

梁桂花, 阮琳琦, 郭泽栋. 知识图谱研究综述及其安保警务领域应用探索 [J]. 智能计算机与应用, 2024, 14(5): 215-220.
DOI: 10.20169/j.issn.2095-2163.240530

知识图谱研究综述及其安保警务领域应用探索

梁桂花¹, 阮琳琦², 郭泽栋³

(1 浙江警察学院 大数据与网络安全研究院, 杭州 310033; 2 浙江警察学院 计算机与信息安全系, 杭州 310033;
3 浙江警察学院 图书馆, 杭州 310033)

摘要: 知识图谱具备强大的语义表示能力, 能够有效组织、管理、挖掘海量信息, 在提供知识服务方面存在着巨大优势, 近年来受到了多领域的广泛关注。安保警务领域数据信息规模庞大且实体关系复杂, 基于此, 本文首先梳理了安保警务领域知识图谱构建框架, 然后从本体构建、知识抽取、知识融合、知识推理等方面对知识图谱构建技术进行了详细的归纳总结, 最后对安保警务领域知识图谱的应用方向进行了探讨, 为知识图谱在安保警务领域的进一步研究和探索奠定基础。

关键词: 知识图谱; 安保警务; 知识抽取; 人工智能

中图分类号: TP182

文献标志码: A

文章编号: 2095-2163(2024)05-0215-06

A survey of knowledge graph research and its application in the field of police security service

LIANG Guihua¹, RUAN Linqi², GUO Zedong³

(1 Institute of Big Data and Cyber Science Research, Zhejiang Police College, Hangzhou 310033, China;

2 Department of Computer Science and Information Security, Zhejiang Police College, Hangzhou 310033, China;

3 Library, Zhejiang Police College, Hangzhou 310033, China)

Abstract: Knowledge graph has powerful semantic representation capabilities which can effectively organize, manage and analyze massive data. It has significant advantages in providing knowledge services and gains extensive attention across various domains in recent years. In police security service domain, the massive scale of data has complex entity relationships. Based on this, this paper firstly outlines the framework for constructing a knowledge graph in the field of police security service. Subsequently, the paper provides the detailed and comprehensive construction of knowledge graph construction techniques, including ontology construction, knowledge extraction, knowledge fusion, and knowledge inference. Lastly, the paper explores potential directions for applying knowledge graphs in the police security domain, thereby laying the foundation for further research and exploration of knowledge graphs in this field.

Key words: knowledge graph; police security service; knowledge extraction; Artificial Intelligence

0 引言

随着人工智能与大数据的不断发展, 各行各业涌现出了海量数据, 如何高效分析利用海量数据成为亟待解决的重要课题。知识图谱具有对碎片化、多源、异构数据进行组织、加工的能力, 成为了目前的研究热点。知识图谱(Knowledge Graph, KG)的概念最早由 Google 在 2012 年提出, 用于改善 Google 搜索引擎性能。知识图谱是以图的形式表示客观世

界中的概念(concept)、实体(entity)及关系的知识库^[1], 其基本组成单位是(实体, 关系, 实体)三元组。根据不同的适用场景, 知识图谱可以划分为通用知识图谱和领域知识图谱两大类。其中, 通用知识图谱是百科类知识图谱, 强调知识的广度, 例如 Wikidata、CN-DBpedia 等。领域知识图谱是面向垂直领域的行业知识库, 强调知识的深度, 也称为行业知识图谱或者垂直知识图谱, 例如中医医案知识图谱^[2]等。

基金项目: 浙江警察学院校级科研项目(2022QNY008)。

作者简介: 梁桂花(1995-), 女, 硕士, 助教, 主要研究方向: 警务大数据, 人工智能; 阮琳琦(1996-), 女, 硕士, 助教, 主要研究方向: 网络安全, 人工智能; 郭泽栋(1996-), 男, 硕士, 助理馆员, 主要研究方向: 图书情报。

收稿日期: 2023-08-30

近年来,在大数据浪潮以及数字化改革的大背景下,警务数据呈现出规模化发展态势,目前,安保警务领域已累积了安保资源、人员信息、事件信息、布防点位、范围路线等大量多维数据,因此亟需应用知识图谱等数据处理技术予以辅助,以提升对数据的利用水平,提高安保警务工作效率。目前,面向安保警务领域的知识图谱研究较少,鉴于此,本文对安保警务领域知识图谱的构建架构进行梳理,然后针对知识图谱构建的关键技术进行归纳分类,最后对安保警务领域的应用方向进行了展望。

1 安保警务领域知识图谱技术架构

知识图谱的逻辑结构可以划分为模式层与数据层^[3]。其中,数据层由一系列的事实组成,例如(实体,关系,实体)三元组,可以用图数据库进行存储。

模式层构建在数据层之上,用于描述实体类型之间的抽象关系,通常由本体库进行管理,用来规范实体、关系以及实体的类型和属性等对象之间的联系。知识图谱的构建方式包括自顶向下(top-down)以及自底向上(bottom-up)两种方式。自顶向下的构建方式先将本体与数据模式定义好,再将实体加入知识库,其优势在于能够提供清晰、完备的概念框架,使得知识图谱易于理解和使用,适用于面向专业领域的知识图谱构建。自底向上的构建方式先从数据中提取出实体,再选择其中置信度较高的实体加入到知识库中,再构建顶层的本体和模式层,更适用于通用知识图谱构建。安保警务领域知识图谱是面向特定领域的知识图谱,由于其知识层次更深、粒度更细、知识质量要求更高,需要完备的模式层作为支撑,因此采用自顶向下的构建方式,其技术架构如图1所示。

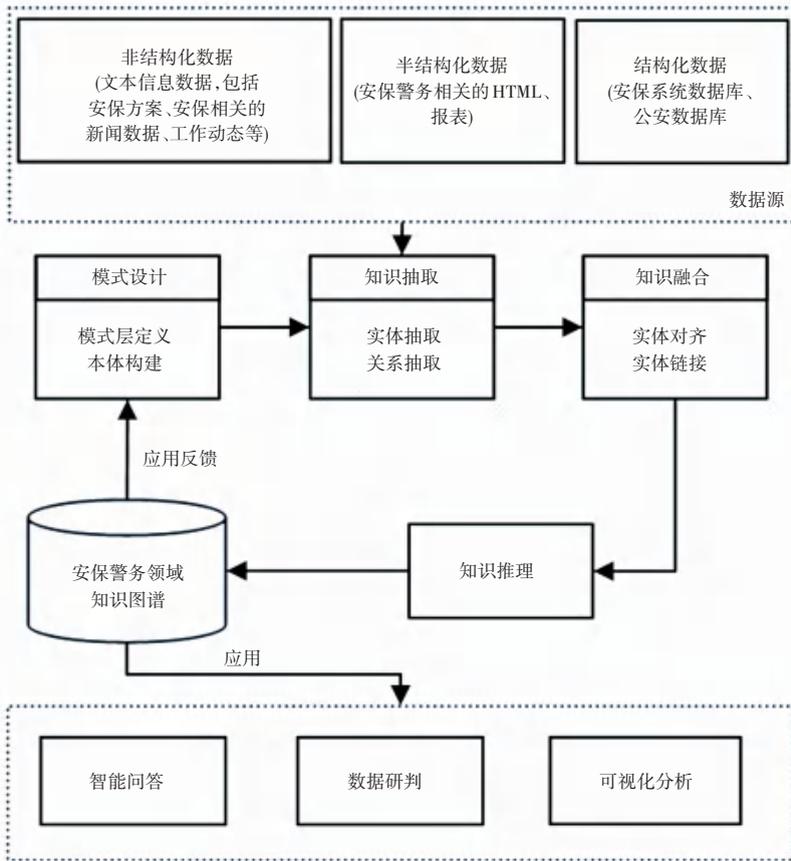


图1 安保警务领域知识图谱技术架构

Fig. 1 Technical architecture of knowledge graph in the field of police security service

安保警务领域知识图谱的构建过程主要分为四大模块:模式设计、知识抽取、知识融合以及知识推理。模式设计的主要目的是确定知识的基本框架,定义领域本体,明确领域的基本概念以及概念之间

的关系。模式设计完成之后,通过网络爬虫、调研等方式获取安保警务领域数据,对其进行知识抽取,获取实体、关系等结构化信息,存入知识库中用作进一步处理。由于安保警务数据来源复杂,知识抽取获

取的结构化信息存在着一定的冗余,因此需要通过知识融合对其进行清理和整合,得到规范化信息。知识推理旨在从前期获得的知识中发现新的知识,从而拓展和丰富知识网络。经过以上步骤初步形成的安保警务领域知识图谱,可用于发展智能问答、数据研判、可视化分析等上层应用,助力智慧安保,并且还需根据实际应用中的反馈不断完善,形成流程闭环。

2 知识图谱构建关键技术

知识图谱领域构建的关键技术包括本体构建、知识抽取、知识融合、知识加工。其中,本体构建借助本体表示框架,对领域基本概念以及概念之间的属性、关系、约束进行描述。知识抽取从多源数据中抽取实体、关系等结构化信息。知识融合将异构数据进行整合、消歧。知识推理挖掘知识间的隐性知识,并将知识库进行补充完善,最终实现知识图谱构建。本节将对知识图谱关键技术进行梳理,对每个技术的常用分类进行总结。

2.1 本体构建

本体是对概念形式及概念间关系的一种规范、明确的定义^[4]。领域本体面向特定的业务场景,能抽象出领域内的概念层次结构,定义概念的相关属性及概念间的关系,用于对知识进行约束,确保知识质量。本体的组成部分可以定义为:

$$O = \langle C, H, R, A \rangle$$

其中, O 表示本体; C 表示一组类或概念; H 表示概念之间的层次联系(分类关系); R 表示概念联系(非分类关系); A 表示规则和公理。领域本体的主要构建方法包括手工构建以及自动或半自动构建方法。手工构建方法高度依赖于领域专家的知识,构建过程费时费力,效率低下。因此,结合机器学习算法进行半自动或自动本体构建成为了领域本体构建的主流算法。杨玉基等学者^[5]利用无监督的OpenIE方法和相关统计方法,结合领域专家的指导,提出了一种半自动的领域本体构建方法。李征等学者^[6]提出了一种基于关联规则与K-means的领域本体构建方法,能够从文本中识别概念间关系,得到初始领域本体,并利用WordNet对其进行扩充。Deepa等学者^[7]利用自然语言处理对文本进行术语提取,并结合Jaccard相似度和朴素贝叶斯算法进行领域本体构建,实现了农业领域的高效自动化本体构建。目前,国内领域本体的构建、复用、扩展尚处于起步阶段,未来研究方向是对现有本体进行重构

和复用,以实现对现有资源有效整合,由此将大幅提升领域本体构建的效率。

2.2 知识抽取

知识抽取的目标是从非结构化或者半结构化数据中挖掘结构化信息,主要包括实体抽取、关系抽取、属性抽取以及事件抽取,其中实体及关系抽取是知识抽取中的关键任务。

2.2.1 实体抽取

实体抽取又称作命名实体识别(Named Entity Recognition, NER),其主要目标是识别出具有特定意义的实体并确定类型^[8]。实体抽取可以划分为:基于词典和规则的方法、基于统计机器学习的方法以及基于深度学习的方法。其中,基于词典和规则的方法是指通过专家定义的语法规则进行实体抽取,其缺点在于领域可移植性和通用性较差。基于传统机器学习的方法主要包括基于隐马尔可夫模型(HMM)^[9]、支持向量机(SVM)、条件随机场模型(CRF)等的实体抽取算法,其准确率、查全率较基于词典和规则的方法相比有所提高,模型的泛化性也得以增强,但其不足之处在于算法高度依赖于训练数据的标注质量,无法对大规模数据集进行处理。

随着深度学习的不断发展,基于深度学习的实体抽取算法已逐渐成为主流,包括基于CNN、RNN、BiLSTM等的算法,利用深度学习捕捉上下文信息,这也显著提升了实体抽取任务的准确度和性能。近年来,随着预训练模型(Pre-training Language Model, PLM)的发展,基于预训练模型进行迁移学习的实体抽取算法成为了目前的研究热点,利用迁移学习进行实体提取训练成本下降明显,具备可移植性好、效率高等优势。Google在2018年提出了BERT预训练模型^[10],大幅提升了自然语言处理任务的效果。为解决中文在BERT模型预训练中缺乏词典限制的问题,Jia等学者^[11]提出了一种半监督实体增强的BERT预训练方法,利用Char Entity Transformer结构将特定实体显式集成到BERT预训练中,有效提升了BERT模型的中文表现能力。陈剑等学者^[12]构建了融合BERT、BiLSTM与CRF的3层结构模型,解决了标注语料规模小、文本实体提取困难的问题。为融合局部特征,Chang等学者^[13]提出了一种基于Bert的NER模型,结合BiLSTM及IDCNN进行特征提取,并通过CRF对模型预测结果进行修正,充分考虑了上下文信息。目前,实体抽取算法不再仅仅局限于单一算法,而是将基于词典和规则的方法、基于统计机器学习的方法以及基于深

度学习的方法进行选择性融合,以适配不同领域的数据特征。

2.2.2 关系抽取

关系抽取的目的是挖掘不同实体间的语义关系,并与实体信息相结合组成(实体,关系,实体)三元组,为知识图谱构建提供基础数据。按照提供数据的标注程度不同,关系抽取可以分为无监督方法、半监督方法、有监督方法以及远程监督方法。其中,基于深度学习的有监督方法及远程监督方法能够避免传统关系抽取方法中的人工特征选择问题,逐渐成为了近年来关系抽取领域的研究热点^[14-15]。

基于深度学习的有监督关系抽取方法可以分为流水线学习和联合学习两类。流水线学习是指在实体抽取的基础之上进行实体间关系抽取,主要采用基于 CNN、RNN、LSTM 等网络模型,但由于受到实体抽取的准确度限制,存在着错误传播问题,且忽视了实体抽取和关系抽取两个子任务间的联系,因此其抽取精度受到了影响。联合学习方法将实体抽取和关系抽取任务融合起来,直接得到实体-关系三元组,解决了流水线模型存在的问题。Zheng 等学者^[16]提出了一种端到端模型将联合提取任务转换为序列标记问题,对实体和关系进行抽取,输出实体-关系三元组。基于深度学习的有监督关系抽取方法难以利用领域中存在的大量无标注数据。远程监督方法利用现有的知识库生成训练数据,在标注数据有限的情况下进行模型训练,弥补了有监督关系提取方法的缺陷。目前,远程监督方法研究的重点是如何去除噪声。Alt 等学者^[17]将生成式预训练语言模型 GPT(Generative Pre-trained Transformer)扩展到远程监督设置,用于捕获语义和句法特征,在大关系集中取得了较高的置信度。Li 等学者^[18]提出了一种用于远程监督关系提取的分层对比学习框架,用于整合全局结构信息和局部细粒度交互信息,减少句子级噪声的影响,有效提升了关系抽取任务的性能。

2.3 知识融合

知识融合的目的是消除概念的歧义,剔除冗余和错误信息,对知识进行加工和整合,确保知识的质量^[19]。知识融合的主要任务包括实体对齐(Entity Alignment, EA)与实体链接(Entity Linking, EL)。

2.3.1 实体对齐

实体对齐的目的是将多数据源或多个知识图谱中指代相同事物的实体进行对齐,消除实体指向不一致性和冲突问题。在实体对齐任务中,基于知识

表示学习的方法占据主导地位。该方法将知识库中的实体或关系表示为低维稠密的向量,并通过计算向量间的距离或相似度得到实体对齐结果。Bordes 等学者^[20]提出的 TransE 模型将头实体和尾实体都表示为向量,并将关系视作头尾实体的翻译,该模型结构简单、易于训练,容易扩展到大型数据库,是知识表示学习的代表性模型。后续以 TransE 模型为基础进行实体对齐的模型相继被提出,包括 MTransE^[21]、IPTransE^[22]以及 BootEA^[23]等。但这些方法的局限性在于仅利用了知识库的结构信息,忽视了知识库中三元组的语义信息。为解决这一问题,出现了融合结构信息与语义信息的实体对齐方法。Zhang 等学者^[24]利用实体名称、实体间关系以及实体的属性作为组合策略来学习实体的嵌入,并设计了跨知识图谱推理方法来完成实体对齐任务。李文娜等学者^[25]将 TransE 模型和 BERT 模型进行联合,分别用于表示实体的结构信息和语义信息,有效提高了模型对实体的表现能力。

2.3.2 实体链接

实体链接是指将半结构化数据及非结构化数据中提取出的实体指称(entity mention)链向其所在特定知识库中的相应实体的过程,也称命名实体链接(Named Entity Linking)。实体链接包括指称识别与实体消歧两项关键技术,指称识别提供指称候选列表,实体消歧给出指称-实体映射结果,其中,实体消歧是实体链接任务的难点,目前大部分实体链接任务专注于实体消歧方法研究。基于神经网络和深度学习的实体消歧方法将任务转换为多类别分类问题^[26],将候选的指称精准映射到实体。Sevgili 等学者^[27]利用图嵌入将知识库中的结构化信息与基于文本表示的非结构化信息进行整合,提升了神经网络模型在实体消歧任务中的性能。为结合全局上下文信息,Yamada 等学者^[28]提出了一种基于单词和实体情境化嵌入的全局实体消歧模型,将实体消歧问题视为顺序决策任务以捕捉全局上下文信息,逐一消除指称的歧义。针对短文本场景下,仅对实体的上下文信息进行建模难以提取到有效特征的伪命题,马瑛超等学者^[29]提出了一种基于实体主题关系的模型消歧方法,通过主题推断计算实体间的主题相关度,并结合 Bert 模型构建消歧网络图,最后通过搜索排序确定实体消歧的结果,有效解决了短文本文体消歧问题。

2.4 知识推理

知识推理旨在识别知识图谱中的错误并挖掘出

其中的隐含知识,提升知识图谱的完整性和准确性。知识推理方法可以分为3类:基于规则的推理、基于分布式表示的推理和基于神经网络的推理^[30]。其中,基于规则的推理指应用简单的规则或者统计特征进行知识推理,其优势在于算法的可解释性较强。基于分布式表示的推理将知识图谱中的实体、关系和属性投影到连续的向量空间中,以获得分布式表示完成知识推理,常用模型包括 TransE^[31], RESCAL^[32]等,由于模型参数较少、因此其计算复杂度较低。基于神经网络的推理具有强大的特征捕捉能力,能够更精准地刻画实体和关系的复杂语义联系。Shen 等学者^[33]提出了隐式推理网络,利用共享内存对大规模结构化关系进行隐式建模,模拟人脑隐式地学习多步推理过程。Tay 等学者^[34]提出了一种多任务知识图谱神经网络方法,在进行知识表示学习的同时对于非离散属性信息进行编码和预测,在三元组分类和属性预测任务上有着优异表现。

3 安保警务领域知识图谱应用展望

随着中国综合国力的大幅提升,承办的大型会议、体育比赛、文艺活动、展览展销、庆典等大型公共活动日益增多,如2022年在北京举办的第24届冬季奥林匹克运动会、2023年在杭州举办的第19届亚运会等。大型活动参与人员众多、社会影响巨大,面临着诸多安保维稳风险^[35],安保压力也随之增大。安保警务领域知识图谱能对领域中大量不同来源的多维度数据进行整合分析研究,可以应用于安保工作中的智能问答、数据研判及安保智能可视化展示等场景。

3.1 智能问答

随着知识图谱的不断发展,基于知识图谱的智能问答系统的应用领域不断扩充,包括医疗、金融、旅游等多个垂直领域。Du 等学者^[36]提出了一种基于大规模 COVID-19 知识图谱的智能问答系统,通过投影算法将来自不同空间的实体、模式和问题的重要特征对齐,提供了准确且解释性强的回答。Pei 等学者^[37]提出了一种中文领域知识图谱通用问答框架,利用 TransE 模型对实体和关系进行计算后用于搜索答案,该框架减少了人工干预,其领域迁移性较好。借助智能问答系统,在安保警务领域知识图谱的辅助下,安保警务人员能以自然语言提问的形式提出信息查询需求,例如“某人在哪些位置频繁出现过?”等问题,并快速获取关注信息,加速获取信息的效率,为安保工作提供支撑。

3.2 数据研判

传统数据研判模型通常由专家系统和逻辑推理计算结合完成,严重依赖领域专家的知识总结能力,且容易忽略大量细节性、隐含性较强的知识,在复杂的实际应用场景中难以发挥作用。结合知识图谱的数据研判模型能够充分利用知识要素间关系,具有强大的知识推理能力,固有优势明显。张思龙等学者^[38]提出了基于知识图谱的网络舆情研判系统模型,实现了对网络舆情的风险点、矛盾点的准确分析研判。围绕安保警务知识图谱中的人、事、物实体,可以结合专家研判经验规则,采用种子人员筛选、规则模型比对、结果概率化验证等技术手段,开发数据研判模型挖掘出潜在风险,发挥知识图谱的风险预测预警、情报研判、辅助决策等关键作用。

3.3 可视化分析

知识图谱可视化是指将复杂的知识图谱数据以图形元素直观地表示出来,并辅以人机交互技术,以帮助用户高效地感知、分析数据。目前主流的知识图谱可视化工具主要包括 Gephi、Cytoscape、Neo4j Bloom、GraphDB、OntoGraf、KeyLines 等。传统安保工作中,面对大量多源异构数据,安保警务人员难以直观理解数据间的逻辑关系。而在安保警务知识图谱的基础上,可借助可视化技术,对事件发展态势、重点人员等信息进行多维度可视化展示,将数据中的多维知识以易于人类理解的方式提供给安保警务人员,帮助其推断出数据中的潜在信息,分析发现超出预期的异常情况。

4 结束语

知识图谱能够对多源异构数据和多维复杂关系进行整合、分析、处理,提供更高层次的数据服务需求,在医疗、金融、法律、教育等多个领域都有广泛的应用。在安保警务领域,沉积了海量多源异构数据,亟需利用知识图谱对数据进行组合和管理,提供知识服务,推进安保警务智能化发展。本文从梳理安保警务领域知识图谱的构建架构出发,对知识图谱关键技术进行了归纳总结,并对其知识应用方向进行了展望。目前,面向安保警务领域的知识图谱研究处于起步阶段,尚需进行不断探索。未来,如何获取高质量领域数据、有效对多源数据进行知识抽取及融合、扩展其知识应用等将成为重要研究方向。

参考文献

[1] 黄恒琪,于娟,廖晓,等. 知识图谱研究综述[J]. 计算机系统应

- 用,2019,28(6):1-12.
- [2] 王松,李正钧,杨涛,等. 中医药知识图谱研究现状及发展趋势[J]. 南京中医药大学学报,2022,38(3):272-278.
- [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.
- [4] 任飞亮,沈继坤,孙宾宾,等. 从文本中构建领域本体技术综述[J]. 计算机学报,2019,42(3):654-676.
- [5] 杨玉基,许斌,胡家威,等. 一种准确而高效的领域知识图谱构建方法[J]. 软件学报,2018,29(10):2931-2947.
- [6] 李征,李斌. 一种基于关联规则与K-means的领域本体构建方法[J]. 河南师范大学学报(自然科学版),2020,48(1):24-32.
- [7] DEEPA R, VBINESHWARI S. An effective automated ontology construction based on the agriculture domain[J]. ETRI Journal, 2022, 44(4): 573-587.
- [8] 赵继贵,钱育蓉,王魁,等. 中文命名实体识别研究综述[J]. 计算机工程与应用,2024,60(1):15-27.
- [9] 俞鸿魁,张华平,刘群,等. 基于层叠隐马尔可夫模型的中文命名实体识别[J]. 通信学报,2006,27(2):87-94.
- [10] DEVLIN J, CHANG Mingwei, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv:1810.04805, 2018.
- [11] JIA Chen, SHI Yuefeng, YANG Qinrong, et al. Entity enhanced BERT pre-training for Chinese NER[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Punta Cana, Dominican: ACL, 2020: 6384-6396.
- [12] 陈剑,何涛,闻英友,等. 基于BERT模型的司法文书实体识别方法[J]. 东北大学学报(自然科学版),2020,41(10):1382-1387.
- [13] CHANG Yuan, KONG Lei, JIA Kejia, et al. Chinese named entity recognition method based on BERT[C]//2021 IEEE International Conference on Data Science and Computer Application (ICDSCA), Dalian, China: IEEE, 2021:294-299.
- [14] 鄂海红,张文静,肖思琪,等. 深度学习实体关系抽取研究综述[J]. 软件学报,2019,30(6):1793-1818.
- [15] ZHANG Linrui, MOLDOVAN D. Chinese relation classification using long short term memory networks[C]//Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018). Miyazaki, Japan: European Language Resource Association,2018:489-494.
- [16] ZHENG Suncong, WANG Feng, BAO Hongyun, et al. Joint extraction of entities and relations based on a novel tagging scheme[J]. arXiv preprint arXiv:1706.05075, 2017.
- [17] ALT C, HÜBNER M, HENNIG L. Fine-tuning pre-trained transformer language models to distantly supervised relation extraction[J]. arXiv preprint arXiv:1906.08646, 2019.
- [18] LI Dongyang, ZHANG Taolin, HU Nan, et al. HiCLRE: a hierarchical contrastive learning framework for distantly supervised relation extraction[J]. arXiv preprint arXiv:2202.13352, 2022.
- [19] 刘知远,孙茂松,林衍凯,等. 知识表示学习研究进展[J]. 计算机研究与发展,2016,53(2):247-261.
- [20] BORDES A, USUNIER N, GARCIA - DURAN A, et al. Translating embeddings for modeling multi-relational data[J]. Advances in Neural Information Processing Systems, 2013, 26: 2787-2795.
- [21] CHEN Muhao, TIAN Yingtao, YANG Mohan, et al. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment[J]. arXiv preprint arXiv:1611.03954, 2016.
- [22] ZHU Hao, XIE Ruobing, LIU Z, et al. Iterative entity alignment via joint knowledge embeddings[C]// Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI). Melbourne, Australia: AAAI Press, 2017, 17: 4258-4264.
- [23] SUN Zequn, HU Wei, ZHANG Qingheng, et al. Bootstrapping entity alignment with knowledge graph embedding[C]// Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI). Stockholm, Sweden: AAAI, 2018: 4396-4402.
- [24] ZHANG Qingheng, SUN Zequn, HU Wei, et al. Multi-view knowledge graph embedding for entity alignment[J]. arXiv preprint arXiv:1906.02390, 2019.
- [25] 李文娜,张智雄. 基于联合语义表示的不同知识库中的实体对齐方法研究[J]. 数据分析与知识发现,2021,5(7):1-9.
- [26] SEVGILI O, SHELMANOV A, ARKHIPOV M, et al. Neural entity linking: A survey of models based on deep learning[J]. arXiv preprint arXiv:2006.00575, 2021
- [27] SEVGILI Ö, PANCHENKO A, BIEMANN C. Improving neural entity disambiguation with graph embeddings[C]//Proceedings of the 57th annual meeting of the Association for Computational Linguistics: Student Research Workshop. New York: ACL,2019: 315-322.
- [28] YAMADA I, WASHIO K, SHINDO H, et al. Global entity disambiguation with pretrained contextualized embeddings of words and entities[J]. arXiv preprint arXiv:1909.00426, 2020.
- [29] 马瑛超,张晓滨. 基于主题关系的中文短文本图模型实体消歧[J]. 计算机工程与科学,2023,45(1):154-162.
- [30] CHEN Xiaojun, JIA Shengbin, XIANG Yang. A review: Knowledge reasoning over knowledge graph[J]. Expert Systems with Applications, 2020, 141: 112948.
- [31] BORDES A, USUNIER N, GARCIA - DURAN A, et al. Translating embeddings for modeling multi-relational data[J]. Advances in Neural Information Processing Systems, 2013, 26: 2787-2795.
- [32] NICKEL M, TRESP V, KRIEGEL H P. A three-way model for collective learning on multi-relational data[C]// Proceedings of the 28th International Conference on Machine Learning. Washington DC, USA: International Machine Learning Society, 2011. 809-816.
- [33] SHEN Yelong, HUANG Posen, CHANG Mingwei, et al. Implicit reasoner: Modeling large-scale structured relationships with shared memory[J]. arXiv preprint arXiv:1611.04642, 2016.
- [34] 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 on Conference on Information and Knowledge Management. Singapore: ACM,2017: 1029-1038.
- [35] 黄悦波. 试析外国冬奥会警务安保的经验及其借鉴[J]. 北京警察学院学报,2021(2):37-43.
- [36] DU Huifang, LE Zhongwen, WANG Haofen, et al. COKG-QA: Multi-hop question answering over COVID-19 knowledge graphs[J]. Data Intelligence, 2022, 4(3): 471-492.
- [37] PEI Zhongmin, ZHANG Jie, XIONG Wei, et al. A general framework for Chinese domain knowledge graph question answering based on TransE[J]. Journal of Physics: Conference Series. IOP Publishing, 2020, 1693(1): 012136.
- [38] 张思龙,王兰成,娄国哲. 基于知识图谱的网络舆情研判系统研究[J]. 现代情报,2021,41(4):10-16.