

时态知识图谱的推理研究综述

沈英汉^{1,2)} 江旭晖^{1,2)} 王元卓^{1,3)} 李紫宣^{2),4)} 李子健^{1),2)} 谭鹤翔^{1),2)} 沈华伟^{1),2)}

¹⁾(中国科学院计算技术研究所数据智能系统研究中心 北京 100190)

²⁾(中国科学院大学 北京 100049)

³⁾(中科大数据研究院 郑州 450018)

⁴⁾(中国科学院计算技术研究所网络数据科学与技术重点实验室 北京 100190)

摘要 随着社交网络、物端感知等技术快速发展,网络空间中涌现了大量的交互、话题、事件、新闻等数据,蕴含大量动态演化、强时效性的知识.相较于忽略知识中时间信息的传统知识图谱,时态知识图谱通过建模知识的时效性以描述动态变化的现实世界,为时间紧耦合的应用提供有效支持.然而,时态知识图谱无法确保涵盖全量知识,知识的缺失严重影响应用性能,需要推理模型自动挖掘新的知识,以解释事物的历史状态,预测未来发展趋势并描述演化规律.由于实际应用的迫切需要,近年来,时态知识图谱的推理研究工作层出不穷,逐渐引起学术界和工业界的广泛关注.本文对近年来时态知识图谱的推理工作进行全面介绍和总结.首先,介绍了时态知识图谱的推理相关概念与问题描述;其次,介绍了面向补全任务的推理模型与面向预测任务的推理模型,对其进行比较分析;之后总结了时态知识图谱推理的数据集、推理任务、相关指标以及应用场景;最后展望时态知识图谱推理的未来研究趋势.综上,本文致力于为时态知识图谱的推理领域研究人员提供具有价值的参考,以推动该领域进一步发展.

关键词 时态知识图谱;时态知识推理;知识补全;知识预测;知识图谱

中图法分类号 TP391 **DOI号** 10.11897/SP.J.1016.2023.01272

A Survey of Temporal Knowledge Graph Reasoning

SHEN Ying-Han^{1),2)} JIANG Xu-Hui^{1),2)} WANG Yuan-Zhuo^{1),3)} LI Zi-Xuan^{2),4)} LI Zi-Jian^{1),2)}

TAN He-Xiang^{1),2)} SHEN Hua-Wei^{1),2)}

¹⁾(Data Intelligence System Research Center, Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190)

²⁾(University of Chinese Academy of Sciences, Beijing 100049)

³⁾(Zhongke Big Data Academy, Zhengzhou 450018)

⁴⁾(Key Laboratory of Network Data Science and Technology, Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190)

Abstract With the rapid development of technologies such as social networks and object-side perception, a large number of interactions, topics, events, news, and other data have emerged in cyberspace, containing a large amount of dynamic evolution and highly time-sensitive knowledge. Compared with traditional knowledge graphs that ignore temporal information in the knowledge, temporal knowledge graphs can describe dynamic features of the real world by modeling the temporal aspect of knowledge and provide effective support for temporal-aware applications. However, the temporal knowledge graph cannot guarantee to cover the total amount of knowledge, and the lack

收稿日期:2022-04-29;在线发布日期:2023-01-10. 本课题得到国家自然科学基金(U1836206, U21B2046, 62172393)、中原英才计划-中原科技创新领军人才项目(204200510002)、河南省重大公益专项(201300311200)资助. 沈英汉, 博士研究生, 中国计算机学会(CCF)学生会员, 主要研究方向为社交知识图谱、时态知识图谱推理. E-mail: shenyinhan17s@ict.ac.cn. 江旭晖, 博士研究生, 中国计算机学会(CCF)学生会员, 主要研究方向为社交知识图谱、异质图表示学习. 王元卓(通信作者), 博士, 研究员, 中国计算机学会(CCF)杰出会员与常务理事, 主要研究领域为知识图谱、社会计算. E-mail: wangyuanzhuo@ict.ac.cn. 李紫宣, 博士研究生, 中国计算机学会(CCF)学生会员, 主要研究方向为时态知识图谱、知识推理. 李子健, 硕士研究生, 主要研究方向为社交知识图谱、符号图表示学习. 谭鹤翔, 硕士研究生, 主要研究方向为社交知识图谱. 沈华伟, 博士, 研究员, 中国计算机学会(CCF)高级会员与 YOCSEF 总部 AC 委员, 主要研究领域为社交网络分析和社会媒体计算.

of knowledge seriously affects the application performance. The reasoning model is required to automatically mine new knowledge to explain the historical state of things, predict future development trends and describe the evolution laws. Due to the urgent need for practical applications, in recent years, the research works of temporal knowledge graph reasoning are emerging, attracting increasing attention from academia and industry. This paper comprehensively summarizes existing temporal knowledge graph reasoning studies in recent years. First, the related concepts and problem descriptions of temporal knowledge graph reasoning are introduced. Second, the reasoning models oriented to completion tasks and the reasoning models oriented to prediction tasks are systematically introduced, compared, and analyzed. The datasets, reasoning tasks, related indicators, and application scenarios of temporal knowledge graph reasoning are discussed. Finally, future research trends of temporal knowledge graph reasoning have been prospected. Above all, this paper is dedicated to providing valuable references for researchers in the field of temporal knowledge graphs reasoning for promoting further development in this field.

Keywords temporal knowledge graph; temporal knowledge reasoning; knowledge completion; knowledge prediction; knowledge graph

1 引言

时态知识图谱^[1] (Temporal Knowledge Graph) 由 Leblay 等人于 2018 年提出, 是一种在传统知识图谱中引入时间信息的知识图谱. 传统知识图谱由谷歌于 2012 年提出, 使用节点和边描述真实世界中实体之间的关联, 用于提高搜索引擎性能; 由于知识图谱具有强大的语义表达与推理分析能力, 当前, 知识图谱早已超越搜索引擎, 赋能更广泛的智能应用, 被认为是人工智能技术从感知智能跨向认知智能的重要阶梯. 然而, 传统知识图谱一般用于描述静态的常识知识, 较少考虑知识的时间信息, 无法管理网络空间中涌现的大量动态演化、具有时间信息的知识^[2], 即时态知识 (Temporal Knowledge); 难以应用于时间紧耦合的应用中, 如股票市场预测、政治事件预测、疫情传染链溯源等. 时态知识图谱考虑了知识中的时间信息, 有效管理动态演化的时态知识, 并为时间紧耦合的应用提供支持.

知识推理的目标是基于预定义规则或自动学习推理规则, 通过已知知识推断未知知识. 知识推理是时态知识图谱不可或缺的功能, 体现在以下两点: 首先, 时态知识图谱无法涵盖全量知识, 而知识的缺失严重影响下游应用性能, 如基于知识库的问答^[3-4] (Knowledge Base Question Answering, KBQA) 系统无法回答答案并不在知识库中的问句, 需要推

理模型自动挖掘缺失的知识; 其次, 下游应用需要预测未来将要发生的事件, 如电商软件中推荐系统^[5] 为用户推荐未来可能购买的商品, 医疗辅助决策系统^[6] 结合病人历史临床数据, 判断疾病未来发展趋势等.

时态知识图谱推理 (Temporal Knowledge Graph Reasoning) 研究时态知识如何以复杂的动态规律和逻辑规则相互影响和变化. 考虑到时态知识仅在固定的时间点或时间区间内成立, 以及时态知识持续涌现并不断演化, 较于传统的知识图谱推理工作, 其在学习结构信息与语义信息之外, 需要建模知识中的时间信息, 考虑知识的时效性, 以解释事物的历史状态, 预测未来发展趋势并描述演化规律, 具有巨大应用价值. 例如面向刑事侦查的推理模型分析涉案团伙成员在犯罪前后的行为以补全隐含线索, 挖掘潜在的团伙成员; 面向政治预测的推理模型依据政要人物历史行为建模其政治倾向性, 依此预测该政要法案投票结果; 面向风险评估的推理模型通过建模涵盖供应链、资金链、担保链数据的时态知识图谱, 学习风险在企业与金融机构中传播模式, 以识别系统性重大风险, 评估其带来的影响. 自时态知识图谱概念提出后, 由于实际应用的迫切需要, 近年来, 时态知识图谱的推理研究工作层出不穷. 其中 CIKM、EMNLP、WSDM、SIGIR、TKDE 等数据挖掘、自然语言处理与信息检索领域的国际顶级会议与期刊都刊出了相关工作, 推动该研究领域快速发展.

时态知识图谱的推理研究工作是知识图谱领域当前的学术研究与工业应用热点,然而截至目前,未有针对该专题的综述性工作.已有综述文献[7-11]总结了面向传统知识图谱的推理方法,但仅将其作为未来有潜力的发展方向简单展望,缺少对时态知识图谱推理工作的全面分析与总结.综述文献[12]以动态图表示学习中编码-解码器的视角简单探讨了部分时态知识图谱表示方法,但未专门从时态知识图谱推理专题的分类体系与应用出发,探究研究工作之间的关联;综述文献[13-14]介绍了时态知识图谱补充方法及其进展,但未涉及时态知识图谱的预测方法;综述文献[15]将时态知识图谱视作新一代知识图谱关键技术中的一部分,并作简要介绍,但涵盖工作不全面,未构建分类体系且未涉及模型之间性能比较.

本文致力于为对时态知识图谱推理方向感兴趣的研究人员提供参考,全面介绍该领域发展现状,以推动该领域的进一步发展.本文贡献包括:首先,系统地整理了时态知识图谱推理方向相关的研究工作,理清了其他综述中未提及的相关定义与任务描述;其次,充分调研了截至2022年7月之前的时态知识图谱推理工作,基于此提出系统的方法分类体系,从补充与预测的角度全面地总结了时态知识图谱的推理工作最新研究进展;进一步地,本文对各类时态知识图谱推理任务涉及的数据集、评价指标、实验结果与应用场景进行论述与总结,弥补了当前时态知识图谱推理专题综述的空白.

本文在第2节中介绍预备知识,包括概念定义与任务描述;第3节将时态知识图谱推理工作分为面向补充与面向预测的时态知识图谱推理方法两大类,在此基础上系统归纳已有的时态知识图谱推理研究工作,并比较其共性与特性;第4节介绍并分析时态知识图谱推理任务对应的数据集、相应任务的评价指标、模型在不同任务的评测结果以及应用场景等;最后,第5节讨论时态知识图谱推理面临的挑战以及有潜力的研究方向.

2 预备知识

本节内容涉及时态知识图谱、时态知识以及时态知识图谱推理等概念,以及时态知识图谱推理任务描述.

2.1 相关定义

本节首先给出了时态知识图谱与时态知识的定

义.考虑到时间信息的不同类型,本节进一步将时态知识分为无时态知识、瞬时知识与区间知识三类并依次给出了相应的形式化定义.最后我们给出了时态知识图谱现有的两种表现形式以及时态知识图谱推理任务定义.

定义 1. 时态知识图谱.时态知识图谱是包含时态知识的知识图谱,最早由 Leblay 等人^[1]提出.其表示为四元组 $G=(E,R,F,T)$ 形式. E 为时态知识图谱的实体集合; R 为时态知识图谱的关系类别集合; F 为时态知识图谱内的知识集合; $T=[t_0,t_T]$ 为时态知识图谱的可观测时间域,时间域的左右区间端点由知识集合 F 中知识的最早与最晚时间构成.

定义 2. 时态知识.时态知识 $f \in F$ 表示为四元组 (u,r,v,τ) 形式.其中 $u,v \in E$ 分别代表知识的头实体与尾实体, $r \in R$ 为知识的关系类别, $\tau \in T$ 为知识的时间信息,且 $\tau \neq \phi$ (ϕ 为空值).

通过关系类型的时间性质区分,时态知识包括瞬时知识与区间知识(此处 E,R,F,T 含义已在定义 1 中介绍).下面分别给出瞬时知识、区间知识与无时态知识的形式化定义.

定义 3. 瞬时知识(Instant Knowledge).当 f 中的时间信息满足:

$$\tau = \{t | t_0 \leq t \leq t_T\}$$

时, f 为瞬时知识. t 代表 f 的发生时间点.

定义 4. 区间知识(Interval Knowledge).当 f 中的时间信息满足:

$$\tau = \{[t_b, t_e] | t_b \neq t_0 \wedge t_e \leq t_T \wedge t_b < t_e\}$$

时, f 为区间知识. t_b 代表 f 的起始(生效)时间点, t_e 代表 f 的结束(失效)时间点.

定义 5. 无时态知识(Atemporal Knowledge).当 f 中的时间信息满足:

$$\tau = \phi$$

时(ϕ 为空值), f 为无时态知识.

瞬时知识常用于表示瞬发性的知识(如发送邮件行为、社交平台的点赞行为等);区间知识常用于表示具有延续性的知识,具备起始与结束时间(如人员任职于某单位等).无时态知识是与不具备时间信息(如常识性知识等经久不变的知识),被视作在可观测时间域中永久成立.图 1(a)展示了时态知识图谱中的瞬时知识、区间知识与无时态知识.表 1 从定性与定量的角度展示了瞬时知识、区间知识与无时态知识的区别.

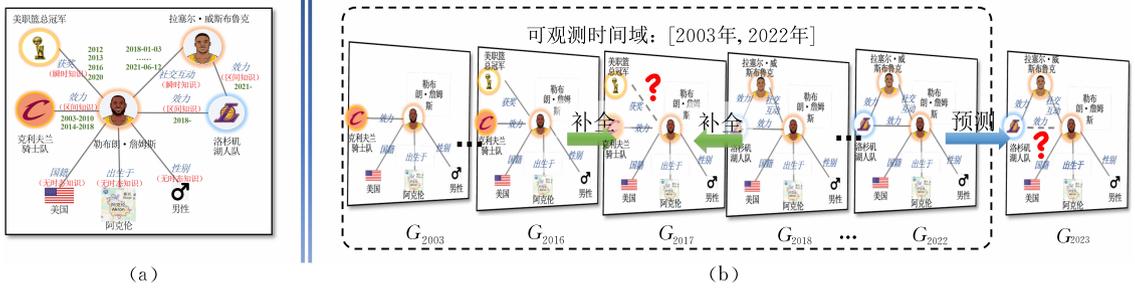


图 1 时态知识图谱的两种表示形式以及两种推理任务示意((a)为连续动态图形式,其中无时态知识、瞬时知识与区间知识通过关系上带时间属性的边表示;(b)为离散动态图形式,其中瞬时知识通过某个时间戳对应快照中的一条边表示,无时态知识与区间知识通过不同快照中的多条重复边表示)

表 1 无时态知识、瞬时知识与区间知识的区别

知识类别	定性区别	定量区别
瞬时知识 (u, r, v, t)	关系类型 r 具备瞬时性,知识的持续时间可忽略不计	时间信息表示为时间点
区间知识 ($u, r, v, [t_b, t_e]$)	关系类型 r 具备持续性,知识的有效期时间不可被忽略	时间信息表示为连续的时间区间
无时态知识 (u, r, v)	关系类型 r 具备持久性,知识被视作永久成立	无时间信息

时态知识图谱的表示形式. 根据不同的实际需求,时态知识图谱可被表示为离散时态动态图(Discrete Temporal Dynamic Graph, 简称为离散动态图)或连续时态动态图(Continuous Temporal Dynamic Graph, 简称为连续动态图)两种形式^[12].

为了方便读者理解两种表示形式的区别,图 1 以 Wikidata 中美职篮球员勒布朗·詹姆斯这一实体(实体 ID 为 Q36159)的相关知识为例,分别展示了时态知识图谱的连续动态图(对应图 1(a))与离散动态图(对应图 1(b))表示形式. 在离散动态图表示的时态知识图谱中,按照预定义的时间粒度,区间知识与无时态知识会被拆分为若干瞬时知识:在预定义时间粒度为年的前提下,区间知识(勒布朗·詹姆斯,效力于,克利夫兰骑士队, [2014 年~2018 年])表示为分别存在于快照 $\{G_{2014}, G_{2015}, \dots, G_{2018}\}$ 中的 5 条瞬时知识.

离散动态图的表示方式是根据预定义的时间粒度,对时态知识图谱进行均匀切分,得到静态图快照序列;较之连续动态图,其显式表达了时态知识图谱中的时序信息,简化了图谱的演化过程:每张快照内共享相同时间信息,可被近似视作图谱在某时刻的演化状态. 然而,预定义时间粒度过粗会造成时间信息的损失问题,忽略细粒度的图谱演化细节信息;反之,则会造成知识表示冗余问题,如图 1(b)所示,在多种时态知识并存的图谱中,区间知识需要被

划分为若干条存储在快照中;因此,离散动态图的表示方式对于大规模、时间跨度长的知识图谱并不友好. 连续动态图中的时间信息被视作边的属性,因此,这种表示方式更加灵活,可以被表示为时间点或时间区间的形式,不需要预定义时间粒度. 连续动态图可以转化为离散动态图,但反之不成立. 具体地,表 2 展示了两种表示形式的定义及特点.

表 2 时态知识图谱的表示形式

表示形式	定义	特点
离散动态图	G 表示为快照序列的形式: $G = \{G_0, \dots, G_T\}$, 时间作为快照的属性表示; t 时刻快照 $G_t = (E_t, R_t, F_t)$ 代表 G 在时间区间 $[t, t+1)$ 内的状态; E_t, F_t 分别为 G 在 t 时刻的实体集合与知识集合	时间只能表示为时间点的形式;可直接应用静态图分析方法,但存在表示冗余问题与时间信息损失问题
连续动态图	G 表示为四元组 $G = (E, R, F, T)$ 形式,时间作为知识的属性表示	时间可以表示为时间点或时间区间的形式;时间表示形式更加灵活,但难以直接应用静态图分析方法

定义 6. 时态知识图谱的推理. 时态知识图谱的推理是对时态知识图谱中未知信息的推断,包含时态知识图谱的补全(Temporal Knowledge Graph Completion)与时态知识图谱的预测(Temporal Knowledge Graph Prediction).

需要指出的是,对于无时态知识,由于不考虑知识的时间信息,“推理”、“补全”和“预测”三类表述是等价的. 但就时态知识而言,“推理”、“补全”和“预测”存在区别. 本文给出时态知识补全与时态知识预测的概念:

定义 7. 时态知识图谱的补全. 时态知识图谱补全的目标是推理可观测时间域内隐含的时态知识. 待补全知识的时间信息 t 位于已观测时间域内,即 $t_0 \leq t \leq t_T$ 或 $[t_b, t_e] \subseteq T$.

定义 8. 时态知识图谱的预测. 时态知识图谱预测的目标是推理在可观测时间域未来产生的知识.

待预测知识的时间信息 t 位于已观测时间域后,对于瞬时知识,满足 $t > t_r$;对于区间知识,满足 $[t_b, t_e] \not\subseteq T$ 且 $t_b > t_r$.

图 1(b)中展示了时态知识图谱的补全与预测任务的区别.由于连续动态图未显式表达时序信息,不能直观体现补全与预测任务的区别,故本文仅在离散动态图形式表示的时态知识图谱上展示了两种推理任务.补全和预测是基于已观测时间域 T 提出的概念,两者推理模式并不相同.在时态知识图谱补全中,由于待补全知识在可观测时间域内,可以利用 F 中相对于待补全知识的历史与未来的知识推理,即内插式(Interpolation)推理^[12],对应方法将时间

视作知识具有的额外特征,未刻意强调时间的单向性;在时态知识图谱预测中,由于预测的知识在可观测时间域外,只能利用时间单向的特征学习历史知识演化规律,即外插式(Extrapolation)推理^[12].鉴于此,本文分别从补全和预测的角度构建时态知识图谱推理方法分类体系.

2.2 时态知识图谱的推理任务

按照推理的对象区分,本文将时态知识图谱的推理任务由微观至宏观分为 3 大类,即实体级别推理任务、知识级别推理任务与图谱级别推理任务,并总结在表 3 中;各类任务的评测指标在第 4 节中会详细介绍.

表 3 时态知识图谱推理任务

推理任务名称	所属问题	评测指标
实体级别推理任务	动态实体分类	多分类问题或多标签问题
	实体推理	排序问题
知识级别推理任务	关系推理	二分类问题
	关系存在推理	排序问题
	关系类型推理	回归问题
	时间信息推理	区间预测问题
图谱级别推理任务	时态知识图谱分类	多分类问题
	时态知识图谱趋势分析	—

实体级别推理任务的目标是推理时态知识图谱中实体本身不断演化的性质,判断实体在某时刻所属类别,即动态实体分类^[16].时态知识由实体、关系与时间信息等元素构成,因此知识级别推理任务包括实体推理^[17]、关系推理^[1,18]与时间信息推理^[18],在给定时态知识中其他三元的情况下,判断缺失的元素.由于时态知识图谱随时间不断变化,图谱级别推理任务从宏观角度判断时态知识图谱的状态,以及状态演化趋势,包括时态知识图谱分类^[19-20]与时态知识图谱趋势分析^[21].

2.2.1 动态实体分类

传统知识图谱中的实体所属类别固定不变.在时态知识图谱中,实体在不同时间所属的类别可能是动态变化的,判断实体类别时需要考虑时间信息这一前提.动态实体分类的目标为:给定预先定义的 m 类实体类别集合 $\mathcal{E} = \{\epsilon_1, \epsilon_2, \dots, \epsilon_m\}$ 、时态知识图谱 G 中待标注类别的实体 $e \in \mathcal{E}$ 与时间点 $t \in T$,推理 e 在 t 时刻所属的一个或多个实体类别.动态实体分类属于多分类问题或多标签问题.

2.2.2 实体推理

实体推理的目标是给定缺失头实体的时态知识 $(?, r, v, \tau)$,或缺失尾实体的时态知识 $(u, r, ?, \tau)$,判断缺失的头实体或尾实体.实体推理属于排序问题.

2.2.3 关系推理

关系推理的目标是推断实体间的关系性质.关系推理可分为两类:第一类是关系存在推理问题,即判断实体之间是否存在关系;第二类为关系类型推理问题,即判断实体间存在的关系类型.

关系存在推理问题的目标是基于给定的时间信息 τ ,推断头实体 u 与尾实体 v 之间是否存在关系,但并不需要判断是何种关系.关系存在推理问题属于二分类问题.

关系类型推理问题的目标是推理缺失关系信息的时态知识 $(u, ?, v, \tau)$ 中的关系类别.关系类型推理问题属于排序问题.

2.2.4 时间信息推理

时间信息推理的目标是推断知识中缺失的时间信息.根据知识中时间信息性质的不同,时态知识图谱推理分为时间点推理与时间区间推理两类问题.

时间点推理的目标是判断瞬时知识 $(u, r, v, ?)$ 中缺失的时间点 t .时间点推理属于回归问题.

时间区间推理的目标是判断区间知识 $(u, r, v, ?)$ 中缺失的时间区间 $[t_b, t_e]$.时间区间推理属于区间预测问题.

2.2.5 时态知识图谱分类

时态知识图谱分类的目标为:给定预先定义的 n

类时态知识图谱状态类别集合 $\mathcal{T} = \{\gamma_1, \gamma_2, \dots, \gamma_n\}$ 与时态知识图谱在 t 时刻的状态快照 G_t , 推断 G_t 所属状态类别 $\gamma \in \mathcal{T}$, 时态知识图谱分类属于多分类问题。

2.2.6 时态知识图谱趋势分析

时态知识图谱趋势分析的目标为: 给定定时态知识图谱 G 与时间区间 $[t_1, t_2] \subseteq T$, 研究 G 在 $[t_1, t_2]$ 内的演变趋势. 时态知识图谱趋势分析属于定性研究问题, 并无问题的形式化定义。

3 时态知识图谱的推理方法

从可观测时间域的角度划分, 本文将时态知识图谱推理方法分类为面向补全的时态知识图谱推理方法与面向预测的时态知识图谱推理方法. 前者包括基于张量分解的推理方法、基于转移表示的推理方法与基于规则的推理方法; 后者包括基于游走路径的

推理方法、基于时序点过程的推理方法、基于序列神经网络的推理方法与基于增量式更新的推理方法。

3.1 面向补全的时态知识图谱推理方法

时态知识图谱补全任务的关键是使模型理解已观测时间域内的时间信息, 并将其时间信息整合至知识图谱中复杂的语义与结构信息中进行推理. 面向补全任务的推理方法通过学习实体在特定时刻的表示, 以补全缺失的知识. 基于张量分解的推理方法从宏观角度学习整个图谱的演化规律, 通过预定义的分解方法得到实体、关系与时间的表示; 基于转移表示的推理方法从微观角度学习实体的演化规律, 从时态知识数据中学习得到实体、关系与时间的表示. 基于规则的推理方法通过显式符号表达推理规则, 通过图谱中已有的知识, 演绎推理缺失的知识. 表 4 列举了面向补全任务的时态知识图谱的推理方法。

表 4 面向补全的时态知识图谱推理方法对比

方法名称	代表方法	时态知识图谱表示形式	时间信息建模方式	方法特点	方法优缺点	
基于张量分解的推理方法	基于串行分解的推理	BCGD ^[22] 、DHPE ^[21] 、DyHNE ^[23] 、Yu 等人 ^[24] 、LIST ^[25] 等	离散动态图	串行分解每张快照, 基于平滑假设约束实体变化, 以体现时间信息的渐变性, 或直接建模可学习的时态矩阵	从宏观的图谱角度学习实体、关系与时间表示	优点: 成熟度高, 推理性能稳定 缺点: 分解算法复杂度高, 在大规模知识图谱中推理效率低下; 可解释性差
	基于并行分解的推理	Dunlavy 等人 ^[26] 、Lacroix 等人 ^[27] 、Tresp 等人 ^[28] 、ConT ^[29] 、TIMEPLEX ^[124] 等	离散动态图	将时间信息视作高维张量的一维, 通过并行张量分解得到时间信息的表示		
基于转移表示的推理方法	时间信息显式表示的推理	TAE ^[30] 、TTransE ^[1] 、HyTE ^[18] 、TOKEI ^[31] 、TeLM ^[32] 等	连续动态图	时间信息独立于实体和关系的表示, 被显式表示为可训练的向量或投影矩阵	从微观的知识角度学习实体、关系与时间表示	优点: 训练效率高, 可扩展性强 缺点: 不适用于变化频繁、时间信息丰富的知识图谱; 可解释性差
	时间信息隐式表示的推理	TRESCAL ^[1] 、DE ^[33] 、ATiSE ^[34] 、T-GAP ^[35] 等	连续动态图	时间信息在时变的实体与关系的表示中被隐式表达		
基于规则的推理方法	Dylla 等人 ^[36] 、Chekol 等人 ^[37] 、Chekol 等人 ^[38] 、ETC ^[39] 等	连续动态图	—	通过预定义推理规则或在软规则基础上应用概率方法推理	优点: 可解释性强 缺点: 推理方式不灵活, 可扩展性差	

3.1.1 基于张量分解的推理方法

时态知识图谱表示为离散动态图形式, 其中每一张知识图谱快照可被建模为矩阵序列或高维张量的形式, 通过张量分解的方法得到实体、时间等对应向量, 再重构张量以挖掘隐含的知识, 重构张量中的元素值即为对应知识的置信度得分. 基于张量分解的推理方法可分为基于串行分解的方法与基于并行分解的方法。

(1) 基于串行分解的推理

基于串行分解的推理通常被用于建模单关系的时态知识图谱, 时态知识图谱被表示为离散动态图

的形式, 每张快照表示为二维 0-1 矩阵序列 $G_t \in \mathbb{R}^{|\mathcal{E}_t| \times |\mathcal{E}_t|}$; 其关注时态知识图谱每一时刻的状态, 串行分解每张快照, 得到实体在各时刻的表示。

按照演化规律建模方式的不同, 基于串行分解的方法可分为两类. 第一类方法基于平滑演化 (Smoothing Evolving) 假设, 认为时态知识图谱的演化是平缓渐变的. 在分解快照 G_t 时, 在使分解后的低维实体向量尽可能还原快照结构外, 快照序列中相邻时刻的实体向量应尽量相似. 面向关系推理任务的 BCGD^[22] 对角化分解 G_t , 得到 t 时刻的实体表示 V_t , 在最大程度还原图谱快照中拓扑结构的同

时,还考虑了相邻快照中实体表示的变化. BCGD 的损失函数包含了重建链接损失与平滑演化的正则化项,后者在损失函数中约束了相邻时间快照的实体表示 $\mathbf{V}_t(u)$ 与 $\mathbf{V}_{t-1}(u)$ 变化:

$$\text{loss} = \arg \min_{\mathbf{V}_1, \dots, \mathbf{V}_T} \sum_{t=1}^T \|\mathbf{G}_t - \mathbf{V}_t \mathbf{V}_t^T\|_F^2 + \lambda \sum_{t=1}^T \sum_u (1 - \mathbf{V}_t(u) \mathbf{V}_{t-1}(u)^T),$$

BCGD 直接分解快照矩阵,无法捕捉到实体在网络结构中的高阶相似性质,且需要分解每张快照,在快照数目多、知识图谱规模较大时分解效率低下. DHPE^[21] 利用广义 SVD(General SVD)的方法计算保留高阶邻近度的实体表示;进一步地, DHPE 假设实体在相邻时间的变化在一定范围内,使用矩阵扰动(Matrix Perturbation)方法,根据当前快照分解得到的实体表示,高效近似计算下一快照的实体表示,避免分解每一张快照,大幅度提高了串行分解方法的效率. TIMERS^[40]、DANE^[16] 同样应用了矩阵扰动方法高效更新实体表示. 由于矩阵扰动方法是一种近似计算实体表示的方法,存在计算误差,且对于不完整数据比较敏感,分解效果不够鲁棒,前者针对增量更新中的实体误差传播问题设计了监控重启机制,后者针对时态知识图谱数据中实体属性、结构的缺失问题,提出了一种鲁棒的级联表示模型. DyHNE^[23] 通过元路径中一阶和二阶邻近度,保留知识图谱中的结构和语义信息,并使用矩阵扰动建模时态知识图谱的演化过程.

实体的平滑演化是一种启发式的先验假设,并不能考虑到演化过程中的特殊情况(如在异常检测场景下,某些实体可能发生突变). 第二类方法直接将实体表示为时间的函数,以体现实体随时间的演化,并从分解过程中拟合函数,而非启发式的演化假设. Yu 等人^[24] 提出时态矩阵分解(Temporal Matrix Factorization)的方法建模实体演化. 如图 2 所示,该方法将快照分解为常量矩阵 \mathbf{U} 与时态矩阵 $\mathbf{V}(t)$ 相

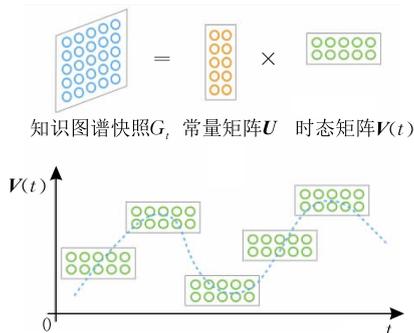


图 2 时态矩阵分解方法^[24]

乘的形式: $\mathbf{G}_t = f(\mathbf{U}\mathbf{V}(t)^T)$. 前者代表实体的固定特征,后者是与时间有关的矩阵函数,代表实体的演化特征. LIST^[25] 直接将实体表示建模为时间 t 的多项式函数形式: $\mathbf{V}(t) = \sum_{i=0}^p \mathbf{W}^{(i)} t^i$, 通过学习到的因子参数矩阵 $\mathbf{W}^{(i)}$ 生成实体表示.

(2) 基于并行分解的推理

基于并行分解的推理并不关注时态知识图谱在某时刻的状态,而是将快照直接堆叠为高维张量,将时间作为张量的一维,一次性分解得到实体的表示与时间信息的表示;相应实体与时间信息的表示作点乘即可得到实体在特定时间的表示. 高维张量分解的代表性方法为 CP 分解法^[41] 与 Tucker 分解法^[42]: 前者将高维张量分解为一系列的秩-张量之和的形式;后者则在 CP 分解法的基础上考虑了核心张量(Core Tensor),即 PCA 中的主成分因子,表示原张量的主要性质,当核心张量是一个超对角矩阵时, Tucker 分解法是 CP 分解法的特例.

Dunlavy 等人^[26] 与 UPD^[43] 分别将动态的社交交互网络、推荐系统中的用户-商品网络建模为 3 维实数张量形式 $G \in \mathbf{R}^{|\mathbf{E}| \times |\mathbf{E}| \times |\mathbf{T}|}$, 并使用 CP 分解法将其分解为实体向量与时间向量. Lacroix 等人^[24] 将时态知识图谱表示为 4 维实数张量形式 $G \in \mathbf{R}^{|\mathbf{E}| \times |\mathbf{R}| \times |\mathbf{E}| \times |\mathbf{T}|}$, 并考虑到非对称关系,将无时态知识图谱推理方法 COMPLEX 扩展到时态知识图谱推理中,提出了基于复数域的 CP 分解法 TComplex,在实体推理任务中取得了更好的性能.

相较于 CP 分解法, Tucker 分解法的推理性能更优,但由于涉及核心张量的运算,分解效率更低. Tresp 等人^[28] 以及 ConT^[29] 使用 4 阶的 Tucker 分解法得到实体、关系及时间的表示. Shao 等人^[44] 在 Tucker 分解法的基础上加入相邻时间向量距离的正则化约束. TIMEPLEX^[27] 考虑到了不同的关系可能会具有不同的时态性质,如某些关系是周期性的(如“举办奥运会”关系每 4 年出现一次),以及不同关系之间存在时序依赖性质,在 Tresp 等人^[28] 的工作基础上,在推理时态知识时考虑了关系的周期分数与时序关联分数,因此在实体推理和时间信息推理任务中取得了更好的性能.

综上所述,基于张量分解的推理方法从整图角度学习时态知识图谱演化规律,通过分解得到实体、关系与时间的语义表示. 该类方法较为成熟,具有稳定的性能表现. 然而张量分解算法时间复杂度高,占用大量计算资源,难以应用于大规模知识图谱数据

中. 此外, 该类方法灵活性较差, 仅能对训练集中出现的实体以及时间点学习表示, 缺乏泛化表示能力, 应用效果有限.

3.1.2 基于转移表示的推理方法

该类方法类似于静态知识图谱的转移(Translation)表示方法, 实体、关系与时间等元素的表示并非分解得到, 而是学习其映射至高维语义空间中的向量、矩阵等表示形式(这一过程称之为转移表示), 以拟合其在时态知识图谱中的语义特征与时间特征. 较于静态知识图谱中的转移表示方法, 需要考虑如何将时间信息转移表示至高维语义空间中, 以体现图谱或个体的动态演化性. 根据表示时间信息的方式, 本文将基于转移表示的推理方法归为两类, 即时间信息显式表示的推理与时间信息隐式表示的推理.

(1) 时间信息显式表示的推理

时间信息显式表示的推理方法将时态知识图谱中的时间表示为时序转移矩阵、嵌入式向量表示、时间映射矩阵等形式. 时间的表示独立于实体与关系的表示, 从宏观层面表示时态知识图谱在每个时刻的演化信息. 实体与关系的表示是静态且持续不变的, 与时间无关.

文献[30]注意到, 同一实体的关系之间具有时序信息, 如(爱因斯坦, 出生于, 乌尔姆市, 1879年), (爱因斯坦, 获奖, 诺贝尔物理奖, 1922年), (爱因斯坦, 逝于, 普林斯顿, 1955年)的时序为: 出生于 \rightarrow 获奖 \rightarrow 逝于. 考虑到这种时序信息可以更好描述关系之间的依存性质, 提出了 TAE 模型, 在经典的转移表示模型基础上, 使用时序矩阵融入了关系的时序信息, 从而学习蕴含时序信息的关系表示; 在 TAE 的基础上, TAE-ILP^[45]考虑了知识的有效时间区间, 使用了整型线性规划(Integer Linear Programming, ILP)技术限制共享同一头实体的时态知识所处时间区间不能产生重叠.

TAE 与 TAE-ILP 只提取了时序信息以更好地学习关系的表示, 模型无法利用具体时间信息. Leblay 等人^[1]提出了 TTransE 模型, 是最早将时间信息的表示加入转移表示模型的工作; 具体地, TTransE 在经典的静态知识推理模型 TransE 基础上增加并学习时间信息的表示, 通过组合实体、关系和时间的表示以计算置信度, 但实体、关系的表示与时间信息的表示是完全割裂的, 无法准确反映特定时刻的实体与关系信息; 基于此, Dasgupta 等人^[18]提出了时间超平面方法 HyTE. 如图 3 所示, 在推理过程中,

HyTE 分别将头实体、关系、尾实体向量 e_h 、 e_r 与 e_t , 分别转移至时间信息 τ_1 、 τ_2 在高维空间对应的超平面中, 以获取特定时刻的实体与关系表示. 这种时间建模方式能够有效帮助模型区分时间敏感型的关系, 如“出生于”、“死亡于”关系等, 在知识级别的推理任务中, 尤其是关系预测任务上取得了更优的性能. 为了增强转移表示的表示能力, 同时体现时态知识图谱中的实体信息演化过程, TeRo^[46]将时间表示为复数域的向量, 并将实体在不同时刻的表示定义为在复杂向量空间中的旋转, 即实体复数向量与时间复数向量的埃尔米特点积(Hermitian Dot Product), 以体现实体的演化过程.

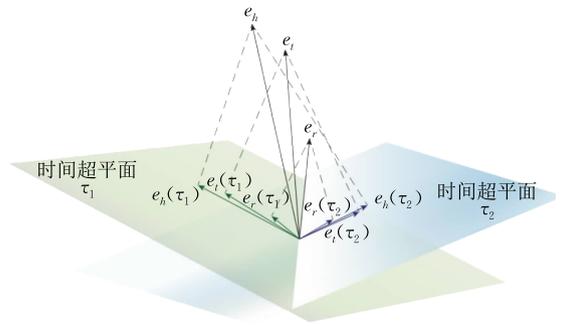


图 3 HyTE 中的时间超平面示意图^[18]

知识中的时间信息存在不同粒度表示的情况, 如(德国, 首都, 柏林, 1980年代)与(德国, 首都, 柏林, 1989年1月16日)的时间信息粒度分别精确到年代和日. 考虑到这一点, TOKEI^[31]设计了面向不同时间粒度表示的映射矩阵, 依据自定义的时间信息层级体系(如年-月-日或年-季度-月-周-日等)自适应地编码实体在不同时间粒度下的表示. 如图 4 所示, 同一实体或关系在“1980年代”和“1989年1月16日”被不同时间粒度代表的映射矩阵连乘, 转化为不同的语义表示, 以计算不同粒度时间信息下的知识置信度. TA-TRANSE^[17]模型考虑到不同粒度的时间信息是不等长的, 如精确到年的“1989年”与精确到日的“1989年1月16日”; 将时间信息转化为时间 token 的序列, 如将“1989年1月16日”转化为[1989, 1, 16], 并在 TransE 基础上使用 LSTM 编码不等长的序列作为知识的时间信息; 这种方式可以有效地在关系中注入时间信息, 较于静态知识推理模型, 在实体推理任务中取得了更好的效果.

前述几种方法忽略了时间信息的关联性. TeLM^[32]认为, 时间是线性变化的, 相邻时刻的表示差异应尽可能小; 基于此, TeLM 在损失函数中引入了时态平滑(Temporal Smoothing)机制, 约束相邻时间的向量

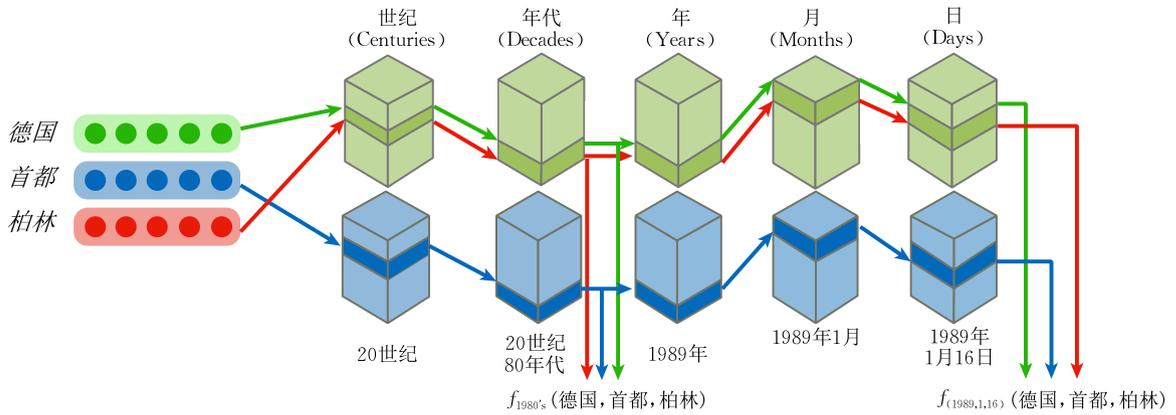


图4 TOKEI中自适应粒度的时间表示方法

表示变化;同样地,TIME2BOX^[47]、RTGE^[48]也使用时态平滑机制约束相邻时间向量的变化.实验证明,时态平滑机制有效地捕捉相邻时间点之间的相关性,距离较近的时间较于距离较远的时间在向量表示的高维空间中更为相近,更好表示时间的相关性.

综上所述,在时间信息显式表示的推理方法中,时间的表示独立于实体与关系的表示,蕴含时态知识图谱在该时刻的宏观演化信息.该类方法需要为训练集中出现的所有时间信息训练相应表示,不适用于变化频繁、时间信息丰富的知识图谱;当时间信息粒度过细时,虽然可以提升模型的推理性能,但会导致大量的训练计算开销.

(2) 时间信息隐式表示的推理

时间信息隐式表示的推理精细化地建模每个实体在各个时刻的演化趋势,将实体或关系随时间的演化建模为函数的形式.时间信息依存于实体或关系的表示中,并不具有其自身的显式表示.

TRESCAL^[1]将静态知识图谱推理方法 RESCAL^[49]扩展至时态知识图谱推理中,其认为关系的信息会随时间演化,时间信息依存于关系存在,为每类关系训练在不同时刻的映射矩阵 $W_{r,t}$.然而,关系-时间的组合数目巨大,意味着 TRESCAL 的时空复杂度很高,且无法学习时间信息的相关性. DE^[33]认为实体与关系均应表示为时间的函数,随时间推移发生变化,基于此,其提出了一种历时的时间嵌入方法(Diachronic Embedding),使用参数可训练的傅立叶函数序列编码任意时刻的实体向量与关系向量,这种编码方式被证明可以反映时间信息之间的相关性,有效建模演化过程的线性变化与周期变化,且显著降低了模型参数量,较于 TTransE、HyTE 模型,在实体推理任务中 MRR 指标平均提升了 19.4%.类似地,ATiSE^[34]也将实体与关系表示

为时间的函数,其考虑了演化过程中的不确定性,在线性趋势与周期趋势两种因素之外,还在实体与关系的表示中加入了随机噪音以模拟随机的干扰因素,通过学习三类因素构成的多维高斯分布的参数进行推理.

上述推理方法直接将实体、关系等建模为时间的函数,推理过程黑盒化,不具备可解释性. T-GAP^[35]尝试赋予模型可解释性:从待补充知识 $(u, r, ?, t)$ 中的目标实体 u 出发,使用注意力剪枝策略迭代地扩充子图,并通过时间信息感知的图神经网络动态地更新子图中每个实体的表示与注意力分值,注意力分值一定程度上可以解释推理过程.在扩充过程结束后,将子图中注意力分值最高的实体作为补充的正确答案.

综上所述,时间信息隐式表示的推理认为实体或关系的表示随时间动态变化,并不需要专为时间设计显式表示方法.这类方法从微观层面建模特定实体或关系随时间的演化特征,具有更强的灵活性,然而,当图谱的可观测时间域跨度较大时,往往不能训练优质的实体表示^[35].

3.1.3 基于规则的推理方法

与之前所述两种基于表示学习的方法不同,基于规则的推理方法属于演绎推理的范畴,目标是从时态知识学习明确表示的推理规则,并使用推理规则补充图谱中缺失的时态知识.静态知识图谱中的推理规则表达为 Horn 子句(Horn Clause)组成的形式,如:父子关系 $(A, B) \wedge$ 父子关系 $(B, C) \rightarrow$ 祖孙关系 (A, C) .

时态知识图谱的推理规则(简称时态推理规则)需要进一步考虑知识中的时间信息,长度为 n 的推理规则形式为

$$P_1(u_1, v_1, t_1) \wedge P_2(u_2, v_2, t_2) \wedge \cdots \wedge P_n(u_n, v_n, t_n) \rightarrow P(u, v, t),$$

其中 $\{t_1, t_2, \dots, t_n\}$ 代表规则体(body)中知识的时间

信息, t 代表规则头(head)中推导出新知识的时间信息. 在推导时, 需要考虑 $\{t_1, t_2, \dots, t_n\}$ 的关系, 如时间区间之间的相等、重叠、相交、相离关系等^[50], 时间点之间的先序、后序、同步等关系. 此外, 在推理时态知识时还需遵守时态一致性约束, 例如一个人的结婚时间不能在其出生时间之前.

Dylla 等人^[36]首次提出在时态知识图谱中利用时态推理规则以及时态一致性约束推导新的知识, 但这种方法只能使用预定义的规则, 难以穷举所有规则; 且假设这些规则一定是成立的, 推理灵活度差, 不能很好地适应真实世界的不确定性. 在此基础上, Chekol 等人^[37]假设时态推理规则并不是完全成立, 而带有相应置信度分数, 这种规则被称为软规则; 其使用马尔科夫逻辑网表示软规则, 将推理知识的过程抽象化为统计学上的最大后验概率问题, 并在预定义的时态一致性约束下推理缺失知识, 一定程度上缓解了推理灵活性问题, 类似地, 文献^[38]使用概率软

逻辑表示软规则并进行推理. 前述工作均需手工设计时态一致性约束规则, 难免会遇到规则不完整性问题, 基于此, ETC 模型^[39]设计了约束图这一数据结构来自动检测并消解推理过程中的时态不一致性冲突.

综上所述, 较于前两类方法, 基于规则的推理方法需要人工干预制定规则并进行推理, 具有很强的可解释性. 然而时态推理规则难以被穷举, 这类方法难以从图谱中自适应学习规则, 可扩展性差.

3.2 面向预测的时态知识图谱推理方法

面向预测的时态知识图谱推理方法学习时态知识图谱历史状态中的单向演化规律以预测未来. 从建模时间单向演化规律的方式区分, 可进一步分为基于游走路径的推理方法、基于时序点过程的推理方法、基于序列网络模型的推理方法与基于增量式更新的推理方法. 表 5 对比了面向预测的时态知识图谱推理方法.

表 5 面向预测的时态知识图谱推理方法对比

方法名称	代表方法	时态知识图谱表示形式	时间信息建模方式	方法优缺点	
基于游走路径的推理方法	基于快照约束的游走路径推理	StreamLearner ^[51] 、Dyn2Vec ^[52] 、NetWalk ^[53] 、EvoNRL ^[54] 、GloDyNE ^[55] 等	离散动态图	采集快照内同时间信息路径, 以表示某一时刻的时态知识图谱状态	优点: 路径一定程度上可以挖掘隐式规则, 具有一定的可解释性 缺点: 图谱数据稀疏时, 路径采样效率低下
	基于时序约束的游走路径推理	CTDNE ^[56] 、TLogic ^[57] 、T-EDGE ^[58] 、DHNE ^[59] 、TITer ^[60] 、CluSTeR ^[61] 、CAW ^[62] 、xERTE ^[63] 等	离散动态图或连续动态图	采集时序递增路径, 表示时态知识图谱的演化规律	
基于时序点过程的推理方法	Deep Coevolutionary Network ^[64] 、Know-Evolve ^[65] 、DyRep ^[66] 、M ² DNE ^[67] 、TDIG ^[68] 等	连续动态图	将时态知识视作连续时间域上的异步事件, 通过时序点过程建模事件发生概率	优点: 解决时间插值问题, 可预测未来任意时刻, 具有很强的灵活性 缺点: 存在冷启动问题, 无法学习知识稀疏实体的高质量表示	
基于序列神经网络的推理方法	基于实体演化的推理	dyngraph2vec ^[69] 、RE_NET ^[70] 、RE-GCN ^[71] 、STGCN ^[72] 、DySAT ^[73] 等	离散动态图	快照编码器输出的实体表示随时间不断变化, 蕴含演化规律	优点: 结合了神经网络的强大学习能力, 推理性能优越 缺点: 强烈依赖数据驱动, 在训练数据不足时表现不佳; 由于神经网络本身的局限性, 推理的形式不可解释
	基于参数演化的推理	DynGEM ^[74] 、EvolveGCN ^[75] 、VGRNN ^[76] 等	离散动态图	快照编码器的参数随时间不断变化, 将抽象的演化规律间接体现在其编码的实体表示中	
基于增量式更新的推理方法	JODIE ^[5] 、TGN ^[77] 、TGAT ^[78] 、DDGCL ^[79] 等	离散动态图或连续动态图	依据实体的最近历史表示, 不断更新实体的最新表示以进行推理	优点: 推理形式灵活, 适用于变化频繁的知识图谱推理 缺点: 训练效率不高, 存在训练过程中的信息不对称问题	

3.2.1 基于游走路径的推理方法

由于时态知识图谱具备图的性质, 在时态知识图谱中采集的游走路径可被视作实体间的多跳关系, 一定程度上代表了推理规则. 由于实体之间的关系具有时效性, 在采集游走路径时需要受到时间信息的约束. 根据采集路径时遵守的约束区分, 基于游走路径的推理方法可被分为基于快照约束的路径推

理与基于时态约束的路径推理. 对于前者, 路径中的时间信息相同, 因为采集的路径被约束在快照内; 对于后者, 路径中的时间信息遵循一定的约束规则, 以体现图谱的演化性.

(1) 基于快照约束的游走路径推理

时态知识图谱对应的快照 G 代表了知识图谱在 t 时刻的演化状态. 基于快照约束的游走路径推

理被限制在快照内采样多跳路径,代表了时态知识图谱在 t 时刻的状态,从中挖掘不同快照对应路径中存在的规则,以学习图谱演化规律.

Omran 等人^[51]将时态知识图谱推理任务视作逻辑归纳任务,在给定时刻知识图谱的前提下,从中提炼 Horn 子句表示的规则,并演绎至图谱中推理新的知识.基于此,Omran 等人提出了时态知识中的闭环路径规则(Close Path Rules),即通过 G_t 内采集的 n 跳路径 $[u, z_1, z_2, \dots, z_{n-1}, v]$,推导出 $t+k$ 时刻(k 为一正实数)的时态知识 $(u, v, t+k)$,闭环路径推理规则表示长度为 n 的合取范式形式:

$$P_1(u, z_1, t) \wedge P_2(z_1, z_2, t) \wedge \dots \wedge P_n(z_{n-1}, v, t) \rightarrow P(u, v, t+k).$$

与 3.1.3 节所述时态推理规则不同,闭环路径规则的规则体中所有时间信息必须保持一致,且规则头中的头尾实体分别与规则体中第一个子句的头实体和最后一个子句的尾实体一致.基于上述闭环路径规则,Omran 等人提出了 StreamLearner 模型,使用频率统计方法评估闭环路径规则的置信度,以此筛选可信度高的时态推理规则以预测未来事件.

在时态知识图谱中,实体局部结构的变化蕴含了知识图谱的演化规律.较于规则式的频率统计方法,表示学习方法可以更灵活地学习隐式表达的演化规律. Dyn2Vec^[52]、DynSEM^[80] 分别借鉴了 Deepwalk^[81] 与 Node2Vec^[82],在每张快照中分别采样若干随机游走路径并训练实体向量表示.在预测时,前者将 t_T 时刻的实体表示作简单拼接,作为预测 t_{T+1} 时刻中知识的依据;后者使用基于正交普鲁克分析的映射函数将实体在不同快照中的表示映射至同一空间,确保实体演化的连贯性,并通过映射函数生成实体未来时刻的向量表示以进行预测.

对每张快照重新采样路径会耗费大量计算资源. NetWalk^[53]、EvoNRL^[54]、Dynnode2vec^[83]、change2vec^[84]、ISGNS^[85] 等工作认为,时态知识图谱整体演化过程是渐变式的,图谱从 G_{t-1} 演化至 G_t 时,仅会有一小部分实体发生变化.上述方法仅对发生变化的实体重采样路径并学习相应表示,或在知识图谱整体变化较大时才对重新训练实体表示.这类基于“变化-重采样”策略的方法避免了重复采样和训练,并保留了时态知识图谱演化的连贯性.

具体地,NetWalk 提出了一种动态更新实体状态的路径采样策略.如图 5 所示,其设计了节点维护池,用来动态维护实体在每一快照中的最新邻居集合.节点维护池极大地提升了模型训练的效率,较于

采样每张快照中路径的 Node2Vec 算法,训练时间降低了 90%,在应用于异常检测的动态节点分类任务中超过了应用于静态图谱上的游走路径的推理方法. EvoNRL 设计了峰值检测策略,用于监测图谱的全局变化,当变化超过一定阈值时才重新计算全部实体表示,较于在每张快照中采样全量实体路径的 NRL 基线方法,EvoNRL 的训练时间加速了近 100 倍. GloDyNE^[55] 认为演化过程中,拓扑结构未变化实体的信息也会受变化实体的影响而改变,而增量更新算法仅局限于更新拓扑结构变化的实体.因此, GloDyNE 在效率和准确率之间作了平衡,首先将当前网络划分为若干子网络,每个子网均有一个代表实体;模型监测代表实体邻居的近期演化状态,以此判断该子网是否处于活跃状态;最后基于 Skip-Gram 的负采样算法,增量更新快照中活跃子网内的实体表示.

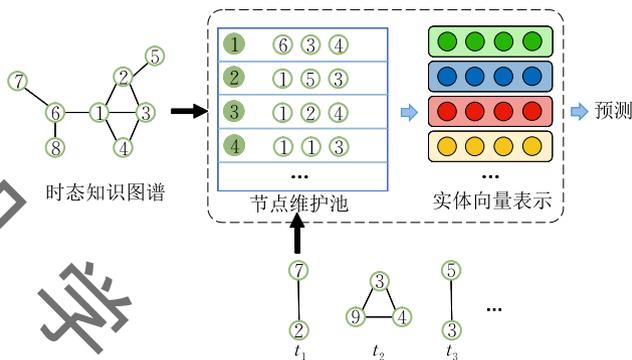


图 5 NetWalk 动态更新实体状态的路径采样策略^[53]

综上所述,基于快照约束的路径推理方法被限制在单一快照中采样路径,以获取实体在特定时刻的演化特征.为体现时态知识图谱的演化过程,该方法基于启发式的平滑演化假设,约束相邻快照的节点表示变化,或采用“变化-重采样”策略更新变化较大的实体表示.

(2) 基于时序约束的游走路径推理

基于时序约束的游走路径推理方法认为时序信息体现了事物的演化规律.该类方法在采样路径时考虑了时间单向性质,采样遵守时序约束的路径,学习图谱随时间单向度的演化规律以预测未来.

CTDNE^[56] 首次提出了时态路径(Temporal Walk)的概念.时态路径中邻接的时态边需满足时序递增约束关系,保证采样的路径中蕴含实体间动态交互的时序依赖信息.对于长度为 L 的时态路径 $(v_1, v_2, t_1), (v_2, v_3, t_2), \dots, (v_L, v_{L+1}, t_L)$,路径中时间信息的偏序关系为: $t_1 \leq t_2 \leq \dots \leq t_L$.

如图 6 所示,对于路径 $v_4 \xrightarrow{t_4} v_1 \xrightarrow{t_1} v_2 \xrightarrow{t_2} v_3$, 由于 (v_1, v_2, t_1) 发生在 (v_4, v_1, t_4) 之前, 前者不可能包含后者中的任何信息. 因此该路径并不是一条遵守时序递增约束的路径. 实验证明, 较于不考虑时序约束的随机游走方法, CTDNE 在关系存在推理任务中的 AUC 指标提升了 15.6%.

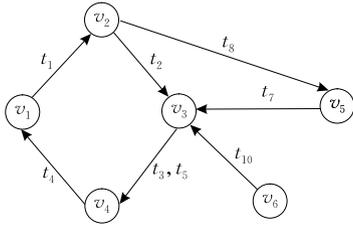


图 6 时态路径示例^[56] ($v_4 \xrightarrow{t_4} v_1 \xrightarrow{t_1} v_2 \xrightarrow{t_2} v_3$ 为无效的时态路径, $v_1 \xrightarrow{t_1} v_2 \xrightarrow{t_2} v_3 \xrightarrow{t_3} v_4$ 为有效时态路径)

时序约束的采样方法能够无监督地提取知识图谱中时态依赖的拓扑特征. Liu 等人^[57]考虑了多跳关系推理的时序性质, 提出循环时态逻辑规则 (Cyclic Temporal Logical Rules) 的概念, 表示为

$$P_1(u, z_1, t) \wedge P_2(z_1, z_2, t+1) \wedge \dots \wedge P_n(z_{n-1}, v, t+(n-1)) \rightarrow P(u, v, t+n).$$

区别于前述 Omran 等人^[51]提出的闭环路径规则, 循环时态逻辑规则的规则体严格遵守时序递增约束. Liu 等人提出的 TLogic 模型使用频率统计的手段以学习循环时态逻辑规则的置信度, 将置信度较高的路径作为推理规则. 在国际政治事件知识图谱 ICEWS 中, TLogic 能够挖掘如 $(E1, \text{制造暴乱}, E2, t) \wedge (E2, \text{发表声明}, E1, t+1) \wedge (E1, \text{制造暴乱}, E2, t+2) \rightarrow (E1, \text{示威或集会}, E2, t+3)$ 的循环时态逻辑规则以推理事件未来发展趋势.

在图谱数据稀疏时, 随机游走的时态路径采样方法效率过低, 需要面向不同推理任务设计特定的

采样方法, 以提高模型训练效率. T-EDGE^[58]设计了一种面向带权图谱的时序约束采样方法, 高权重的边连接的实体具有更高的被采样概率; FiGTNE^[86]提出了时间增强的随机游走采样方法, 依据实体被采样的次数动态改变采样概率, 避免了路径采集的偏见现象, 从而更好地捕捉时态知识图谱的演化规律; ATGEB^[87]认为实体演化的活跃程度是不均匀的, 将实体的活跃时间排序并使用 DBSCAN 进行无监督聚类, 得到若干活跃时间段, 在活跃时间段内进行游走采样.

上述方法均属于启发式的路径采样方法, 无法从数据中学习规律, 自适应地采样时态路径. HIN_DRL^[88]考虑到知识图谱中不同类型的实体具有不同的特征, 且这些特征会不断演化, 提出了结合实体类型与时序信息的元路径采样方法, 在采样时根据实体类型与关系的时间信息, 动态地计算实体之间的转移概率. 实验证明, 较于随机游走的采样方法, HIN_DRL 能够捕捉图谱中丰富的语义信息与演化信息. TITer^[60]与 CluSTeR^[61]设计了基于强化学习的时态路径采样方法, 通过设计策略函数以激励时态路径采集方法高效搜索通向正确答案的推理路径.

如图 7 所示, 应用于动态节点分类任务的 DHNE^[59]构建 t 时刻前目标实体邻居的 Historical-Current 子图, 包含目标实体在当前 t 时刻与历史快照的邻居实体信息. DHNE 学习 Historical 子图 ($G_{t-1}, G_{t-2}, G_{t-3}$) 中历史邻居对 t 时刻的目标实体的影响权重 W , 并基于影响权重在 Historical-Current 子图中自适应地采样时态约束的元路径, 并用 Skip-Gram 的路径编码方法计算实体 t 时刻的向量表示, 以预测实体在 $t+1$ 时刻的类别.

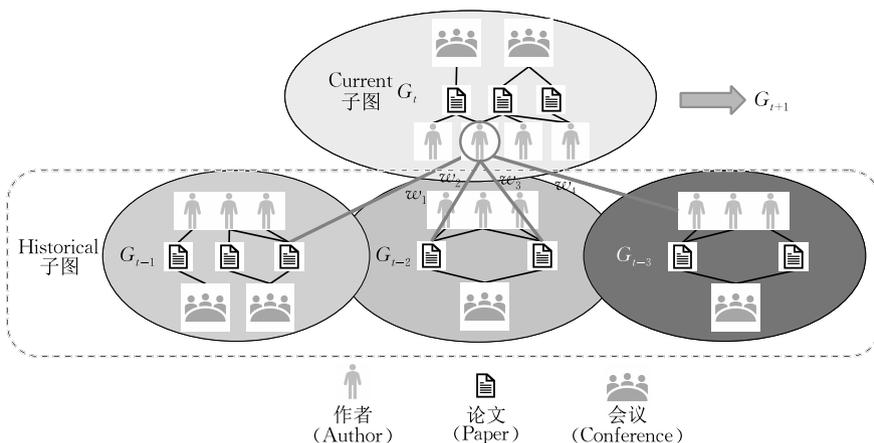


图 7 DHNE 通过待推理目标实体构建的 Historical-Current 子图^[59] (以学术知识图谱为例)

采样时态路径后需要从中提取推理规则. 在编码路径信息时, 基于 Skip-gram 的时态路径编码方法只能学习采样路径中实体的共现关系, 不能反映路径中的时间信息, 如相邻时态边发生的时间差值, 以及时态边之间的时序先后关系. TITer^[60] 与 CluSTeR^[61] 设计了基于 LSTM 的时态路径编码器, 学习时序先后关系; DEMS^[89] 采用了自注意力机制, 在建模时序先后关系的基础上考虑了时间差值, 训练实体表示时为路径中不同位置与时间信息的实体赋予不同的权重, 更好地学习实体的拓扑与时间信息的关联; Wang 等人^[62] 提出了因果匿名路径 (Causal Anonymous Walk, CAW), 其采样方式是将路径中实体局部结构信息匿名化后, 从匿名路径中提炼出抽象的时态演化规律. xERTE^[63] 从查询的目标实体出发采样时态路径, 并沿着时态路径传播注意力分值, 不断剪枝扩充查询子图; xERTE 设计了一种时间关系图注意力 (Temporal Relation Graph Attention) 机制, 引导子图向有利于查询作出正确预测的方向扩展, 扩充的子图可被视作对预测实体的可解释说明.

综上所述, 基于时序约束的游走路径推理方法采样具有时序依赖关系的路径, 挖掘路径中蕴含的推理规则. 时态路径本质上是一条事件链, 其蕴含了知识图谱的部分演化规律; 然而, 事件链中邻接的两条时态边仅保证时间的先后关系, 并不能确保事件间真正存在因果关系. 从时态路径中提炼更纯粹的因果关系, 有助于挖掘知识图谱演化的本质规律.

3.2.2 基于时序点过程的推理方法

时序点过程 (Temporal Point Process, TPP) 是一种随机事件概率建模方法. 基于时序点过程的推理方法将时态知识图谱中实体与关系的出现、消失等视为随机事件序列, 事件发生的概率取决于相关实体的历史演化特征, 包括拓扑结构、实体特征与事件的时间间隔特征等.

在基于时序点过程的推理方法中, 知识在 t 时刻的预期存在概率被表示为条件强度函数与生存函数之积的形式 $f(t) = \lambda(t)S(t)$. 条件强度函数 $\lambda(t)$ 的含义为已知事件历史信息 $H(t)$, 在 t 时刻时间窗口 $[t, t + \Delta t)$ 中的预期存在概率:

$$\lambda(t | H(t)) dt = \mathbb{E}[N(t, t + dt) | H(t)].$$

生存函数 $S(t)$ 评估了事件在时间窗口 $[t, t + \Delta t)$ 内并不存在的条件概率. 条件强度函数是时序点过程的关键, 其提供了依据历史数据预测未来的能力. 泊松过程 (Poisson Process)、霍克斯过程 (Hawkes Process)、瑞利过程 (Rayleigh Process) 与神经点过程 (Neural Point Process) 等方法^[90] 提出了不同的

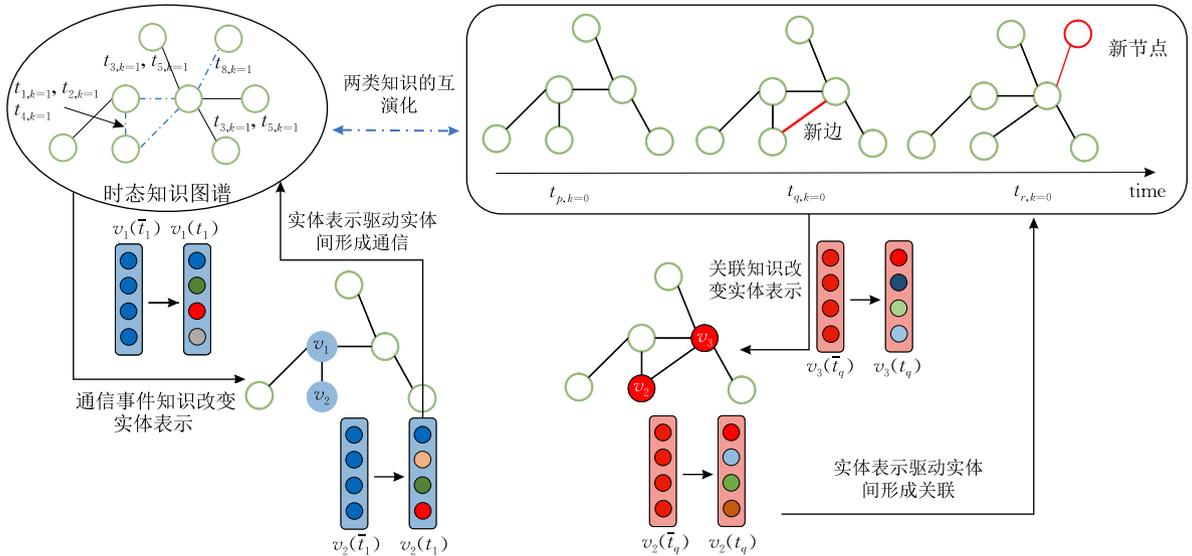
条件强度函数建模方式.

在推理单关系时态知识 (u, v, t) 时, 基于时序点过程的推理方法首先通过实体的历史交互数据, 使用时序点过程方法计算出实体在 t 时刻向量表示 u_t 与 v_t , 通过实体向量的点乘计算时态边的条件强度函数, 结合生存函数计算预期发生概率. Dai 等人^[64] 于 2016 年提出等深度共演化网络 (Deep Coevolutionary Network), 最早将时序点过程用于关系存在推理任务; 其针对推荐系统中的用户-物品交互网络, 提出了一套依据交互过程, 不断迭代更新用户与物品实体表示的框架: 使用 RNN 模型编码用户与商品表示的演化, 采用了基于瑞利过程的联合非负似然概率函数计算损失. 由于建模了图谱中的演化信息, 较之传统的时序点过程推理方法, 深度共演化网络在推荐系统中的商品推荐与点击时刻推荐 (分别对应实体推理与时间点推理任务) 取得了更优结果. HTNE^[91] 采用注意力机制建模不同时期的历史邻居对实体的影响力, 并利用霍克斯过程建模实体邻居的序列化产生过程. MTNE^[92] 认为中观动力学结构能够更好地建模知识的演化交互过程, 并使用了基于霍克斯过程的开放三角模体 (Open Triad Motif) 重建概率作为损失函数训练实体表示, 以学习中观动力学结构中蕴含的演化规律.

Know-Evolve^[65] 是最早将时序点过程用于多关系类别推理的工作, 其将瞬时知识 (u, r, v, t) 看作概率事件, 在表示实体向量之外, 建模每种关系类型代表的映射矩阵, 并利用基于多变量瑞利点过程的损失函数来建模时态知识图谱中事件的发生概率, 以服务于关系推理任务与时间点推理任务. Han 等人^[93] 提出了图霍克斯神经网络 (Graph Hawkes Neural Network, GHNN) 建模多关系时态知识图谱, 可以有效聚合当前时刻实体邻居信息以预测未来.

不同于上述参数化时序点过程模型依赖于手工设计的条件强度函数, 神经点过程方法使用神经网络模拟条件强度函数. 在先验知识匮乏或数据特征较多、分布复杂, 无法预知真实的条件强度函数情况下, 神经网络可以从数据驱动的角度拟合真实的条件强度函数, 挖掘隐藏的时态知识演化规律, 预测性能更强. 目前, 神经时序点过程成为了基于时序点过程的推理方法的热门研究方向, 代表性工作有 DyRep^[66]、M²DNE^[67]、TDIG^[68] 与 EvoKG^[94] 等.

如图 8 所示, DyRep 使用关联 (Association) 与通信 (Communication) 两类事件知识建模社交网络中人员之间的稳态与瞬态关系, 前者会改变网络拓扑结构, 代表长期稳定的联系, 后者代表短暂、临时

图 8 DyRep 中关联事件与通信事件的互演化过程^[66]

的联系. 发生的事件会通过实体邻居信息聚合传播 (Localized Embedding Propagation)、实体自身信息传播 (Self-propagation) 以及外因驱动 (Exogenous Drive) 三种信息传播方式改变参与事件的实体表示. t_p 时刻的实体 v 表示为

$$\mathbf{z}^v(t_p) = \sigma(\mathbf{W}^{struct} \mathbf{h}_{struct}^u(\bar{t}_p) + \mathbf{W}^{rec} \mathbf{z}^v(\bar{t}_p) + \mathbf{W}^t(t_p - \bar{t}_p)),$$

其中 \mathbf{W}^{struct} 、 \mathbf{W}^{rec} 与 \mathbf{W}^t 分别对应实体邻居聚合信息、实体自身信息以及外因驱动的映射矩阵, $\mathbf{h}_{struct}^u(\bar{t}_p)$ 为 t_p 时刻之前最新的邻居结构信息, $\mathbf{z}^v(\bar{t}_p)$ 为 t_p 时刻前实体 v 最新的表示向量.

DyRep 使用神经网络建模条件强度函数 $\lambda_k^{u,v}(t)$, 计算实体对 (u, v) 在 t 时刻存在关联知识的概率 (k 代表关系类型), 然后使用基于条件密度函数与生存概率的损失函数更新模型参数. 其中 ω_k 是关系类型 k 的向量表示; ψ_k 是关系类型 k 对应的标量时间尺度参数:

$$\begin{aligned} \lambda_k^{u,v}(t) &= f_k(g_k^{u,v}(\bar{t})), \\ g_k^{u,v}(\bar{t}) &= \omega_k^\top \cdot [\mathbf{z}^u(\bar{t}); \mathbf{z}^v(\bar{t})], \\ f_k(x) &= \psi_k \log\left(1 + \exp\left(\frac{x}{\psi_k}\right)\right). \end{aligned}$$

实验证明, 由于建模了更复杂的信息传播方式, DyRep 在关系推理任务与时间点推理任务中取得了较于 Know-Evolve 模型更优的性能.

M²DNE 使用宏观与微观层面的演化趋势学习实体表示. 在宏观层面, M²DNE 通过网络动力学指标对模型进行约束, 如 t 时刻知识图谱中新增知识的数量是由 $t-1$ 时刻知识的数目决定的; 在微观层面, M²DNE 捕捉实体对之间形成关联的演化规律, 利用神经网络表示的条件强度函数 $\tilde{\lambda}_{i,j}(t)$ 计算实体

对之间形成边的概率:

$$\begin{aligned} \tilde{\lambda}_{i,j}(t) &= g(\mathbf{u}_i, \mathbf{u}_j) + \beta_{ij} \sum_{p \in N^i(t)} \alpha_{pi}(t) g(\mathbf{u}_p, \mathbf{u}_j) \kappa(t - t_p) + \\ &\quad (1 - \beta_{ij}) \sum_{q \in N^j(t)} \alpha_{qj}(t) g(\mathbf{u}_q, \mathbf{u}_i) \kappa(t - t_q), \end{aligned}$$

其中 \mathbf{u}_i 与 \mathbf{u}_j 分别是实体 i 与 j 在 t 时刻的向量表示, $\alpha(\cdot)$ 为节点对的匹配函数, $\kappa(\cdot)$ 为时间距离函数; p 与 q 分别代表实体 i 与 j 在时刻 t 的邻居实体, α 为学习到的注意力因子, β 为调节头、尾节点邻居信息影响比例的因子.

TDIG 提出了时态依赖交互图 (Temporal Dependency Interaction Graph, TDIG) 的概念, 用于建模电商领域的用户-物品时序交互数据, 并利用动态信息传递网络、异质信息注意力网络与循环门控神经网络得到用户与物品实体在 t 时刻的表示. TDIG 通过神经网络表示的条件强度函数计算 t 时刻用户 u 与物品实体 v 交互的概率:

$$\begin{aligned} \lambda^{u,v}(t | H_t^{u,v}) &= \text{Softplus}(\mathbf{w}_{add}^\top (\bar{\mathbf{h}}_{u(t^{u-})}^r + \bar{\mathbf{h}}_{v(t^{v-})}^r) + \\ &\quad \mathbf{w}_{mul}^\top (\bar{\mathbf{h}}_{u(t^{u-})}^r \odot \bar{\mathbf{h}}_{v(t^{v-})}^r) + b_\lambda^{u,v}), \end{aligned}$$

其中, $H_t^{u,v}$ 为 u 与 v 的历史交互数据, $\bar{\mathbf{h}}_{u(t^{u-})}^r$ 与 $\bar{\mathbf{h}}_{v(t^{v-})}^r$ 分别为实体 u, v 在 t 时刻的最新历史表示, \mathbf{w}_{add} 与 \mathbf{w}_{mul} 是可训练的参数向量, $b_\lambda^{u,v}$ 是可训练的偏置参数. TDIG 的损失函数为正样例实体对的负似然联合概率与负样例实体对的生存概率之和:

$$L = -\sum_i^N \log \lambda^{u_i, v_i}(t_i | H_{t_i}^{u_i, v_i}) + \int_0^T \sum_{u,v} \lambda^{u,v}(t) dt.$$

类似地, EvoKG 使用图神经网络与循环门控图神经网络建模神经时序点过程, 用于关系推理与时间信息推理等任务.

综上所述, 基于时序点过程的推理方法将时态

知识视作连续时间域上的异步事件序列,使用损失函数中的条件强度函数与生存函数计算知识在 t 时刻的置信度.由于时间作为密度函数的参数,该类方法属于插值推理方式^[64],可预测任意时间的知识发生概率,预测形式灵活.然而,该类方法存在冷启动问题^[86],对于知识稀疏的实体,无法学习其高质量表示,推理性能不佳.

3.2.3 基于序列神经网络的推理方法

由于神经网络具有强大的学习拟合能力,近年来,基于神经网络的推理方法被证明能够有效学习知识图谱复杂的语义特征与结构特征并用于推理.基于序列神经网络的推理方法将时态知识图谱视作离散动态图,使用神经网络提取离散动态图中快照序列的特征,以学习演化信息.

从模型架构分析,序列神经网络由快照编码器与时态编码器组成:快照编码器从快照序列中分别提取时态知识图谱在不同时刻的表示;时态编码器整合快照序列表示,从中学习演化信息.进一步地,从演化信息体现的对象区分,本文将基于序列神经网络的推理方法划分为两类,即实体演化类方法与参数演化类方法.

(1) 实体演化类推理方法

实体演化类方法认为不断变化的实体表示体现了时态知识图谱的演化规律,试图从不同时刻的实体表示中挖掘这种演化规律.依据时态编码器的种类划分,可分为拼接式时态编码方法、基于循环神经网络(Recurrent Neural Network, RNN)的时态编码方法、基于卷积网络的时态编码方法(Convolutional Neural Network, CNN)与基于自注意力(Self-attention)机制的时态编码方法.

dyngraph2vec^[69]提出了自编码器、循环神经网络与自编码器+循环神经网络(dyngraph2vec-AE/-RNN/-AERNN)三种不同的快照-时态编码器组合.dyngraph2vec-AE使用自编码器提取知识图谱快照特征,将 t 时刻及之前的实体表示简单拼接后作为历史信息;后两种组合均使用了循环神经网络作为时态编码器.较于将序列简单地拼接,循环神经网络能够更好地捕捉到快照间的时序依赖关系,在关系推理任务中取得更好的性能.如图9所示,对于待推断知识 $(s, r, ?, t)$ 与历史时间步中的邻居实体集合序列 $\{\dots, O_{t-3}^r(s), O_{t-2}^r(s), O_{t-1}^r(s)\}$, RE_NET^[70]聚合历史时间步中邻居表示,并与头实体 s 与关系 r 的向量表示拼接后,通过循环神经网络编码演化信息得到最新的尾实体表示,用于预测下一时间步中与之可能建立关系的尾实体.

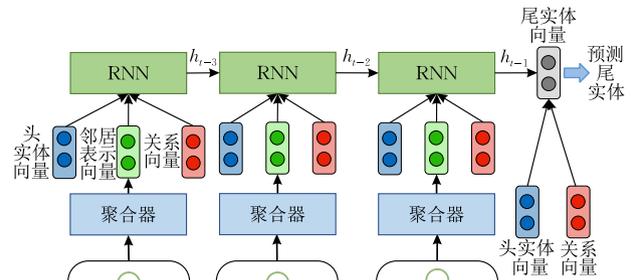


图9 RE_NET模型示意图^[70]

为了更好地提炼知识图谱在每个阶段的拓扑特征,RE-GCN^[71]使用关系感知的图卷积网络(Relation-aware Graph Convolutional Network, RGCN)编码知识图谱中的快照特征,再通过循环神经网络学习特征演化规律.CEN^[95]在RE-GCN的基础上考虑了时态模式的长度多样性和时序变化性,使用关系感知的图卷积网络对多个长度进行编码从而建模长度多样性,同时在线地训练模型从而解决时序变化性.HiSMATCH^[96]使用关系感知的图神经网络和循环神经网络区分建模查询相关的图序列和候选实体相关的图序列并提出了一个匹配框架进行时态推理.同样地,文献[19-20,97]均采用了图神经网络-循环神经网络的组合.然而,循环神经网络在编码长距离时间信息时会存在信息遗忘问题,在多步预测的任务中表现不佳^[73].

卷积神经网络具有优秀的局部特征提取能力,且其权值共享与下采样特性能够有效减少模型参数量,被广泛应用于时序数据建模中.STGCN^[98]使用GraphCNN模块与Temporal CNN模块分别抽取并融合交通网络中的空间与时态特征,以预测交通网络流量的动态变化.较于ARIMA等传统序列预测模型,STGCN在减少了参数量的前提下,将MAPE指标提升了5.5%.DynGraphGAN^[99]、TNDN^[100]等工作也采用CNN编码知识图谱演化过程中的时态序列特征.然而,CNN的局部特征感知特性导致其在编码长距离时间序列中效果有限.

自注意力机制可有效缓解长距离时间序列编码的遗忘问题.TeMP^[101]将自注意力机制应用至时态编码器中,如图10所示,TeMP使用RGCN作为快照编码器,提取目标实体 s 的历史向量序列 $x_{s,t-\tau}, \dots, x_{s,t-1}, x_{s,t}$;基于自注意力机制的时态编码器有权重地聚合结构历史向量序列,得到实体 s 在 t 时刻的

向量表示 $z_{s,t}$. 用于时间信息的自注意力机制能够感知整个时间序列的信息, 且能够编码长距离时间信息, 缓解信息遗忘问题. 此外, TeMP 还设计了历史权重系数 α , 以综合考虑当前时刻实体编码信息与历史实体编码信息.

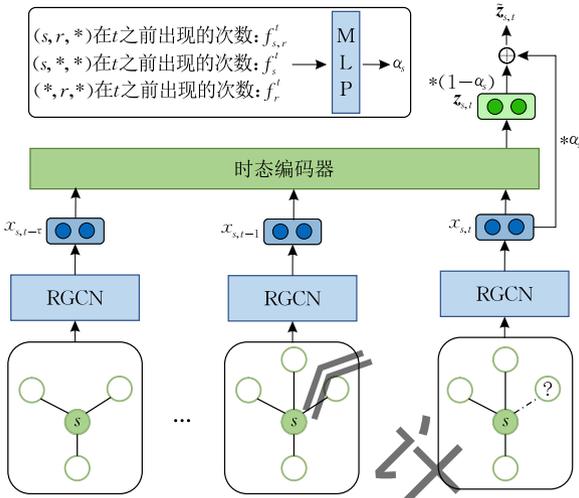


图 10 TeMP 中的时态编码器中应用 Attention 机制, 有权重地聚合实体历史信息^[101]

进一步地, DySAT^[73] 提出了结构-时态自注意力机制. 结构自注意力机制从每个快照中的局部实体邻域中提取特征并有权重地聚合, 而时态自注意力机制通过灵活加权多个时间步的历史实体表示来捕获演变规律. 此外, STAR^[72]、DANE^[102]、DACHA^[103]、HIP Network^[104] 等也设计了结构-时态自注意力机制, 应用于动态实体分类、实体推理与关系推理任务. 为了更好地学习图谱的复杂演化机制, TRRN^[105] 在结构-时态自注意力机制基础上设计了动态记忆更新机制, 能够在生成当前时刻节点表示时, 自适应地为各类信息(如节点拓扑结构)分配权重, 在动态实体分类与关系推理任务中取得了比 STAR、DySAT 等模型更好的实验效果.

(2) 参数演化类方法

实体演化类方法试图从实体表示的变化中学习演化规律. 这种规律是从训练集数据中学习得到的, 不一定适用于未出现在训练集中的实体, 泛化性能不佳. 因此不适用于实体频繁加入、消失的实体知识图谱. 参数演化类方法试图学习抽象的演化规律, 这种演化规律与特定实体无关. 具体地, 在参数演化类方法中, 时态编码器学习知识图谱快照间时序依赖关系, 直接作用于快照编码器参数, 而非实体表示. 随着知识图谱的不断变化, 快照编码器参数也在不断演化改变, 将抽象的演化规律间接体现在其编码

的实体表示中.

DynGEM^[74] 与 LDANE^[106] 未设计显式的时态编码器结构, 而是借鉴了迁移学习的思想. 在编码快照序列时, 使用 $t-1$ 时刻的快照编码器参数初始化 t 时刻快照编码器参数, 从而加速模型的训练过程. 此外, 两种方法在损失函数中设计了正则化项, 约束相邻时刻快照编码器的参数变化.

EvolveGCN^[75] 提出了参数演化 (Weight Evolution) 的概念, 其认为快照编码器参数应随知识图谱在不同时刻的演化而更新. EvolveGCN 使用了基于 RNN 的时态编码器动态改变快照编码器的参数, 而非实体在不同时刻的表示, 从而学习图的演化规律. 如图 11 所示, EvolveGCN 将双层的图卷积网络作为快照编码器, 使用每一时刻的快照训练对应的快照编码器参数, 快照编码器的参数受到时态编码器的控制, 随时间推移而产生变化. 实验结果表明, 较于 dyngraph2vec 等实体演化类推理方法, 在动态节点分类与关系推理任务中性能表现更优异. 类似地, VGRNN^[76] 提出变分图循环神经网络的概念, 使用了变分图自编码器^[107] (Variational Graph Auto-Encoders, VGAE) 与 RNN 的快照-时态编码器的组合, 将 RNN 在 $t-1$ 时刻的隐状态表示 h_{t-1} 作为 t 时刻快照编码器 VGAE 变分参数的先验分布. 前两种方法在解码时刻的快照编码器参数时只应用了历史数据中单时间步 ($t-1$ 时刻) 的信息, Developing GCN^[108] 设计了注意力机制以捕捉历史多时间步中更充分的信息.

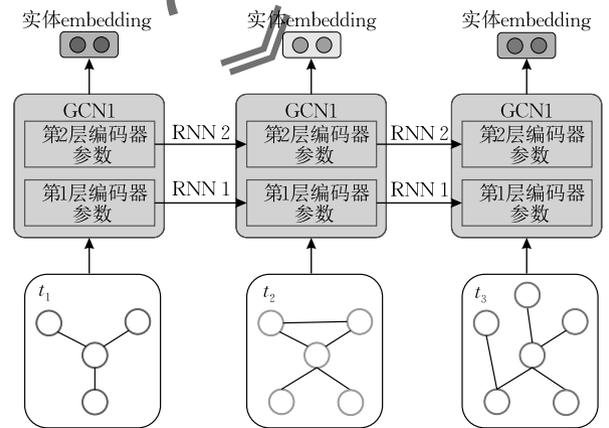


图 11 EvolveGCN 中的快照编码器参数随时间演化^[75]

综上所述, 由于结合了神经网络的强大学习能力, 基于序列神经网络模型的推理方法能够很好地学习实体的动态演化规律. 然而, 该类方法强烈依赖训练数据, 在训练数据不足时, 模型效果欠佳; 此外, 囿于神经网络本身的黑盒性质, 推理的不可解释性

也是该类方法存在的问题。

3.2.4 基于增量式更新的推理方法

随着数据源不断推送新产生的知识,图谱中会不断引入新的实体与关系,图谱中的语义信息与结构信息也在不断演化。例如,在电商场景中,随着用户点击不同的商品,其喜好与兴趣也在不断改变。基于增量式更新的推理方法使用连续动态图建模时态知识图谱,将时态知识视作不断涌现的事件流,动态更新实体最新的表示以预测未来信息。

Dai 等人^[64]认为已有方法存在强烈依赖实体属性、时间复杂度高、新实体加入后需要重新训练等缺点,提出了一种在线近似的推理方法 DeepCoEvolve。该方法采用了平滑演化约束,为新加入图中的实体动态且高效地生成实体表示,推理未来知识。然而,DeepCoEvolve 仅考虑了时序信息,未建模事件之间的时间间隔信息,作用有限。

JODIE^[5]将推荐系统中用户-商品交互序列建模为动态二部图结构,通过更新操作与投影操作获取实体在任意时刻的表示,如图 12 所示。在更新操作中,对于 t 时刻的交互 (u, i, t, A) , JODIE 设计了用户-商品耦合循环神经网络 RNN_u - RNN_i , 依据上一历史事件后形成的用户表示 $u(t^-)$ 与商品表示 $i(t^-)$, 以及交互属性 A , 实时学习 t 时刻的用户与商品实体向量表示 $u(t)$ 与 $i(t)$ 。在投影操作中,基于注意力机制的时态投影模块计算时间间隔 Δ 后的实体表示以预测未来。此外, JODIE 模型设计了 t-Batch 算法,在训练模型时,将训练集中事件流数据划分并调整为时间一致性 (Time-constant) 的批量事件序列,同一分批量内的动态边不会分享相同的用户或商品实体;在此基础上, JODIE 实现了时序约束下的并行训练算法,相较于 CTDNE、DeepCoEvolve 等方法,训练效率提高了约 9 倍,且在实体推理任务中取得更优性能,在 LastFM 等三

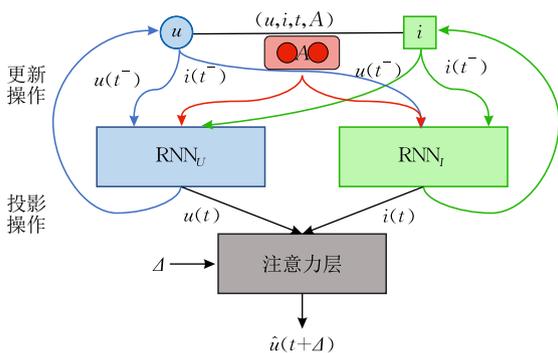


图 12 JODIE 中的更新操作与投影操作示意图^[5]

个数据集上的 MRR 值平均提升 40.3%。考虑到新知识 (u, v, t) 出现后,不仅会对涉及实体 u 和 v 产生影响,信息还会扩散至与 u 和 v 相关联的实体,基于此, DyGNN^[109] 设计了信息扩散模块,将事件的信息传递给与事件涉及实体具有历史交互的实体。

上述方法均基于循环神经网络更新实体表示,无法实现并行计算,在大规模数据场景中训练效率低下。基于此, TGN^[77] 设计了消息传播-聚合以及记忆单元更新机制,在使用实体事件序列数据更新实体表示时,使用注意力机制计算每个事件序列的权重,并以此更新记忆单元中的实体表示。实验表明,单图注意力层 TGN 的训练时间相较于 JODIE 提升了 3 倍,但 TGN 中的记忆单元要为每一实体维护在所有时刻的最新表示,空间复杂度较高。TGAT^[78] 受到 GraphSAGE^[110] 等图神经网络模型的启发,提出了时态图注意力层 (Temporal Graph Attention Layer) 模型。TGAT 使用了基于时态核函数设计的时态编码模块,将实体的表示建模为时间的函数,并能够随着图的演化,动态聚合邻居节点中蕴含的时态特征与拓扑特征,从而学习到实体的时态-拓扑邻居聚合函数,快速生成实体表示以进行推理。DyGCN^[111] 采用了先后更新一阶/二阶节点信息的方式,增量更新改变状态的实体,并将变化的信息传播到其他实体,从而高效率地更新节点表示。

时态知识图谱推理任务过度依赖标注数据训练模型,然而在实际应用中往往难以大量获取标注数据。Tian 等人^[10] 设计了面向时态知识的通用对比学习框架 DDGCL,通过采样同一实体在两个不同时刻的子图,构建丰富的对比样本对,利用样本对相似性与两个不同采样时间的相似性设计损失函数并训练模型,增强模型的性能。相较于 TGN 与 TGAT, DDGCL 显著提升了实体分类、关系推理等任务中的表现性能。

综上所述,基于增量式更新的推理方法将时态知识视作事件流,通过实体的时态知识序列动态地学习实体的表示,适用于预测变化频繁的时态知识图谱推理场景。该类方法更贴近工业界实际需求(如推荐系统等),然而该方法存在训练过程中的信息不对称问题^[112]:即在不同的训练批次中,先训练的实体表示蕴含信息量更少,造成了表示信息中的不公平现象。其次,目前研究囿于有限规模的实验数据集,模型训练效率不高,设计面向大规模数据的增量式更新推理方法,是未来时态知识图谱推理研究方向的趋势。

4 时态知识图谱推理任务评价

本节主要针对时态知识图谱推理任务的数据集、评测指标以及不同任务对应的实验进行介绍比较。

表 6 时态知识图谱推理数据集总结

作者(第一)	数据集名称	数据集类型	数据规模	时间粒度	知识性质	构建方式	发表会议
Leblay ^[1]	WIKIDATA	通用	1.1 万个实体 15 万条知识	年	无时态/瞬时/ 区间知识	依据开放知识图谱 Wikidata 构建	CIKM 2018
Dasgupta ^[18]	Wikidata12k	通用	1.25 万个实体 4 万条知识	年	区间知识	从开放知识图谱 Wikidata 中挑选前 24 种最频繁的关系构建, 仅保留区间知识	EMNLP 2018
Cai ^[47]	WIKIDATA 114k	通用	11.4 万个实体 169.4 万条知识	年	无时态/瞬时/ 区间+知识	抽取 Wikidata 中具有“member-OfSportsTeam”关系的运动员实体对应的全量知识构建	K-CAP 2021
Dasgupta ^[18]	YAGO11k	通用	1.06 万个实体 2.06 万条知识	年	区间知识	从开放知识图谱 YAGO3 的时态知识中挑选前 10 种最频繁的关系构建	EMNLP 2018
García-Durán ^[17]	ICEWS' 14	事件	6869 个实体 9.6 万条知识	日	瞬时知识	从 ICEWS 中抽取 2014 年全年的军事、政治事件构建	EMNLP 2018
García-Durán ^[17]	ICEWS 05-15	事件	1.0 万个实体 15 万条知识	日	瞬时知识	从 ICEWS 中抽取 2005~2015 年部分军事、政治事件构建	EMNLP 2018
Trivedi ^[65]	GDELT	事件	1.4 万个实体 312.9 万条知识	15 分钟	瞬时知识	从 GDELT 中选择 2015.4.1 至 2016.3.31 的事件构建	ICLR 2017
Yu ^[25]	DBLP	社交	31.5 万个实体 74.3 万条知识	年	瞬时知识	包括研究人员、文献、研究领域、学术会议与期刊等实体与合作关系、发表关系等	IJCAI 2017
Xu ^[72]	Reddit	社交	8291 个实体 26.4 万条知识	秒	瞬时知识	从社交新闻网站 Reddit 中爬取用户、帖文以及用户之间的即时性互动构建	IJCAI 2019
Li ^[16]	Epinions	社交	1.4 万个实体 22.7 万条知识	日	瞬时知识	从购物网站 Epinions 中抽取用户对商品的评论以及用户之间的社交信任关系构建	CIKM 2017
Dimitrios ^[43]	LastFM	推荐	17.7 万个实体 191.5 万条知识	秒	瞬时知识	音乐推荐数据集, 包括用户、艺术家、音乐作品等	RecSys 2014
Dai ^[64]	Yelp	推荐	4.9 万个实体 29.1 万条知识	秒	瞬时知识	商户点评数据集, 包括用户、商户以及用户对商户的评价构成	arXiv

通用知识图谱数据集来源于著名的开源通用知识数据库 Wikidata^[113]与 YAGO^[114]。前者是维基媒体基金会负责维护的众包标注式通用知识图谱, 用于为维基媒体项目(如维基百科、维基教科书等)提供支持, 对应的数据集名称分别为 WIKIDATA、Wikidata12k与 WIKIDATA 114k; 后者是马克斯·普朗克研究所维护的百科知识图谱, 其融合了 Wikidata、WordNet 与 GeoNames 等开源知识图谱, 涵盖信息更加全面; 从 YAGO2 版本起, 开发者为知识增加了时间信息与空间信息描述, 对应的数据集名称为 YAGO11k。

事件知识图谱数据集来源于两个著名的开源事件数据库: 全球危机预警系统^[115](Integrated Crisis Early Warning System, ICEWS)与全球社会数据库^[116](The Global Database of Events, Language

4.1 数据集介绍

本节介绍了时态知识图谱推理任务中的代表性数据集, 依据采集来源的不同, 可分为通用知识图谱数据集、事件知识图谱数据集、社交知识图谱数据集与推荐系统数据集, 具体内容如表 6 所示。

and Tone, GDELT), 前者是一个主要面向军事及政治事件的开源数据库, 由美国最大的国防承包商洛克希德·马丁公司研发, 搜集并整合来自社交媒体、新闻媒体等即时事件数据并每天更新, 对应的数据集名称分别为 ICEWS' 14^[17]与 ICEWS 05-15^[17]; 后者依托于谷歌的 Jigsaw 项目, 监控感知从 1979 年起全球 100 多种语言对应的广播、印刷刊物、在线新闻媒体发布的公开事件, 包括政治、军事、外交、经济等多元事件类型, 每 15 分钟更新一次, 对应的数据集为 GDELT^[65]。

社交知识图谱数据集来源于即时性强的在线社交平台(如 Reddit、Epinions)或学术社交网络(如 DBLP)等。Reddit 是一个社交新闻网站, 用户可在不同的话题版块发帖讨论, 并与其他网友产生互动, 对应的数据集名称为 Reddit^[25]; Epinions 是一个

社交电商网站,用户可以对商品评论打分,与其他用户建立“信任”的社交关系,对应的数据集名称为 Epinions^[72];DBLP(Digital Bibliography & Library Project)由德国特里尔大学开发并维护,提供计算机科学领域英文文献的搜索服务并提供开源数据,用于构建具有社交性质的动态学术知识图谱,记录了研究人员、文献、研究领域、研究机构、会议及期刊等实体以及实体之间的异质关联,如研究人员的学术合作关系等,对应的数据集名称为 DBLP^[16].

推荐系统数据集来源于电商或音乐软件等。LastFM 是一个在线音乐软件,对应的数据集名称为 LastFM^[43],其中收录该软件中用户收听艺术家音乐作品的记录,以及收听的时间信息;Yelp 是一个商户点评网站,用户可以在上面发布对商户的评论与打分,并交流体验等。Yelp 官方每年都会举办推荐挑战赛,Dai 等人使用了第 7 轮挑战赛的公开数据,对应的数据集名称为 Yelp^[61].

除上述已有的数据集外,时态知识也广泛存在于一些其他的开源知识库中,比如 DBpedia^①等。DBpedia 在 Wikidata 知识库的基础上添加了额外的抽取模块,从维基百科的非结构化文本(如 Infobox、实体描述等)中抽取知识,并汇总为信息更丰富的知识库。因此其中也存在大量的时序知识。然而,目前尚未有研究人员以此构建时态知识图谱推理数据集。这些开源知识库也具备被构造为时态知识图谱数据集的潜质,值得在将来的研究中被探索。

4.2 动态实体分类

动态实体分类通过学习知识图谱中被标注类别的实体信息,推理某时刻未标注所属类别实体的标签。具体地,模型首先学习实体在特定时刻的表示,将带有标签的实体分为训练集与测试集,通过训练集数据训练基于支持向量机、逻辑回归、softmax 等实现的分类器判断测试集中的节点类别。

4.2.1 评测指标与实验结果

动态实体分类属于多分类问题或多标签问题,其评价指标包括准确率(Accuracy, ACC)、精确率(Precision)、召回率(Recall)、微平均 F1 值(Micro_F1)、宏平均 F1 值(Macro_F1)等。

准确率是指在测试样本中,预测正确的结果所占比例。计算公式为

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

准确率在正负样本不均衡时不能准确衡量模型性能。精确率与召回率分别计算了正负样本分别占

据模型判定正负样本的比例。计算公式分别为

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

F1 值同时考虑了精确率与召回率,有效表现模型在正负样本上的分类效果。计算公式为

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

F1 值仅适用于衡量二分类问题,不适用于评估知识图谱中多样的实体类别分类结果。对于 C 类别的多分类问题与多标签问题,微平均 F1 值与宏平均 F1 值考虑了各个类别上的 F1 值指标。前者忽略样本类别,直接计算所有样本的判断结果;后者计算各类的 F1 值后再求平均。计算公式分别为

$$Micro_F1 = \frac{2 \times \sum_{i=1}^c T(i)}{2 \times \sum_{i=1}^c TP(i) + \sum_{i=1}^c FP(i) + \sum_{i=1}^c FN(i)}$$

$$Macro_F1 = \frac{1}{C} \sum_{i=1}^c F1(i)$$

表 7 展示了部分模型在 DBLP、Epinions 与 Reddit 数据集上的实验结果(实验数据为百分比形式)。较于其他模型,采用了动态记忆更新机制的 TRRN 模型在 DBLP 数据集的 ACC 指标上平均提高了 17.2%,在节点特征稀疏的数据集 Epinions 和 Reddit 上,ACC 指标仍超过其他基线模型,分别提升 2.6%与 6.5%,证明其可以有效编码实体的时间演化特征和其在图谱中的语义特征。

表 7 动态实体分类的实验结果对比

模型	实验数据集		
	DBLP	Epinions	Reddit
DynGEM ^[74]	ACC 52.3	ACC 31.6	
	Micro_F1 78.0	Micro_F1 28.0	ACC 39.9
	Macro_F1 76.0	Macro_F1 26.0	
DANE ^[16]	ACC 82.5	ACC 31.8	
	Micro_F1 82.0	Micro_F1 32.0	ACC 45.7
	Macro_F1 81.0	Macro_F1 29.0	
STAR ^[72]	ACC 80.3	ACC 32.6	ACC 50.8
TRRN ^[105]	ACC 88.9	ACC 34.6	ACC 52.0

4.2.2 应用场景

动态实体分类任务被用于分析时态知识图谱中的实体在不同时间所处的状态,在社交网络分析中的应用场景包括学术社交网络的学者研究领域兴趣

① www.dbpedia.org

补全与预测^[23,59]、基于社交网络的民意倾向性分析、网络钓鱼账户发现^[58]等应用;在交通网络中,通过实时分析道路中的车流量变化,判断道路交叉节点是否处于拥堵状态^[98]。

实体分类结果还可被用于分析实体演化趋势。DynGraph2Seq^[117]建模在线诊断网站中乳腺癌患者用户在不同主题论坛的在线状态与发帖记录变化,跟踪并预测患者的健康状况;DHNE^[59]通过分析学术社交网络中学者研究兴趣的演化趋势,以及与学术社区的动态关系(如是否在该领域的会议中发表论文等),判断该学者是特定领域或跨学科领域研究人员;文献^[118]使用时态知识图谱建模特定政治党派成员对法案投票的表决结果,挖掘党派成员实体表示蕴含的语义信息(如政治意见倾向性),并跟踪其意识形态随时间的变化。

4.3 实体推理

在实体推理任务中,模型对测试集中缺少头实体或尾实体的待推理知识 $(?, r, v, \tau)$ 或 $(u, r, ?, \tau)$,为实体集合 E 中的全部候选实体打分排序,选择排名最高的实体作为答案。

4.3.1 评测指标与实验结果

实体推理任务属于排序问题,其评价指标包括 MR 、 MRR 与 $Hits@N$ 等。

MR (Mean Rank)指标计算测试集 S 中所有 query 的排名均值,该指标越小(越接近 1),证明正确答案排位更靠前,排序效果越好。计算公式为

$$MR = \frac{1}{|S|} \sum_{i=1}^{|S|} rank_i.$$

考虑到时态知识图谱数据实体集规模不一, $rank_i$ 的取值可能会很大,因此 MR 并非一个好的指标。 MRR (Mean Reciprocal Ranking)指标计算测试集 S 中所有 query 倒数排名均值,该指标越大,证明正确答案排位更靠前,排序效果越好。计算公式为

$$MRR = \frac{1}{|S|} \sum_{i=1}^{|S|} \frac{1}{rank_i}.$$

$Hits@N$ (简称 $H@N$)指标计算在排序结果的前 N 名命中答案的 query 数目占测试集 S 的比例,该指标越大,排序效果越好。 N 值一般选择 1、3、5、10。计算公式为

$$H@N = \frac{1}{|S|} \sum_{i=1}^{|S|} \mathbb{I}(rank_i \leq N).$$

测试集负样例数据是随机构造的,并未考虑到待补全知识的候选答案实体可能不唯一的情况,可能会将正样例放入测试集负样例中从而导致误判。为了避免该情况,部分工作将上述指标区分为 raw 与 filtered 两类。filtered 是指将测试集中出现在训

练集正样例集合中的错误负例数据剔除后,再对模型进行评估。

表 8 展示了部分模型在 WIKIDATA 与 YAGO11k 数据集中的实体推理任务实验结果(实验数据为百分比形式,前 3 行展示 raw/filtered 指标,后 6 行展示 raw 指标)。从实验结果中可以看出,基于序列神经网络的方法(TeMP、HIP Network 等)能够准确捕捉实体的时间演化与拓扑结构演化,进而准确预测缺失实体。

表 8 实体推理的实验结果对比

模型	实验数据集					
	WIKIDATA			YAGO11k		
	MRR	H@3	H@10	MRR	H@3	H@10
Know-Evolve ^[65]	10.5/	13.1/	20.2/	5.2/	5.6/	10.2/
	12.6	14.3	21.6	6.2	6.6	11.4
DyRep ^[66]	4.9/	6.5/	20.9/	4.9/	5.5/	10.2/
	11.6	12.7	21.6	5.9	6.5	11.9
RE-NET ^[70]	32.4/	35.4/	43.2/	48.6/	54.2/	63.6/
	53.5	54.1	55.7	66.8	67.23	69.7
TTransE ^[1]	31.74	36.25	43.45	32.57	43.39	53.37
HyTE ^[18]	43.02	45.12	49.49	23.16	45.74	51.94
DySAT ^[73]	31.82	26.59	35.59	43.43	43.67	46.49
TeMP ^[101]	49.61	50.24	51.81	62.25	64.63	66.12
HIP Network ^[104]	54.71	54.73	56.46	67.55	68.49	70.37

4.3.2 应用场景

实体推理的目标是补全时态知识四元组中缺失的实体,可被广泛用于推荐系统应用场景中,包括政治事件图谱中预测事件参与者^[65],电商场景中预测用户未来可能点击浏览或购买的商品^[5],社交媒体平台中向用户推荐潜在好友,为科研人员推荐潜在的学术合作者等场景。

4.4 关系推理

关系推理任务包括关系存在推理与关系类型推理两类。前者在训练模型时,将已观测的知识图谱数据分为训练集、验证集及测试集,在不完整的数据上训练模型,并判定测试集中的待推理关系是否存在。后者在前者基础上,需要进一步地推理关系所属的类别。

4.4.1 评测指标与实验结果

(1) 关系存在推理

关系存在推理属于二分类问题,评价指标包括平均准确率 MAP (Mean Average Precision)等。考虑到知识图谱在演化中会不断涌现出新的实体,测试集中的节点不一定在训练集中出现,因此,关系存在推理任务分为直推式(Transductive)与归纳式(Inductive)两种测试方式,前者仅对训练集中出现

过的节点作测试,后者的测试集中包含训练集中未出现的节点,其结果反映了模型的泛化性。

表 9 展示了部分模型在 Reddit 数据集上的关系存在推理任务实验结果(实验指标为 MAP 与标准差,实验数据为百分比形式)。由于关系存在推理不必判断关系类别,较之关系类型推理任务更为简单,因此当前的方法在该任务中均取得了不错的效果,且效果很稳定。

表 9 关系存在推理实验结果对比

模型	测试指标	
	MAP(Transductive)	MAP(Inductive)
JODIE ^[5]	97.11±0.3	94.36±1.1
CAW ^[62]	99.72±0.1	99.37±0.1
TGNs ^[77]	98.70±0.1	97.55±0.1
TGAT ^[78]	98.12±0.2	96.62±0.3
DDGCL ^[79]	99.13±0.1	98.45±0.1

(2) 关系类型推理

关系类型推理属于排序问题。在时态知识图谱中,关系类型的数量一般远小于实体集合数量,因此在关系类型推理任务中,MR 也可被用作评价排序性能;其他评价指标包括 MRR 与 Hits@N 等。有关这些指标的计算过程已在实体推理一节中论述。

表 10 展示了部分模型在不同数据集中的关系类型推理实验结果(MR、MRR 与 H@1 对应实验结果为百分比形式),其中包括 t-TransE、HyTE 与 RTGE 在区间知识的推理结果,与 Know-Evolve、RE-NET 与 DACHA 在瞬时知识的实验结果。由于 RTGE 在损失函数中加入了使相邻时间超平面参数光滑表示机制,以及面向关系类型推理的负采样机制,在两个区间知识数据集的实验结果中,MR 指标与 H@1 指标超过了 t-TransE 与 HyTE 模型。在瞬时知识的实验结果中可以看出,较之其他基线方法,通过结构-时态注意力机制捕捉图谱演化模式的 DACHA 模型在关系类型推理任务上取得了更好的结果。

表 10 关系类型推理的实验结果对比

模型名称	数据集及实验结果
t-TransE ^[1]	Wikidata12k; MR 1.97 H@1 74.2 YAGO11k; MR 1.66 H@1 75.5
HyTE ^[18]	Wikidata12k; MR 1.13 H@1 92.6 YAGO11k; MR 1.23 H@1 81.2
RTGE ^[48]	Wikidata12k; MR 1.08 H@1 93.5 YAGO11k; MR 1.11 H@1 88.9
Know-evolve ^[65]	GDELT; MRR 23.1 H@1 11.4 ICEWS'18; MRR 25.4 H@1 14.8
RE-NET ^[70]	GDELT; MRR 40.7 H@1 33.3 ICEWS'18; MRR 43.5 H@1 35.6
DACHA ^[103]	GDELT; MRR 43.0 H@1 37.5 ICEWS'18; MRR 46.9 H@1 38.9

4.4.2 应用场景

关系推理任务有着广泛的应用场景,用于判断实体之间的关联性质,如在金融反欺诈场景中寻找诈骗者刻意隐匿的交易记录线索^[119];在人-人接触网络中挖掘与确诊病例的潜在历史接触者,及时阻断疫情大规模传播^[120-121];以及用于医疗辅助系统中,在依据电子病历构建的临床知识图谱中挖掘患者、药品、检验指标与疾病之间存在的隐含动态关联,以跟踪病人病情随时间演化状态,预测病情发展状况,并提出合理的诊断建议^[122-123]。

4.5 时间信息推理

时间信息推理分为时间点推理与时间区间推理两类任务。时间点推理任务需要判定瞬时知识发生的时间点数值,如时序点过程的方法可计算实体对在特定时间发生社交联系的概率^[64,66]。时间区间推理任务一般应用于推理区间知识的有效时间区间范围,在评估时,时间区间被表示为连续的时间点序列的形式,如区间[2014年,2016年]被离散化表示为三个离散的年份:{2014年,2015年,2016年},模型通过判断三元组(u,r,v)在各时间点的成立概率,以计算该三元组成立的最长连续时间区间。

4.5.1 评测指标与实验结果

(1) 时间点推理

时间点推理任务使用均方差 MAE (Mean Average Error) 指标评估预测时间点与真实时间点的数值误差,均方差越低,模型判断的时间点越精确。表 11 列出了部分模型在时间点推理任务中的实验结果(指标为 MAE,单位为小时)。由于 EvoKG 在建图谱演化时同时应用了循环神经网络与时序点过程用于捕捉复杂的时序演化特征以预测事件未来发生的时间,较于仅利用时序点过程的 Know-Evolve 模型与 GHNN 模型,在时间点推理结果中取得了更好的结果。

表 11 时间点推理的实验结果对比

模型	实验数据集	
	GDELT	ICEWS-500
Know-Evolve ^[65]	478.30	42.82
GHNN ^[93]	7.18	146.40
ATiSE ^[34]	303.80	2592.00
EvoKG ^[94]	2.89	9.65

(2) 时间区间推理

时间区间推理任务属于区间预测问题。在评价指标方面,TAC 指标计算预测区间 $[t_b^{pr}, t_e^{pr}]$ 与真实区间 $[t_b, t_e]$ 中起始时间、结束时间的绝对值差距;

Lacroix 等人^[27]认为 TAC 忽略了时间区间之间的交集,将基于计算机视觉目标检测任务中的交并比 IOU (Intersection Over Union) 指标迁移至时间区间预测任务中,将其归一化后,提出了泛化交并比 $gIOU$ (Generalized IOU) 指标,用于衡量两个时间区间的交集程度, $gIOU$ 值越高,代表两个区间更为重合度越高.然而,相对于真实区间[2014 年,2018 年],预测区间 1[2010 年,2013 年]以及预测区间 2[1900 年,1903 年]的 $gIOU$ 值均为 0,然而,从时间信息的邻近性看,预测区间 1 距离真实区间更近, $gIOU$ 值无法反映不存在交集的区间相似度.

基于此,Lacroix 等人^[27]考虑了时间的邻近性,设计了亲和增强交并比 $aeIOU$ (affinity enhanced IOU) 指标,计算两个区间并集的最短连续区间长度,最短连续区间值越小,证明预测区间越靠近真实区间.预测区间 1 与真实区间的最短连续区间为[2010 年,2018 年],长度为 8;预测区间 2 与真实区间的最短连续区间为[1900 年,2018 年],长度为 118.较于交并比指标,亲和增强交并比更好地衡量了不存在交集的预测区间与真实区间的绝对距离.进一步地,Cai 等人^[47]提出了泛化的亲和增强交并比 $gaeIOU$ (generalized $aeIOU$) 指标,较于 $aeIOU$, $gaeIOU$ 考虑了两个不相交时间区间之间的间隔,间隔越小,意味着预测区间与真实区间越相似.

表 12 展示了部分模型在时间区间推理任务中的实验结果(实验数据形式为百分比,更高的 $gIOU$ 、 $aeIOU$ 与 $gaeIOU$ 代表预测时间区间与真实时间区间重合度更高).从实验结果可以看出,由于针对时间区间特性设计了时间感知的盒推理(time-aware box reasoning)与时间负采样(time negative sampling)技术,较于 HyTE、TIMEPLEX 等模型,TIME2BOX 模型取得了更为优越的性能.

表 12 时间区间推理的实验结果对比

模型名称	数据集及实验结果
HyTE ^[18]	YAGO11k; $aeIOU$ 5.41 Wikidata12k; $aeIOU$ 5.41
TNT-Complex ^[27]	YAGO11k; $aeIOU$ 8.40 Wikidata12k; $gIOU$ 31.4, $aeIOU$ 18.8, $gaeIOU$ 11.0 Wikidata114k; $gIOU$ 27.9, $aeIOU$ 16.2, $gaeIOU$ 7.31
TIMEPLEX ^[124]	YAGO11k; $aeIOU$ 14.21 Wikidata12k; $gIOU$ 35.6, $aeIOU$ 18.6, $gaeIOU$ 12.6 Wikidata114k; $gIOU$ 29.3, $aeIOU$ 18.5, $gaeIOU$ 12.5
TIME2BOX ^[47]	Wikidata12k; $gIOU$ 41.2, $aeIOU$ 24.7, $gaeIOU$ 16.9 Wikidata114k; $gIOU$ 38.0, $aeIOU$ 24.4, $gaeIOU$ 15.8

4.5.2 应用场景

时间信息推理在事件预测方面有着广泛的应

用^[125]:在自然灾害预测领域,模型通过传感器收集的地区历史监测数据,预测该地区未来何时会发生地震、海啸等自然灾害;在商业风险预测领域,模型通过分析公司供应链、资金链等经营数据构成的时态知识图谱,预测其未来何时可能发生资金链断裂,或停牌、裁员、破产等风险事件的产生时间.

4.6 时态知识图谱分类

时态知识图谱分类的目标是判断时态知识建模的动态系统在特定时刻所属状态类别.

4.6.1 评测指标与实验结果

时态知识图谱分类的衡量指标为准确率与 $F1$ 值等分类问题的经典指标.当前的图分类研究主要集中于静态的图数据分类,面向时态知识图谱对应的分类研究工作较少,目前尚无时态知识图谱分类研究的基准数据集.表 13 展示了部分模型的实验结果(实验结果形式为百分比).

表 13 时态知识图谱分类的实验结果对比

模型名称	数据集及实验结果
Dynamic GCN (WD) ^[20]	CAD-120; ACC 54.3 $Micro_F1$ 50.6 HDM05; ACC 80.4 $Micro_F1$ 76.7
Dynamic GCN (CD) ^[20]	CAD-120; ACC 60.7 $F1$ 61.0 HDM05; ACC 85.1 $F1$ 81.5
DyGGNN ^[19]	Baboon Day 1; ACC 88.02 Baboon Day 2; ACC 86.21

4.6.2 应用场景

视频中的人体动作识别是时态知识图谱分类的一个重要应用场景,即通过建模视频中人体关节、骨骼为图谱结构,分析图谱的变化规律,从而判断每一帧中的人体动作状态(如静止、进食、行走等).时态知识图谱分类也可以被应用于视频对话任务中^[126],通过帧序列的场景图(即识别帧内物体及物体间位置关系构成的图谱)状态变化来辅助判断视频的语义内容.

时态知识图谱分类的另一应用场景是异常检测.当时态知识图谱建模的动态系统中出现异常时,往往会出现意料之外的网络结构与时态模式突变.文献^[19]分析传感器采集狒狒群体中每个个体动态行为,并构建群体网络以监测群体在不同时刻的状态(如活跃、休眠等).文献^[83]跟踪计算机网络系统中的通信日志变化,通过知识图谱建模系统中个人计算机与服务器间的不同网络通信模式,包括通信频率、通信流量等,以推断网络集群系统是否正在遭受 DDoS 攻击.在临床医疗中,异常检测可以应用于智能医疗助理场景中,在诊断处方、患者症状变化与治疗手段构成的知识图谱中检测患者病情的突变或

病历记录错误,以便及时进行人工干预,防止出现医疗事故^[53].

4.7 时态知识图谱趋势分析

知识图谱演化趋势跟踪的目标是研究各时刻知识图谱的状态之间的变化关联,与实体演化趋势跟踪不同,知识图谱演化趋势跟踪更关注宏观图谱层面(知识图谱及其包含的子图)变化,而非微观个体的演化趋势.

知识图谱演化趋势跟踪任务可分为三类.第一类方式是以点-边拓扑结构的形式直接将图谱可视化,分析图谱变化趋势;如图 13 所示,Yu 等人^[24]将 DBLP 数据集中的学术知识图谱可视化,研究不同学术领域社区的扩张与收缩,以挖掘正在兴起的学术热点研究领域.第二类方式采用降维技术在低维空间中表示不同时刻的实体向量或知识图谱向量,通过降维技术与聚类技术展示实体之间的亲疏变化;Hou 等人^[55]将维基百科社区投票网络中的用户向量降维至二维空间,挖掘维基百科用户群体投票交互演化规律;Taheri 等人^[19]使用 t-SNE 技术降维并映射图谱在各个时间的表示至 3 维空间中,直观地展示了图谱演化过程中的连贯性.第三类方式是预先设计宏观量化指标,展示图谱在不同时间的变化趋势;Goyal 等人^[74]通过将全体实体向量表示较于上一时间步的变化差值和作为指标以衡量图谱整体的变化,分析外部事件对公司社交网络中通信规模的影响.

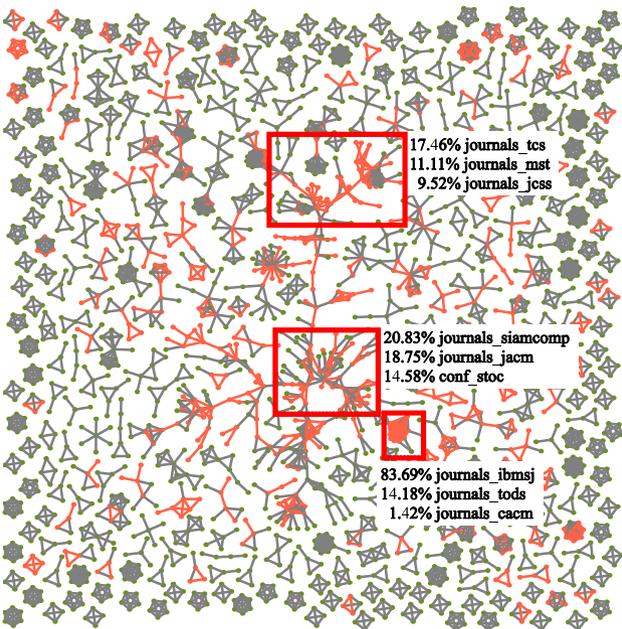


图 13 在 DBLP 中发现正在扩张的学术热点研究领域(已用红色矩形方框标注)^[24]

5 总结与展望

时态知识图谱是管理与分析动态演化知识的有效工具.时态知识图谱推理不仅能够提升知识完备性,支撑智能问答等基于时态知识图谱的检索类应用,还可以预知未来事件发展趋势,为决策性应用提供参考依据.因此,时态知识图谱推理是崭新且具有广阔前景的研究领域.近年来,时态知识图谱推理已经形成了一些研究成果,但是在以下方面仍然面临巨大挑战:

5.1 时态知识的可解释推理

可解释性是指时态知识的可解释推理可分为两类研究方向,分别是推理形式的可解释性与推理过程的可解释性.

在推理形式方面,目前时态知识图谱的推理方法大多基于表示学习与深度学习技术,使用具有强大学习能力的神经网络搭建模型,尽管取得了很好的效果,但其黑盒属性令推理结果无法解释.符号推理的方法试图从知识图谱中学习显式表示的逻辑规则表达式以推理知识,具有更好的可读性与可解释性^[10].神经网络结合符号(Neural-Symbolic)的时态知识图谱推理有望继承两者分别在推理性能与可解释性方面的优势,将会是今后的热门研究方向.

在推理过程方面,时态知识之间的因果关联是推理过程的重要依据^[127].目前的推理方法试图学习图谱中的时序信息,寻找知识演化的因果规律,例如,基于时序约束的路径推理方法通过时态路径中的时序递增关系学习演化规律^[56,62].然而,时序关系为因果关系的必要而非充要条件,但因果关联一定具有时序约束,即因事件必发生在果事件之前,但反之并不成立.时序信息不能确保一定存在因果关联,推理知识的过程往往不具有可解释性,这不仅导致模型推理性能的下降,也在一定程度上影响了推理结果的可信度.因此,如何结合因果学习方法,筛选时序信息中存在的混杂因子,提炼出纯粹的事件因果链用于解释推理是有意义的研究方向.

5.2 多类型、多粒度与模糊时间信息的混合推理

知识图谱中的时间信息并不保证是统一的,可能以多类型、多粒度、模糊的形式存在.多类型指知识图谱中可能并存有多种时间类型的知识,如图 1 展示的时态知识图谱涵盖 3 种类型知识:无时态知识(“出生于”关系等)、瞬时知识(“获奖”、“社交互

动”关系等)与区间知识(“效力于”关系等);其次,由于不同关系类型具有不同规模的演化尺度,知识图谱中时间信息表述粒度也并非统一,如图 1 中的社媒互动关系时态粒度精确到日,获奖关系精确到年。再次,考虑到时间信息抽取来源可能来自非结构化文本内容,时间信息的模糊表述(如“昨天下午”,“几个小时以前”)也是推理模型不可忽视的挑战。目前的时态知识图谱推理方法简单地假设知识图谱中时间信息为单一类型与单一事件粒度,时间信息均表述为统一格式,不适用于实际应用场景。研究面向多类型、多粒度以及模糊时间信息的时态知识图谱推理方法,捕捉不同演化尺度的关系信息,以及多粒度、模糊时间信息的表征能力,是未来有潜力的研究方向。

5.3 面向大规模数据的时态知识图谱推理

在工业界中,知识图谱的大规模可体现为两点:一是实体数量规模巨大,如科技情报图谱 AMiner^[128] 涵盖上亿体量的学者、论文、机构等实体;二是知识快速涌现,大量的时态知识数据以事件流形式不断涌现并快速更新迭代。在线社交平台 Twitter 每天都会产生近千万条推文,天猫电商平台在 2020 年的双十一购物节的订单产生峰值高达 58.3 万笔/秒。模型需要高效计算、在线推理实时产生的大规模时态知识数据,从而为用户提供即时性服务。随着新增加实体、知识的持续涌入,考虑到知识图谱实体数目巨大,若当数据更新后就重复训练模型,训练模型的计算代价相当高,无法支持实时推理的需求。在保证模型性能的前提下,研究模型的高效训练策略是有意义的研究方向。目前,基于增量式更新的推理方法已经做出了有意义的尝试,但仅在规模有限的数据集进行验证,距工业级应用还有很大提升空间。此外,在系统研究方面^[129-130],面向大规模时态知识图谱数据的高性能分布式存储、图数据检索算法与图计算工具也是不可忽视的工作,有助于高效分析知识,提升模型的训练与推理效率。

5.4 结合先验信息的时态知识图谱推理

目前的时态知识图谱推理工作主要为数据驱动模式,单纯从训练数据中学习规律会导致模型学习训练速度缓慢以及模型推理性能不佳等问题,结合领域或通用先验信息可有效解决该问题。

首先,结合不同领域的先验信息可提升模型的训练效率与推理性能。例如,在 ICEWS 数据集中推断(金正恩,会晤,特朗普,2019 年 6 月 30 日)这条知

识的置信度时,如果注入金正恩与特朗普分别在 2011 年至今、2017 年~2021 年分别为朝鲜与美国最高领导人,以及外交领域的“同等级别会晤”原则等先验信息,推理过程将会变得更加简单。在信贷风险监控领域,模型在学习用户借偿款数据之外,若融合个人风控领域相关的先验业务信息,如调高最近半年内频繁改变住址、更换职业用户的风险等级,将有助于模型更精准识别潜在风险用户,从而拒绝其贷款申请,降低金融风险。

其次,结合通用先验信息也有助于提高推理模型性能。在无时态知识图谱推理中的研究已证明了引入通用先验信息(如知识图谱类别体系、大规模预训练语言模型等)有利于提升推理任务的性能^[131]。目前有一些方法试图结合通用先验信息进行推理(如 RE-GCN 引入了实体类型信息),但效果有限。综上所述,如何有效融合先验信息,以提升模型训练效率与推理准确度有待进一步研究。

5.5 结合多模态信息的时态知识图谱推理

众多开源知识图谱如 Wikidata 等不仅记录了实体之间的关联,也记录了实体的多模态描述信息(如图片、视频、音频等),这为知识推理提供了更为丰富的信息源。多模态知识图谱推理领域的经典工作有^[132-133]等,其基本思路是将实体的视觉特征、文本特征以及其在知识图谱的结构特征融入为统一的实体表示进行推理。然而,这些工作仅限于静态知识图谱领域,目前在时态知识图谱推理领域暂无结合多模态数据的研究工作。

事实上,在时态知识图谱领域推理领域中,实体在特定时期对应的多模态数据可以作为推理知识的佐证。例如,在推断时态知识(勒布朗·詹姆斯,效力于,克利夫兰骑士队,[2014 年~2018 年])是否成立时,实体“勒布朗·詹姆斯”在关联图片的语义信息以及图片相应的时间信息(例如在 2016 年詹姆斯与骑士队队友捧起总冠军奖杯的照片)可以提升这条知识的置信度。尽管目前尚无多模态的时态知识图谱推理工作,考虑到多模态信息在知识图谱领域的应用,多模态信息结合时态知识图谱推理是有潜力且具有一定挑战性的发展方向。

5.6 时态知识图谱推理领域生态建设

时态知识图谱推理研究生态建设是推动该研究领域发展并在工业界大规模落地应用的关键,生态建设包括开源框架开发与维护,以及学术研讨社区建设。当前知识推理工作已经涌现出许多开源框架,集

成了代表性的知识推理方法与实验数据集,如亚马逊公司负责维护的 Deep Graph Library^①、清华大学自然语言处理团队研发的 OpenKE^② 以及 pykg2vec^③ 与 scikit-kge^④ 等. 目前时态知识图谱推理的开源框架较少,这与该领域刚刚兴起,发展并不成熟,且大多数研究工作未提供开源代码有关. Han 等人设计了集成部分时态知识图谱推理方法的开源框架^⑤,截至本文撰写完毕,这是唯一的时态知识图谱推理任务框架. 在数据集方面,未来研究应扩展至更广泛的时态知识图谱数据集,如通用知识图谱 DBpedia 或其他领域知识图谱中. 在学术研讨社区建设方面,本文对该领域的工作进行了系统性总结,此外,也有一些时态知识图谱推理领域的学术研讨社区^{⑥⑦}正在涌现. 今后,时态知识图谱推理领域亟需建立完整的生态社区,包括构建统一的 benchmark 评估数据集,实现涵盖各种模型的开源框架,以及建设时态知识图谱推理研究的研讨社区等,以便促进该领域在学术研究方向发展与工业落地应用.

作者贡献声明 沈英汉、江旭晖对本文贡献相同,为共同第一作者.

参 考 文 献

- [1] Leblay J, Chekol M W. Deriving validity time in knowledge graph//Proceedings of the Web Conference 2018 (Companion). Lyon, France, 2018: 1771-1776
- [2] Wang Yuan-Zhou, Jin Xiao-Long, Cheng Xue-Qi. Network big data: Present and future. Chinese Journal of Computers, 2013, 36(6): 1125-1138(in Chinese)
(王元卓, 靳小龙, 程学旗. 网络大数据: 现状与展望. 计算机学报, 2013, 36(6): 1125-1138)
- [3] Saxena A, Chakrabarti S, Talukdar P. Question answering over temporal knowledge graphs. arXiv preprint arXiv: 210601515, 2021
- [4] Jia Z, Pramanik S, Saha Roy R, et al. Complex temporal question answering on knowledge graphs//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. Queensland, Australia, 2021: 792-802
- [5] Kumar S, Zhang X, Leskovec J. Predicting dynamic embedding trajectory in temporal interaction networks//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2019: 1269-1278
- [6] Vives-Boix V, Ruiz-Fernández D, Ramón-Fernández A D, et al. A knowledge-based clinical decision support system for monitoring chronic patients//Proceedings of the 2017 International Work-Conference on the Interplay Between Natural and Artificial Computation. Almería, Spain, 2017: 435-443
- [7] Chen X, Jia S, Xiang Y. A review: Knowledge reasoning over knowledge graph. Expert Systems with Applications, 2020, 141: 112948
- [8] Guan Sai-Ping, Jin Xiao-Long, Jia Yan-Tao, et al. Knowledge reasoning over knowledge graph: A survey. Journal of Software, 2018, 29(10): 2966-2994(in Chinese)
(官赛萍, 靳小龙, 贾岩涛等. 面向知识图谱的知识推理研究进展. 软件学报, 2018, 29(10): 2966-2994)
- [9] Hou Zhong-Ni, Jin Xiao-Long, Chen Jian-Yun, et al. A survey of interpretable reasoning on knowledge graphs. Journal of Software, 2022, 33(12): 4644-4667(in Chinese)
(侯中妮, 靳小龙, 陈剑贇等. 知识图谱可解释推理研究综述. 软件学报, 2020, 33(12): 4644-4667)
- [10] Zhang J, Chen B, Zhang L, et al. Neural, symbolic and neural-symbolic reasoning on knowledge graphs. AI Open, 2021, 2: 14-35
- [11] Ma Rui-Xin, Li Ze-Yang, Chen Zhi-Kui, et al. Review of reasoning on knowledge graph. Computer Science, 2022, 49(S1): 74-85(in Chinese)
(马瑞新, 李泽阳, 陈志奎等. 知识图谱推理研究综述. 计算机科学, 2022, 49(S1): 74-85)
- [12] Kazemi S M, Goel R, Jain K, et al. Representation learning for dynamic graphs: A survey. Journal of Machine Learning Research, 2020, 21(70): 1-73
- [13] Shen Yu-Ming, Du Jian-Feng. Temporal knowledge graph completion: Methods and progress. Big Data Research, 2021, 7(3): 30-41(in Chinese)
(申宇铭, 杜剑峰. 时态知识图谱补全的方法及其进展. 大数据, 2021, 7(3): 30-41)
- [14] Gai B, Xiang Y, Gao L, et al. Temporal Knowledge Graph Completion: A Survey. arXiv preprint arXiv: 220108236, 2022
- [15] Wang Meng, Wang Hao-Fen, Li Bo-Han, et al. Survey of key technologies of new generation knowledge graph. Journal of Computer Research and Development, 2022, 59(9): 1947-1965(in Chinese)
(王萌, 王昊奋, 李博涵等. 新一代知识图谱关键技术综述. 计算机研究与发展, 2022, 59(9): 1947-1965)
- [16] Li J, Dani H, Hu X, et al. Attributed network embedding for learning in a dynamic environment//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. Singapore, 2017: 387-396
- [17] García-Durán A, Dumančić S, Niepert M. Learning sequence encoders for temporal knowledge graph completion//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels, Belgium, 2018: 4816-4821

① <https://www.dgl.ai/>

② <https://github.com/thunlp/OpenKE>

③ <https://github.com/Sujit-O/pykg2vec>

④ <https://github.com/mnick/scikit-kge>

⑤ https://github.com/TemporalKGTTeam/A_Unified_Framework_of_Temporal_Knowledge_Graph_Models

⑥ <https://github.com/Cantoria/dynamic-graph-papers>

⑦ <https://github.com/woojeongjin/dynamic-KG>

- [18] Dasgupta S S, Ray S N, Talukdar P. HyTE: Hyperplane-based temporally aware knowledge graph embedding//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels, Belgium, 2018; 2001-2011
- [19] Taheri A, Gimpel K, Berger-Wolf T. Learning to represent the evolution of dynamic graphs with recurrent models//Proceedings of the 2019 World Wide Web Conference. San Francisco, USA, 2019; 301-307
- [20] Manessi F, Rozza A, Manzo M. Dynamic graph convolutional networks. *Pattern Recognition*, 2020, 97: 107000
- [21] Zhu D, Cui P, Zhang Z, et al. High-order proximity preserved embedding for dynamic networks. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(11): 2134-2144
- [22] Zhu L, Guo D, Yin J, et al. Scalable temporal latent space inference for link prediction in dynamic social networks. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(10): 2765-2777
- [23] Wang X, Lu Y, Shi C, et al. Dynamic heterogeneous information network embedding with meta-path based proximity. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(3): 1117-1132
- [24] Yu W, Aggarwal C C, Wang W. Temporally factorized network modeling for evolutionary network analysis//Proceedings of the 10th ACM International Conference on Web Search and Data Mining. Cambridge, UK, 2017: 455-464
- [25] Yu W, Cheng W, Aggarwal C C, et al. Link prediction with spatial and temporal consistency in dynamic networks//Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne, Australia, 2017: 3343-3349
- [26] Dunlavy D M, Kolda T G, Acar E. Temporal link prediction using matrix and tensor factorizations. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 2011, 5(2): 1-27
- [27] Lacroix T, Obozinski G, Usunier N. Tensor decompositions for temporal knowledge base completion//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA, 2019
- [28] Tresp V, Ma Y, Baier S, et al. Embedding learning for declarative memories//Proceedings of the 15th European Semantic Web Conference. Portorož, Slovenia, 2017: 202-216
- [29] Ma Y, Tresp V, Daxberger E A. Embedding models for episodic knowledge graphs. *Journal of Web Semantics*, 2019, 59: 100490
- [30] Jiang T, Liu T, Ge T, et al. Encoding temporal information for time-aware link prediction//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin, USA, 2016: 2350-2354
- [31] Leblay J, Chekol M W, Liu X. Towards temporal knowledge graph embeddings with arbitrary time precision//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. Galway, Ireland, 2020: 685-694
- [32] Xu C, Chen Y-Y, Nayyeri M, et al. Temporal knowledge graph completion using a linear temporal regularizer and multivector embeddings//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Online, 2021: 2569-2578
- [33] Goel R, Kazemi S M, Brubaker M, et al. Diachronic embedding for temporal knowledge graph completion//Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York, USA, 2020: 3988-3995
- [34] Xu C, Nayyeri M, Alkhoury F, et al. Temporal knowledge graph embedding model based on additive time series decomposition. *arXiv preprint arXiv:191107893*, 2019
- [35] Jung J, Jung J, Kang U. Learning to walk across time for interpretable temporal knowledge graph completion//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. Singapore, 2021: 786-795
- [36] Dylla M, Miliaraki I, Theobald M. A temporal-probabilistic database model for information extraction. *Proceedings of the VLDB Endowment*, 2013, 6(14): 1810-1821
- [37] Chekol M, Pirrò G, Schoenfish J, et al. Marrying uncertainty and time in knowledge graphs//Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco, USA, 2017: 88-94
- [38] Chekol M W, Stuckenschmidt H. Rule based temporal inference//Proceedings of the Technical Communications of the 33rd International Conference on Logic Programming. Melbourne, Australia, 2018: 4:1-4:14
- [39] Gu L, Fang J, Zhao P, et al. Eliminating temporal conflicts in uncertain temporal knowledge graphs//Proceedings of the 19th International Conference on Web Information Systems Engineering. Dubai, United Arab Emirates, 2018: 333-347
- [40] Zhang Z, Cui P, Pei J, et al. TIMERS: Error-bounded SVD restart on dynamic networks//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans, USA, 2018: 224-231
- [41] Hitchcock F L. The expression of a tensor or a polyadic as a sum of products. *Journal of Mathematics and Physics*, 1927, 6(1-4): 164-189
- [42] Tucker L R. Some mathematical notes on three-mode factor analysis. *Psychometrika*, 1966, 31(3): 279-311
- [43] Rafailidis D, Nanopoulos A. Modeling the dynamics of user preferences in coupled tensor factorization//Proceedings of the 8th ACM Conference on Recommender Systems. Foster City, USA, 2014: 321-324
- [44] Shao P, Zhang D, Yang G, et al. Tucker decomposition-based temporal knowledge graph completion. *Knowledge-Based Systems*, 2022, 238: 107841
- [45] Jiang T, Liu T, Ge T, et al. Towards time-aware knowledge graph completion//Proceedings of the 26th International Conference on Computational Linguistics: Technical Papers. Osaka, Japan, 2016: 1715-1724

- [46] Xu C, Nayyeri M, Alkhoury F, et al. TeRo: A time-aware knowledge graph embedding via temporal rotation//Proceedings of the 28th International Conference on Computational Linguistics. Barcelona, Spain (Online), 2020: 1583-1593
- [47] Cai L, Janowicz K, Yan B, et al. Time in a box: Advancing knowledge graph completion with temporal scopes//Proceedings of the 11th on Knowledge Capture Conference. Virtual Event, 2021: 121-128
- [48] Xu Y, Sun S, Zhang H, et al. Time-aware graph embedding: A temporal smoothness and task-oriented approach. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 2021, 16(3): 1-23
- [49] Nickel M, Tresp V, Kriegel H-P. A three-way model for collective learning on multi-relational data//Proceedings of the 28th International Conference on Machine Learning. Washington, USA, 2011: 809-816
- [50] Allen J F. Maintaining knowledge about temporal intervals. *Communications of the ACM*, 1983, 26(11): 832-843
- [51] Omran P G, Wang K, Wang Z. Learning temporal rules from knowledge graph streams//Proceedings of the AAAI Spring Symposium: Combining Machine Learning with Knowledge Engineering. Palo Alto, USA, 2019
- [52] Mitrovic S, De Weerd J. Dyn2Vec: Exploring dynamic behaviour using difference networks-based node embeddings for classification//Proceedings of the International Conference on Data Science. Prague, Czech Republic, 2019: 194-200
- [53] Yu W, Cheng W, Aggarwal C C, et al. NetWalk: A flexible deep embedding approach for anomaly detection in dynamic networks//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 2672-2681
- [54] Heidari F, Papagelis M. EvoNRL: Evolving network representation learning based on random walks//Proceedings of the 7th International Conference on Complex Networks and their Applications. Lyon, France, 2018: 457-469
- [55] Hou C, Zhang H, HE S, et al. GloDyNE: Global topology preserving dynamic network embedding. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(10): 4826-4837
- [56] Nguyen G H, Lee J B, Rossi R A, et al. Continuous-time dynamic network embeddings//Proceedings of the Web Conference 2018. Lyon, France, 2018: 969-976
- [57] Liu Y, Ma Y, Hildebrandt M, et al. TLogic: Temporal logical rules for explainable link forecasting on temporal knowledge graphs//Proceedings of the 26th AAAI Conference on Artificial Intelligence. Virtual, 2021: 4120-4127
- [58] Lin D, Wu J, Yuan Q, et al. T-EDGE: Temporal weighted multidigraph embedding for Ethereum transaction network analysis. *Frontiers in Physics*, 2020, 8: 204
- [59] Yin Y, Ji L-X, Zhang J-P, et al. DHNE: Network representation learning method for dynamic heterogeneous networks. *IEEE Access*, 2019, 7: 134782-134792
- [60] Sun H, Zhong J, Ma Y, et al. TimeTraveler: Reinforcement learning for temporal knowledge graph forecasting. *arXiv preprint arXiv:210904101*, 2021
- [61] Li Z, Jin X, Guan S, et al. Search from history and reason for future: Two-stage reasoning on temporal knowledge graphs//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics. Virtual Event, 2021: 4732-4743
- [62] Wang Y, Chang Y-Y, Liu Y, et al. Inductive representation learning in temporal networks via causal anonymous walks//Proceedings of the 2021 International Conference on Learning Representations. Vienna, Austria, 2021
- [63] Han Z, Chen P, Ma Y, et al. Explainable subgraph reasoning for forecasting on temporal knowledge graphs//Proceedings of the 9th International Conference on Learning Representations. Virtual Event, 2021
- [64] Dai H, Wang Y, Trivedi R, et al. Deep coevolutionary network: Embedding user and item features for recommendation. *arXiv preprint arXiv:160903675*, 2016
- [65] Trivedi R, Dai H, Wang Y, et al. Know-Evolve: Deep temporal reasoning for dynamic knowledge graphs//Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia, 2017: 3462-3471
- [66] Trivedi R, Farajtabar M, Biswal P, et al. DyRep: Learning representations over dynamic graphs//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA, 2019
- [67] Lu Y, Wang X, Shi C, et al. Temporal network embedding with micro-and macro-dynamics//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing, China, 2019: 469-478
- [68] Chang X, Liu X, Wen J, et al. Continuous-time dynamic graph learning via neural interaction processes//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. Virtual Event, Ireland, 2020: 145-154
- [69] Goyal P, Chhetri S R, Canedo A. dyngraph2vec: Capturing network dynamics using dynamic graph representation learning. *Knowledge-Based Systems*, 2020, 187: 104816
- [70] Jin W, Qu M, Jin X, et al. Recurrent event network: Autoregressive structure inference over temporal knowledge graphs//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Virtual Event, 2019: 6669-6683
- [71] Li Z, Jin X, Li W, et al. Temporal knowledge graph reasoning based on evolutionary representation learning//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. Virtual Event, Canada, 2021: 408-417
- [72] Xu D, Cheng W, Luo D, et al. Spatio-temporal attentive RNN for node classification in temporal attributed graphs//

- Proceedings of the 28th International Joint Conferences on Artificial Intelligence. Macao, China, 2019; 3947-3953
- [73] Sankar A, Wu Y, Gou L, et al. DySAT: Deep neural representation learning on dynamic graphs via self-attention networks// Proceedings of the 13th International Conference on Web Search and Data Mining. Houston, USA, 2020; 519-527
- [74] Goyal P, Kamra N, He X, et al. DynGEM: Deep embedding method for dynamic graphs. arXiv preprint arXiv:180511273, 2018
- [75] Pareja A, Domeniconi G, Chen J, et al. EvolveGCN: Evolving graph convolutional networks for dynamic graphs//Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA, 2020; 5363-5370
- [76] Hajiramezani E, Hasanzadeh A, Narayanan K, et al. Variational graph recurrent neural networks. Advances in Neural Information Processing Systems, 2019, 32: 10700-10710
- [77] Rossi E, Chamberlain B, Frasca F, et al. Temporal graph networks for deep learning on dynamic graphs. arXiv preprint arXiv:200610637, 2020
- [78] Xu D, Ruan C, Korpeoglu E, et al. Inductive representation learning on temporal graphs//Proceedings of the 8th International Conference on Learning Representations. Addis Ababa, Ethiopia, 2020
- [79] Tian S, Wu R, Shi L, et al. Self-supervised representation learning on dynamic graphs//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. Queensland, Australia, 2021; 1814-1823
- [80] Zhou Y, Liu W, Pei Y, et al. Dynamic network embedding by semantic evolution//Proceedings of the 2019 International Joint Conference on Neural Networks (IJCNN). Budapest, Hungary, 2019; 1-8
- [81] Perozzi B, Al-Rfou R, Skiena S. Deepwalk: Online learning of social representations//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York City, USA, 2014; 701-710
- [82] Grover A, Leskovec J. node2vec: Scalable feature learning for networks//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA, 2016; 855-864
- [83] Mahdavi S, Khoshraftar S, An A. dynnode2vec: Scalable dynamic network embedding//Proceedings of the 2018 IEEE International Conference on Big Data (Big Data). Seattle, USA, 2018; 3762-3765
- [84] Bian R, Koh Y S, Dobbie G, et al. Network embedding and change modeling in dynamic heterogeneous networks// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France, 2019; 861-864
- [85] Peng H, Li J, Yan H, et al. Dynamic network embedding via incremental skip-gram with negative sampling. Science China Information Sciences, 2020, 63(10): 1-19
- [86] Liu Z, Zhou D, Zhu Y, et al. Towards fine-grained temporal network representation via time-reinforced random walk// Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA, 2020; 4973-4980
- [87] Wu A, Yuan Y, Ma Y, et al. Node embedding research over temporal graph. International Journal of Software and Informatics, 2021, 11(1): 5-28
- [88] Meilian L, Danna Y. HIN_DRL: A random walk based dynamic network representation learning method for heterogeneous information networks. Expert Systems with Applications, 2020, 158: 113427
- [89] Yuan W, Shi C, Guan D. Dynamic network embedding via multiple sequence learning. Neural Computing and Applications, 2021, 34(5): 3843-3855
- [90] Yan J, Xu H, Li L. Modeling and applications for temporal point processes//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2019; 3227-3228
- [91] Zuo Y, Liu G, Lin H, et al. Embedding temporal network via neighborhood formation//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018; 2857-2866
- [92] Huang H, Fang Z, Wang X, et al. Motif-preserving temporal network embedding//Proceedings of the 29th International Joint Conference on Artificial Intelligence. Yokohama, Japan, 2020; 1237-1243
- [93] Han Z, Ma Y, Wang Y, et al. Graph Hawkes neural network for forecasting on temporal knowledge graphs//Proceedings of the 2nd Conference on Automated Knowledge Base Construction. Virtual, 2020
- [94] Park N, Liu F, Mehta P, et al. EvoKG: Jointly modeling event time and network structure for reasoning over temporal knowledge graphs//Proceedings of the 15th ACM International Conference on Web Search and Data Mining. Tempe, USA, 2022; 794-803
- [95] Li Z, Guan S, Jin X, et al. Complex evolutionary pattern learning for temporal knowledge graph reasoning//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Dublin, Ireland, 2022; 290-296
- [96] Li Z, Hou Z, Guan S, et al. HiSMATCH: Historical structure matching based temporal knowledge graph reasoning. arXiv preprint arXiv:221009708, 2022
- [97] Gao Y, Chowdhury T, Wu L, et al. Modeling health stage development of patients with dynamic attributed graphs in online health communities. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(2): 1831-1843
- [98] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting// Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden, 2018; 3634-3640

- [99] Xiong Y, Zhang Y, Fu H, et al. DynGraphGAN: Dynamic graph embedding via generative adversarial networks//Proceedings of the 24th International Conference on Database Systems for Advanced Applications. Chiang Mai, Thailand, 2019: 536-552
- [100] Wang Y, Li P, Bai C, et al. Generic representation learning for dynamic social interaction//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining Workshop. San Diego, USA, 2020
- [101] Wu J, Cao M, Cheung J C K, et al. TeMP: Temporal message passing for temporal knowledge graph completion//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Virtual Event, 2020: 5730-5746
- [102] Xu Z, Ou Z, Su Q, et al. Embedding dynamic attributed networks by modeling the evolution processes//Proceedings of the 28th International Conference on Computational Linguistics. Barcelona, Spain (Online), 2020: 6809-6819
- [103] Chen L, Tang X, Chen W, et al. DACHA: A dual graph convolution based temporal knowledge graph representation learning method using historical relation. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 2021, 16(3): 1-18
- [104] He Y, Zhang P, Liu L, et al. HIP Network: Historical information passing network for extrapolation reasoning on temporal knowledge graph//Proceedings of the 30th International Joint Conference on Artificial Intelligence. 2021: 1915-1921
- [105] Xu D, Liang J, Cheng W, et al. Transformer-style relational reasoning with dynamic memory updating for temporal network modeling//Proceedings of the 35th AAAI Conference on Artificial Intelligence. Virtual Event, 2021: 4546-4554
- [106] Wei H, Hu G, Bai W, et al. Lifelong representation learning in dynamic attributed networks. *Neurocomputing*, 2019, 358: 1-9
- [107] Kipf T N, Welling M. Variational graph auto-encoders. arXiv preprint arXiv:161107308, 2016
- [108] Lan L, Fu Y-G. Developing GCN: Graph convolutional network with evolving parameters for dynamic graphs//Proceedings of the 27th International Conference on Neural Information Processing. 2021: 369-376
- [109] Ma Y, Guo Z, Ren Z, et al. Streaming graph neural networks//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Virtual Event, China, 2020: 719-728
- [110] Hamilton W, Ying Z, Leskovec J. Inductive representation learning on large graphs//Proceedings of the Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing Systems 2017. Long Beach, USA, 2017: 1024-1034
- [111] Cui Z, Li Z, Wu S, et al. DYGCN: Dynamic graph embedding with graph convolutional network. arXiv preprint arXiv: 210402962, 2021
- [112] Chen H, Xiong Y, Zhu Y, et al. Highly liquid temporal interaction graph embeddings//Proceedings of the 2021 Web Conference. Ljubljana, Slovenia, 2021: 1639-1648
- [113] Vrandečić D. Wikidata: A new platform for collaborative data collection//Proceedings of the 21st International Conference on World Wide Web. Lyon, France, 2012: 1063-1064
- [114] Hoffart J, Suchanek F M, Berberich K, et al. YAGO2: A spatially and temporally enhanced knowledge base from Wikipedia. *Artificial Intelligence*, 2013, 194: 28-61
- [115] O'brien S P. Crisis early warning and decision support: Contemporary approaches and thoughts on future research. *International Studies Review*, 2010, 12(1): 87-104
- [116] Leetaru K, Schrodt P A. GDELT: Global data on events, location, and tone, 1979 – 2012//Proceedings of the ISA Annual Convention. 2013: 1-49
- [117] Gao Y, Wu L, Homayoun H, et al. DynGraph2Seq: Dynamic-graph-to-sequence interpretable learning for health stage prediction in online health forums//Proceedings of the 2019 IEEE International Conference on Data Mining (ICDM). Beijing, China, 2019: 1042-1047
- [118] Ferreira C H G, Ferreira F M, De Sousa Matos B, et al. Modeling dynamic ideological behavior in political networks. *The Journal of Web Science*, 2019, 7
- [119] Min S, Gao Z, Peng J, et al. STGSN—A spatial-temporal graph neural network framework for time-evolving social networks. *Knowledge-Based Systems*, 2021, 214: 106746
- [120] Firth J A, Hellewell J, Klepac P, et al. Using a real-world network to model localized COVID-19 control strategies. *Nature Medicine*, 2020, 26(10): 1616-1622
- [121] Yang X, Xu T, Jia P, et al. Transportation, germs, culture: A dynamic graph model of COVID-19 outbreak. *Quantitative Biology*, 2020, 8(3): 238-244
- [122] Chen De-Hua, Yin Su-Na, Le Jia-Jin, et al. A link prediction model for clinical temporal knowledge graph. *Journal of Computer Research and Development*, 2017, 54(12): 2687-2697 (in Chinese)
(陈德华, 殷苏娜, 乐嘉锦等. 一种面向临床领域时序知识图谱的链接预测模型. *计算机研究与发展*, 2017, 54(12): 2687-2697)
- [123] Song F, Wang B, Tang Y, et al. Research of medical aided diagnosis system based on temporal knowledge graph//Proceedings of the International Conference on Advanced Data Mining and Applications. Foshan, China, 2020: 236-250
- [124] Jain P, Rathi S, Chakrabarti S. Temporal knowledge base completion: New algorithms and evaluation protocols//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Punta Cana, Dominican Republic, 2020: 3733-3747

- [125] Zhao L. Event prediction in the big data era: A systematic survey. *ACM Computing Surveys (CSUR)*, 2021, 54(5): 1-37
- [126] Geng S, Gao P, Chatterjee M, et al. Dynamic graph representation learning for video dialog via multi-modal shuffled transformers//*Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Virtual, 2021: 1415-1423
- [127] Du L, Ding X, Xiong K, et al. ExCAR: Event graph knowledge enhanced explainable causal reasoning//*Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*. Virtual Event, 2021: 2354-2363
- [128] Tang J. AMiner: Toward understanding big scholar data//*Proceedings of the 9th ACM International Conference on Web Search and Data Mining*. San Francisco, USA, 2016: 467-467
- [129] Besta M, Fischer M, Kalavri V, et al. Practice of streaming and dynamic graphs: Concepts, models, systems, and parallelism. arXiv preprint arXiv:1912.12740, 2020
- [130] Wang Xin, Chen Wei-Xue, Yang Ya-Jun, et al. Research on knowledge graph partitioning algorithms: A survey. *Chinese Journal of Computers*, 2021, 44(1): 235-260(in Chinese) (王鑫, 陈蔚雪, 杨雅君等. 知识图谱划分算法研究综述. *计算机学报*, 2021, 44(1): 235-260)
- [131] Ji S, Pan S, Cambria E, et al. A survey on knowledge graphs: Representation, acquisition, and applications. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 494-514
- [132] Xie R, Liu Z, Luan H, et al. Image-embodied knowledge representation learning. arXiv preprint arXiv:160907028, 2016
- [133] Mousselly-Sergieh H, Botschen T, Gurevych I, et al. A multimodal translation-based approach for knowledge graph representation learning//*Proceedings of the 7th Joint Conference on Lexical and Computational Semantics*. New Orleans, USA, 2018: 225-234



SHEN Ying-Han, Ph. D. candidate. His research interests include social knowledge graph and temporal knowledge reasoning.

JIANG Xu-Hui, Ph. D. candidate. His research interests include social knowledge graph and heterogeneous graph representation learning.

WANG Yuan-Zhuo, Ph. D., professor. His research

interests include knowledge graph and social computing.

LI Zi-Xuan, Ph. D. candidate. His research interests include temporal knowledge graph and knowledge reasoning.

LI Zi-Jian, M. S. candidate. His research interests include social knowledge graph and signed network representation learning.

TAN He-Xiang, M. S. candidate. His research interest includes social knowledge graph.

SHEN Hua-Wei, Ph. D., professor. His research interests include social network analysis and social media computing.

Background

With the rapid development of the knowledge graph, knowledge reasoning, as the core research problem of the knowledge graph, has received extensive attention. However, the traditional reasoning over knowledge graph mainly focuses on atemporal knowledge, such as common knowledge, which is static. Temporal knowledge graphs consider the temporal aspect of knowledge to describe the dynamic features of the real world. The temporal knowledge graph reasoning model is required to automatically mine new knowledge to explain the historical state of things, predict future development trends and describe the evolution rules to provide effective support for time-aware applications.

This paper provides a comprehensive review of existing research works in temporal knowledge graph reasoning. This paper first introduces the related concepts and task descriptions

of temporal knowledge graph reasoning. Next, this paper surveys and summarizes the research and developments of temporal knowledge graph reasoning methods from the perspectives of completion task and prediction task. Then, the data sets, reasoning tasks, related indicators, and application scenarios of temporal knowledge graph reasoning are discussed. During the end part of this paper, the future direction and development trend of temporal knowledge graph reasoning is outlined and discussed.

This paper is funded by the National Natural Science Foundation of China (Nos. U1836206, U21B2046, and 62172393), the Zhongyuanyingcai Program-Funded to Central Plains Science and Technology Innovation Leading Talent Program (No. 204200510002), and the Major Public Welfare Project of Henan Province (No. 201300311200).