACO: A Modality Adversarial and Contrastive Framework for Modality-missing Multimodal Knowledge Graph Completion [J]. arXiv: 2308.06696, 2023.

- [271] PENG B, GALLEY M, HE P, et al. Check Your Facts and Try Again: Improving Large Language Models with External Knowledge and Automated Feedback[J]. arXiv:2302.12813, 2023.
- [272] BRUNO A, MAZZEO P, CHETOUANI A, et al. Insights into Classifying and Mitigating LLMs' Hallucinations[J]. arXiv:2311.08117, 2023.
- [273] KANDULA V, BHATTACHARYYA P. Decision Knowledge Graphs: Construction of and Usage in Question Answering for Clinical Practice Guidelines[J]. arXiv:2308.02984, 2023.
- [274] LYU K, TIAN Y, SONG Y, et al. Causal knowledge graph construction and evaluation for clinical decision support of diabetic nephropathy [J]. Journal of Biomedical Informatics, 2023, 139(C), Article No. 104298.
- [275] JAIMINI U, SHETH A. CausalKG: Causal Knowledge Graph Explainability Using Interventional and Counterfactual Reasoning[J]. IEEE Internet Computing, 2022, 26(1):43-50.
- [276] HUANG H. Causal Relationship over Knowledge Graphs[C]// Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta, GA, USA: ACL, 2022:5116-5119.
- [277] ZHU W, LIU H, DONG Q, et al. Multilingual Machine Translation with Large Language Models: Empirical Results and Analysis[J]. arXiv:2304.04675, 2023.
- [278] JIN B, LIU G, HAN C, et al. Large Language Models on Graphs: A Comprehensive Survey[J]. arXiv:2312.02783, 2023.
- [279] WU L, QIU Z, ZHENG Z, et al. Exploring Large Language Model for Graph Data Understanding in Online Job Recommendations[J]. arXiv:2307.05722, 2023.
- [280] SUN J, XU C, TANG L, et al. Think-on-Graph: Deep and Responsible Reasoning of Large Language Model on Knowledge Graph[C]// Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria, 2024.
- [281] WEN Y, WANG Z, SUN J. MindMap: Knowledge Graph Prompting Sparks Graph of Thoughts in Large Language Models[J]. arXiv:2308.07929, 2023.
- [282] CHEN M, TAO Z, TANG W. Enhancing Emergency Decision-making with Knowledge Graphs and Large Language Models [J]. arXiv:2311.08732, 2023.
- [283] GAO J, DING X, QIN B, et al. Is ChatGPT a Good Causal Reasoner? A Comprehensive Evaluation[C]// Findings of the Association for Computational Linguistics (EMNLP 2023). Singapore: ACL, 2023:11111-11126.
- [284] YUAN C, XIE Q, ANANIADOU S. Zero-shot Temporal Relation Extraction with ChatGPT[C]// The 22nd Workshop on Biomedical Natural Language Processing and BioNLP Shared Tasks. Toronto, Canada: ACL, 2023:92-102.
- [285] CAFFAGNI D, COCCHI F, BARSELLOTTI L, et al. The Revolution of Multimodal Large Language Models: A Survey[J]. arXiv:2402.12451, 2024.



ZENG Zefan, born in 1993, Ph.D candidate. His main research interests include pre-trained language model and knowledge reasoning.



HU Xingchen, born in 1989, Ph.D, associate professor. His main research interests include machine learning, evolutionary optimization and target engineering.

(责任编辑:柯颖)