计算机科学
COMPUTER SCIENCE

知识图谱推理研究综述

马瑞新，李泽阳，陈志奎，赵亮

引用本文

马瑞新，李泽阳，陈志奎，赵亮. 知识图谱推理研究综述[J]. 计算机科学, 2022, 49(6A): 74-85.

MA Rui-xin, LI Ze-yang, CHEN Zhi-kui, ZHAO Liang. Review of Reasoning on Knowledge Graph[J]. Computer Science, 2022, 49(6A): 74-85.

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)

一种可快速迁移的领域知识图谱构建方法

Fast and Transmissible Domain Knowledge Graph Construction Method

计算机科学, 2022, 49(6A): 100-108. https://doi.org/10.11896/jsjkx.210900018

军事指控保障领域命名实体识别语料库的构建

Construction of Named Entity Recognition Corpus in Field of Military Command and Control Support

计算机科学, 2022, 49(6A): 133-139. https://doi.org/10.11896/jsjkx.210400132

融合用户偏好的图神经网络推荐模型

Graph Neural Network Recommendation Model Integrating User Preferences

计算机科学, 2022, 49(6): 165-171. https://doi.org/10.11896/jsjkx.210400276

基于学术知识图谱的辅助创新技术研究

Academic Knowledge Graph-based Research for Auxiliary Innovation Technology

计算机科学, 2022, 49(5): 194-199. https://doi.org/10.11896/jsjkx.210400195

学术引用信息可视化方法综述

Survey of Visualization Methods on Academic Citation Information

计算机科学, 2022, 49(4): 88-99. https://doi.org/10.11896/jsjkx.210300219

计算机科学 COMPUTER SCIENCE
http://www.jsjkx.com
DOI:10.11896/jsjkx.210100122

知识图谱推理研究综述

马瑞新　李泽阳　陈志奎　赵　亮
大连理工大学软件学院　辽宁 大连 116620
(maruixin@dlut.edu.cn)

摘　要　近年来,随着互联网技术以及引用模式的快速发展,计算机世界的数据规模呈指数型增长,这些数据中蕴含着大量有价值的信息,如何从中筛选出知识并将这些知识进行有效组织和表达引起了广泛关注。知识图谱由此而生,面向知识图谱的知识推理就是知识图谱研究的热点之一,已经在语义搜索、智能问答等领域取得了重大成就。然而,由于样本数据存在各种缺陷,例如样本数据缺少头尾实体、查询路径过长、样本数据错误等,因此面对上述特点的零样本、单样本、少样本和多样本知识图谱推理更受瞩目。文中将从知识图谱的基本概念和基础知识出发,介绍近年来知识图谱推理方法的最新研究进展。具体而言,根据样本数据量大小的不同,将知识图谱推理方法分为多样本推理、少样本推理和零与单样本推理。模型使用超过5个实例数进行推理的为多样本推理,模型使用2～5实例数进行推理的为少样本推理,模型使用零个或者一个实例数进行推理的为零与单样本推理。根据方法的不同,将多样本知识图谱推理细分为基于规则的推理、基于分布式的推理、基于神经网络的推理以及基于其他的推理,将少样本知识图谱推理细分为基于元学习的推理与基于相邻实体信息的推理,具体分析总结这些方法。此外,进一步讲述了知识图谱推理的典型应用,并探讨了知识图谱推理现存的问题、未来的研究方向和前景。

关键词:知识图谱;知识推理;多样本推理;少样本推理;单样本推理;零样本推理
中图法分类号　TP391

Review of Reasoning on Knowledge Graph

MA Rui-xin,LI Ze-yang,CHEN Zhi-kui and ZHAO Liang
School of Software Technology,Dalian University of Technology,Dalian,Liaoning 116620,China

Abstract　In recent years,the rapid development of Internet technology and reference models has led to an exponential growth in the scale of computer world data,which contains a lot of valuable information. How to select knowledge from it,and organize and express this knowledge effectively attract wide attention. Knowledge graphs are also born from this. Knowledge reasoning for knowledge graphs is one of the hotspots of knowledge graph research,and important achievements are obtained in the fields of semantic search and intelligent question answering. However,due to various defects in the sample data,such as the lack of head and tail entities in sample data,the long query path,as well as the wrong sample data. In the face of the above characteristics,the knowledge graph reasoning of zero-shot,one-shot,few-shot and multi-shot get more attention. Based on the basic concepts and basic knowledge of knowledge graph,this paper introduces the latest research progress of knowledge graph reasoning methods in recent years. Specifically,according to the size of sample data,the knowledge graph reasoning method is divided into multi-shot reasoning,few-shot reasoning,zero-shot and single-shot reasoning. Models that use more than five instances for reasoning are multi-sample reasoning,models that use two to five instances for reasoning are few-shot reasoning,and those use zero or one instance number for reasoning are zero-shpt and one-shot reasoning. The multi-shot knowledge graph reasoning is subdivided into rule-based reasoning,distributed-based reasoning,neural network-based reasoning,and other reasoning. The few-shot knowledge graph reasoning is subdivided into meta-learning-based reasoning and neighboring entity information-based reasoning. And these methods are analyzed and summarized. In addition,this paper further describes the typical application of knowledge graph reasoning,and discusses the existing problems,future research directions and prospects of knowledge graph reasoning.

Keywords　Knowledge graph,Knowledge reasoning,Multi-shot reasoning,Few-shot reasoning,One-shot reasoning,Zero-shot reasoning

---

基金项目:国家重点研发计划(2018YFC0830203);国家自然科学基金(61906030);辽宁省自然科学基金(2020-BS-063);装备预先研究领域基金(80904010301);中央高校基本科研业务费专项资金(DUT20RC(4)009)
This work was supported by the National Key Research and Development Program of China(2018YFC0830203),National Natural Science Foundation of China (61906030),Natural Science Foundation of Liaoning Province(2020-BS-063),Equipment Advance Research Fund(80904010301) and Fundamental Research Funds for the Central Universities(DUT20RC(4)009).
通信作者:赵亮(liangzhao@dlut.edu.cn)

1 引言

知识图谱推理即面向知识图谱的知识推理。知识图谱有很多种定义，是以图的形式表示真实世界的实体与实体之间关系的知识库。知识图谱的研究源于 2000 年 XML 大会上 Tim Berners Lee 提出的语义 Web 的理念，最初的作用是为 Web 网页添加语义信息，提供信息代理、搜索代理、信息过滤等语义信息服务。2005 年，美国 Metaweb 公司成立，致力于开发开放共享的世界知识库。Metaweb 基于维基百科、美国证券交易委员会等公开的数据集，提取出现实世界中人或事物（实体）及他们之间的关系，并且以图的结构储存在计算机中。2010 年，谷歌收购了 Metaweb 公司，并在 2012 年提出了知识图谱[1]的概念。

具体来说，知识图谱是通过将应用数学、图形学、信息可视化技术、信息科学等学科的理论、方法与计量学引文分析、共现分析等方法结合，并利用可视化的图谱形象地展示其核心结构、发展历史、前沿领域以及整体知识架构，达到多学科融合目的的现代理论。它把复杂的知识领域通过数据挖掘、信息处理、知识计量和图形绘制显示出来，揭示知识领域的动态发展规律，为学科研究提供切实的、有价值的参考。迄今为止，其实际应用已经逐步拓展并取得了较好的效果。

目前，已经涌现出一大批知识图谱，其中具有代表性的有 DBpedia[2]，Freebase[3]，NELL[4]，Probase[5] 等。这些知识图谱从大量数据资源中抽取、组织和管理知识，希望为用户提供能够读懂用户需求的智能服务。例如：理解搜索的语义，提供更精准的搜索答案。大批的知识图谱被广泛应用于知识图谱补全与去噪的学术研究领域。除此之外，知识图谱在问答系统、推荐系统、机器翻译等领域也发挥了重要作用，并已在医学诊断、金融安全、军用等领域展示出很好的应用前景。

虽然现在已经存在一些知识图谱综述文献，但是基于数据样本量的知识图谱算法的分类归纳仍然缺乏。模型的样本量越多，推理难度越低，准确性也越高，但是现实世界的适用率越低。为此，本文根据样本数据量大小的不同，将知识图谱推理方法分为多样本推理、少样本推理和零与单样本推理，并对其最新进展进行详细分类总结；最后提出知识图谱推理未来的潜在发展方向。

本文第 2 节总结知识图谱推理的基础知识；第 3 节分析多样本知识图谱推理相关方法；第 4 节论述少样本知识图谱推理相关方法；第 5 节指出知识图谱推理的未来研究趋势；最后总结全文。

2 基础知识

2.1 知识图谱架构

知识图谱是图 $G=(V,E)$ 的某种扩展形式，G 代表所有知识组成的图结构，V 代表图结构的顶点集合，E 代表图结构中边的集合。知识图谱的架构由数据层和模式层两部分构成。图 1[6] 给出知识图谱由数据层到模式层的转化过程，以及知识图谱的更新进程。

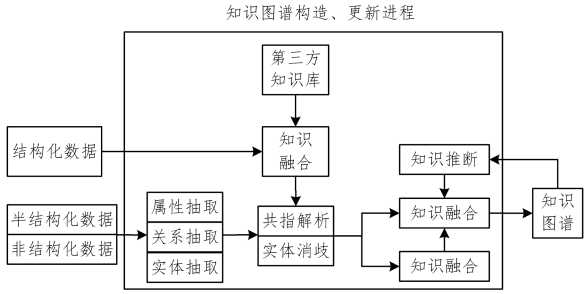

图 1 知识图谱数据层到模式层的转化过程[6]

Fig. 1 Process from data layer to model layer of knowledge graph[6]

在数据层，数据以（头实体，关系，尾实体）的三元组形式储存，形成一个图状知识库。实体包括具体的人名、地名等事物和时间、大小等属性值；关系是两个实体间的语义关系。节点表示实体，边表示实体间的关系。

模式层在数据层之上，是知识图谱的核心，其中存储的是经过提炼的知识。模式层是数据层的概念模型或者逻辑模型，对数据层规范和约束；模式层更适用于知识图谱推理。在知识图谱的模式层，节点表示本体概念，边表示概念之间的对应关系。

2.2 常用的知识图谱

按照构建方式的不同，知识图谱可以分为手工构建和自动构建两类。第一类知识图谱的典型实例有 WordNet[7] 和 HowNet[8] 等，第二类包括 NELL 和 WikiData[9] 等。第一类的特点是规模较小，但是由专业人士创建，能够确保准确性与完整性，知识质量高，耗时长；第二类的特点是能够自动抽取实体与关系，规模较大，但是存在大量的不完整关系、噪声信息等，常用在知识图谱补全、查询等研究中。表 1 列出了部分常用的中文知识图谱信息，表 2 列出了部分常用的外文知识图谱信息[10]。

表 1 部分常用中文知识图谱信息

Table 1 Some commonly used Chinese knowledge graph information

知识图谱名称	研究机构	实体数量	关系数量	知识源	应用
HowNet	中国科学院计算机语言信息中心	1.1 万		专家人工构建	语义倾向计算
THUOCL	清华大学自然语言处理与社会人文计算实验室	15.7 万		主流网站的社会标签、搜索热词等	
大词林	哈尔滨工业大学社会计算与信息检索研究中心			百度百科、同义词词林、Web 网页	
Zhishi. me	上海交通大学	1000＋万	1.2 亿	百度百科、互动百科、中文维基百科	
CN-DBpedia	复旦大学知识工场实验室	1686 万	2228.6 万	中文百科类网站	自然语言问答
CN-Probase	复旦大学知识工场实验室	1700 万	3300 万	CN-DBpedia、海量中文网页语料等	

表 2 部分常用国外知识图谱信息

Table 2 Some commonly used foreign knowledge graph information

知识图谱名称	研究机构	实体数量	关系数量	知识源	应用
CYC	美国 Cycorp 公司	50 万	1.5 万	专家人工构建	
WordNet	普林斯顿大学	15 万	20 万	专家人工构建	语义搜索
conceptNet	麻省理工媒体实验室		2800 万	专家人工构建	语音识别、机器翻译
Freebase	谷歌	6800 万	10 亿	Wikipedia	
DBpedia	莱比锡大学和曼彻斯特大学	458 万	30 亿	Wikipedia	语义标注
YAGO	德国马普研究所	1000 万	1.8 亿	Wikipedia, WordNet, GeoNames	
TextRunner	华盛顿大学国灵中心			Web 网页	
WolframAlpha	沃尔夫勒姆研究公司	10 万亿			知识搜索
NELL	卡内基梅隆大学	519 万	5 亿	Web 网页	
WikiData	维基	453.6 万		Wikapedia、用户编辑	语义搜索
Google Knowledge Vault	谷歌	5 亿	180 亿	Wikipedia, Freebase	语义搜索
Microsft Concept Graph	微软	1255 万	8760 万	Web 网页	

3 多样本知识图谱推理

随着互联网和大数据技术的进一步发展，知识图谱的种类不断增多并且数据量不断变大，多样本知识图谱推理在现实应用场景中具有重要意义。随着多样本知识图谱推理的发展，近年来已经出现了很多的方法，包括基于传统规则表示的推理、基于分布式的推理、基于神经网络的推理等。

3.1 基于规则表示的推理

单跳推理：在知识图谱构建早期，主要利用基于规则表示的方法进行推理，主要是应用简单规则或者统计特征在一些早期人工构建的知识图谱上。其中，NELL 知识图谱内部采用的是简单的一阶关系学习算法进行推理[11]。Wang 等[12]提出一阶概率语言模型 ProPPR(Programming with Personalized PageRank)进行知识图谱推理。该模型生成了有向证明图，节点对应查询的子句，边对应规则，推理过程为一个查询子句通过规则到另一个查询子句。ProPPR 的评分系统是基于图结构的个性化网页评分。Cohen[13]提出了 Tensor Log 的方法，该方法是基于可微的过程，给每一个关系定义一个 $\{0,1\}$ 的操作矩阵，并且关联一个 one-shot 向量，(i,j) 表示第 i 个实体与第 j 个实体之间是否存在关系，如果存在为 1，否则为 0。该方法可以将逻辑规则的推理形式转化为操作矩阵相乘。通过带学习的置信度参数对所有的路径结果进行加权求和，从而得到所有实体对应的得分向量。Paulheim 等[14]提出了算法 SDType 和 SDValidate，利用图中的属性和实体的类型补全类型三元组和识别错误的三元组。SDType 方法实现了一种类似加权的投票机制，为每一个属性赋予权重。SDValidate 算法首先需要计算关系-尾实体的频率，然后计算低频三元组的得分，当得分小于设定的阈值时被判定为潜在错误的三元组。Jang 等[15]基于不同的模式评估知识图谱的三元组质量。鉴于更经常出现的模式更加可靠，Jang 等人通过选择出现频率高的模式，例如头实体模式、尾实体模式等，进行三元组质量分析。

然而，以上基于规则的单步推理方法可计算性低、代价高、方法简单、适用的知识图谱较少、速度较慢。

多跳推理与单跳推理有很大的不同，其规则更加复杂，例如随机行走规则、传递性规则等。以使用规则区域的大小为标准，可以将其分为基于全局的规则和基于局部的规则推理两种。

(1)基于全局的推理

Lao 等[16-17]提出了 PRA 算法，将推理的路径作为特征，预测实体间是否存在特定的关系；通过将正例三元组的头尾实体替换得到负例三元组，然后训练回归分类器；之后，基于受限和加权的随机行走策略，进一步改进该模型的路径产生过程。该模型试图产生潜在能够有助于推理的路径，减少路径的数量，但是必须实体之间有联系，否则无效。Zhao 等[18]就前者的问题，提出基于内容和结构的 CSRI 的模型。该模型结合了内容信息和结构信息，最终的概率得分也由影响因子和结构因子两部分组成。Kotnis 等[19]提出新的算法，该算法通过 5 亿网络文本语料挖掘的实体和边(关系)增广知识图谱的关系，然后在增广知识图谱上推理。Galárraga 等[20-21]提出了知识图谱关联规则挖掘算法 AMIE(Association Rule Mining under Incomplete Evidence)，挖掘传递性规则。AMIE 维护一个规则队列，将其初始化为空规则，并迭代地从规则队列中每次取出一个规则，如果规则是封闭规则且未被删除，则输出该规则。同时，该规则用定义的规则挖掘操作算子作用，将未被删除的规则插入规则队列。之后，Galárraga 等人更新了 AMIE 算法得到了 AMIE+模型，该模型主要是使用剪枝策略和近似策略来挖掘更大的知识图谱，利用实体的类型信息和联合推理提高预测精度。

以上模型基于全局的图结构在整个知识图谱上进行推理，成本代价较高，而知识推理一般是在局部图结构上进行；另一方面，全局的细粒度太粗，局部信息的细粒度能够提高推理的准确性。

(2)基于局部的推理

Gardner 等[22]提出了更简单、有效的从知识图谱产生特征矩阵的 SFE(Subgraph Feature Extraction)算法，该算法使用广度优先策略对头实体的相邻实体进行遍历，然后在局部结构进行特征抽取，之后进行推理。Liu 等[23]提出了层次随机行走推理算法(Hierarchical Random-walk Inference, Hi-Ri)，上层对应于全局学习的视角，下层对应知识图谱局部的学习推理。

多样本知识图谱中基于规则的推理即使设定有一定的过滤机制，也仍然存在效率低下、噪声信息大、规则较少等缺点，并且当前的规则较少，人工挖掘更多复杂规则的代价也很高，可解释性难以保证。但是，通过关联局部的结构信息弥补单纯规则的推理值得进一步的研究。

3.2 基于分布式的推理

多样本知识图谱推理中基于分布式推理的过程是先要通过模型得到低维向量表示，然后用向量操作来进行对应知识图谱的推理。在基于分布式推理中，近年来已经有很多的

研究结果，单跳推理主要通过不同的嵌入矩阵来表示三元组样本。相较于单跳推理，多跳推理增加了多跳的关系约束。

(1)单跳推理

Bordes 等[24]提出了第一个基于转移的表示模型 TransE，它也是基于分布式的基础模型，掀起了 Trans 系列的研究热潮。TransE 的主要思想是：如果三元组(头实体，关系，尾实体)成立，头实体向量 $\boldsymbol{h}$ 与关系向量 $\boldsymbol{r}$ 的和与尾实体向量 $\boldsymbol{t}$ 相近($\boldsymbol{h}+\boldsymbol{r}\approx\boldsymbol{t}$)，否则远离。由上述基本转移假设得到欧几里得距离即为得分函数，用 L1 或 L2 范数衡量距离。学习过程替换头实体或尾实体得到负例，类似支持向量机，最小化一个基于 Margin 的损失，使正例的得分比负例的得分至少高一个 Margin。在进行推理时，得分函数取值大的候选实体/关系即为推理结果。TransE 简单有效，但是只能处理一对一关系，不能处理层级关系，且没有考虑丰富的语义信息，参数的选区和知识图谱的数据没有关系，没有考虑知识的时间约束等。

Wang 等[25]提出了 TransH，在 TransE 的基础上为每个关系多学一个映射向量，用于将实体映射到关系指定的超平面，一定程度上缓解了不能很好地处理多映射属性关系的问题。Wen 等[26]提出了 m-TransH，直接建模多元关系，关系的损失函数不通过将多元关系分解为二元关系进行分析，而是将多元关系中的每一元看成一个角色，直接建模为角色函数的累加。

Jia 等[27]提出了 TransA，TransA 引入 $\boldsymbol{Wr}$ 矩阵为不同维度的向量进行加权，并利用 LDL 方法对 $\boldsymbol{Wr}$ 进行分解，然后得到一个对角阵 $\boldsymbol{Dr}$，对角线上的元素表示不同维度上的权重。通过图像来描述不同的损失度量函数，给人直观的感觉。Xiao 等[28]提出了 TransG，TransG 能够解决关系的多语义问题，利用贝叶斯非参数无限混合模型对一个关系生成多个翻译部分，根据三元组的特定语义得到其中的最佳部分，并利用最大数据相似度原理进行训练，优化采用 SGD。

Lin 等[29]提出了 TransR 和 CTransR。TransR 在单独的实体空间和关系空间建立实体和关系的表示，每个关系对应一个空间，有一个映射矩阵，关系通过对应的映射矩阵映射到关系空间后，可以将关系向量转化成两个实体向量间的转移。CTransR 还将关系按照一定的类型划分为关系组，并以组为单位进行接下来的推理。Ji 等[30]在 CTransR 基础上提出了 TransD，实体和关系均用两个向量表示，第一个向量表示实体或关系的意义，第二个向量用来构造映射矩阵，通过对应关系和实体的第二个向量的乘积来表示实体的映射矩阵。该模型同时考虑到了实体和关系的多样性。Fan 等[31]提出了 TransM，直接根据关系的映射属性预先计算每个训练三元组的权重，用于加权损失函数。

Ji 等[32]提出了 TranSparse，TranSparse(share)和 TranSparse(separate)，解决了知识图谱中关系连接的实体对数目差异很大以及关系中头尾实体的数目差异很大的问题。

Guo 等[33]提出了 SSE(Semantically Smooth Embedding)学习知识图谱实体和关系的表示，利用实体语义类信息强制表示空间几何结构语义平滑。直观地，属于相同语义类的实体在表示空间中邻近，实体语义类信息作为损失函数的正则项。Nguyen 等[34]提出了 TransE-NMM(TransE-neighborhood Mixture Modeling)，在 TransE 的基础上定义基于邻居的实体表示，引入邻居实体信息进行实体和关系的表示学习。这两种模型都解决了未考虑丰富语义信息的问题。

Nickel 等[35]提出了 RESCAL，基于三阶张量进行表示学习，如果三元组成立，三阶张量上对应的元素值为 1，否则为 0。通过最小化重构误差学习实体和关系的表示提高了推理准确率，但其内存占用量大，计算速度慢。Chang 等[36]提出了 TRESCAL，引入实体类型信息这一关系域知识，在损失函数的计算中排除不满足关系特定的实体类型约束的三元组，加速了计算。Nickel 等[37]提出了新的张量分解模型(Additive Relational Effects，ARE)学习知识图谱三元组的隐性和观察到的模式，用一个附加项增广 RESCAL 模型(隐性模式)，对应观察到的模式，并且可以通过减少不连接的部分来降低 RESCAL 分解需要的阶。Trouillon 等[38]提出了基于复数值向量表示的矩阵分解方法进行链接预测。关系矩阵的分解形式化为对称矩阵和反对称矩阵的和，能够更好地处理对称和反对称关系。

上述方法虽然准确率较高，计算速度相对较快，但是都不能处理动态变化的知识图谱。Tay 等[39]在 RESCAL 基础上提出了 RSTE 模型，该模型采用了分治策略，从知识图谱中采样多个更小规模的子图；通过 RESCAL 进行连接预测，这个模型很大程度上降低了内存的占用，减少了运行时间，可以快速对动态变化的知识图谱进行增删操作。

He 等[40]提出了 KG2E 模型，直接建模实体和关系的确定性，在多维高斯分布空间中学习知识图谱的表示。每个实体或者关系用一个高斯分布表示，并使用均值指示实体位置，用协方差传达实体或关系的不确定度。该模型的得分函数使用基于实体转移分布和关系分布的 KL 散度计算。KL 散度的非对称性使得 KG2E 可以有效处理多种类型关系。Xiao 等[41]提出了基于流形的表示模型 ManifoldE，将三元组在向量空间的一个点扩展到了一个流形结果，取得了很好的链接预测效果。

综上，多样本知识图谱推理中基于分布式的单跳推理表示现在主要可以分为 Trans 系列、基于张量分解以及基于空间表示的 3 类。Trans 系列目前研究的工作已经比较全面，进一步研究的价值较小。基于张量分解的方法具有可解释性强、实验的准确性较高等优点，但是时间复杂度较其他方法高，所以推广使用的代价较高。基于空间表示的方法在空间上模拟三元组结构的分布，推理能力较强，但是该类方法研究还不是很多，进一步发展的空间很大。表 3 对单跳推理方法进行了总结。

(2)多跳推理

Lin 等[42]提出了 PTransE，区别对待实体间的不同路径。PTransE 在 TransE 的基础上多建模了关系路径约束，通过关系的组合操作建模路径，然后对实体间的多条路径进行加权，提高了推理的准确性。之后，Lin 等[43]提出了关系路径表示的组合学习模型 RPE(Relation Paths Embedding)，其推理效果优于 PTransE。Feng 等[44]提出了图感知的知识表示方法 GAKE(Graph Aware Knowledge Embedding)，利用图上下文信息的同时设计了 attention 机制，提高了样本信息的利用率与推理结果。Wang 等提出使用邻居信息和内存网络，发掘样本数据潜在的关系信息，并把门控机制、结构和邻居的表示集成到联合表示中，丰富实体的特征信息。Wang 等[45]

提出了一种基于组合的方法，首先通过随机行走找到实体之间的多条路径，并根据其与查询的语义相似性计算每条路径的注意力，然后根据它们的注意力聚合这些路径的表示，最终结果基于该聚合表示和查询的相似性形成。Chen 等[46]提出了一种新的 RL 框架，用于学习更准确的链路预测模型，该模型将 KG 中的链路预测问题构建为概率图形模型（PGM）中的推理问题，并使用最大熵 RL 来最大化预期回报。

多跳推理是在单跳推理的基础上加上多跳关系的建模，其建模方式主要可以分为两种：补充建模和共同建模。补充建模的方式是以单跳关系为主，然后利用多条关系的约束辅助学习；共同建模的方式是同等对待直接关系和间接关系，获得更好的向量表示。后者虽然可能获得更好的间接关系向量表示，但是也有较大的可能引入级联误差，将中间的一个误差逐步放大，使最终预测结果偏离实际结果；并且这样的预测过程类似基于传递性规则的推理。因此，如何避免或者减少级联误差是一个值得研究的方向。

表 3 多样本知识图谱种基于分布式单跳推理方法的总结

Table 3 Summary of multi-sample knowledge graph based on distributed single-hop reasoning method

方法名	提出人	原理简介	说明
TransE	Bordes 等	使用欧几里得距离作为得分函数	第一个基于转移的模型，Trans 系列最基础的模型
TransH	Wang 等	为每一个关系多学一个映射向量	一定程度缓解了不能很好处理多映射的问题
m-TransH	Wen 等	直接建模多元关系，将多元关系每一个元看成一个角色	
TransA	Jia 等	引入 Wr 矩阵为不同的向量进行加权，并且利用 LDL 方法对其分解	针对参数与时间方面的不足进行改进
TransG	Xiao 等	利用贝叶斯非参数无限混合模型对一个关系生成多个翻译部分，采用 SGD 优化	第一次从产生式的角度看待表示学习，能够解决关系的多语义问题
TransR	in 等	在单独的实体空间和关系空间，每个关系有一个映射矩阵	将关系与实体用向量矩阵表示，改进了多属性关系推理
CTransR		在 TransR 的基础上将关系划分为关系组，以组为单位	
TransD	Ji 等	实体和关系均用两个向量表示，实体的映射向量为对应实体和关系第二个向量的乘积	同时考虑了实体和关系的多样性
TransM	Fan 等	根据关系的映射属性预先计算三元组的权重，用于加权损失函数	
TranSparese	Ji 等	用自适应的稀疏转移矩阵替换一般的转移矩阵	解决了知识图谱中关系连接的实体对数目差异很大以及关系中头尾实体的数目差异很大的问题
TranSparse(share)		转移矩阵的稀疏度由关系连接的实体对数目决定，头尾实体共享相同的转移矩阵	
TranSparse(separate)		每个关系有两个单独的稀疏转移矩阵，头尾实体各一个	
SSE	Guo 等	学习知识图谱实体和关系的表示，属于相同语义类的实体在表示空间中邻近	解决了 TransE 中为考虑丰富语义信息的问题
TransE-NMM	Nguyen 等	引入实体邻居节点信息进行实体和关系的表示学习	
RESCAL	Nickel 等	基于三阶张量进行学习，最小化重构误差进行学习实体关系的表示	将三元组看成张量/矩阵的元素，通过张量分解方法进行学习，元素值对应是否有效的得分，从而筛选得分较高的候选三元组
ARE		增广 RESCAL 模型，学习三元组的隐形和观察到的模式	
TRESCAL	Chang 等	引入实体类型的信息，在损失函数的计算中排除不满足关系的三元组	通过筛选符合条件的三元组提高计算速度
（没有特殊名称）	Trouillon 等	关系矩阵的分解形式化为对称矩阵和反对称矩阵的和	更好地处理矩阵对称和反对称的关系
RSTE	Tay 等	采用分治策略，从知识图谱中采样多个更小规模的子图	降低了内存的占用，减少运行时间，可以快速对动态知识图谱进行操作
KG2E	He 等	直接建模实体和关系的确定性，在多维高斯分布空间中学习知识图谱的表示，得分函数使用 KL 散度计算	能够有效处理具有多种类型关系的知识图谱
ManifoldE	Xiao 等	将三元组的位置从向量空间扩展到一个流形结构	将之前头实体向量加关系向量等于尾实体向量的假设扩展到了流形函数，链接预测效果更好
TranSparse(separate)		每个关系有两个单独的稀疏转移矩阵，头尾实体各一个	
SSE	Guo 等	学习知识图谱实体和关系的表示，属于相同语义类的实体在表示空间中邻近	解决了 TransE 中为考虑丰富语义信息的问题

3.3 基于神经网络的推理

近年来，伴随着神经网络技术的快速发展，基于神经网络的知识图谱研究受到了广泛的关注。神经网络在知识图谱推理方面具有可以实现自学习功能、计算速度快、准确性高的优点，在单跳推理方面，主要是通过直接建模知识图谱三元组的方式得到向量表示，完成进一步推理；在多跳推理中，除了直接建模多跳关系之外，还可以通过模拟人脑的推理过程进行推理。

（1）单跳推理

Socher 等[47]提出了 NTN（Neural Tensor Network），用双线性张量层代替传统的神经网络层，将头实体和尾实体联系起来，能够在不同的维度下表示出实体间复杂的语义联系。其中，实体的向量表示通过词向量的平均得到，充分利用词向量构建实体表示。模型的评价结果反映：如果头尾实体之间存在特定关系，则返回高的得分；否则，返回低的得分。Chen 等[48]在 2013 年通过类似的神经张量网络模型预测知识图谱中新的关系，主要的创新是通过从文本无监督学到的词向量初始化实体表示，可以实现类似零样本的效果，甚至可以预测知识图谱中未出现实体的关系。近期，Shi 等[49]在 2017 年提出了共享变量神经网络模型 ProjE，它通过学习知识图的实体和边的联合嵌入，并通过对标准损失函数的更改，来填补知识图中缺失的信息。Nguyen 等[50]提出了一种新的模型 ConvKB，该模型通过使用卷积神经网络，能够捕捉实体和关系之间的全局关系和过渡特性。在 ConvKB 中，每个三元组（头实体，关系，尾实体）被表示为一个三列矩阵，其中每个列向量表示一个三重元

素；然后将这个三列矩阵送入卷积层，在该卷积层上操作多个滤波器以生成不同的特征映射；接着将这些特征映射连接到表示输入三元组的单个特征向量中，通过点积将特征向量与权重向量相乘，以返回分数；最后用这个分数来预测三元组是否有效。

基于神经网络的单跳推理的优点是能过利用神经网络强大的学习、推理能力来建模知识图谱三元组，但是神经网络的可解释性一直是一个严重的问题，如何提高解释性是一个值得研究的方向。

(2)多跳推理

在神经网络的多跳推理中，主要有两种方法：通过神经网络建模多跳路径，模拟人脑的过程进行推理。前者充分学习多跳路径的表示，然后根据路径的表示和直接关系表示的相似度来得到得分；后者主要利用一个外部存储结构模拟人脑的存储，利用人脑的强大推理能力得到推理结果。Neelakantan 等[51]为每个关系类型训练一个 RNN 得到任意长度的组合表示，通过输入路径上的关系向量和当前的路径向量产生下一步的组合向量，最后一步的输出作为路径向量的表示。该模型的训练目标是最大化正确三元组的概率。其缺点是只考虑一条路径，没有考虑其他路径以及不同路经的权重问题，也没有考虑实体的建模。Das 等[52]在 2017 年提出新的模型，该模型通过训练一个 RNN 模型预测所有的关系类型，然后利用注意力机制在多条路径上进行推理，并联合学习与推理关系类型、实体以及实体关系，提高了在多样本知识图谱上推理的准确性和实用性。Graves 等[53]提出了 DNC(Differentiable Neural Computer)，其中包含一个 LSTM 神经网络控制器和可以读写的外部存储矩阵。知识图谱三元组向量作为输入，通过神经网络对外部存储进行读写，模拟人脑利用先验知识学习推理新知识，并更新已有的知识。Wang 等[54]基于最近提出的具有大量外部记忆和灵活写入/读取方案的神经记忆网络，设计了一种新模型 TravNM(见图 2)，引入单个网络层，然后将其用作 TravNM 的多层神经网络的构建块，并开发灵活的内存更新方法，以便于在多跳推理期间将中间实体信息写入存储器。

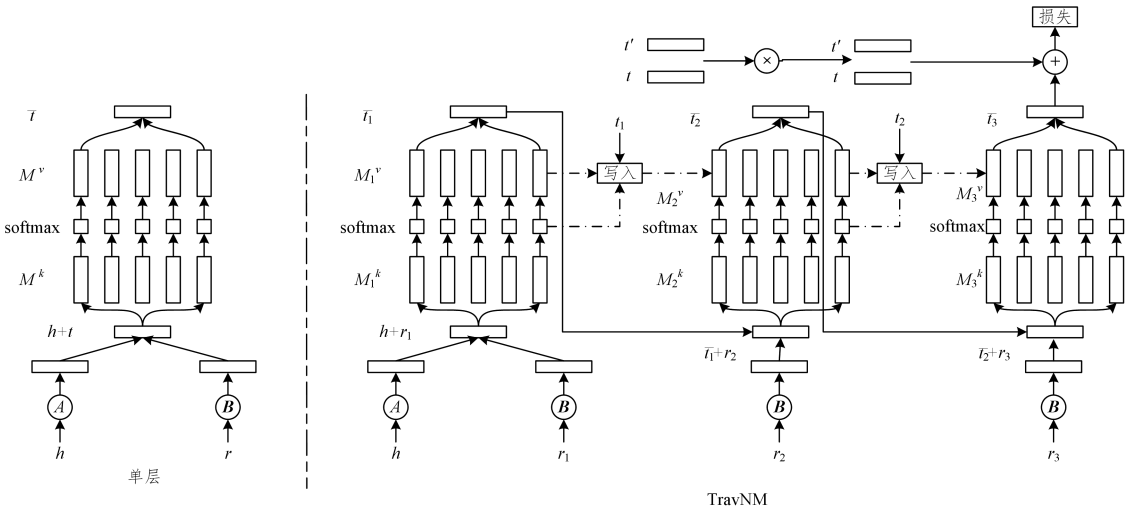

图 2 TravNM 模型示例[55]

Fig. 2 Example of TravNM model[55]

相比单跳的知识图谱推理，上述两种基于神经网络的多跳推理方法研究的方向更多，可解释性也有更强，是一个比较热门的方向，其重点在于提高模拟人脑推理的可解释性。

3.4 混合推理方法

除了以上基于一种原理的模型之外，还有将它们组合起来的模型，比如混合规则和分布式表示的推理、混合神经网络与分布式表示推理、混合规则与神经网络的推理等。由于单跳推理的步骤更为简单，所以混合单跳推理的方法虽然实现了优势互补，但是还在浅层的混合，利用一种方法去弥补主要方法的缺点。目前，在单跳推理方面，由于神经网络被广泛关注，因此未来以神经网络为主的混合单跳推理值得进一步研究。由于混合多跳推理存在多步约束，所以混合多跳推理的方法更为丰富，两种方法深层次的结合共同建模产生了更好的效果。神经网络方法的强学习能力和高泛化能力，以及基于规则的方法的高效果和高解释性，将促使这方面在未来取得更好的成果。

(1)混合规则和分布式表示的推理

Han 等[55]使用分布式辅助规则，并且加入了上下文关系，提出了上下文敏感的方法。该方法基于关系图学习特定的上下文关系，然后计算关系向量之间的相似度，通过设定阈值选取推理规则。Wang 等[56]通过矩阵分解直接学习一阶逻辑表示，首先从三元组训练集产生推理规则集合，然后将证明图转为一个矩阵，进行映射推理。在共同建模方向，Guo 等[57]提出了 KALE(Embeddings by Jointly Modeling Knowledge and Logic)模型，在一个统一框架中通过三元组和规则联合建模，将三元组和规则都形式化为对应的公式。训练目标是最小化公式的全局损失，然后获得实体和关系的向量表示。

(2)混合神经网络与分布式表示推理

Schlichtkrull 等[58]使用 R-GCN 建模知识图谱，并且通过邻居实体节点产生隐性特征向量表示，通过头实体向量的转置向量、关系的对角矩阵与尾实体向量的乘积表示得分函数，通过模型的交叉熵损失进行训练学习。

(3)混合神经网络和规则的推理

端对端的模型 Neural LP[59]在 TensorLog[13]的基础上引入了注意力机制(attention)和外部储存的神经网络系统；Neural LP 通过 LSTM 和 attention 机制来实现对所有储存向量的加权，然后计算所有向量的加权平均，通过 attention 来

选择合适的规则长度进行推理。

总体来说，混合多步推理更为丰富，结合更深层次，可以实现优势互补，其中混合规则和神经网络方向、神经网络与分布式值得进一步研究。

3.5 部分多样本知识图谱

多样本知识图谱推理算法主要是需要较多的样本，所以该方向对于数据集的筛选没有特别高的约束，本节将对常用数据集进行介绍。

Freebase 数据集：类似于维基百科，Freebase 的内容是由社区成员贡献的结构化知识。除了人工输入外，Freebase 也主动导入如维基百科的结构化知识，包含超过 125 000 000 个 tuple 关系元组、超过 4 000 种类别和 7 000 多种属性，支持信息之间的丰富关联并且赋能这种关联的使用。目前，本方向论文中常用的是 FB13 数据集[1)]，FB13 是 Freebase 的子集，包含 13 种关系和 75000 种实体。表 4 列出了 FB13 数据集的数据量信息。

表 4 FB13 数据集信息

Table 4 FB13 dataset information

类别	数量	类别	数量
# Relation	13	# Valid	5 908
# Entity	75 043	# Test	23 733
# Train	316 232		

WordNet 数据集[2)]：WordNet 是一个描述英文词汇之间关联特点的数据集，同时也是一个数据库。该数据库将英语名词、动词、形容词和副词与同义词联系起来，这些同义词通过语义关系相互联系，从而确定单词的定义。该数据集构建起一个关于 word 的网络，并且试图为这个网络增加语义信息。该网络构建之初，提出了 6 种词汇之间的同义、反义、上义与下义、部分整体关系、方式关系和蕴含关系。该方向最近论文中常用的是 WN18 数据集，其是 WordNet 数据集的子集。WN18 数据集[3)] 中的主要模式是对称关系、非对称关系和反转关系。

YAGO(Yet Another Great Ontology)数据集[4)]：由马克斯·普朗克计算机科学研究院开发的一个开源知识库，从 Wikipedia 和其他来源自动提取。截至目前，YAGO 拥有超过 1 000 万个实体的知识，并且包含有关这些实体的 1.2 亿多个事实。YAGO 中的信息是从 Wikipedia(例如类别、重定向、信息框)，WordNet(例如同义词集、下位字母)和 GeoNames 中提取的。手动评估 YAGO 的准确性达到 95%以上。YAGO 还考虑了时间和空间知识，为很多知识条目增加了时间和空间维度的属性描述。目前，YAGO 包含 1.2 亿条三元组知识。YAGO 是 IBM Watson 的后端知识库之一。

4 少样本知识图谱推理

如图 3 所示，知识图谱推理中数据有很大一部是长尾实体，并且包含很少的三元组信息，这样的数据可以称作少样本关系(Few-shot)[60]。事实上，自动抽取实体与关系构建的知识图谱，数据量大，噪声数据以及不完整的数据占很大一部分，现在知识图谱补全领域的研究也是一个研究热点。少样本知识图谱推理主要是通过几个实例去训练模型，进行实体预测或者关系预测。

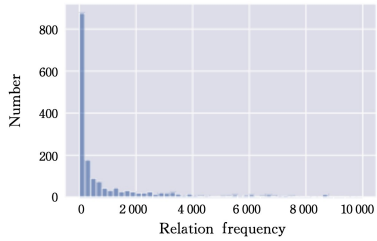

图 3 Wikidata 中的相关频率直方图[60]

Fig. 3 Correlation frequency histogram in Wikidata[60]

4.1 基于元学习的推理

链接预测是知识图谱完成(Knowledge Graph Completion)的重要方法，而基于嵌入的方法对 KG 中的链接预测有效，但是对只有几个关联三元组的关系表现不佳。

Chen 等[61] 提出了一个元关系学习(MetaR)框架来进行 KG 中常见但具有挑战性的少量链接预测。Chen 提出了两个储存单位：关系元(Relation Meta)和梯度元(Gradient Meta)。关系元表示在支持集和查询集中连接头和尾实体的关系，该方法从支持集提取每个任务的关系元，以向量表示，并将其转移到查询集；梯度元是支持集中关系元的损失梯度。由于梯度元显示了如何更改关系元以达到损失最小值，从而加快学习过程，因此关系元在被转移到查询集之前通过梯度元进行了更新。此更新可以看作关系元的快速学习。这个模型主要由关系元学习器和嵌入学习器两部分组成。前者是为了从支持集中提取关系元，并且从支持集中学习长尾实体到关系元的映射；后者通过梯度元对关系元进行快速更新，通过一个得分函数来评估特定关系下实体对的真值以及它们的任务损失函数；通过最小化损失函数来更新模型。

元学习框架模型在 GMatching 基础上使用元知识进行改进，在多跳的结果上有很大的改进，并且不依赖背景知识图。但是该模型受到实体的稀疏性和任务数量的影响，如果数据集极度稀疏，性能会差很多；选择训练前实体嵌入是更好的选择。

Lv 等[62] 参考了 Lin 提出的多跳推理方法[63]，同样采用元学习从高频关系中学习有效的参数，从而能快速适应少样本关系，提高了推理结果的可解释性。Lv 等提出了一个新的模型(Meta-KGR)，其使用 MAML(Model-agnostic Meta-learning)算法[64] 进行初始化参数学习。该模型分为两部分：特殊关系学习和元学习。前者通过学习一个特定于关系的多跳代理来搜索知识图谱上的推理路径和目标实体；后者的目标是学习良好初始化的参数 θ^*，这样参数的微小变化将对任何任务的损失函数产生显著的改进。在形式上，该模型使用参数 θ 的元策略网络。当适应新任务 Tr 时，模型的参数变为 θ_r'。在 MAML 之后，使用任务 Tr 上的一个或多个梯度下降

1) FB13 数据集：https://download.csdn.net/download/qq_21097885/110130

2) WordNet 数据集：http://www.github.com/moos/wordnet-db

3) WN18 数据集：https://download.csdn.net/download/qq_21097885/1101393

4) YAGO 数据集：https://old.datahub.io/zh_CN/dataset/yago

更新来计算更新的参数θ_r'。

Meta-KGR 模型的稳定性很高，在不删除任何三元组的情况下，对于 K 是稳健的，并且优于基线模型；使用自适应元学习提高了少样本数据的可解释性和有效性。但是，该模型使用的少样本数据要求训练的三元组有高频的关系，不能很好地适应大多知识图谱。

Wang 等[65]提出了一种新的元学习框架。针对不同的训练任务，该框架设计的元编码器将元信息编码为特定的初始化参数。这使得推理模块在学习对不同关系进行推理时可以有不同的起点，元编码器能够解决原始推理代理新的查询关系的嵌入很难初始化的问题。该模型的元编码器对有关任务的一些元信息进行编码，并且将状态定义为查询问题、推理答案和当前位置的组合结果；使用 LSTM 表示先前的隐藏状态；使用两个线性层对观察值进行编码，动作分布使用动作嵌入和级联嵌入投影之间的匹配分数来表示。

元编码分为邻居编码器和路径编码器。邻居编码器可以利用相邻实体的信息来表示起始实体和终止实体之间的差异，路径编码器考虑到了图谱中的成功路径，提高了推理的准确率。

该模型在 FB15K-237 数据集上的性能优于基线模型，能够对不同的初始点有不同的初始化。但是邻居编码器对于邻居数较小的数据集，比如 NELL，效果比较差。路径编码器对于查询路径较多的推理比较繁琐，不是很稳定，在样本大小为 10～20 时有很好的实验结果。

少样本知识图谱中基于元信息的推理主要将仅有的训练样本进行划分，利用元学习可以通过之前的样本来指导新任务的预测，可以最大化地利用现有的样本。但现有的研究方法还比较少，值得进一步的研究。

4.2 基于相邻实体信息的推理

Zhang 等[66]提出了一个基于实体信息的模型 Few-Shot Relation Learning model(FSRL)，其目的是学习一个匹配函数，该函数可以为给定每个关系的少量参考实体对，有效地推断出真实实体对。首先，设计一种基于异构图结构和注意力机制的关系感知异构邻居编码器，以学习实体嵌入，它捕获了不同的关系类型以及对本地邻居节点的影响差异；然后，设计了一个循环自动编码器聚合网络，以对少样本触发的参考实体对的交互进行建模，并为每个关系积累其表达能力。通过参考集的聚集嵌入，该模型最终采用匹配网络来发现参考集的相似实体对；采用基于元训练的梯度下降方法来优化模型参数；学习到的模型可以进一步应用于推断任何新关系的真实实体对，而无需任何微调步骤。

FSRL 模型的优点在于利用图结构和异构性增加邻居节点信息的影响，并使用循环自动编码聚合网络提高了关系的表达能力，而且该模型的鲁棒性更高，同时在数据集上也有很大的改进。该模型的缺点是缺少多跳推理，解释性较差，并且所需时间随样本的增多指数增加。

少样本知识图谱多跳推理(MH-KG)推理包括多种场景。例如，给定头部实体和关系路径的条件下预测尾部实体；或者给定两个通过某些关系路径连接的实体的条件下预测实体之间的未知关系。Yin 等[67]提出了一种基于单跳改进的方法——循环单跳预测法：ROPs(Recurrent One-hop Predictors)。该模型的主要思想是模拟路径，使用 GRU 编码路径并且表达隐藏状态。Yin 等通过用不同的编码方式编码上下文关系，提出了 3 个体系结构 ROP_ARC1，ROP_ARC2 和 ROP_ARC3(见图 4)。

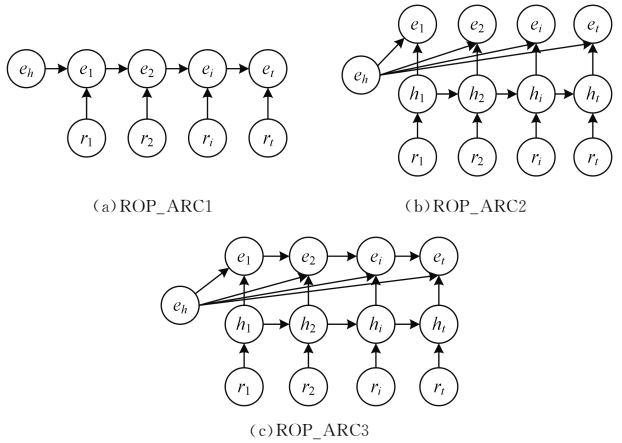

图 4 循环单跳预测法示意图[67]

Fig. 4 Schematic diagram of cyclic single-hop prediction method[67]

ROPs 模型能够建模任意长度的多跳路径，同时在每一步通过训练信号更新实体和关系表示。该模型也能够在统一框架内处理不同类型的 mh-KG 推理；还提出了一种新的多跳知识图谱路径 RNN 序列建模。但是该模型具有大量的反向关系，关系在不同路径长度的百分比较高，导致实验性能较差；并且没有通过实体嵌入与实体的分布式表示初始化来整合文本来源的知识。

之前的模型主要是在处理少样本的推理问题，虽然有涉及到权重分配的模型，但是都只是局限在固定的权重分配。为了解决这个问题，FAAN[68]根据实体在不同任务中扮演的不同角色，给实体不同的权重值。该模型中实体由自适应邻居编码器建模以识别其面向任务的角色，然后由自适应查询感知聚合器建模以区分其贡献。通过注意力机制，实体和引用都可以捕获其细粒度的语义，从而呈现更具表达力的表示形式。对于少数情况下的知识获取，这将更具预测性。该模型主要由 3 部分组成：1)自适应邻居编码器，用于学习自适应实体表示；2)变压编码器，用于学习实体对的关系表示；3)自适应匹配处理器，用于将查询任务与给定参考集进行比较。

FANN 能够更好地适应少样本知识图谱推理的不同任务，通过自适应的注意力机制捕获实体更细粒度的语义信息，这样能够提高模型的可解释性。但是其在单样本的情况下效果很差，同时缺少多跳推理，所需时间随任务样本数量增加而增加。

4.3 部分少样本知识图谱

相较于多样本知识图谱推理的数据集，少样本数据集需要更多的约束。例如，筛选出长尾实体或者很多不完整数据的数据集，然后进行算法的检测。

NELL-995 数据集[1)]：该数据集由 NELL 数据集发展而来。NELL 数据集先由一个框架一直从 Web 中不停地抽取信息，然后进行数据清洗和数据集成。NELL 数据集目前已经有 500 多万个实体数量和 5 亿多个关系。NELL-995 数据

1) NELL-995 数据集：http://www.github.com/moos/wordnet-db

集在 NELL 数据集的基础上，通过给所有的三元组增加反三元组(反向关系)扩展样本数量，这种数据处理方法适用于少样本的数据集。

FB15k-237 数据集[1)]：该数据集是 Freebase 数据集的子集，它产生于 2017 年。该数据集保留的关系主要是对称关系、非对称关系和组合关系，去除掉了反转关系。

WN18RR 数据集[2)]：该数据集是 WN18 数据集的子集，它在 WN18 数据集的基础上保留了原数据集的对称关系、非对称关系与组合关系，而去除了反转关系。

WikiData 数据集[3)]：WikiData 的目标是构建一个免费开放、多语言、任何人或机器都可以编辑修改的大规模链接知识库。

WikiData 由维基百科于 2012 年启动，它早期得到微软联合创始人 Paul Allen、Gordon Betty Moore 基金会以及 Google 的联合资助。同时，WikiData 继承了 Wikipedia 的众包协作的机制。但与 Wikipedia 不同，WikiData 支持的是以三元组为基础的知识条目(Items)的自由编辑。一个三元组代表一个关于该条目的陈述(Statements)。例如，可以给“地球”的条目增加相应三元组陈述。WikiData 是一个大型数据库，存储了维基百科、Freebase 中的海量信息。为了便于机器识别、算法调用，WikiData 在存储时将数据结构化成了固定的格式——RDF。

GMatching 模型能在没有路径的情况下取得较高的准确率，该方法也是第一次实现了对单样本的知识图谱推理，对以后的研究有很大的影响。但是从逻辑的角度看，它没有足够的证据证明知识图谱中没有连接路径实体对之间的关系，并且该方法仍然属于基于嵌入的方法，缺乏多跳推理和可解释性。该模型需要每个候选者都正向通过神经网络，但是这对于大规模知识图谱计算成本高，甚至难以处理；并且该模型过度关注相似性而不是实体间关系，所以推理过程可能导致不正确的事实。

Du 等[69]提出了认知知识图谱推理(CogKR)，其中摘要模块和推理模块一起工作以解决一次性知识图谱推理问题。在摘要模块中，CogKR 收集关于训练实例中的实体的知识，并且将实体间的基础关系表示为连续向量；在推理模块中，CogKR 通过关系向量和知识图谱推理出关系的新事实。因为单样本学习在很大程度上依赖先验知识，Du 等受人类推理过程的启发，将推理模块分为两个迭代过程(如图 5 所示)，系统 1 在知识图谱上检索并收集推理信息，系统 2 对收集的信息进行推理。模型使用一种称为认知图谱(知识图谱的子图)的独特结构来存储检索到的信息和推理结果。另外，由于单样本数据实体间关系较少，CogKR 采用反向传播技术增加实体间的关系，以设定阈值的方式作为停止搜索的条件。该模型的训练目标是最大化预测概率。

CogKR 相比传统基于嵌入的方法，有更好的推理能力，比 GMatching，能更准确地预测认知图谱中的实体。CogKR 在路径推理步数为 1，2，3 的推理结果上明显优于基线模型，该模型的运行时间随候选者数量增加基本保持不变；但是 CogKR 受知识图谱不连通性影响很大，该模型扩展节点必须有连接路径，适用范围小，且没有充分考虑知识图谱中结点的相邻结点信息。

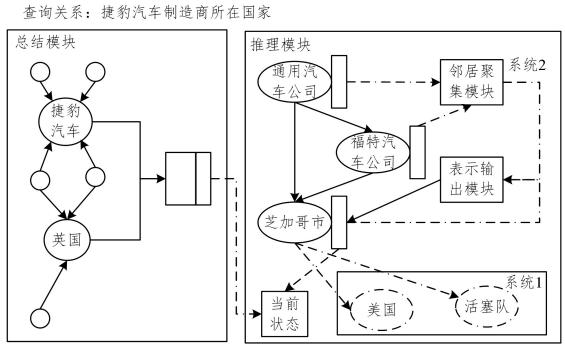

图 5 CogKR 框架概述[69]

Fig. 5 Overview of CogKR framework[69]

以上模型都只为静态知识图谱量身定制，并且不容易推广到时间设置。这种情况下，受到数据缺失的影响比较大。为了解决这个问题，Mirtaheri[70]等提出一种用于在时间知识图中进行链接预测的一次性学习框架 FTAG。FTAG 主要由两部分组成：邻居编码器和相似性网络。前者将给定实体 e 的邻域信息表示为一个二维向量。它将过去一定时间步的一跳邻居结构编码为一个序列，然后利用注意力机制捕获实体序列之间的时间相关性。后者将得到的序列在查询实例和支持集之间输出标量相似度得分，最后通过最小化损失训练得到一个单样本框架。

FTAG 模型第一个解决了单样本时间知识图谱的问题。它使用自注意力机制解决实体之间的时间信息编码问题，这样能够提高模型的可解释性。在预测不频繁关系的新事件时，FTAG 优于现有的基线方法。但是该模型不能适应少样本的场景，同时受实体稀疏性的影响仍然比较大。

零样本与单样本的知识图谱推理方法在知识图谱的补全方面有重要的意义，并且现有的研究成果较少，所以该方向研究更多的模型将是一个热点。

零样本与单样本知识图谱推理的常用数据集和少样本知识图谱推理常用数据集一样，但是在模型训练过程中样本筛选更为严格，面对的条件更为艰难。

5 未来研究趋势

5.1 多样本知识图谱推理方向

(1)混合推理的方向

该方向现有知识图谱混合推理效果更好的主要有混合神经网络和规则的推理与混合分布式和神经网络的推理。目前，已有的方法主要是通过一主一辅或共同建模的方法，未来该方向的研究可以探索更多混合的规则，或者可以在共同建模的基础上引入上下文信息、相邻实体信息和注意力机制加强实体属性信息。

(2)多元关系推理方向

目前的推理方法主要是面对一元、二元关系建立的，大部分推理方法是三元组存储推理结构，现在对多元关系的研究还

1) FB15K-237 数据集：https://github.com/deepakn97/relationPrediction

2) WN18RR 数据集：https://github.com/deepakn97/relationPrediction

3) wikidata 数据集：https://github.com/xwhan/One-shot-Relational-Learnin

很少。现实生活场景中，老师类型可能是语文老师、数学老师、英语老师等，这就是一个典型的多元关系结构。由于多元关系比一元与两元关系结构更加复杂，相关的实体信息更加多样化，上下文信息更加繁琐，目前的研究进展很缓慢。未来如何高效、准确、灵活地实现多元关系的推理，是一个较重要的研究方向。

(3)动态更新的推理方向

近年来，知识图谱的更新速度越来越快，目前已有的知识图谱推理方法大部分没有考虑到知识的时间约束条件，如何实现知识图谱的实时更新已经成为当前研究需要考虑的重要因素。比如在军事辅助决策系统中，如果系统可以快速获取最新的敌方武器数据，就可以降低指挥部做出错误指令的概率。动态更新的知识图谱推理方法需要能够对知识存储结构灵活地进行更新操作，目前已有的研究还只较为浅层，研究更有效的方法是一个重要的方向。

(4)神经网络推理的方向

近年，基于神经网络的知识图谱推理方法越来越多。虽然在多样本知识图谱推理领域充分利用神经网络的运行能力与推理能力可以有效提高推理结的果准确性，但是这样也引入了神经网络的解释性问题。现有方法主要是通过引入相邻实体信息、外部存储机制等多源信息提高解释性。未来研究更多的方法提高神经网络的解释性，可以改进知识图谱推理领域的很多方法，所以这将是一个长期的重点研究方向。

5.2 少样本知识图谱推理方向

(1)增加样本的方向

由于少样本知识图谱推理的样本量特别少，所以在少样本知识图谱推理的方向如何合理地增加样本量是一个重要的研究方向。现有的方法都使用样本的反向链路传播方法，还需要研究更多合适的增加样本的方法。

(2)先验知识方向

现有的方法都需要充分利用先验知识，模型需要先验知识作为训练的标准。少样本知识图谱推理方向的研究受限于样本量少的原因，模型训练会存在很大的错误先验知识概率，所以该方向的方法都需要一个纠错模块，例如 CogKR 模型中的总结模块的系统 2。减少先验知识噪声信息是少样本推理方向的一个重要研究方向。

(3)基于元学习的推理方向

现有的少样本推理方法中一部分是基于元学习方法的推理。元学习在少样本推理方向可以更好地学习训练模型，目前在该方面的研究还比较少，所以该方向是未来的一个研究热点。

5.3 零样本或单样本知识图谱推理方向

零样本和单样本知识图谱推理由于受到样本量的限制，现有的研究方法很少，但是有很大的研究必要性。目前主要是通过现有的数据集训练最大化推理正确率来得到一个框架，存在的问题还比较大，虽然研究的难度相对较高，但是值得进一步的研究。

5.4 通用的研究方向

除去样本数据类型关系比较大的研究方向以外，知识图谱推理研究还存在一些一直存在的研究方向：优化推理模型，提高模型的推理速度，知识图谱的补全与扩展，扩展知识图谱的类型等。

结束语 本文首先介绍知识图谱的来源、构建、基本知识和应用，然后介绍了现有的国内外常见知识图谱。之后，从知识图谱不同的样本量的角度，对不同样本的知识图谱推理算法进行了分类总结，具体从多样本、少样本、零样本或单样本知识图谱的推理模块进行分析、阐述，总结了现有知识图谱推理方法的优缺点、常用数据集，以及知识图谱的典型应用领域和未来潜在的研究方向。

参 考 文 献

[1] GUAN SP, JIN X L, JIA Y T, et al. Knowledge reasoning over knowledge graph: A survey[J]. Journal of Software, 2018, 29(10): 2966-2994.

[2] AUER S, BIZER C, KOBILAROV G, et al. Dbpedia: A nucleus for a web of open data[M]// The Semantic Web. Berlin: Springer, 2007: 722-735.

[3] BOLLACKER K, EVANS C, PARITOSH P, et al. Freebase: a collaboratively created graph database for structuring human knowledge[C]// Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data. 2008: 1247-1250.

[4] CARLSON A, BETTERIDGE J, KISIEL B, et al. Toward an architecture for never-ending language learning[C]// Twenty-Fourth AAAI Conference on Artificial Intelligence. 2010: 1306-1313.

[5] WU W, LI H, WANG H, et al. Probase: A probabilistic taxonomy for text understanding[C]// Proceedings of the 2012 ACM SIGMOD International Conference on Management of Data. 2012: 481-492.

[6] 自底向上构建知识图谱全过程[OL]. [2018-07-03]. https://zhuanlan.zhihu.com/p/38891715.

[7] MILLER G A. WordNet: An electronic lexical database[M]. MIT press, 1998.

[8] YOU B, LIU X R, LI N, et al. Using information content to evaluate semantic similarity on HowNet[C]// 2012 Eighth International Conference on Computational Intelligence and Security. IEEE, 2012: 142-145.

[9] ERXLEBEN F, GÜNTHER M, KRÖTZSCH M, et al. Introducing Wikidata to the linked data web[C]// International Semantic Web Conference. Cham: Springer, 2014: 50-65.

[10] HUANG H Q, YU J, LIAO X, et al. Review on Knowledge Graphs. Computer Systems & Applications, 2019, 28(6): 1-12.

[11] CARLSON A, BETTERIDGE J, KISIELB, et al. Toward an architecture for never-ending language learning[C]// Twenty-Fourth AAAI Conference on Artificial Intelligence. 2010: 1306-1313.

[12] WANG W Y, MAZAITIS K, COHEN W W. Programming with personalized pagerank: a locally groundable first-order probabilistic logic[C]// Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. 2013: 2129-2138.

[13] COHEN W W. Tensorlog: A differentiable deductive database[J]. arXiv: 1605.06523, 2016.

[14] PAULHEIM H, BIZER C. Improving the quality of linked data using statistical distributions[J]. International Journal on Semantic Web and Information Systems, 2014, 10(2): 63-86.

[15] JANG S, MEGAWATI M, CHOI J, et al. Semi-Automatic Quality Assessment of Linked Data without Requiring Ontology[C]// NLP-DBPEDIA@ ISWC. 2015: 45-55.

[16] LAO N, COHEN W W. Relational retrieval using a combination

of path-constrained random walks[J]. Machine Learning, 2010, 81(1): 53-67.
[17] LAO N, MITCHELL T, COHEN W. Random walk inference and learning in a large scale knowledge base[C]// Proceedings of the 2011 Conference on Empirical Methods in Natural Language Processing. 2011: 529-539.
[18] ZHAO Z, JIA Y, WANG Y. Content-structural relation inference in knowledge base[C]// Twenty-Eighth AAAI Conference on Artificial Intelligence. 2014: 3154-3155.
[19] KOTNIS B, BANSAL P, TALUKDAR P. Knowledge base inference using bridging entities[C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015: 2038-2043.
[20] GALÁRRAGA L A, TEFLIOUDI 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. 2013: 413-422.
[21] GALÁRRAGA L, TEFLIOUDI C, HOSEK, et al. Fast rule mining in ontological knowledge bases with AMIE $ $ + $ $ + [J]. The International Journal on Very Large Data Bases, 2015, 24(6): 707-730.
[22] GARDNER M, MITCHELL T. Efficient and expressive knowledge base completion using subgraph feature extraction[C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015: 1488-1498.
[23] LIU Q, JIANG L, HAN M, et al. Hierarchical random walk inference in knowledge graphs[C]// Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2016: 445-454.
[24] 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.
[25] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[C]// Proceedings of the 28th AAAI Conference on Artificial Intelligence. 2014: 1112-1119.
[26] WEN J, LI J, MAO Y, et al. On the Representation and Embedding of Knowledge Bases beyond Binary Relations[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. 2016: 1300-1307.
[27] JIA Y, WANG Y, LIN H, et al. Locally adaptive translation for knowledge graph embedding[C]// Thirtieth AAAI Conference on Artificial Intelligence. 2016: 992-998.
[28] XIAO H, HUANG M, HAO Y, et al. TransG: A generative mixture model for knowledge graph embedding[J]. arXiv: 1509.05488, 2015.
[29] LIN Y, LIU Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion[C]// Twenty-ninth AAAI Conference on Artificial Intelligence. 2015: 2181-2187.
[30] JI G, HE S, XU L, et al. Knowledge graph embedding via dynamic mapping matrix[C]// Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Long Papers). 2015: 687-696.
[31] FAN M, ZHOU Q, CHANG E, et al. Transition-based knowledge graph embedding with relational mapping properties[C]// Proceedings of the 28th Pacific Asia Conference on Language, Information and Computing. 2014: 328-337.
[32] JI G, LIU K, HE S, et al. Knowledge graph completion with a daptive sparse transfer matrix[C]// Thirtieth AAAI Conference on Artificial Intelligence. 2016: 985-991.
[33] GUO S, WANG Q, WANG B, et al. Semantically smooth knowledge graph embedding[C]// Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Long Papers). 2015: 84-94.
[34] NGUYEN D Q, SIRTS K, QU L, et al. Neighborhood mixture model for knowledge base completion[C]// Proceedings of the 20th SIGNLL Conference on Computational Natural Language Learning. 2016: 40-50.
[35] NICKEL M, TRESP V, KRIEGELH P. A three-way model for collective learning on multi-relational data[C]// Proceedings of the 28th Int'l Conf. on Machine Learning. New York: ACM Press, 2011: 809-816.
[36] CHANG K W, YIH W, YANG B, et al. Typed tensor decomposition of knowledge bases for relation extraction[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2014: 1568-1579.
[37] NICKEL M, JIANG X, TRESP V. Reducing the Rank in Relational Factorization Models by Including Observable Patterns [C]// Advances in Neural Information Processing Systems 27: Annual Conference on Neural Information Processing Systems. 2014: 1179-1187.
[38] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction[C]// International Conference on Machine Learning. PMLR, 2016: 2071-2080.
[39] TAY Y, LUU A T, HUI S C, et al. Random semantic tensor ensemble for scalable knowledge graph link prediction[C]// Proceedings of the Tenth ACM International Conference on Web Search and Data Mining. 2017: 751-760.
[40] HE S, LIU K, JI G, et al. Learning to represent knowledge graphs with gaussian embedding[C]// Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. 2015: 623-632.
[41] XIAO H, HUANG M, ZHU X. From one point to a manifold: Knowledge graph embedding for precise link prediction[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. 2016: 1315-1321.
[42] LIN Y, LIU Z, LUAN H, et al. Modeling relation paths for representation learning of knowledge bases[C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015: 705-714.
[43] LIN X, LIANG Y, GIUNCHIGLIA F, et al. Compositional Learning of Relation Path Embedding for Knowledge Base Completion[J]. arXiv: 1611.07232, 2016.
[44] FENG J, HUANG M, YANG Y, et al. GAKE: Graph aware knowledge embedding[C]// Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers. 2016: 641-651.
[45] WANG Z, LI L, ZENG D D, et al. Attention-based multi-hop reasoning for knowledge graph[C]// 2018 IEEE International Conference on Intelligence and Security Informatics (ISI). IEEE, 2018: 211-213.
[46] CHEN H, LI G, SUN Y, et al. A multi-hop link prediction approach based on reinforcement learning in knowledge graphs [C]// 2018 11th International Symposium on Computational Intelligence and Design (ISCID). IEEE, 2018: 165-169.

[47] SOCHER R,CHEN D,MANNING C D,et al. Reasoning with neural tensor networks for knowledge base completion[C]// Advances in Neural Information Processing Systems,2013:926-934.

[48] CHEN D,SOCHER R,MANNING C D,et al. Learning new facts from knowledge bases with neural tensor networks and semantic word vectors[J]. arXiv:1301.3618,2013.

[49] SHI B,WENINGER T. ProjE:Embedding projection for knowledge graph completion[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2017:1236-1242.

[50] NGUYEN D Q,NGUYEN T D,NGUYEN D Q,et al. A novel embedding model for knowledge base completion based on convolutional neural network[C]// Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2018:327-333.

[51] 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 of the Asian Federation of Natural Language Processing. 2015:156-166.

[52] DAS R,NEELAKANTAN A,BELANGER D,et al. Chains of reasoning over entities,relations,and text using recurrent neural networks[C]// Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics. 2017:132-141.

[53] GRAVES A,WAYNE G,REYNOLDS M,et al. Hybrid computing using a neural network with dynamic external memory[J]. Nature,2016,538(7626):471-476.

[54] WANG Q,YIN H,WANG W,et al. Multi-hop path queries over knowledge graphs with neural memory networks[C]// International Conference on Database Systems for Advanced Applications. Cham:Springer,2019:777-794.

[55] HAN X,SUN L. Context-Sensitive inference rule discovery:A graph-based method[C]// Proceedings of COLING 2016,the 26th International Conference on Computational Linguistics: Technical Papers. 2016:2902-2911.

[56] WANG W Y,COHEN W W. Learning First-Order Logic Embeddings via Matrix Factorization[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. 2016:2132-2138.

[57] GUO S,WANG Q,WANG L,et al. Jointly embedding knowledge graphs and logical rules[C]// Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016:192-202.

[58] SCHLICHTKRULL M,KIPF T N,BLOEM P,et al. Modeling relational data with graph convolutional networks[C]// European Semantic Web Conference. Cham:Springer,2018:593-607.

[59] YANG F,YANG Z,COHEN W W. Differentiable learning of logical rules for knowledge base reasoning[C]// Annual Conference on Neural Information Processing Systems. 2017:2319-2328.

[60] XIONG W,YU M,CHANG S,et al. One-shot relational learning for knowledge graphs[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018:1980-1990.

[61] CHEN M,ZHANG W,ZHANG W,et al. Meta relational learning for few-shot link prediction in knowledge graphs[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. 2019:4216-4225.

[62] LV X,GU Y,HAN X,et al. Adapting meta knowledge graph information for multi-hop reasoning over few-shot relations[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. 2019:3374-3379.

[63] LIN X V,SOCHER R,XIONG C. Multi-hop knowledge graph reasoning with reward shaping[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018:3243-3253.

[64] FINN C,ABBEEL P,LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]// International Conference on Machine Learning. PMLR,2017:1126-1135.

[65] WANG H,XIONG W,YU M,et al. Meta reasoning over knowledge graphs[J]. arXiv:1908.04877,2019.

[66] ZHANG C,YAO H,HUANG C,et al. Few-shot knowledge graph completion[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020:3041-3048.

[67] YIN W,YAGHOOBZADEH Y,SCHÜTZE H. Recurrent one-hop predictions for reasoning over knowledge graphs[C]// Proceedings of the 27th International Conference on Computational Linguistics. 2018:2369-2378.

[68] SHENG J,GUO S,CHEN Z,et al. Adaptive Attentional Network for Few-Shot Knowledge Graph Completion[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. 2020:1681-1691.

[69] DU Z,ZHOU C,DING M,et al. Cognitive knowledge graph reasoning for one-shot relational learning[J]. arXiv:1906.05489,2019.

[70] MIRTAHERI M,ROSTAMI M,REN X,et al. One-shot Learning for Temporal Knowledge Graphs[J]. arXiv:2010.12144,2020.



MA Rui-xin, born in 1975, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include big data and cloud computing.



ZHAO Liang, born in 1988, Ph.D, associate professor. His main research interests include big data and artificial intelligence.