

知识图谱构建技术研究综述

赵莹莹¹, 朱率率^{1,2}

(1. 武警工程大学密码工程学院, 陕西 西安 710086; 2. 网络与信息安全武警部队重点实验室, 陕西 西安 710086)

摘要: 知识图谱(KG)作为一种以实体为节点、关系为边的结构化语义知识表示形式,能够精准刻画现实世界中各类事物及其复杂关联,已成为人工智能、自然语言处理、推荐系统、智能问答等多个领域的核心支撑技术,为机器理解语义和实现认知智能提供了重要基础。首先,阐述知识图谱的基本概念与体系架构,明确以“实体-关系-属性”三元组为核心的知识表示单元,并分别剖析自顶向下和自底向上两种构建模式的适用场景与技术特点;其次,重点分析知识图谱构建过程中信息抽取、知识融合以及知识推理三大核心环节的技术演进,系统梳理技术发展脉络,并对比不同方法的优势与局限;再次,深入剖析 DBpedia 和百度两个典型知识图谱在技术路线选择上的差异,将理论方法与实际知识图谱构建场景相结合;最后,总结当前知识图谱构建在数据质量、语义一致性、动态演化等方面面临的挑战,并展望未来研究方向,旨在为知识图谱构建的理论研究与实际应用提供全面参考,推动该领域技术的进一步发展。

关键词: 知识图谱;信息抽取;知识融合;知识推理;深度学习

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0252971

Research Review of Knowledge Graph Construction Technology

ZHAO Yingying¹, ZHU Shuaishuai^{1,2}

(1. College of Cryptography Engineering, Engineering University of PAP, Xi'an 710086, Shaanxi, China;

2. Key Laboratory of Network and Information Security, Armed Police Force, Xi'an 710086, Shaanxi, China)

【Abstract】 Knowledge Graphs (KGs) are structured semantic knowledge representations with entities as nodes and relations as edges. They accurately depict various things in the real world and their complex associations and have become a core supporting technology across multiple domains, including artificial intelligence, natural language processing, recommendation systems, and intelligent question-answering. Hence, they form an important foundation for machines to understand semantics and achieve cognitive intelligence. This paper describes the basic concepts and system architecture of a KG, clarifies the knowledge representation unit with the "entity-relation-attribute" triple as the core, and analyzes the applicable scenarios and technical characteristics of both top-down and bottom-up construction approaches. The technical evolution of three core links in the KG construction process, namely, information extraction, knowledge fusion, and knowledge reasoning, are analyzed. Subsequently, the technical development context is systematically discussed, and the advantages and limitations of different methods are discussed. Further, through an in-depth analysis of the differences in technical route selection between DBpedia and Baidu as two typical KGs, the theoretical method is combined with an actual KG construction scenario. Finally, the challenges faced by current KG construction in terms of data quality, semantic consistency, and dynamic evolution are summarized, and future research directions are examined. This review provides comprehensive guidance for both theoretical research and practical applications in KG construction, thereby advancing technological development in this field.

【Key words】 Knowledge Graph (KG); information extraction; knowledge fusion; knowledge reasoning; deep learning

0 引言

知识图谱(KG)作为一种结构化语义网络,旨在描述客观世界的概念、实体、事件及其相互关系,已经成为人工智能和大数据时代组织管理知识的关键

技术。自 2012 年谷歌正式提出知识图谱概念以来^[1],这项技术已经从最初的搜索引擎优化工具发展成为支撑智能问答、推荐系统、决策分析等多种人工智能应用的基础设施。知识图谱融合了图形学、应用数学、信息可视化技术等多学科理论与本体技

基金项目: 国防科技自主科研项目重点课题(ZZKY20243102)。

作者简介: 赵莹莹,女,硕士研究生,主研方向为知识图谱;朱率率(通信作者),教授、博士。

收稿日期: 2025-08-29

修回日期: 2025-11-10

E-mail: zsseupap@163.com

术,成功地将知识从字符串形式转化为结构化语言形式,并借助图结构建模,直观呈现出知识的结构及其相互间的关联。

知识图谱构建是一个从数据到知识的转化过程,学术界围绕知识图谱构建展开了广泛探索,研究焦点集中在构建流程中的信息抽取、知识融合与知识推理三大核心环节。信息抽取是构建知识图谱的基础数据来源,负责从多源数据中提取实体、关系与属性等知识要素;知识融合是保证图谱质量与一致性的关键,旨在解决异构知识之间存在冗余、歧义和冲突的问题,实现知识的整合与统一;知识推理是提升图谱认知能力的核心,通过逻辑规则、表示学习、神经网络等方法挖掘隐含知识,实现图谱的补全与深化。这三者构成了知识图谱构建的核心技术链条,缺一不可。近年来,随着深度学习、自然语言处理特别是大语言模型(LLM)技术的突破,知识图谱的自动化与智能化构建水平得到了显著提升,新的技术、模型与方法层出不穷,呈现出百花齐放的局面。然而,正是这种快速的发展与技术的多样性,使得研究者难以系统地把握该领域的全貌与技术脉络,不同技术路线各有优劣,其使用场景也各不相同。因此,本文将系统梳理和总结知识图谱构建的关键技术及其最新进展,对比不同方法的性能与特点,旨在为相关领域的研究与应用提供全面参考。

本文所综述的文献主要来源于国内外权威学术数据库与会议,其中,英文文献来源于国外顶刊顶会,包括 KDD、AAAI、ACL、EMNLP、WWW、NeurIPS 等,中文文献来源于国内具有影响力的数据库,包括中国知网(CNKI)、万方数据知识服务平台、维普中文科技期刊等。数据库检索关键词包括“知识图谱构建”、“信息抽取”、“知识融合”、“知识推理”、“实体对齐”、“关系抽取”、“机器学习”、“深度学习”和“大语言模型”等中英文对应术语。文献筛选遵循以下原则:1)重点关注近十年的研究成果,同时对奠基性经典文献予以保留;2)注重代表性方法的覆盖性与对比性;3)兼顾经典方法与前沿进展,确保综述的全面性与时效性。通过系统梳理与分类比较,旨在为研究者提供清晰的技术脉络与方法选型参考。

本文的组织结构如下:第 1 章阐述知识图谱的基本概念与体系架构,明确其核心构成与构建模式;第 2 章聚焦信息抽取环节,详细分析命名实体识别、关系抽取(RE)与属性抽取(AE)等关键技术的发展与挑战;第 3 章探讨知识融合技术,包括实体对齐(EA)、关系对齐(RA)、实体消歧(ED)及冲突消解

(CR)的研究进展;第 4 章综述知识推理技术;第 5 章选取代表性知识图谱案例,分析其构建技术路线;第 6 章总结全文并展望未来研究方向。

1 知识图谱的基本概念与体系架构

在维基百科中,知识图谱被定义为“谷歌用于增强其搜索引擎功能的知识库^[2]”,本质上它是一种语义网络,能够揭示实体之间的关系,并将现实世界中的实体及其相互关系以一种结构化的形式呈现出来。随着技术的不断进步,知识图谱这一概念已被广泛应用于描述各类大规模知识库,其核心特征是以图结构形式组织和表示知识。其中,节点代表实体或概念,边代表实体间的关系或属性。

从技术构成看,知识图谱的基本单位是三元组,通常表示为 $G=(E,R,S)$,其中, E 是实体集合, R 是关系集合, $S \subseteq E \times R \times E$ 代表知识库中的三元组集合。三元组主要有两类基本形态,即“实体-关系-实体”与“实体-属性-属性值”。每个实体都能通过全局唯一的 ID 加以区分,其中属性与属性值构成的配对用于描述实体的内在特征,关系则起到连接两个实体的作用,以此体现它们之间的语义联系。

知识图谱的体系架构指其构建模式结构,如图 1 所示,主要包括自顶向下和自底向上两种构建方式^[3]。自顶向下方式相对直观,需先从已有高质量结构化知识库抽取本体模式,明确概念层次关系,搭建知识图谱基本框架,再添加其他数据源的实体及属性。知识图谱发展初期,谷歌借助 Freebase 数据库、DBpedia 基于维基百科数据,通过这种方式快速构建知识图谱。但该方式高度依赖已有结构化知识库,当缺乏合适基础库时,构建工作会受阻。而自底向上的方式首先从异构数据源中提取实体,再抽象归纳构建概念体系,最终完成本体构建。在实际中,自底向上方式更灵活创新,尤其适用于缺乏成熟结构化知识库的领域,能更好满足知识需求的变化。其中,谷歌的 Knowledge Vault^[4]是这种构建方式的典型代表。

2 信息抽取

信息抽取是知识图谱构建的基础环节,其核心任务是从结构化、半结构化及非结构化数据中提取实体、关系、属性等知识要素,为后续知识融合与推理奠定基础。信息抽取技术的演进反映了自然语言处理技术从依赖人工规则到数据驱动、从浅层特征到深层语义理解的进步。早期基于规则的方法严重依赖专家知识,难以适应海量、异构且动态变化的互




图 1 知识图谱的体系架构

Fig.1 Architecture of KG

联网数据。随后兴起的机器学习方法虽转向数据驱动,但仍受制于复杂的特征工程和对大量标注数据的依赖。近年来,大语言模型的崛起从根本上改变了这一范式,通过在海量无标注语料上进行预训练,显著降低了对特定任务标注数据的需求,并在跨领域、跨任务的泛化与迁移方面展现出强大能力,推动了信息抽取技术向更高层次的自动化与智能化发展。依据抽取对象的差异,信息抽取技术可划分为实体抽取、关系抽取和属性抽取三类。

2.1 命名实体识别

命名实体识别是指从文本数据中检测并归类特定类别的实体,例如人物名称、地理位置、机构名称等关键信息元素。形式上,假设存在一个由 N 个单词组成的句子 $S = \{w_1, w_2, \dots, w_N\}$,命名实体识别的核心目标是检测文本中的所有实体实例,并采用 (I_s, I_e, t) 的三元组形式来表示。其中: I_s 和 I_e 分别为实体提及在句子中的起始和结束位置索引,且均满足 $I_s, I_e \in [1, N]$; t 是从预定义的实体类型集合中选取的一个元素,用于标识该实体提及的具体类型。命名实体识别方法经历了从规则匹配到机器学习、深度学习和大语言模型的演进过程。

2.1.1 基于规则和字典的命名实体识别方法

早期实体识别依赖人工制定规则模板和专用词典,通过模式匹配提取符合规则的实体。文献[5]提出了 FASTUS 系统。该系统基于明确的规则体系

构建信息抽取框架,通过层叠的非确定性有限状态自动机实现了从自然语言文本中有效提取目标信息。文献[6]提出一种面向语音输入的基于规则的命名实体识别系统,针对语音输入场景的特殊性进行了方法适配,通过明确的规则设计实现了命名实体的识别功能。尽管基于规则和词典的命名实体识别方法在特定领域可以达到较好的识别效果,但其严重依赖人工制定的规则或模板,不仅构建成本较高,而且领域适应性较差,难以适应数据动态变化带来的新挑战。

2.1.2 基于机器学习的命名实体识别方法

为突破人工规则的限制,研究者开始探索采用机器学习技术来实现命名实体识别。文献[7]通过整合 k 近邻算法和条件随机场模型,有效识别了推特文本中的命名实体。另有研究者探索了机器学习与规则方法的混合策略,通过结合两者的优势来提高实体识别效果。文献[8]采用融合条件随机场与规则的方法,在地理学领域开展了实体识别研究,获得显著成效。文献[9]提出了一种基于双向长短期记忆(BiLSTM)网络与条件随机场结合的端到端神经网络架构,通过融合多粒度特征、捕捉序列依赖并优化标注一致性,显著提升了实体边界的识别精度和类型分类的准确性。然而,这种基于统计的机器学习方法对训练数据的依赖性较强,标注数据的质量和数量会直接影响模型的性能。

2.1.3 基于深度学习的命名实体识别方法

近年来,随着深度学习技术的飞速发展,基于深度学习的命名实体识别模型取得了更好的效果。该方法减少了人工干预,在少量标注数据下也能适配新领域,显著提升了跨句子和文档级别的实体识别效果。在实际应用中,卷积神经网络(CNN)^[10]、LSTM 网络^[11-12]、基于 Transformer 的双向编码器表示(BERT)^[13-14]、注意力机制(Attention)^[15-16]等深度学习技术被广泛用于特征提取和实体识别。但上述深度学习模型在命名实体识别任务中均存在一定的局限性。为此,部分研究者探索了深度学习方法的融合策略,尝试通过整合多种模型的优势来提升实体识别性能。文献[17]提出了一种结合 CNN 与自注意力机制的混合模型,通过集成反思机制来缓解模型内部的语义冲突问题。文献[18]提出一种融合 BERT 字向量和 Word2Vec 词向量的兽药文本命名实体识别模型,结合 BiLSTM 网络和多头自注意力机制提取特征,之后通过条件随机场得到文本的标签序列。

2.1.4 基于大语言模型的命名实体识别方法

近年来,大语言模型凭借其卓越的自然语言处理能力成为研究热点,大语言模型通过大规模预训练捕捉语言信息与语义关系,参数规模常达数十亿甚至更高量级,在文本理解与生成任务中表现突出。这一特性促使研究者将大语言模型引入命名实体识别领域,探索利用大语言模型强大的上下文建模与语义理解能力,突破传统方法瓶颈,提升实体识别的准确性与效率。文献[19]提出了一个三阶段框架 ConsistNER,通过引入本体和上下文一致性,为低资源命名实体识别任务提供了一种新的解决方案,显著提高了实体识别的准确性和大语言模型的实体识别能力。文献[20]设计了一种融合标签注入的提示模板,让大语言模型可以直接输出实体名称或表明实体不存在,同时采用掩码损失优化策略来增强少样本情况下的识别效果。文献[21]提出一种将小规模模型与大语言模型进行链接的方法 LinkNER,通过不确定性策略提升命名实体识别任务的性能与鲁棒性。

表 1 对上述不同命名实体识别方法进行了总结。

表 1 不同命名实体识别方法对比
Table 1 Comparison of different named entity recognition methods

Method	Working Principle	Advantages	Disadvantages	References	Year	Publications/ conferences
Based on rules and dictionaries	Pattern matching based on manually defined grammar rules, dictionaries, regular expressions, etc.	Requires less labeled data, low initial development costs, strong interpretability, and high accuracy in specific domains	Highly dependent on manual rules, has high maintenance costs of rules, and poor generalization ability	Literature [5]	1992	MUC
				Literature [6]	2000	ICSLP
				Literature [7]	2011	ACL
Based on machine learning	Extracting text features through feature engineering and learning entity boundary laws with statistical models	Automatic learning features, reducing manual rule design, with certain generalization capabilities	Requires a large amount of labeled data, complex feature engineering, and relies on domain knowledge	Literature [8]	2015	Computer Applications and Software
				Literature [9]	2016	NAACL
Based on deep learning	Automatically learn text representations through neural networks, and output entity labels in combination with sequence annotation frameworks	Does not require too many additional features, performs best on large datasets, and has strong generalization capabilities	Requires more training data and computing resources, long training time, complex models, and poor interpretability	Literature [17]	2019	IJCAI
				Literature [18]	2025	Journal of Chinese Agricultural Mechanization
Based on LLM	Utilize pre-trained large language models for entity recognition through fine-tuning or prompting	Outstanding semantic understanding ability, able to handle complex text without a large amount of labeled data, and strong cross-domain migration ability	The model is large, the inference speed is slow, the output result is uncertain, and the computational resource requirements are high	Literature [19]	2024	AAAI
				Literature [20]	2024	ICANN
				Literature [21]	2024	ACM

2.2 关系抽取

关系抽取旨在从文本中抽取出实体间的语义关联,形成<实体,关系,实体>形式的三元组。具体而言,对于包含 N 个词汇的语句 $S = \{w_1, w_2, \dots, w_N\}$ 及从该句子中识别出的实体集合 $E = \{e_1,$

$e_2, \dots, e_k\}$, RE 需要构建一个三元组集合 R , 其中每个三元组 $(e_i, r, e_j) \in R$ 表示实体 e_i 和实体 e_j 之间存在特定语义关系 r , e_i 和 e_j 均属于实体集合 E , 而 r 是从预定义的关系类型集中选取的一个元素。关系抽取方法可以分为基于规则和模板的方法、基

于传统机器学习的方法、基于深度学习的方法以及基于大语言模型的方法。

2.2.1 基于规则和模板的关系抽取方法

基于规则和模板的方法是一种早期的关系抽取方法,其核心思想是通过人工编写规则或模板来匹配文本中的实体关系。这类方法通常依赖于语言学家或领域专家的知识,根据特定领域的背景和特点,构建能够识别特定关系的规则集合。例如,通过定义触发词、依存句法结构等模式,系统可以自动识别文本中符合规则的实体对。文献[22]开发了 Auto-Slog 系统,该系统通过制定抽取规则,能够自动构建特定领域的字典,进而用于抽取该领域的相关信息。文献[23]采用矩阵形式表征实体对及抽取的词法、句法特征,进而提出了一种序列联合聚类算法,实现特征模板与实体对的联合聚类分析。

然而,这种方法存在明显的局限性,首先是灵活性差,规则和模板的制定需要大量的人工工作,并且一旦文本的表达方式发生变化,规则可能失效,需要重新调整和优化;其次是泛化能力弱,这种方法对特定领域的依赖性较强,难以适应不同领域的文本数据,在面对跨领域或跨语言的关系抽取任务时,其适用性受到很大限制。

2.2.2 基于传统机器学习的关系抽取方法

基于机器学习的关系抽取方法是自然语言处理领域的重要突破,它标志着该任务从传统的规则与模板匹配模式转向数据驱动的自动化模式。该方法将关系抽取视为一个分类问题,首先,需要人工标注大量的训练数据;然后,通过特征工程提取文本中的语法、词法和语义信息,将这些特征转化为高维向量表示作为输入;最后,使用支持向量机(SVM)、决策树、逻辑回归等分类器对实体对之间的关系进行分类。文献[24]在研究中开创性地将最大熵模型应用于关系抽取任务,通过整合实体类型、依存关系等多种文本特征,显著提升了特征向量的表达能力。文献[25]通过在句法树节点上加入丰富的判别特征,并设计相应的特征感知树核,使得基于 SVM 的关系抽取在多个基准上实现了约 5% 的 F1 值提升。

相比基于规则和模板的方法,传统机器学习方法能够自动从标注数据中学习实体关系的特征表示,减少了人工设计规则的工作量,并且更具泛化能力。然而,该方法仍存在局限性:首先,通常需要大量的标注数据来训练模型,标注工作成本较高且容易出错;然后,特征工程复杂,需要人工设计和提取大量的特征,这些特征的质量和数量直接影响模型的性能;最后,预处理在文本解析过程中产生的错误

会随着句法特征传递到关系抽取模型,导致错误逐级放大。

2.2.3 基于深度学习的关系抽取方法

深度学习技术的进步推动了关系抽取方法的革新,使神经网络模型成为该领域的主流解决方案。这类方法能够自动从文本数据中学习实体关系的特征表示,避免了传统方法中特征工程的繁琐过程。目前主流的深度学习模型包括 CNN、循环神经网络(RNN)、图神经网络(GNN)、Transformer 等,这些模型能够自动捕捉文本中的局部和全局语义信息,从而实现关系抽取。文献[26]首次将注意力机制与 BiLSTM 结合,用于关系抽取任务,通过注意力机制,模型能够动态地关注与当前任务最相关的上下文信息,从而提升模型对语义关系的理解能力。实验结果表明,该模型在多个基准数据集上表现出了优异的性能。文献[27]提出了一种基于文档级图卷积神经网络的方法,用于跨句关系抽取,该方法通过构建图结构来捕捉句子间的相互关系,并结合多实例学习进行关系分类。在文档级建模与 GNN 的融合方面,这一方法展现了显著的创新性,但在大规模数据上的计算复杂度和图结构设计方面仍存在挑战。文献[28]提出了一种结合依赖句法信息和对比学习的双曲图卷积网络关系抽取模型。该模型通过在噪声与去噪句法图上最大化实体间互信息,缓解词嵌入集中和句法噪声问题,显著提升公共数据集的关系抽取性能。

2.2.4 基于大语言模型的关系抽取方法

近年来,大语言模型在自然语言处理任务中取得了突破性进展,也逐渐被应用于关系抽取任务。该方法通常通过预训练模型提取文本的语义表示,然后结合微调策略进行关系分类。这类方法的优势在于能够利用海量无标注文本进行预训练,从而减少对标注数据的依赖。此外,大语言模型在处理长距离依赖、上下文信息等方面具有天然优势,能够更准确地捕捉实体之间的语义关系,从而提高抽取的准确率和召回率。文献[29]提出了一种名为基于协同优化的知识感知提示调优方法(KnowPrompt),旨在通过知识感知和协同优化来提升关系抽取任务的性能。文献[30]提出了一种结合大语言模型、思维链(CoT)及微调技术的关系抽取方法,该方法通过知识蒸馏从 GPT-3 中获取 CoT 推理信息,并借助微调策略提升模型对关系抽取任务的适应能力,实验结果表明,该方法在 ADE、CoNLL04、NYT 等数据集上均达到最优性能。文献[31]利用大语言模型微调小语言模型,使其在推理阶段兼具高效性与

较强的模式学习能力,实现了在几乎无标注成本的情况下,接近有监督模型的抽取效果。

当前,基于大语言模型的关系抽取方法仍面临多重挑战。在提示学习方面,构建有效的提示模板不仅依赖专业的领域知识,还需借助大量数据对模

板进行验证,过程成本高昂。同时,标签词的检索也极为复杂,尤其在关系类别众多的情况下,难以高效、准确地确定合适的标签词,严重影响方法的可扩展性与实用性。

表 2 为本节所列不同关系抽取方法的优缺点对比。

表 2 不同关系抽取方法对比

Table 2 Comparison of different relation extraction methods

Method	Working Principle	Advantages	Disadvantages	References	Year	Publications/ conferences
Based on rules and templates	Matching entity relationships in text by manually writing rules or templates	Strong interpretability, flexible domain customization, and no training data required	Poor flexibility and weak generalization ability	Literature [22]	1993	AAAI
				Literature [23]	2010	WWW
Based on traditional machine learning	Transform relationship extraction into a classification problem, and use classification algorithms to learn the mapping relationship between features and relationship categories from labeled data by artificially designing features	It can automatically learn rules from data, simple model structure, and has better generalization ability	Relying on a large amount of high-quality labeled data, feature engineering is complex, and syntactic parsing errors accumulate	Literature [24]	2004	ACL
				Literature [25]	2014	ACL
Based on deep learning	Automatically learn text representations through neural networks, and end-to-end output of relational classification results	Automatic learning of complex features, capturing complex semantic information, end-to-end training, and simplifying feature engineering	The model structure is complex, the demand for labeled data is large, the interpretability is poor, and the model decision-making process is difficult to trace back	Literature [26]	2016	ACL
				Literature [27]	2019	ACL
				Literature [28]	2025	International Journal of Computational Intelligence Systems
Based on LLM	Using pre-trained semantic knowledge, zero-sample or small-sample relationship recognition can be achieved through instruction fine-tuning or prompt engineering	No need for a large amount of labeled data, outstanding semantic understanding, and strong cross-domain adaptability	It is suggested that learning requires professional domain knowledge and a large amount of data verification, and the retrieval process is complex and poor interpretable	Literature [29]	2022	ACM
				Literature [30]	2023	ACL
				Literature [31]	2024	EMNLP

2.3 属性抽取

属性抽取的任务是从文本中识别并抽取出特定实体的属性及其对应的属性值,形成<实体,属性,属性值>形式的三元组。例如,从句子“无人机的续航时间是 45 min”中,可以抽取出实体“无人机”的属性“续航时间”及其值“45 min”。实体属性本质上定义了实体与属性值之间的名词性关系。因此,属性抽取问题可被视作关系抽取的一种特殊形式,其发展先后经历了基于规则与特征工程、统计机器学习以及深度学习与大语言模型等几个标志性阶段。

早期属性抽取依赖人工定义的规则模板,这些规则通常是一些模式匹配的表达式,用于识别文本中符合特定格式的属性信息。文献[32]通过结合统计分析和模式匹配技术,从文本数据中发现属性词

大多具备名词性特征,并据此提出了名词性关联规则抽取方法。基于规则的属性抽取方法研究主要集中于 21 世纪初,后期因灵活性不足、依赖人工等局限性,相关研究热度逐渐降低。

随着技术的演进,基于机器学习的方法使得属性抽取研究步入自动化特征学习的阶段。文献[33]首次在大规模商品评论上系统化引入半监督方法,实现了高召回率的属性抽取,为后续深度学习模型奠定了特征工程基线。在后续的发展中,以 RNN、BiLSTM、BERT 以及 GPT 等为代表的深度学习和预训练语言模型,为属性抽取技术带来了显著变革,其中, BERT 是目前最常用的预训练模型。文献[34]为提升商品属性抽取效果,提出了一种基于 BERT 和多层交互注意力机制的模型,显著提升了

属性抽取的准确率。

3 知识融合

知识融合是知识图谱构建过程中确保质量与一致性的关键环节。信息抽取阶段通常面向多源异构数据,导致抽取的知识存在大量冗余、歧义和冲突。知识融合通过实体对齐、关系对齐、实体消歧、冲突消解等技术,对不同来源的知识进行整合、清洗和统一,消除噪声和矛盾,最终形成高质量、无歧义、内部一致的知识库。

知识融合技术的发展脉络清晰地体现了从表面匹配到深层理解的跨越。早期基于规则与字符串相似度的方法效率高但泛化能力弱;机器学习方法实现了从数据中自动学习规律的突破,降低了对人工定义的依赖;表示学习,尤其是 GNN 实现了从“比较特征”到“比较语义表示”的范式转变,能更深刻地捕捉结构与语义信息;当前基于预训练语言模型的方法则进一步利用其内化的常识与推理能力,将融合技术提升至语义理解与逻辑推理的新层次。

3.1 实体对齐

实体对齐的目标是从两个异构知识图谱 $G_1 = \{E_1, R_1, T_1\}$ 和 $G_2 = \{E_2, R_2, T_2\}$ 中找到所有等价实体对构成的集合 $A = \{(e_1, e_2) \in E_1 \times E_2 \mid e_1 \equiv e_2\}$, 其中, E 表示实体集合, R 表示关系集合, $T \subseteq E \times R \times E$ 表示三元组集合, 符号“ $\equiv$ ”表示“指向现实世界同一对象”的等价关系。实体对齐技术最初源于知识库的本体匹配任务,随着知识库数据量的持续增长,自动化识别等价实体对逐渐发展为知识融合的关键步骤。近年来,该领域研究主要围绕基于特征相似度计算、机器学习及表示学习等技术展开,通过综合分析实体名称、属性特征及其取值等多维度信息来实现实体匹配。

3.1.1 基于特征相似度计算的实体对齐

基于特征相似度计算的实体对齐方法主要通过量化分析实体特征的匹配度来实现。该方法首先将实体的各类特征转换为数值化表示,随后运用相似性度量算法计算实体间的匹配程度,最终识别出语义等价的实体对。文献[35]将实体对齐转化为文本相似度匹配问题,引入基于标识符的词频-逆文档频率(TF-IDF)距离作为识别相同实体名称对的关键特征。TF-IDF 方法在计算文本相似性方面表现出色,但在融合语义信息方面尚未深入拓展。文献[36]通过融合图结构相似性与其他特征度量,采用迭代优化策略动态调整匹配规则,从而有效提升了实体对齐的精度并筛选出高置信度匹配对。文

献[37]针对跨语言知识图谱中的实体对齐任务,提出了一种基于相似度传播的半监督框架,通过图结构的邻接关系,将已知相似度信息沿图的节点和边进行迭代传播并动态扩充高置信度种子对,实现了对未标记实体的有效对齐。

3.1.2 基于机器学习的实体对齐

基于机器学习的方法通过从标注数据中自动学习匹配规律,并利用训练得到的分类模型来推断实体间的对应关系。文献[38]采用分类与回归树模型来解决实体对齐问题,该方法从实体数据中提取特征,通过递归划分数据集构建决策树,最终生成对齐规则。文献[39]提出了一种基于主动学习的交互式实体去重框架,有效提高了去重的效率和准确性,该方法在处理大规模数据时表现出色,能够显著减少用户标注的工作量,同时保持较高的去重精度。文献[40]提出了一种基于多视图融合的实体对齐方法,通过联合学习知识图谱的结构视图与属性视图,将两类嵌入向量线性融合为统一表示,从而在跨图谱实体匹配中实现了更鲁棒的对齐效果。

与基于特征相似度计算的方法相比,这类方法的关键在于通过数据驱动的方式自动学习匹配规律,而非依赖固定的相似度度量,因此更能适应复杂数据场景并可通过模型优化持续提升对齐精度。

3.1.3 基于表示学习的实体对齐

近年来,表示学习技术已成为实体对齐领域的研究热点,其核心思想是将知识图谱中的实体和关系映射到低维向量空间进行表示。现有方法依据技术路径和模型特点,可分为多个类别,主要方法包括基于翻译模型的实体对齐、基于 GNN 模型的实体对齐和基于预训练语言模型的实体对齐等。

基于翻译模型的实体对齐是早期实体对齐研究的重要分支,其核心思想源于知识图谱嵌入中的“翻译假设”,通过将实体和关系映射到低维向量空间,利用向量“翻译”操作捕捉实体间的语义关联,进而实现跨知识图谱的实体匹配。TransE^[41]是最经典的翻译模型,TransE 模型因其结构简单、计算高效、易于实现和良好的通用性而受到广泛关注。然而,该模型在处理复杂关系类型和实体映射问题时表现出一定的局限性。针对这些不足,研究者提出了多种改进模型。其中,TransR^[42]模型通过将实体和关系映射到不同的语义空间,有效解决了头尾实体相似时的区分问题。另一种改进模型 TransH^[43]则采用了关系特定的超平面投影方法,使得不同关系下的实体能够获得更具区分性的向量表示。

尽管后续研究对翻译模型进行了诸多改进和扩

展,但其存在的缺陷依然不容忽视。例如:1)TransE 假设关系是简单的平移操作,难以准确建模一对多、多对一和多对多等复杂关系模式;2)对于跨语言场景,仅靠结构化关系无法捕捉语言层面的语义关联,性能会大幅下降。为此,研究者开始探索更强大的表示学习方法,基于 GNN 的模型能够直接对知识图谱的拓扑结构进行编码,通过消息传递机制聚合邻域信息,从而学习更具区分性的实体表示。这种方法弥补了翻译模型对复杂结构建模不足、纯文本模型对拓扑信息利用有限的缺陷,尤其在实体文本描述缺失或异构图谱场景中展现出独特优势。

监督模型 GCN-Align^[44]将 GNN 引入实体对齐任务的研究,该模型采用孪生神经网络架构,能够并行学习两个知识图谱的实体表示,然而该方法在处理过程中未能充分考虑关系语义的特征表示。半监督模型 MixTEA^[45]提出了一种创新的半监督学习框架,该模型的核心创新在于其匹配多样性基础校正模块,通过引入概率性伪映射机制有效缓解了标注数据不足的困境。自训练框架 STEA^[46]通过显式建模并利用实体间的依赖关系增强自训练过程的稳定性和对齐效果,并且在自训练循环中引入结构依赖感知的伪标签筛选与传播机制,有效缓解了错误累积问题。RHGN^[47]引入关系门控卷积机制,该方法在聚合邻居信息的过程中,以关系作为调控信号来控制邻居信息的传递,从而削弱噪声关系对实体表示的不良影响,进而实现实体与关系的有效区分。FGWEA^[48]创新性地构建了一个基于

Gromov-Wasserstein 距离的无监督学习框架,该方法将语义特征与结构特征统一建模,展现出对复杂图谱的良好适应能力,但由于最优传输问题的计算复杂度较高,其在大规模场景下的应用仍面临挑战。

近年来,随着预训练语言模型的发展,研究者开始探索如何结合知识图谱的结构特征与深度语义表示来提升实体对齐效果。这类方法的核心创新在于借助大规模语言模型的上下文理解与逻辑推理能力,克服传统对齐技术在语义建模方面的局限性。SEU^[49]将实体对齐问题转化为基于名称词汇相似性的分配问题,并利用匈牙利算法或 Sinkhorn 操作进行求解,该方法仅保留了用于特征传播的基本图卷积操作,而摒弃了复杂的神经网络,显著提高了计算效率和可解释性。IMEA^[49]框架通过引入 Transformer 架构来融合知识图谱中的上下文信息,并创新性地设计了软标签编辑与反馈循环机制,将全局推理所得的对齐证据反馈至嵌入学习阶段^[50],从而有效提升了实体对齐的精度与鲁棒性。ChatEA^[51]框架通过知识图谱-代码翻译模块将图谱结构转化为大语言模型可以理解的格式,利用大语言模型的丰富背景知识进行多轮对话式推理,并在两阶段对齐流程中降低对实体嵌入比较的依赖,显著提高了实体对齐任务的准确性。LGEA^[52]框架利用大语言模型对噪声进行感知、过滤并生成语义增强信息,在噪声较大的多模态对齐任务上取得了显著性能提升,验证了噪声感知策略在实体对齐中的有效性。

表 3 为本节所列不同实体对齐方法的优缺点对比。

表 3 不同实体对齐方法对比
Table 3 Comparison of different entity alignment methods

Method	Working Principle	Advantages	Disadvantages	References	Year	Publications/ conferences
Based on feature similarity calculations	Compute similarity scores for entity names, attribute values, structural features, etc., and set threshold matching criteria	Intuitive, highly interpretable, and relatively simple to calculate	Dependent on feature design and selection, difficult to capture deep semantics, sensitive to noise	Literature [35]	2002	KDD
				Literature [36]	2012	CIKM
				Literature [37]	2024	Engineering Applications of Artificial Intelligence
Based on machine learning	Use labeled data to train classification models and learn entity matching laws	Capable of automatically learning complex matching patterns, with superior generalization capabilities compared to rule-based approaches	Requires a large amount of labeled data, and model performance depends on feature engineering	Literature [38]	2001	Information Sciences
				Literature [39]	2002	KDD
Based on representation learning	Mapping entities to a low-dimensional vector space and judging equivalent entities by vector similarity	Can automatically capture structural and semantic information, reducing manual design and offering strong generalization capabilities	Poor interpretability, complex training, relies on negative sampling, and hyperparameter tuning	Literature [41]	2013	NeurIPS
				Literature [45]	2023	EMNLP
				Literature [51]	2024	ACL
				Literature [52]	2025	EMNLP

3.2 关系对齐

关系对齐是知识融合过程中继实体对齐之后的关键步骤。其核心任务是判定来自两个或多个异构知识图谱中的两个关系谓词是否在语义上指向现实世界中的同一种关联或属性。简单而言,关系对齐旨在解决“什么关系是同一个关系”的问题。只有同时完成高质量的实体对齐与关系对齐,才能将异构的知识图谱无缝集成为一个统一、一致的整体,从而支持有效的知识查询与推理。相较于实体对齐,关系对齐更依赖于结构信息与语义约束,在实现中常常面临以下挑战:一是关系粒度不一致,不同知识图谱中同一语义的关系可能以不同的标签或层次出现,例如,一个图谱使用广义关系“位于”,而另一个图谱使用更具体的“总部位于”或“出生地”;二是结构比较复杂,关系本身缺乏像实体名称那样直观的标识符,其语义高度依赖于所处的上下文;三是数据的稀疏性,某些关系在知识图谱中出现的实体对可能非常稀少,难以基于统计信息进行有效匹配。

为克服这些难点,近年来,部分研究者对关系对齐的方法进行了深入研究。文献[53]提出了一种用于多关系网络对齐的向量化关系图卷积网络模型(VR-GCN),该模型在图卷积过程中显式引入角色区分与平移属性,通过在图卷积过程中同时学习实体和关系的向量表示,实现了多关系网络的高精度实体与关系对齐。实验表明,该方法在实体、关系以及链接预测任务上均显著优于仅使用实体嵌入的基线。文献[54]提出了一种新的实体对齐联合学习框架,通过门控图卷积网络同时学习实体嵌入和基于实体嵌入近似的关系表示,该框架在 DBP15K 三语种数据集上实现了实体与关系对齐的双向提升,验证了“实体-关系相互促进”的假设。文献[55]在多语言知识图谱补全中采用多视图 GNN,实现统一的实体与关系对齐,实验表明对齐精度提升约 3%。

3.3 实体消歧

实体消歧是自然语言处理中的关键任务,旨在解决文本中同名实体的语义歧义问题。当一个实体指称项可能对应多个真实世界实体时,实体消歧通过上下文分析和知识匹配,确定其唯一语义指向。

3.3.1 基于全局和局部特征的实体消歧

局部特征基于实体提及的上下文独立消歧,方法简单高效,但忽略语义关联且易受数据稀疏性影响。全局特征则从文档整体出发,将消歧问题建模为一个优化问题,但该方法计算复杂度较高,且对文档中实体的语义一致性要求较高。目前,融合局部与全局特征的混合方法能显著提升消歧性能。

文献[56]提出了一种高效的大规模网络嵌入方法 Line,通过优化一个联合目标函数,同时保留了网络的局部和全局结构,然而 Line 主要针对静态网络,无法处理动态演化网络。文献[57]提出了一种新的集体实体链接神经模型 NCEL,该模型将图卷积网络引入集体实体链接,实现了局部与全局特征的端到端融合,同时引入注意力机制,提高了 NCEL 对数据噪声的鲁棒性,但其在计算效率、低资源实体处理及跨领域适应性上存在局限性。文献[58]将结构化梯度提升(SGTB)应用于集体实体消歧,实现了局部特征与全局一致性的高效融合,避免了传统结构化模型的复杂推理过程,提升了在大规模数据上的实用性,然而该方法高度依赖预构建的知识图谱且对复杂语义适应性较弱。

3.3.2 基于上下文特征的实体消歧

基于上下文特征的实体消歧是自然语言处理中的一个重要研究方向,其核心思想是利用实体提及周围的上下文信息来确定该提及所指代的正确实体。

针对短文本实体消歧任务中存在的语义表达不完整、上下文信息稀疏等问题,文献[59]构建了一种融入多视角注意力机制的神经网络模型,通过增强不同视角下实体提及的表征能力来捕获更丰富的特征信息,进而提升实体消歧任务的性能表现。文献[60]提出了一种新的融合多个关系的消歧网络模型 HRFAENE,该模型通过对网络结构和属性的多次学习,有效解决了有效信息利用不充分的问题。文献[61]创新性地提出了一种基于混合卷积网络(MCN)的解决方案,该模型结合了 CNN 和图卷积网络,以充分利用局部和全局语义信息,有效提高了短文本实体消歧的准确性,但该方法的性能受限于外部知识库的完整性,部分训练样本缺乏对应的实体标注。文献[62]聚焦实体遮蔽场景,提出一种去偏技术,该技术在训练阶段引入一种简单的约束,使模型在预测时不能仅依赖实体的出现频率或先验概率,而是必须利用上下文信息,该方法在不降低推理速度的情况下显著提升了对遮蔽实体的消歧能力。

3.3.3 基于字符串相似度的实体消歧

基于字符串相似度的实体消歧是一种通过量化文本中模糊的实体提及与知识图谱中候选实体名称之间的字符串匹配程度来解决实体歧义问题的技术。其核心目标是将具有多义性的实体提及精准映射到知识图谱中唯一对应的真实实体。

文献[63]提出了一种基于词和类别嵌入联合学习的 Category2Vec 嵌入模型,该模型能更精准地计

算词类别的相似性,有效提升了短文本实体消歧任务的性能表现。实验结果表明,该方法在缺乏充分上下文信息的情况下仍能保持较高的消歧准确率。文献[64]提出了一种面向中文命名实体消歧的多元相似度融合方法,该方法通过综合语义、上下文及主题等多个维度的相似性信息,有效提升了特定领域

环境下实体消歧的准确性。文献[65]提出了一种名为 3SA(Three-Step Affiliation)的实体链接方法,专门用于科研出版物中机构名称的消歧,该方法采用编辑距离作为字符串相似度度量,显著提升了复杂机构名称的匹配精度与效率。

表 4 为本节所列不同实体消歧方法的优缺点对比。

表 4 不同实体消歧方法对比

Table 4 Comparison of different entity disambiguation methods

Method	Working Principle	Advantages	Disadvantages	References	Year	Publications/ conferences
Based on global and local features	Integrate local context features and document-level global consistency features, achieve collective entity linking through graph model, joint inference and other algorithms, and pursue overall semantic consistency	Capable of leveraging the semantic association between entities, with high disambiguation accuracy and strong ability to model document-level overall semantic consistency	High computational complexity, slow inference speed, high requirements for semantic consistency of entities within documents, making it difficult to handle documents with sparse entities or scattered topics	Literature [56]	2015	WWW
				Literature [57]	2018	ACL
				Literature [58]	2018	NAACL
Based on contextual features	Depending on the local context information around the entity references, neural networks are used to encode the context with deep semantics and match it with the descriptions of candidate entities in the knowledge base to determine the target entity	The method is flexible, and the deep model can effectively capture complex semantics, with strong adaptability to short texts and specific contexts	Performance depends on the richness and quality of contextual information, degrades when context is sparse or ambiguous, and depends on the integrity of the external knowledge base	Literature [59]	2019	IEEE Access
				Literature [60]	2020	IEEE Access
				Literature [61]	2021	Journal of Chinese Information Processing
				Literature [62]	2024	EMNLP
Based on string similarity	By calculating the string similarity or shallow semantic similarity between the name of the entity reference item in the text and the candidate entity name in the knowledge base, the reference is connected to the most matching candidate entity	The method is simple and intuitive, with high computational efficiency, without complex models and large amounts of training data, and is suitable for scenarios with high speed requirements	It relies heavily on the literal matching of names, and cannot handle polysemy, abbreviations, aliases, etc. The accuracy rate is limited and the practicality is low	Literature [63]	2018	Expert Systems with Applications
				Literature [64]	2024	Data Analysis and Knowledge Discovery
				Literature [65]	2025	Scientometrics

3.4 冲突消解

在知识融合过程中,不同来源的知识可能存在冲突,例如同一体表的属性值不一致、同一对实体间的关系矛盾等。冲突消解是知识融合的最后一步,任务就是检测并解决这些知识冲突,确保融合后知识图谱的一致性和可靠性。

传统的冲突消解方法主要关注各种三元组的正确性及其数据源的可靠性,常采用基于规则的推理、概率推理、投票原则和机器学习算法来解决数据记录间的冲突。文献[66]提出了一套基于贝叶斯分析的模型,该模型通过估计数据源之间的复制依赖来同时检测依赖与发现真值,并在模型中进一步引入源的准确率和属性值的相似度进行细化。实验表明,该方法能够显著提升真值发现的准确率,且在源数量大幅增加时仍保持良好的可扩展性。文献[67]

提出一种用于数据融合的框架 SLiMFAST,该框架将数据融合建模为判别式逻辑回归问题,结合源冲突与领域特征,并通过 EM 算法与基于少量标注的 ERM 自动选择学习算法,从而在有限训练数据下实现对真实值的高精度预测和对源可靠性的低误差估计。以上方法在解决冲突时主要集中在判断哪个来源提供了真实的信息,而很少考虑数据结构的特征,很难处理外部三元组,特别是看不见的实体,忽略了冲突检测。为解决上述限制,文献[68]提出了一种将冲突检测与大语言模型相结合的创新方法 CRDL。该方法首先利用预训练模型检测三元组之间的冲突,然后引入大语言模型进行深度推理以消解冲突,通过将冲突消解构建为自然语言任务,大语言模型能够灵活运用其丰富的常识和上下文理解能力,判断冲突事实的可信度并选择最优解,显著提高

了复杂冲突求解的准确性。

当前,冲突消解技术正经历从依赖数据源可靠性评估向融合深度语义理解与推理的转变。传统方法(如贝叶斯分析或逻辑回归)虽具备良好的可解释性,但在处理复杂语义冲突时表现有限;而结合大语言模型的冲突消解方法则展现出强大的常识推理与上下文理解能力,能够灵活应对多源异构知识中的复杂矛盾。未来,融合符号推理与神经语义模型的混合方法,将是提升冲突消解自动化与精准度的重要方向。

4 知识推理

知识推理是提升知识图谱认知能力和应用价值的核心技术。受限于数据源的不完备性和信息抽取技术的局限性,构建的知识图谱往往存在知识缺失。知识推理旨在利用图谱中已有的显性知识,通过逻辑推导、模式挖掘、关系路径分析等方式,发现并补充图谱中隐含、未直接陈述的知识。这不仅能够丰富和扩展知识图谱的内容,还能支持更复杂的智能应用,如深度问答、复杂决策支持等。知识图谱上的推理方法主要包括基于逻辑规则的推理方法、基于表示学习的推理方法和基于深度学习的推理方法。

知识图谱推理方法的技术演进的内在驱动力源于对可解释性、可扩展性及复杂语义建模能力三者间平衡的持续追求。早期基于逻辑规则的方法虽具备强可解释性,但依赖专家手动构建,难以适应大规模知识图谱的扩展需求。为突破这一局限,基于表示学习的推理通过将实体与关系嵌入向量空间实现高效计算,显著提升了扩展性与泛化能力,但在处理深层语义关联时存在短板。近年来,基于深度学习的方法进一步兴起,旨在利用神经网络的强大拟合能力,直接建模知识间复杂的非线性交互与路径依赖,以解决前两者在应对多跳推理、动态图谱等复杂场景时的不足。

4.1 基于逻辑规则的推理方法

基于逻辑规则的推理的核心在于通过形式化的逻辑体系进行知识的表示和推理。这种规则的结构通常包括前提条件和结果,类似于 if-then 语句。例如,规则可以表示为:如果 A 与 B 有关系,B 与 C 有关系,那么可以推断 A 与 C 有关系。基于逻辑规则的推理方式具备清晰明确的特性与可解释的优势,因此在知识图谱研究的初期阶段受到广泛采用。文献[69]提出的一阶归纳学习方法通过引入大量开放领域的事实,从事实集合中学习推理规则,并将其应用于查找用户查询的答案。文献[70]开发了一种专门为支持开放世界假设场景而定制的规则挖掘模

型,并引入了一种新的置信度量方法,实现了对大规模、开放世界知识库的快速、可扩展且高质量的逻辑规则挖掘。基于逻辑规则的推理方法因其简洁性和高效性,在处理小型知识图谱时表现出色,然而在面对大型知识图谱时,随着规则的数量和复杂度的增加,推理的效率会下降。

4.2 基于表示学习的推理方法

基于表示学习的推理方法的核心在于将知识图谱中的实体和关系转化为低维稠密的向量表示,通过向量空间的代数运算实现逻辑推理,避免显式规则依赖。众多研究者提出了丰富的基于表示学习的推理方法,包括基于张量分解^[71-73]、距离模型^[74-76]、语义匹配^[77-79]和多元信息模型^[80-82]等。知识图谱中基于表示学习的推理方法能够高效处理大规模知识图谱,自动捕捉潜在语义关系,并具备较强的泛化能力,尤其适合链接预测等任务。同时,这类方法无需人工设计复杂规则,降低了领域知识依赖。但该方法的向量化表示缺乏可解释性,难以追溯推理过程。另外,基于表示学习的推理对复杂逻辑的建模能力有限,且严重依赖训练数据的质量和覆盖度,在稀疏或动态更新的知识图谱中性能可能会下降。

4.3 基于深度学习的推理方法

近年来,基于深度学习的知识图谱推理方法取得了显著进展,其主要思想是将实体和关系映射到低维连续向量空间,通过神经网络建模它们的交互模式。典型方法包括基于 CNN^[83-85]、基于 RNN^[86-87]、基于强化学习的神经网络^[88-90]和基于 GNN^[91-93]。这些方法能够自动学习知识图谱中的潜在语义和结构特征,并通过向量运算模拟逻辑推理过程,从而有效支持链接预测、实体分类等任务。与传统的基于规则或统计的方法相比,基于深度学习的推理方法在处理大规模知识图谱和复杂语义关系时表现出显著的优势。文献[94]提出了一个四元组提及文本增强的时序知识图谱推理模型 QMmod。该模型首先在 NOW 语料库中抽取每条四元组的自然语言提及文本,利用基于 BERT 的文本编码器获得语义表示,并将其与图结构表示进行联合融合,从而提升实体和关系的表征能力。文献[95]提出了面向基于 GNN 的知识图谱补全模型的路径式解释框架 Power-Link。该框架在实体对之间并行搜索所有可行路径,结合模型梯度与边得分每条路径计算重要性分数,进而挑选出若干高置信度的关键路径作为解释,从而为知识图谱补全提供简洁、直观且高效的路径式推理解释。文献[96]在知识图谱补全任务中系统化地引入多概念

表示与跨概念交叉注意力,将概念层语义与图结构深度融合,实现了结构信息与语义概念的协同增强,在多概念稀疏场景下显著提升了知识图谱补全的准确性。但这些模型通常具有较高的复杂度,导致训

练和推理成本较高,对计算资源的要求也更为严格,并且性能高度依赖训练数据的质量和覆盖范围。

表 5 为本节所列不同知识图谱推理方法的优缺点对比。

表 5 不同知识图谱推理方法对比

Table 5 Comparison of different KG reasoning methods

Method	Working Principle	Advantages	Disadvantages	References	Year	Publications/ conferences
Based on logical rules	Reasoning using predefined logical rules, deriving new knowledge through rule matching and deduction	It is highly interpretable and can capture the hidden semantic information in the KG	Unable to solve data sparsity problems, unable to handle multi-hop inference problems well, and have limited generalization ability	Literature [69]	2010	EMNLP
				Literature [70]	2013	WWW
Based on representation learning	Transform entities and relationships in the KG into low-dimensional dense vector representations, and realize logical reasoning through algebraic operations in vector spaces	No need to manually design complex rules, solves the problem of data sparsity, and has strong generalization ability	Poor interpretability, heavy reliance on the quality and coverage of training data, and limited ability to model complex logic	Literature [75]	2018	EMNLP
				Literature [76]	2019	AAAI
				Literature [81]	2019	NeurIPS
Based on deep learning	Mapping entities and relationships into low-dimensional continuous vector spaces and modeling their interaction patterns through neural networks	Ability to handle large-scale KGs and complex semantic relationships	The demand for labeled data is large, the model complexity is relatively high, and the interpretability is poor	Literature [94]	2024	Engineering Applications of Artificial Intelligence
				Literature [95]	2024	KDD
				Literature [96]	2025	Applied Intelligence

5 典型知识图谱构建案例分析

为将理论技术与实际应用相结合,本章遴选 2 个具有代表性的知识图谱案例,分析其构建技术路线,并对照本文所述的技术分类进行梳理。

5.1 DBpedia

DBpedia 是从维基百科中抽取结构化知识构建的通用知识图谱,旨在为语义网提供基础数据支撑。其构建过程采用自顶向下与自底向上相结合的模式。

在信息抽取环节,DBpedia 采用基于规则的抽取方法,充分利用维基百科自身的结构化设计,以轻量、高效的规则化方法为主,无需依赖复杂的深度学习模型。其中,实体抽取聚焦维基百科页面的“信息框”与“分类标签”两大核心模块,通过预设的字典库匹配人物、地点、机构等实体类型,并结合正则表达式对实体名称进行规范化处理,例如将“爱因斯坦”“A. Einstein”统一规整为“阿尔伯特·爱因斯坦”;关系抽取则直接基于“信息框”内的属性-值对模板,自动转化为“实体-关系-实体”三元组,以“爱因斯坦”页面为例,从“出生地”属性中可直接提取<爱因

斯坦,出生地,乌尔姆>这一核心关系;属性抽取同样依托“信息框”完成,无需额外处理逻辑,例如从页面中直接获取<爱因斯坦,出生日期,1879 年 3 月 14 日>、<爱因斯坦,职业,物理学家>等属性-值对,这种方式的高效性完全得益于维基百科数据本身较高的结构化程度。

在知识融合环节,DBpedia 的核心需求聚焦于跨语言实体对齐与少量数据冲突消解两大任务。由于其数据覆盖全球多语言维基百科版本,因此跨语言实体对齐成为该环节的核心挑战,DBpedia 采用前文第 3.1.1 节所述的“基于特征相似度计算的实体对齐方法”,具体通过“字符串相似度校验+核心属性匹配”的双重验证策略实现精准对齐。首先,利用编辑距离、余弦相似度等算法,量化比对不同语言版本实体名称的文本相似性;随后,结合实体的核心属性进行一致性校验,进一步确认不同语言实体指向同一现实对象,有效规避仅依赖名称匹配可能产生的歧义问题。在实体消歧方面,采用前文第 3.3.1 节“基于局部特征+全局一致性的方法”,依托维基百科自带的结构化信息实现高效消歧。在冲突消解方面,DBpedia 采用前文第 3.4 节所述的“基

于规则的冲突消解方法”。由于其数据源高度集中于维基百科单一平台,而非多源异构数据聚合,数据冲突发生率较低,冲突类型也以“信息更新时序差异”为主,针对这类常规冲突,DBpedia 直接采用“取最新编辑版本”的规则化策略,自动同步数据更新状态,确保属性值的时效性。对涉及事实性争议的内容,则参考维基百科标注的权威来源进行人工辅助裁定,最大程度地降低了冲突数据对知识质量的影响。

在知识推理环节,DBpedia 以“补全基础关系、保障知识完整性”为目标,采用前文第 4.1 节综述的“基于逻辑规则的推理方法”,通过人工定义一系列符合本体逻辑的推理规则,例如“若实体 A 是实体 B 的父亲,且实体 B 是实体 C 的父亲,则实体 A 是实体 C 的祖父”等,随后通过 Jena 规则引擎加载这些规则,对已有的三元组数据进行批量推理,自动补全缺失的关系链路,有效提升了知识图谱的关系密度与完整性。

5.2 百度知识图谱

百度知识图谱是中国领先的中文知识图谱,其核心目标是提升百度搜索、智能问答、信息流推荐等产品的理解与推理能力。其构建过程采用数据驱动的底自向上构建模式。

在信息抽取环节,百度知识图谱采用基于深度学习和大语言模型的抽取方法,突破了单一数据源限制,构建了多源数据的全方位抽取体系,且深度适配中文场景特性。其中:实体抽取以“深度学习+大语言模型”为核心技术底座,采用 BERT+BiLSTM-CRF 的经典组合模型,从网页正文、新闻报道、垂直领域网站中精准识别实体;关系抽取则依托百度自研的预训练大语言模型 ERNIE,通过“微调+提示学习”的双重优化,解决非结构化文本中关系隐含性、歧义性问题,同时支持少样本场景,仅需少量标注样本即可实现关系抽取能力迁移;属性抽取进一

步融合多源数据类型,不仅从结构化数据中直接获取明确属性值,还通过深度学习模型从非结构化文本、图片甚至语音数据中挖掘隐性属性。

在知识融合环节,百度知识图谱需处理海量异构数据的整合与矛盾消解,技术方案聚焦“精准对齐”与“高效冲突处理”两大目标。在实体对齐方面,采用前文第 3.1.3 节所述的基于表示学习的方法,针对跨来源、跨领域、跨语言的复杂对齐场景,构建了“GNN+预训练模型”的融合框架,实现多特征维度的实体匹配;在关系对齐方面,依托百度自主研发的统一知识本体,将不同数据源中的关系、属性名称映射到标准本体体系,确保跨源知识的一致性;在实体消歧方面,主要采用前文第 3.3.2 节所述的基于上下文特征的深度学习方法,通过利用其强大的语义表示模型,在复杂语境下实现精准消歧;在冲突消解方面,采用前文第 3.4 节所述的基于机器学习的方法,构建了“机器学习模型+领域规则”的双层冲突消解机制,具体来说,先通过基于 XGBoost 的可信度评估模型,对同一实体的冲突属性值进行打分,初步筛选出高置信度候选值,再结合领域专属规则进行最终裁定,有效避免了纯数据驱动方法在专业领域可能出现的偏差。

在知识推理环节,百度知识图谱以“支撑搜索引擎实时服务”为导向,采用“表示学习+深度学习推理”的混合方案,平衡推理精度与响应速度。一方面,基于 TransE 改进的知识图谱嵌入模型,对缺失的实体关系进行补全;另一方面,通过 GNN 实现多跳推理,满足搜索场景的关联推荐需求。同时,百度采用自主研发的分布式推理引擎,将推理任务拆解到多节点并行处理,确保在大规模知识图谱下仍能实现毫秒级推理响应,满足搜索引擎的实时服务要求。

表 6 为本节所介绍的两种典型知识图谱构建技术路线对比。

表 6 典型知识图谱构建技术路线对比

Table 6 Comparison of typical KG construction technology link

Core Technology Link		DBpedia	Baidu KG
Build pattern	Top down and bottom up		Data-driven bottom-up pattern
Information extraction	Methods based on rule extraction		Methods based on deep learning and LLMs
Knowledge fusion	Entity alignment: methods based on feature similarity		Entity alignment: methods based on representation learning
	Conflict resolution: methods based on the rule		Conflict resolution: methods based on machine learning
	Entity disambiguation: methods based on local features and global consistency		Entity disambiguation: deep learning methods based on contextual features
Knowledge reasoning	Methods based on logical rules		Methods based on representation learning and deep learning
Core technical features	Low cost, high stability, relying on Wikipedia's structured data and rule-based technology as the primary approach		Strong generalization ability, deep learning and multi-source fusion as the core

6 结束语

知识图谱作为结构化知识表示与智能应用的核心载体,其构建技术的发展始终围绕“从数据到知识、从知识到智能”的核心目标展开。本文系统梳理了知识图谱构建的关键环节,从信息抽取中实体与关系的精准识别,到知识融合中异构知识的对齐与消歧,再到知识推理中隐含关联的挖掘与补全,各环节技术均经历了从规则驱动到数据驱动、从单一模型到多方法融合的演进过程。在知识图谱的构建过程中,如何从海量异构数据中高效、准确地提取知识,是当前研究的重点和难点。尽管已有研究在知识图谱的表示、推理和应用方面取得了显著进展,但仍面临数据质量、知识表示的语义一致性、知识图谱的动态更新与维护等挑战。随着技术的持续突破,知识图谱将进一步打破数据壁垒,为认知智能的实现提供坚实的知识基础,在人机协同、智能决策等领域发挥更深远的作用,推动人工智能从“感知”向“理解”与“推理”跨越。

参考文献

- [1] SINGHAL A. Introducing the knowledge graph: things, not strings [EB/OL]. [2025-07-19]. <https://blog.google/products/search/introducing-knowledge-graph-things-not-strings/>.
- [2] Wikipedia. Knowledge graph [EB/OL]. [2025-07-19]. https://en.wikipedia.org/wiki/Knowledge_Graph.
- [3] 徐增林, 盛泳潘, 贺丽荣, 等. 知识图谱技术综述[J]. 电子科技大学学报, 2016, 45(4): 589-606.
XU Z L, SHENG Y P, HE L R, et al. Review on knowledge graph techniques [J]. Journal of University of Electronic Science and Technology of China, 2016, 45(4): 589-606. (in Chinese)
- [4] DONG X, GABRILOVICH E, HEITZ G, et al. Knowledge vault: a Web-scale approach to probabilistic knowledge fusion[C]// Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2014: 601-610.
- [5] HOBBS J R, APPELT D, BEAR J, et al. Fastus: a system for extracting information from natural-language text[C]// Proceedings of the 4th Message Understanding Conference. Washington D.C., USA: IEEE Press, 1992: 29-32.
- [6] KIM J H, WOODLAND P C. A rule-based named entity recognition system for speech input[C]// Proceedings of the 6th International Conference on Spoken Language Processing (ICSLP 2000). [S. l.]: ISCA, 2000: 528-531.
- [7] LIU X H, ZHANG S D, WEI F R, et al. Recognizing named entities in Tweets [C]// Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies. Portland, USA: Association for Computational Linguistics, 2011: 359-367.
- [8] 何炎祥, 罗楚威, 胡彬尧. 基于 CRF 和规则相结合的地理命名实体识别方法[J]. 计算机应用与软件, 2015, 32(1): 179-185, 202.
HE Y X, LUO C W, HU B Y. Geographic entity recognition method based on CRF model and rules combination [J]. Computer Applications and Software, 2015, 32(1): 179-185, 202. (in Chinese)
- [9] LAMPLE G, BALLESTEROS M, SUBRAMANIAN S, et al. Neural architectures for named entity recognition[C]// Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. San Diego, USA: Association for Computational Linguistics, 2016: 260-270.
- [10] DONG X S, QIAN L J, GUAN Y, et al. A multiclass classification method based on deep learning for named entity recognition in electronic medical records[C]// Proceedings of the New York Scientific Data Summit (NYSDS). Washington D.C., USA: IEEE Press, 2016: 1-10.
- [11] PENG N Y, DREDZE M. Improving named entity recognition for Chinese social media with word segmentation representation learning[C]// Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Berlin, Germany: Springer, 2016: 149-155.
- [12] 尹光花, 陈鹏. 基于双向 LSTM 模型的中文命名实体识别[J]. 信息技术与信息化, 2021(10): 44-46.
YIN G H, CHEN P. Chinese named entity recognition based on bidirectional LSTM model [J]. Information Technology and Informatization, 2021(10): 44-46. (in Chinese)
- [13] 封红旗, 孙杨, 杨森, 等. 基于 BERT 的中文电子病历命名实体识别[J]. 计算机工程与设计, 2023, 44(4): 1220-1227.
FENG H Q, SUN Y, YANG S, et al. Chinese electronic medical record named entity recognition based on BERT methods [J]. Computer Engineering and Design, 2023, 44(4): 1220-1227. (in Chinese)
- [14] 王为国. 基于 BERT 的命名实体识别研究[D]. 广州: 广州大学, 2021.
WANG W G. Research on named entity recognition based on BERT [D]. Guangzhou: Guangzhou University, 2021. (in Chinese)
- [15] 陈琛, 刘小云, 方玉华. 融合注意力机制的电子病历命名实体识别[J]. 计算机技术与发展, 2020, 30(10): 216-220.
CHEN C, LIU X Y, FANG Y H. Named entity recognition in electronic medical record introducing attention mechanisms [J]. Computer Technology and Development, 2020, 30(10): 216-220. (in Chinese)
- [16] 姜因, 庞永恒, 高爽. 基于注意力机制语谱图特征提取的语音识别[J]. 吉林大学学报(理学版), 2024, 62(2): 320-330.
JIANG N, PANG Y H, GAO S. Speech recognition based on attention mechanism and spectrogram feature extraction [J]. Journal of Jilin University (Science Edition), 2024, 62(2): 320-330. (in Chinese)
- [17] GUI T, MA R T, ZHANG Q, et al. CNN-based Chinese NER with lexicon rethinking [C]// Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, China: International Joint Conferences on Artificial Intelligence Organization, 2019: 4982-4988.
- [18] 颜士军, 朱红梅, 王雅童, 等. 基于字词融合和注意力机制的兽药文本命名实体识别[J]. 中国农机化学报, 2025, 46(3): 336-342, 352.
YAN S J, ZHU H M, WANG Y T, et al. Named entity recognition of veterinary drug text based on character and word fusion and attention mechanism [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(3): 336-342, 352. (in Chinese)
- [19] WU C X, KE W J, WANG P, et al. ConsistNER: towards instructive NER demonstrations for LLMs with the consistency of ontology and context [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2024: 19234-19242.
- [20] ZHU X Y, DAI F F, GU X Y, et al. GL-NER: generation-aware large language models for few-shot named entity recognition [C]// Proceedings of the 2024 International

- Conference on Artificial Neural Networks and Machine Learning, Berlin, Germany: Springer, 2024: 433-448.
- [21] ZHANG Z, ZHAO Y H, GAO H, et al. LinkNER: linking local named entity recognition models to large language models using uncertainty[C]//Proceedings of the ACM Web Conference 2024. New York, USA: ACM Press, 2024: 4047-4058.
- [22] RILOFF E. Automatically constructing a dictionary for information extraction tasks[C]//Proceedings of the 11th National Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 1993: 811-816.
- [23] BOLLEGALA D T, MATSUO Y, ISHIZUKA M. Relational duality: unsupervised extraction of semantic relations between entities on the Web[C]//Proceedings of the 19th International Conference on World Wide Web. New York, USA: ACM Press, 2010: 151-160.
- [24] KAMBHATLA N. Combining lexical, syntactic, and semantic features with maximum entropy models for information extraction[C]//Proceedings of the ACL 2004 on Interactive Poster and Demonstration Sessions. Philadelphia, USA: Association for Computational Linguistics, 2004: 178-181.
- [25] SUN L, HAN X P. A feature-enriched tree kernel for relation extraction[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Philadelphia, USA: Association for Computational Linguistics, 2014: 61-67.
- [26] ZHOU P, SHI W, TIAN J, et al. Attention-based bidirectional long short-term memory networks for relation classification[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Philadelphia, USA: Association for Computational Linguistics, 2016: 207-212.
- [27] SAHU S K, CHRISTOPOULOU F, MIWA M, et al. Inter-sentence relation extraction with document-level graph convolutional neural network[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Philadelphia, USA: Association for Computational Linguistics, 2019: 4309-4316.
- [28] LI J Z. Hyperbolic graph convolutional network relation extraction model combining dependency syntax and contrastive learning[J]. International Journal of Computational Intelligence Systems, 2025, 18(1): 18.
- [29] CHEN X, ZHANG N Y, XIE X, et al. KnowPrompt: knowledge-aware prompt-tuning with synergistic optimization for relation extraction[C]//Proceedings of the ACM Web Conference 2022. New York, USA: ACM Press, 2022: 2778-2788.
- [30] WADHWA S, AMIR S, WALLACE B. Revisiting relation extraction in the era of large language models[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Philadelphia, USA: Association for Computational Linguistics, 2023: 15566-15589.
- [31] ZHOU S Z, MENG Y, JIN B W, et al. Grasping the essentials: tailoring large language models for zero-shot relation extraction[C]//Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2024: 13462-13486.
- [32] HU M Q, LIU B. Mining and summarizing customer reviews[C]//Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2004: 168-177.
- [33] MUKHERJEE A, LIU B. Aspect extraction through semi-supervised modeling[C]//Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Philadelphia, USA: Association for Computational Linguistics, 2012: 339-348.
- [34] 苏明星, 吴厚月, 李健, 等. 基于多层交互注意力机制的商品属性抽取[J]. 数据分析与知识发现, 2023, 7(2): 108-118.
- SU M X, WU H Y, LI J, et al. AEMIA: extracting commodity attributes based on multi-level interactive attention mechanism[J]. Data Analysis and Knowledge Discovery, 2023, 7(2): 108-118. (in Chinese)
- [35] COHEN W W, RICHMAN J. Learning to match and cluster large high-dimensional data sets for data integration[C]//Proceedings of the 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2002: 475-480.
- [36] NIU X, RONG S, WANG H F, et al. An effective rule miner for instance matching in a Web of data[C]//Proceedings of the 21st ACM International Conference on Information and Knowledge Management. New York, USA: ACM Press, 2012: 1085-1094.
- [37] YAN Z H, PENG R, WU H Y. Similarity propagation based semi-supervised entity alignment[J]. Engineering Applications of Artificial Intelligence, 2024, 130: 107787.
- [38] COCHINWALA M, KURIEN V, LALK G, et al. Efficient data reconciliation[J]. Information Sciences, 2001, 137(1/2/3/4): 1-15.
- [39] SARAWAGI S, BHAMIDIPATY A. Interactive deduplication using active learning[C]//Proceedings of the 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2002: 269-278.
- [40] ZHANG C X, YANG X Z, WANG S L, et al. A multi-view fusion approach for entity alignment[C]//Proceedings of the IEEE 16th International Conference on Cognitive Informatics & Cognitive Computing. Washington D. C., USA: IEEE Press, 2017: 388-393.
- [41] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems. South Lake Tahoe, USA: Curran Associates Inc., 2013: 2787-2795.
- [42] CHEN M H, TIAN Y T, CHANG K W, et al. Co-training embeddings of knowledge graphs and entity descriptions for cross-lingual entity alignment[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden: International Joint Conferences on Artificial Intelligence Organization, 2018: 3998-4004.
- [43] LIN Y K, LIU Z Y, SUN M S, et al. Learning entity and relation embeddings for knowledge graph completion[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2015: 2181-2187.
- [44] WANG Z C, LÜ Q S, LAN X H, et al. Cross-lingual knowledge graph alignment via graph convolutional networks[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2018: 349-357.
- [45] XIE F, SONG X, ZENG X, et al. MixTEA: semi-supervised entity alignment with mixture teaching[C]//Proceedings of the Findings of the Association for Computational Linguistics: EMNLP 2023. Philadelphia, USA: Association for Computational Linguistics, 2023: 886-896.
- [46] LIU B, LAN T C, HUA W, et al. Dependency-aware self-training for entity alignment[C]//Proceedings of the 16th ACM International Conference on Web Search and Data Mining. New York, USA: ACM Press, 2022: 796-804.
- [47] LIU X K, ZHANG K, LIU Y, et al. RHGN: relation-gated heterogeneous graph network for entity alignment in

- knowledge graphs [C] // Proceedings of the Findings of the Association for Computational Linguistics: ACL 2023. Philadelphia, USA: Association for Computational Linguistics, 2023: 8683-8696.
- [48] TANG J H, ZHAO K F, LI J. A fused Gromov-Wasserstein framework for unsupervised knowledge graph entity alignment [C] // Proceedings of the Findings of the Association for Computational Linguistics: ACL 2023. Philadelphia, USA: Association for Computational Linguistics, 2023: 3320-3334.
- [49] MAO X, WANG W T, WU Y B, et al. From alignment to assignment: frustratingly simple unsupervised entity alignment [C] // Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2021: 2843-2853.
- [50] XIN K X, SUN Z Q, HUA W, et al. Informed multi-context entity alignment [C] // Proceedings of the 15th ACM International Conference on Web Search and Data Mining. New York, USA: ACM Press, 2022: 1197-1205.
- [51] JIANG X H, SHEN Y H, SHI Z C, et al. Unlocking the power of large language models for entity alignment [C] // Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Philadelphia, USA: Association for Computational Linguistics, 2024: 7566-7583.
- [52] LU C L, LI C X, CHENG J W, et al. Breaking the noise barrier: LLM-guided semantic filtering and enhancement for multi-modal entity alignment [C] // Proceedings of the 2025 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2025: 33153-33167.
- [53] YE R, LI X, FANG Y J, et al. A vectorized relational graph convolutional network for multi-relational network alignment [C] // Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, China: International Joint Conferences on Artificial Intelligence Organization, 2019: 4135-4141.
- [54] WU Y T, LIU X, FENG Y S, et al. Jointly learning entity and relation representations for entity alignment [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). Philadelphia, USA: Association for Computational Linguistics, 2019: 240-249.
- [55] DONG B B, BU C Y, ZHU Y, et al. Simplified multi-view graph neural network for multilingual knowledge graph completion [J]. *Frontiers of Computer Science*, 2025, 19(7): 197324.
- [56] TANG J, QU M, WANG M Z, et al. LINE: large-scale information network embedding [C] // Proceedings of the 24th International Conference on World Wide Web. Florence, Italy: International World Wide Web Conferences Steering Committee, 2015: 1067-1077.
- [57] CAO Y X, HOU L, LI J Z, et al. Neural collective entity linking [C] // Proceedings of the 27th International Conference on Computational Linguistics. Santa Fe, USA: Association for Computational Linguistics, 2018: 675-686.
- [58] YANG Y, IRSOY O, RAHMAN K S. Collective entity disambiguation with structured gradient tree boosting [C] // Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers). New Orleans, USA: Association for Computational Linguistics, 2018: 777-786.
- [59] WANG C Z, SUN X, YU H F, et al. Entity disambiguation leveraging multi-perspective attention [J]. *IEEE Access*, 2019, 7: 113963-113974.
- [60] DENG C H, DENG H F, LI C R. A scholar disambiguation method based on heterogeneous relation-fusion and attribute enhancement [J]. *IEEE Access*, 2020, 8: 28375-28384.
- [61] 姜丽婷, 古丽拉·阿东别克, 马雅静. 基于混合卷积网络的短文本实体消歧 [J]. *中文信息学报*, 2021, 35(11): 101-108.
- JIANG L T, Gulila Altenbek, MA Y J. Mixed convolution network based entity disambiguation for short text [J]. *Journal of Chinese Information Processing*, 2021, 35(11): 101-108. (in Chinese)
- [62] TASAWONG P, LIMKONCHOTIWAT P, MANAKUL P, et al. Efficient overshadowed entity disambiguation by mitigating shortcut learning [C] // Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2024: 15313-15321.
- [63] ZHU G G, IGLESIAS C A. Exploiting semantic similarity for named entity disambiguation in knowledge graphs [J]. *Expert Systems with Applications*, 2018, 101: 8-24.
- [64] 石水倩, 金晶, 沈耕宇, 等. 基于多元相似度融合的中文命名实体消歧方法 [J]. *数据分析与知识发现*, 2024, 8(2): 56-64.
- SHI S Q, JIN J, SHEN G Y, et al. Chinese named entity disambiguation based on multivariate similarity fusion [J]. *Data Analysis and Knowledge Discovery*, 2024, 8(2): 56-64. (in Chinese)
- [65] MUÑOZ-JORDÁN D, RUIZ G, CABRIADA P, et al. 3SA: an entity-linking algorithm for the institution name disambiguation problem in affiliations using edit distance [J]. *Scientometrics*, 2025, 130(7): 4073-4091.
- [66] DONG X L, BERTI-EQUILLE L, SRIVASTAVA D. Integrating conflicting data: the role of source dependence [J]. *Proceedings of the VLDB Endowment*, 2009, 2(1): 550-561.
- [67] REKATSINAS T, JOGLEKAR M, GARCIA-MOLINA H, et al. SLiMFAST: guaranteed results for data fusion and source reliability [C] // Proceedings of the 2017 ACM International Conference on Management of Data. New York, USA: ACM Press, 2017: 1399-1414.
- [68] PENG H, ZHANG P F, TANG J Y, et al. Detect-then-resolve: enhancing knowledge graph conflict resolution with large language model [J]. *Mathematics*, 2024, 12(15): 2318.
- [69] SCHOENMACKERS S, DAVIS J, ETZIONI O, et al. Learning first-order horn clauses from Web text [C] // Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: Association for Computational Linguistics, 2010: 1088-1098.
- [70] GALÁRRAGA L A, TEFLIUDI C, HOSE K, et al. AMIE: association rule mining under incomplete evidence in ontological knowledge bases [C] // Proceedings of the 22nd International Conference on World Wide Web. New York, USA: ACM Press, 2013: 413-422.
- [71] NICKEL M, TRESP V, KRIEGER H P. A three-way model for collective learning on multi-relational data [C] // Proceedings of the International Conference on Machine Learning. Bellevue, USA: Omnipress, 2011: 809-816.
- [72] NICKEL M, TRESP V, KRIEGER H P. Factorizing YAGO: scalable machine learning for linked data [C] // Proceedings of the 21st International Conference on World Wide Web. New York, USA: ACM Press, 2012: 271-280.
- [73] WU Y B, ZHU D H, LIAO X W, et al. Knowledge graph reasoning based on paths of tensor factorization [J]. *Pattern Recognition and Artificial Intelligence*, 2017, 30(5): 473-480.
- [74] TRIVEDI R S, DAI H J, WANG Y C, et al. Know-evolve: deep temporal reasoning for dynamic knowledge graphs [C] //

- Proceedings of the International Conference on Machine Learning, Sydney, Australia: JMLR, 2017: 3462-3471.
- [75] DASGUPTA S S, RAY S N, TALUKDAR P. HyTE: hyperplane-based temporally aware knowledge graph embedding [C] // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Philadelphia, USA: ACL Press, 2018: 2001-2011.
- [76] CHEN X L, CHEN M H, SHI W J, et al. Embedding uncertain knowledge graphs [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2019: 3363-3370.
- [77] BORDES A, GLOTOT X, WESTON J, et al. A semantic matching energy function for learning with multi-relational data [J]. Machine Learning, 2014, 94(2): 233-259.
- [78] NICKEL M, ROSASCO L, POGGIO T. Holographic embeddings of knowledge graphs [C] // Proceedings of the 30th AAAI Conference on Artificial Intelligence. Menlo Park, USA: AAAI Press, 2016: 1955-1961.
- [79] TROUILLON T, DANCE C R, WELBL J, et al. Knowledge graph completion via complex tensor factorization [J]. Journal of Machine Learning Research, 2017, 18(1): 4735-4772.
- [80] WANG Z G, LI J Z. Text-enhanced representation learning for knowledge graph [C] // Proceedings of the 25th International Joint Conference on Artificial Intelligence. Menlo Park, USA: AAAI Press, 2016: 1293-1299.
- [81] QU M, TANG J. Probabilistic logic neural networks for reasoning [C] // Proceedings of the 33rd Conference on Neural Information Processing Systems. Red Hook, USA: Curran Associates Inc., 2019: 7712-7722.
- [82] ZHANG W, PAUDEL B, WANG L, et al. Iteratively learning embeddings and rules for knowledge graph reasoning [C] // Proceedings of the World Wide Web Conference. New York, USA: ACM Press, 2019: 2366-2377.
- [83] TAY Y, TUAN L A, PHAN M C, et al. Multi-task neural network for non-discrete attribute prediction in knowledge graphs [C] // Proceedings of the 2017 ACM Conference on Information and Knowledge Management. New York, USA: ACM Press, 2017: 1029-1038.
- [84] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2D knowledge graph embeddings [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2018: 1811-1818.
- [85] LI S J, CHEN S D, OUYANG X Y, et al. Joint learning based on multi-shaped filters for knowledge graph completion [J]. High Technology Letters, 2021, 27(1): 43-52.
- [86] NEELAKANTAN A, ROTH B, MCCALLUM A. Compositional vector space models for knowledge base completion [C] // Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Philadelphia, USA: ACL Press, 2015: 156-166.
- [87] GUO L B, ZHANG Q H, GE W Y, et al. DSKG: a deep sequential model for knowledge graph completion [C] // Proceedings of 2018 China Conference on Knowledge Graph and Semantic Computing. Singapore: Springer, 2018: 65-77.
- [88] LI Z X, JIN X L, GUAN S P, et al. Path reasoning over knowledge graph: a multi-agent and reinforcement learning based method [C] // Proceedings of the IEEE International Conference on Data Mining Workshops (ICDMW). Washington D.C., USA: IEEE Press, 2018: 929-936.
- [89] WANG Q, JI Y D, HAO Y S, et al. GRL: knowledge graph completion with GAN-based reinforcement learning [J]. Knowledge-Based Systems, 2020, 209: 106421.
- [90] TIWARI P, ZHU H Y, PANDEY H M. DAPath: distance-aware knowledge graph reasoning based on deep reinforcement learning [J]. Neural Networks, 2021, 135: 1-12.
- [91] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks [C] // Proceedings of the 15th International Conference on the Semantic Web. Berlin, Germany: Springer, 2018: 593-607.
- [92] BANSAL T, JUAN D C, RAVIS, et al. A2N: attending to neighbors for knowledge graph inference [C] // Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Philadelphia, USA: Association for Computational Linguistics 2019: 4387-4392.
- [93] TERU K K, DENIS E, HAMILTON W L. Inductive relation prediction by subgraph reasoning [C] // Proceedings of the International Conference on Machine Learning. New York, USA: PMLR, 2020: 9448-9457.
- [94] ZHU L, ZHAO W J, BAI L Y. Quadruple mention text-enhanced temporal knowledge graph reasoning [J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108058.
- [95] CHANG H, YE J N, LOPEZ-AVILA A, et al. Path-based explanation for knowledge graph completion [C] // Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2024: 231-242.
- [96] CAO S F, LI X D, GONG Z Z, et al. Multiple concepts and cross-attention based knowledge graph completion [J]. Applied Intelligence, 2025, 55(12): 851.

文字编辑 陆燕菲
栏目编辑 宋 圆