

基于历史摘要增强的时序知识图谱补全方法

田晓薇, 张笑燕, 杜晓峰, 陆天波

(北京邮电大学计算机学院(国家示范性软件学院), 北京 100876)

摘要: 时序知识图谱补全旨在基于历史观测事实预测未来缺失的实体链接。为了克服长程信息截断与冗余噪声问题, 提出一种历史摘要增强(HSE)的方法。该方法首先通过关系图神经网络提取实体全局历史行为表示。随后构建紧凑的历史摘要对跨时间历史信息进行浓缩。最后, 通过门控融合机制自适应地结合历史摘要与当前查询表示, 用于链接预测。所提方法在 ICEWS14 与 ICEWS18 数据集上取得了较好的效果, 其中在 ICEWS14 上的 MRR 与 Hits@10 分别达到 47.41% 和 71.00%, 有效提升了时序知识图谱补全的性能。

关键词: 时序知识图谱补全; 历史摘要增强; 长程时间依赖; 时间编码; 链路预测

中图分类号: TP182

文献标志码: A

doi: 10.11959/j.issn.1000

Temporal Knowledge Graph Completion Based on Historical Summary Enhancement

TIAN Xiaowei, ZHANG Xiaoyan, DU Xiaofeng, LU Tianbo

School of Computer Science (National Pilot Software Engineering School), Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: Temporal knowledge graph completion aims to predict future missing entity links based on historical observed facts. To overcome the issues of remote information truncation and redundant noise, a method named Historical Summary Enhancement (HSE) was proposed. In this method, entity global historical behavior representations were first extracted through a relation graph neural network. Subsequently, compact historical summaries were constructed to condense cross-temporal historical information. Finally, the historical summaries and current query representations were adaptively combined via a gated fusion mechanism for link prediction. Better results were achieved by the proposed method on the ICEWS14 and ICEWS18 datasets, with the MRR and Hits@10 on ICEWS14 reaching 47.41% and 71.00%, respectively. This effectively improves the performance of temporal knowledge graph completion.

Key words: Temporal knowledge graph completion, Historical summary enhancement, Long-range temporal dependency, Time encoding, Link prediction

0 引言

时序知识图谱 (temporal knowledge graph, TKG) 在传统知识图谱 (knowledge graph, KG) 中引入时间戳, 用于描述事件随时间变化的动态过程, 已广泛应用于事件预测、情报分析和推荐系统

等场景^[1-3]。时序知识图谱补全 (temporal knowledge graph completion, TKGC) 旨在根据历史观测事实预测缺失或未来事实, 是时序图推理中的核心任务之一。

现有外推式 TKGC 方法通常将 TKG 表示为按

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 张笑燕, xiaoyan@bupt.edu.cn

基金项目: 国家重点研发计划项目 (No. 2023YFB3105902)

Foundation Items: The National Key R&D Program of China (No. 2023YFB3105902)

时间排列的图序列,并结合图神经网络(graph neural networks, GNNs)和时序建模模块学习动态演化规律。RE-NET^[4]、RE-GCN^[5]和 TiRGN^[6]等方法分别从局部结构聚合、循环状态更新和重复事件建模等角度提升了未来链接预测性能。进一步地, DyMemR^[7]通过动态记忆机制保存和更新历史状态,拓展了历史信息的利用范围。

然而,现有外推式TKGC方法对长程历史信息的利用仍存在局限。部分方法依赖有限历史窗口,可能直接截断较早但仍具有预测价值的历史事实。其中,一些基于循环神经网络(recurrent neural networks, RNNs)的方法虽然能够维护历史记忆,但在较长时间跨度下,早期信息可能随状态更新被逐步弱化。当查询时刻附近缺少直接证据时,模型难以充分利用实体的长期历史行为线索,从而影响预测结果。另一方面,直接对完整历史进行建模虽然能够扩大历史信息覆盖范围,但历史事实中通常包含冗余噪声,且历史跨度过长,容易带来额外计算开销。因此,如何在充分利用全局历史信息的同时,控制历史表示规模,是外推式TKGC需要解决的重要问题。

针对上述问题,本文提出一种基于历史摘要增强的TKGC方法。该方法首先利用实体全局历史行为表示学习(historical behavior representation, HBR)模块,在查询时刻前的全局历史事实上学习实体的行为表示。随后,历史摘要构建(historical summary construction, HSC)模块将实体全局历史行为表示与相对查询时刻的时间信息相结合,构造跨时间历史实体表示,并通过聚类将完整历史中的跨时间信息浓缩为数量受控的历史摘要。最后,历史摘要增强预测(summary enhanced prediction, SEP)模块依据当前查询选择相关历史摘要,并将其与查询实体表示进行自适应融合,以完成未来链接预测。本文主要工作如下:

(1) 提出一种历史摘要增强的TKGC方法(historical summary enhancement, HSE),该方法以查询时刻前的全局历史信息为基础,通过历史摘要对跨时间历史信息进行浓缩,为长程历史线索参与当前预测提供紧凑表示。

(2) 设计了HBR、HSC与SEP三个协同模块,从而提升模型长程时间依赖的建模能力。其中,HBR从全局历史事实中提取实体行为表示。HSC

将实体全局历史行为与时间信息结合,构造跨时间历史实体表示,并聚类形成紧凑历史摘要。SEP根据当前查询对历史摘要进行相关性选择,并通过门控机制将其与实体表示融合。

(3) 在ICEWS14和ICEWS18两个基准数据集上进行实验验证。实验结果表明,在本文选取的对比方法和统一实验设置下,HSE取得了较优的链接预测性能,验证了历史摘要增强建模方式的有效性。

1 相关工作

1.1 静态知识图谱补全

静态知识图谱补全^[8](knowledge graph completion, KGC)主要关注实体与关系的低维表示学习,相关方法大致可分为平移模型、张量分解模型和深度学习模型。平移模型以TransE^[9]、TransH^[10]等为代表,将关系建模为实体表示之间的向量平移。张量分解方法如DistMult^[11]和 ComplEx^[12]将KG表示为多维张量,并通过分解实现缺失事实推断。深度学习方法则进一步引入RNNs和GNNs等结构,以增强对复杂关系模式和局部结构信息的刻画能力。上述方法建模对象均为静态事实,未显式考虑时间信息,因而难以描述事件随时间演化的动态规律,不能直接适用于TKGC任务。

1.2 时序知识图谱插值

时间知识图谱补全^[13-14]通常可分为插值和外推两类。插值方法主要面向已知时间范围内的缺失事实补全,例如TTransE^[15]将时间作为附加特征引入评分函数,HyTE^[16]通过时间超平面对实体和关系进行建模,DE-Simple^[17]则设计了随时间变化的实体表示。这类方法能够较好利用观测时间区间内的信息,但其推理范围通常局限于已知时间窗口,对未来事实预测的适应性不足。

1.3 时序知识图谱外推

外推方法关注基于查询时刻前的历史事件预测未来事实,是近年来TKGC的主要研究方向。现有方法通常将TKG表示为按时间排列的图快照序列,在固定窗口内学习结构信息和时间依赖。典型方法中,RE-NET^[4]采用循环事件编码器和邻域聚合器预测未来事件,RE-GCN^[5]使用关系感知图卷积与门控循环单元联合建模局部结构与时间演化,TiRGN^[6]同时建模局部相邻历史、重复模式和周期

性特征。RPC^[18]则显式利用关系相关性对关系类型进行建模,并学习固定窗口内的事件周期模式。RETIA^[19]通过关系-实体双交互聚合机制建模结构信息,并利用门控循环单元(gated recurrent unit, GRU)更新实体和关系的时序表示。HGCT^[20]利用图 Transformer 与时间卷积 Transformer 联合建模历史事实的结构特征和时序依赖。这类基于序列建模的方法能够逐步整合历史信息,但当历史跨度较大时,较早信息可能在持续状态更新中被弱化,且可能忽略窗口之外的历史信息。考虑到 TKG 中的时变性, CEN^[21]提出基于课程学习的策略来处理不同长度的动态演化模式, FS-Net^[22]则基于频次统计信息提取不同历史长度下的实体模式。近期研究进一步从不同角度增强历史信息利用。CENET^[23]通过历史对比学习提升历史事件表示能力, LogCL^[24]从局部与全局历史信息的对比关系中学习更具判别性的表示。DyMemR^[7]提出记忆机制来筛选并保留潜在有用的历史事实。这些研究有效拓展了历史信息的利用范围,但随着历史事实持续累积,如何在避免直接逐条处理完整历史所带来的冗余信息和计算规模增长的同时,使较早历史线索仍能够参与当前预测,仍是外推任务的重要问题。

另一类工作强调推理过程的可解释性。规则方法通过学习时间逻辑规则完成推理,例如 TLogic^[25]基于时间随机游走抽取逻辑规则, TILP^[26]和 TEILP^[27]通过可微逻辑学习或受约束随机游走学习时间规则, TempValid^[28]进一步建模规则置信度的时间有效性。AILR-IR^[29]和 RSRule^[30]等神经符号方法尝试结合神经表示与逻辑规则,以提升规则学习的表达能力和泛化能力。路径和强化学习方法也被广泛用于可解释的 TKGC, xERTE^[31]设计时间关系图注意力机制进行可解释推理, HierarT^[32]利用强化学习进行多跳路径搜索, TPAR^[33]和 TiPNN^[34]等方法则围绕时间路径展开神经符号建模。CognTKE^[35]则构建时间认知关系有向图,并联合利用全局浅层推理和局部深层推理处理历史时间路径。这类方法能够提供相对清晰的推理路径,但显式抽取规则或链式路径通常会带来较高的存储与计算开销,并且在稀疏或复杂动态场景下,往往难以充分刻画丰富的历史交互模式。相较而言,本文并不显式构造规则或路径,而是从历史表示压缩与摘要增强的角度建模跨时间依赖,以兼顾

建模能力与计算效率。

随着大语言模型 (large language models, LLMs) 的发展,部分研究开始利用其语义理解与逻辑推理能力辅助 TKG 外推。LLM-DA^[36]利用 LLMs 从历史事实和关系语义中生成时间逻辑规则,并通过动态更新规则适应 TKG 的演化。SRM-LLM^[37]则利用 LLMs 分析关系类型,并构建关系关联子图以增强关系表示。这类方法通常依赖额外的文本信息及较大的预训练模型。与之不同,本文关注仅利用 TKG 中的结构与时间信息进行历史事实建模。

2 预备知识

2.1 时序知识图谱补全

时序知识图谱 (temporal knowledge graph, TKG) 是在传统静态知识图谱基础上引入时间戳形成的动态知识表示结构。设实体集合、关系集合和时间戳集合分别为 $\mathcal{E}$ 、 $\mathcal{R}$ 和 $\mathcal{T}$, 则 TKG 可表示为:

$$\mathcal{G} = \{(s, r, o, t) | s, o \in \mathcal{E}, r \in \mathcal{R}, t \in \mathcal{T}\} \quad (1)$$

其中, s 和 o 分别表示头实体和尾实体, r 表示关系, t 表示时间戳, 四元组 (s, r, o, t) 表示实体 s 与实体 o 在时间 t 通过关系 r 进行了事实交互。

对于给定的查询时间 t_q , 将其之前的历史观测事实记为:

$$\mathcal{G}_{\text{obs}}^{t_q} = \{(s, r, o, t) \in \mathcal{G} | t < t_q\} \quad (2)$$

本文关注外推式 TKGC 任务,即基于查询时间之前的历史观测事实,对 t_q 时刻的缺失事实进行预测。具体而言,给定查询 $(s, r, ?, t_q)$, 目标是依据历史观测集合 $\mathcal{G}_{\text{obs}}^{t_q}$, 从实体集合 $\mathcal{E}$ 中识别最可能的尾实体。为此,需要学习候选尾实体的评分函数:

$$f(o | s, r, t_q, \mathcal{G}_{\text{obs}}^{t_q}) \quad (3)$$

其中, $f(\cdot)$ 表示在给定头实体 s 、关系 r 、查询时间 t_q 及历史观测事实条件下,候选尾实体 o 的匹配得分。得分越大,说明实体 o 越有可能成为该查询的正确答案。因此,模型的预测结果可表示为:

$$\hat{o} = \operatorname{argmax}_{o \in \mathcal{E}} f(o | s, r, t_q, \mathcal{G}_{\text{obs}}^{t_q}) \quad (4)$$

2.2 符号说明

为了便于后续章节的阅读与公式阐述,本文所使用的主要数学符号及其含义说明如表 1 所示。




图 1 模型概览

表 1 符号说明

符号	说明
$\mathcal{G}$	时序知识图谱
$\mathcal{E}$	实体集合
$\mathcal{R}$	关系集合
$\mathcal{T}$	时间戳集合
(s, r, o, t)	在时间 t 发生的时序事实, 其中 s 为头实体, r 为关系, o 为尾实体
$\mathcal{G}_{\text{obs}}^{t_q}$	时间 t 之前可观测的历史事实集合
$\mathcal{N}(v)$	实体 v 在历史观测图中的邻域集合
d	嵌入表示维度
e_v	实体 v 的表示向量
e'_v	融合历史摘要后的增强实体 v 的表示向量
r	关系 r 的表示向量
$\psi(\cdot)$	ConvTransE ^[38] 解码函数

3 历史摘要增强的 TKGC 方法

3.1 模型概览

本文提出了一种基于历史摘要增强的 TKGC 方法 (historical summary enhancement, HSE)。该方法由实体全局历史行为表示学习 (historical behavior representation, HBR)、历史摘要构建 (historical summary construction, HSC) 和历史摘要增强预测 (summary enhanced prediction, SEP) 3 个部分组成。如图 1 所示, 对于给定查询 $(s, r, ?, t_q)$, HBR 首先基于查询时刻 t_q 之前的观测事实提取实体历史邻域, 学习实体全局历史行为表示。在此基础上, HSC 将实体全局历史行为表示与相对查询时刻的时

间间隔编码相结合, 构造跨时间历史实体表示, 进而采用聚类方法对其进行压缩, 将具有相似特征的历史表示归纳为数量受控的历史摘要。最后 SEP 利用门控融合机制得到增强后的查询表示, 并通过 ConvTransE 解码器完成候选实体评分。

3.2 实体全局历史行为表示学习 HBR 模块

为了从复杂的观测事实中准确提取实体的历史关联信息, 本节提出了实体全局历史行为表示学习 (historical behavior representation, HBR) 模块。给定查询时间 $t_q \in \mathcal{T}$, 对于每个实体 $v \in \mathcal{E}$, 收集其在 t_q 之前的历史邻域事实, 记为 $\mathcal{N}(v)$:

$$\mathcal{N}(v) = \{(u, r) | (v, r, u, t_u) \in \mathcal{G}_{\text{obs}}^{t_q}, t_u < t_q\} \quad (5)$$

其中, $u \in \mathcal{E}$ 表示与实体 v 在历史观测事实中发生交互的邻居实体, $r \in \mathcal{R}$ 表示对应的关系类型, t_u 表示该历史事实发生的时间戳, $\mathcal{G}_{\text{obs}}^{t_q}$ 表示查询时间 t_q 之前的历史观测事实集合。由此, $\mathcal{N}(v)$ 表示实体 v 在查询时间之前的历史邻域信息, 用于刻画其在历史中的交互模式。为获得实体全局历史行为表示, 采用关系图卷积网络 R-GCN^[39] 对邻域实体和关系进行聚合:

$$\mathbf{e}_v^l = \sigma \left(\sum_{u, r \in \mathcal{N}(v)} \frac{1}{c_v} \mathbf{W}_1^l (\mathbf{e}_u^{l-1} + \mathbf{r}) + \mathbf{W}_2^l \mathbf{e}_v^{l-1} \right) \quad (6)$$

其中, $\mathbf{e}_v^l$ 表示实体 v 在第 l 层的表示向量, $\mathbf{r}$ 为关系 r 的表示向量, c_v 为归一化系数, $\mathbf{W}_1^l$ 和 $\mathbf{W}_2^l$ 为可学习参数, σ 为非线性激活函数。在初始层, 即 $l=0$ 时, $\mathbf{e}_v^0$ 为实体 v 的随机初始表示。经过多层关系传播与邻域聚合后, 可得到实体 v 的全局历史行为表示向量 $\mathbf{e}_v$ 。

3.3 时间感知历史摘要构建 HSC 模块

为了在控制计算规模与噪声的同时有效保留长程线索, 本节提出了时间感知历史摘要构建 (historical summary construction, HSC) 模块。HBR 得到的 $\mathbf{e}_v$ 汇集了实体 v 在查询时刻前的全局历史结构信息, 但未显式区分不同历史线索距当前查询的时间远近。为保留历史时间信息并控制历史表示规模, HSC 以 (实体-时间) 对为单位构造具有时间区分能力的跨时间历史实体表示, 对该表示集合进行聚类压缩, 形成紧凑的历史摘要。

首先, 定义 (实体-时间) 对集合:

$$\mathcal{A}^{t_q} = \{(v, t_k) \mid t_k < t_q, v \in \mathcal{E}_{t_k}\} \quad (7)$$

其中, $\mathcal{E}_{t_k}$ 表示在历史时刻 t_k 出现的实体集合。对于 t_k , 定义其与查询时间 t_q 的时间间隔为:

$$\Delta t_k = |t_q - t_k| \quad (8)$$

在此基础上, 对任一 (实体-时间) 对 $(v, t_k) \in \mathcal{A}^{t_q}$, 定义实体 v 在时间 t_k 的跨时间历史实体表示:

$$\mathbf{x}_{v, t_k} = \text{ReLU}(\mathbf{W}_t (\mathbf{e}_v \oplus \text{TE}(\Delta t_k))) \quad (9)$$

其中, $\oplus$ 表示向量拼接操作, $\mathbf{W}_t$ 为可学习参数矩阵, 时间编码函数^[40]TE($\cdot$)定义为:

$$\text{TE}(\Delta t_k) = [\cos(\omega_1 \Delta t_k + \phi_1), \dots, \cos(\omega_d \Delta t_k + \phi_d)] \quad (10)$$

其中 $\omega \in \mathbb{R}^d$ 和 $\phi \in \mathbb{R}^d$ 分别表示可学习的向量。在获得时间感知表示后, 为提取其中具有代表性的跨时间历史模式, 采用 K-means 算法对 $\mathcal{A}^{t_q}$ 中所有 (实体-时间) 对所对应的跨时间历史实体表示进行聚类。令 K 为历史摘要的最大容量, 实际聚类数量定义为:

$$m(t_q) = \min(K, |\mathcal{A}^{t_q}|) \quad (11)$$

K-means 将其划分为 $m(t_q)$ 个簇, 并以各簇中心作为历史摘要, 得到 $\mathbf{H}^{t_q} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{m(t_q)}]$ 。其中, 摘要 $\mathbf{h}_i$ 表征第 i 个簇内实体表示所共有的历史行为和相对时间特征。当实体表示数量较少时, 摘要数量随历史规模相应调整。随着历史规模增加, 摘要数量由 K 限定。历史摘要采用在线构建, 模型基于当前查询时刻生成跨时间历史实体表示, 并通过聚类动态更新摘要, 以捕捉最新的历史行为与时间特征。

3.4 历史摘要增强预测 SEP 模块

为了充分利用压缩后的长程线索来提升未来链接的预测精度, 本节提出了历史摘要增强预测 (summary enhanced prediction, SEP) 模块。预测阶段并非所有历史摘要都与当前查询相关。为减少无关历史噪声, 首先计算查询实体 s 与各历史摘要 $[\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{m(t_q)}]$ 之间的相关性:

$$a_i = \text{Sim}(\mathbf{e}_s, \mathbf{h}_i) \quad (12)$$

其中, $\text{Sim}(\cdot)$ 表示余弦相似度。随后利用 Softmax 归一化得到各摘要权重, 并对历史摘要进行加权聚合:

$$w_i = \frac{\exp(a_i)}{\sum_j \exp(a_j)} \quad (13)$$

$$\mathbf{m}_s = \sum_i w_i \mathbf{h}_i \quad (14)$$

得到查询相关的历史摘要表示向量 $\mathbf{m}_s$ 后, 进一步引入门控融合机制, 自适应融合实体全局历史表示与历史摘要表示, 以增强头实体 s 在当前查询下的预测表示:

$$\mathbf{g} = \text{Sigmoid}(\mathbf{W}_g (\mathbf{e}_s \oplus \mathbf{m}_s)) \quad (15)$$

$$\mathbf{e}'_s = \mathbf{g} \odot \mathbf{e}_s + (1 - \mathbf{g}) \odot \mathbf{m}_s \quad (16)$$

其中, $\mathbf{e}_s$ 为头实体的历史表示向量, $\mathbf{e}'_s$ 为增强后的表示, $\odot$ 表示逐元素乘法, Sigmoid 表示激活函

数。门控融合机制用于自适应控制当前结构信息与历史摘要信息的比例。最后采用 ConvTransE 解码器计算候选尾实体得分：

$$f(o|s, r, t, \mathcal{G}_{\text{obs}}^{t_q}) = \psi(\mathbf{e}'_s, \mathbf{r}, \mathbf{e}_o) \quad (17)$$

3.5 训练目标

训练阶段采用实体预测交叉熵损失函数优化模型参数：

$$L = \sum_{(s, r, o, t) \in \mathcal{G}} -\log f(o|s, r, t, \mathcal{G}_{\text{obs}}^{t_q}) \quad (18)$$

3.6 算法整体流程

为了更直观地展示本文所提 HSE 方法的完整执行细节，表2总结了模型的端到端计算流程。给定历史观测事实集合、待预测查询集合以及 R-GCN 网络层数，该流程依次执行实体全局历史行为表示学习、时间感知历史摘要构建与历史摘要增强预测三个核心阶段，最终输出所有候选尾实体的预测得分。具体地，模型对同一时刻的所有查询进行批量并行计算，HBR 与 HSC 的计算结果由该时刻各查询共享，而摘要选择、门控融合及候选评分则并行执行。该机制有效均摊了不同时刻的摘要构建开销，并借助容量限制有效控制保障了模型的计算效率。

4 复杂度分析

设查询时间 t_q 之前的历史观测事实数为 $|\mathcal{G}_{\text{obs}}^{t_q}|$ ，实体-时间对数量为 $|\mathcal{A}^{t_q}|$ ，嵌入维度为 d ，R-GCN 层数为 L ，历史时刻 t_k 之前出现的实体数量为 $|\mathcal{E}_{t_q}|$ 。在实体全局历史行为表示学习阶段，模型主要开销来自 R-GCN 的消息传递，因此时间复杂度可记为 $O(L|\mathcal{G}_{\text{obs}}^{t_q}|d + L|\mathcal{E}_{t_q}|d^2)$ 。在时间感知历史摘要构建阶段，模型首先对历史实体表示进行时间编码并映射到统一表示空间，复杂度为 $O(|\mathcal{A}^{t_q}|d^2)$ 。随后压缩得到紧凑历史摘要，由于历史摘要数量上限为常数 K ，复杂度可记为 $O(|\mathcal{A}^{t_q}|d)$ 。在历史摘要增强预测阶段，查询表示与历史摘要之间的相关性计算复杂度为 $O(d)$ ，门控融合的复杂度为 $O(d^2)$ ，最终使用解码器对候选实体进行评分，其复杂度记为 $O(|\mathcal{E}|d)$ 。因此，单次预测的总体复杂度可表示为： $O(L|\mathcal{G}_{\text{obs}}^{t_q}|d + L|\mathcal{E}_{t_q}|d^2 + |\mathcal{A}^{t_q}|d^2 + |\mathcal{E}|d)$ 。由于通常有 $K \ll |\mathcal{E}_{t_q}|$ ，本文方法在保留长程历史信息的同时，有效降低了完整历史建模带来的冗余计算开销，因此在复杂度上更适合长时间跨度的时序知识图谱补

表2

基于历史摘要增强的 TKGC 算法流程

输入	历史观测事实集合 $\mathcal{G}_{\text{obs}}^{t_q}$ ，待预测查询集合 $\{(s, r, ?, t_q)\}$ ，R-GCN 网络层数 L
1: // 阶段 1：实体全局历史行为表示学习 (HBR) 2: 根据公式 (5) 提取查询时间 t_q 之前的实体全局历史邻域 $\mathcal{N}(v)$ 3: For $l = 1$ to L do 4: 根据公式 (6) 通过 R-GCN 聚合邻域特征 5: End for 6: 获取各实体的全局历史行为表示 $\mathbf{e}_v$ 7: // 阶段 2：时间感知历史摘要构建 (HSC) 8: For 每个历史时间戳 $t_k < t_q$ do 9: 根据公式 (8) 计算相对时间间隔 $\Delta t_k = t_q - t_k $ 10: 根据公式 (9) 注入时间编码，计算时间感知表示 $\mathbf{x}_{v, t_k}$ 11: End for 12: 使用 K-means 聚类算法对所有跨时间实体表示进行压缩，得到历史摘要 $\mathbf{H}^{t_q} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{m(t_q)}]$ 13: // 阶段 3：历史摘要增强预测 (SEP) 14: 对预测查询集合中的查询并行执行： 15: 根据公式 (12) 和公式 (13) 计算当前查询实体对各个历史摘要的相关性权重 16: 根据公式 (14) 进行加权求和，得到查询相关的历史摘要表示 $\mathbf{m}_s$ 17: 根据公式 (15) 计算门控机制下对实体历史表示的权重 g 18: 根据公式 (16) 利用门控机制将实体历史表示与 $\mathbf{m}_s$ 融合，得到实体的历史增强表示 $\mathbf{e}'_s$ 19: 根据公式 (17) 输入解码器，计算所有候选尾实体 $o \in \mathcal{E}$ 的得分 $f(o s, r, t, \mathcal{G}_{\text{obs}}^{t_q})$	
输出	候选尾实体 o 的预测得分 $f(o s, r, t, \mathcal{G}_{\text{obs}}^{t_q})$

全场景。

5 实验设置

5.1 数据集与评价指标

实验采用 ICEWS14^[41] 和 ICEWS18^[4] 2 个公开数据集。按照已有工作的设置, 数据集均按时间顺序划分为训练集、验证集和测试集。数据集统计信息如表 3 所示。评价指标采用 MRR 和 Hits@1、Hits@3、Hits@10, 并使用时间感知过滤设置。对比方法包括 RE-GCN^[5]、TiRGN^[6]、RPC^[18]、RETIA^[19]、CENET^[23]、LogCL^[24] 和 DyMemR^[7] 的代表性模型。

表 3 数据集统计信息

数据集	ICEWS14	ICEWS18
实体数	7,128	23,033
关系数	230	256
训练集	74,845	373,018
验证集	8,514	45,995
测试集	7,371	49,545
时间粒度	24 h	24 h

5.2 实验环境与超参数设置

本文所有实验均在配备 NVIDIA GeForce RTX 4090 GPU 和 16 核 Intel Xeon Gold 6430 CPU 的服務器上完成。实体和关系嵌入维度 d 设为 200, 优化器采用 Adam, 学习率设为 0.001。R-GCN 的网络层数设置为 $L = 2$ 。为保持不同数据集之间历史摘要容量和实验配置的一致性, 本文在主实验中统一设置最大摘要容量 $K = 100$ 。

5.3 实验结果

表 4 ICEWS14 数据集上的对比实验结果(%)

模型	MRR	Hits@1	Hits@3	Hits@10
RE-GCN	42.00	31.63	47.20	61.65
TiRGN	43.81	33.49	48.90	63.50
CENET	41.30	32.58	-	58.22
RPC	44.55	34.87	49.80	65.08
RETIA	42.77	32.29	47.78	62.76
LogCL	48.87	37.76	54.71	70.26
DyMemR	46.12	36.38	50.71	65.15
HSE (本文方法)	47.41	35.27	53.60	71.00

表 5 ICEWS18 数据集上的对比实验结果(%)

模型	MRR	Hits@1	Hits@3	Hits@10
RE-GCN	32.62	22.39	36.79	52.68
TiRGN	33.58	23.10	37.90	54.20
CENET	29.65	19.98	-	48.23
RPC	34.91	24.34	38.74	55.89
RETIA	32.43	22.24	36.48	52.49
LogCL	35.67	24.53	40.32	57.74
DyMemR	35.50	25.29	39.90	55.44
HSE (本文方法)	37.47	26.18	42.21	59.76

为了充分验证所提方法的有效性, 系统性地选取了 RE-GCN、TiRGN、RPC、CENET、RETIA、LogCL 和 DyMemR 作为代表性基线方法进行比较分析, 具体对比结果详见表 4 与表 5。

在 ICEWS14 数据集上, HSE 在 Hits@10 指标上取得最优结果, 达到 71.00%, 在 MRR 和 Hits@3 指标上取得次优结果。在数据规模更大、历史交互更为复杂的 ICEWS18 数据集上, HSE 在 MRR、Hits@1、Hits@3 和 Hits@10 四项指标上均取得最优结果。其中, RE-GCN、TiRGN、RPC 和 RETIA 这四种方法在两个数据集上整体性能均低于 HSE, 其中在历史交互更为复杂的 ICEWS18 数据集上差距更加明显。这些方法主要通过 RNNs 对有限窗口的事件进行循环状态更新, 能够有效利用相邻时间片及重复事件中的结构信息。当历史跨度增大时, 较早历史线索可能在持续状态更新或局部信息聚合过程中被弱化。实验结果表明, 仅依赖局部历史聚

合和循环更新,可能难以充分利用长程历史信息。DyMemR通过动态记忆机制保存和更新历史状态,在ICEWS14上的MRR和Hits@1均表现出较强竞争力,但在ICEWS18上的各项指标与HSE仍存在较为明显的差距。这表明动态记忆能够增强历史信息保留能力,但在历史规模增大、交互关系更加复杂时,记忆更新过程仍可能受到冗余历史信息的影响。CENET通过历史对比学习区分历史依赖与非历史依赖,但其在两个数据集上的整体结果相对较低,说明历史与非历史依赖的区分尚不足以充分刻画复杂的结构和时间关联。LogCL进一步利用局部与全局历史对比学习和查询相关历史选择,在ICEWS14上的MRR、Hits@1和Hits@3指标上取得最优结果,表明其在精确排序方面具有较强优势,HSE则在Hits@10上取得最优结果,说明历史摘要能够为候选实体预测提供更充分的历史补充信息。在ICEWS18上,HSE则全面超过LogCL、DyMemR等较强基线。该结果表明,历史摘要增强方式能够在保留长程历史线索的同时减少冗余历史信息的干扰,因而在复杂历史场景中表现出较好的适应性。

5.4 消融实验分析

为深入验证HSE模型中各关键模块的有效性,本文在ICEWS14和ICEWS18数据集上进行了消融实验,对比了完整模型与三种变体(“仅HBR”、“w/o HBR”、“w/o TE”)在MRR及Hits@K指标上的表现,具体结果如图2至图5所示。总体来看,完整HSE模型在所有指标上均保持最佳性能,各模块的缺失均会导致预测准确率的明显下滑。其中,去除HBR模块(“w/o HBR”)后的性能跌幅最为严重,例如在ICEWS18上MRR跌至30.19%,这表明通过R-GCN提取实体的基础历史关联信息,是整个时序推理与摘要构建的基石。当模型仅使用HBR模块(即去除了后续的历史摘要构建与门控融合机制)时,由于缺乏对跨时间长程行为模式的提炼,长程有效线索容易在迭代中被截断或稀释,导致各项指标远低于完整HSE模型。此外,去除时间编码模块(“w/o TE”)同样会造成显著的性能损失。值得注意的是,在时间跨度更长、交互更为复杂的ICEWS18数据集上,缺乏时间编码的摘要模型(MRR为33.17%)甚至略低于不构建摘要的“仅HBR”模型(MRR为33.58%)。

这是因为在缺乏时间距离约束的情况下,模型难以区分历史事实发生的先后顺序,不仅无法有效提取演化规律,反而容易将冗余的过时噪声强行压缩入摘要之中。而完整模型通过注入时间感知属性,确保了聚类摘要的有效性,从而在复杂长程场景下准确预测。




图2 本文方法及其变体在不同数据集上的MRR对比




图3 本文方法及其变体在不同数据集上的Hits@1对比




图4 本文方法及其变体在不同数据集上的Hits@3对比




图5 本文方法及其变体在不同数据集上的 Hits@10 对比




图6 在 ICEWS14 上不同时间跨度分组中的 MRR 对比

5.5 时间跨度分析

为验证本文方法对长时间依赖的建模能力,以 ICEWS14 数据集为例,按照查询时间与最近历史事实之间的时间间隔对测试数据进行分组,并以柱形图比较 HSE、RETIA 和 TiRGN 在各区间上的 MRR。如图6所示, HSE 在全部时间间隔分组中均取得最高性能,表明所提历史摘要增强方法能够同时利用近期历史信息 and 较远历史线索。在较短时间间隔 $[0,73]$ 内, 3 种方法均具有较好的预测表现, HSE 保持一定优势。当时间间隔超过 73 时, HSE 相较两种对比方法的优势明显扩大: 在 $[74,146]$ 区间内, HSE 的 MRR 接近对比方法的两倍, 在 $[147,219]$ 区间内, HSE 仍保持稳定领先, 尤其在 $[220,292]$ 和 $[293,365]$ 两个更长时间跨度区间内, HSE 的 MRR 均超过 RETIA 和 TiRGN 的 3 倍。尽管不同区间的绝对性能会受到查询样本构成和任务难度的影响而有所波动, 但 HSE 在各组中始终保持领先, 且在长时间间隔场景下优势更为显著。上述结果表明, HBR、HSC 和 SEP 的协同设计能够在预测阶段为当前查询提供有效的历史摘要信息, 使较早历史中的行为线索仍可参与未来事实预测, 从而避免了长程历史信息截断和递归压缩导致的信息稀释问题。

5.6 敏感性分析

为探究图神经网络聚合层数对实体全局历史行为表示学习 (HBR) 模块的影响, 以 ICEWS14 数据集为例, 本文对 R-GCN 的网络层数在 $L \in \{1,2,3,4,5\}$ 范围内进行了敏感性分析, 实验结果如图7所示。观察数据可知, 当网络层数 $L=1$ 时, 模型的整体性能相对较低 (MRR 为 46.36%)。

这是因为单层网络仅能感知直接相连的一跳邻居, 感受野有限, 不足以充分捕获实体在历史时间片中的丰富结构交互特征。当层数增加至 $L=2$ 时, 模型的 MRR、Hits@1 及 Hits@3 均达到峰值, 表明两层图卷积能够为实体历史表示提供最为适度的局部上下文信息。随着网络层数继续加深 ($L \geq 3$), 尽管较宽松的 Hits@10 指标因感受野的扩大仍有小幅上升, 但对排位要求更高的准确率指标 (MRR 与 Hits@1) 开始出现回落与波动。这种现象主要归因于深层图神经网络容易引发的“过平滑 (over-smoothing)”问题。过深的聚合操作会引入大量不相关的高阶拓扑噪声, 导致不同实体的历史行为特征趋于同质化, 进而模糊了核心实体的个性化线索。综合考虑特征表达能力与噪声控制的平衡, 本文在最终模型中选取 $L=2$ 作为基础的网络聚合层数。

为分析历史摘要最大容量 K 对模型性能的影响, 本文在 ICEWS14 数据集上进行了敏感性实验。如图8所示, 当 K 从 25 增加至 100 时, 各项指标总体上升。当 K 继续增大至 200 时, 性能变化趋于平缓, 相较于 $K=100$ 时, MRR 和 Hits@3 仅小幅提升, Hits@1 略有下降。结果表明, 模型在 $K=100$ 后已进入较稳定的性能区间。继续增加历史摘要数量带来的性能增益较为有限, 同时会增加聚类及摘要相关性计算的用时。综合考虑模型性能、计算效率以及不同数据集间实验设置的一致性, 本文统一设置 $K=100$ 。

5.7 推理时间分析

为评估模型的推理效率, 在相同实验环境下统




图7 R-GCN网络层数对模型性能的影响




图8 历史摘要最大容量 K 对模型性能的影响

计各模型在测试集推理所需的总时间,结果如表6所示。由表6可知,HSE的推理时间略高于RE-GCN,主要是由于历史摘要构建以及查询与历史摘要之间的相关性计算引入了额外开销。然而,受益于历史摘要数量上限的设置,新增计算规模得到有效控制,HSE在ICEWS14和ICEWS18上的推理时间均显著低于RETIA和TiRGN。上述结果表明,HSE在增强长程历史信息建模能力的同时,仍能保持较好的推理效率。

表6 不同模型在两个数据集上的推理时间对比

数据集	HSE	RE-GCN	RETIA	TiRGN
ICEWS14	0.1	0.05	8.46	20.63
ICEWS18	0.48	0.3166	28.71	159.93

6 结束语

本文针对时序知识图谱补全中长程历史信息利用不足及全局历史信息规模大、冗余度高的问题,提出历史摘要增强方法HSE。该方法首先在查询时刻前的全局历史图上提取实体历史行为表示,随后结合相对时间编码与聚类构建容量受限的紧凑历史摘要,最后根据当前查询选择并融合相关摘要。两个基准数据集上的实验结果表明,HSE取得了较优的链接预测性能。消融和时间跨度分析验证了各模块及长程历史建模的有效性,同时兼顾了预测精度与计算开销。

一寸证件照

参考文献:

- [1] Cao G, Cui S M, Joe I. Improving the spatial-temporal aware attention network with dynamic trajectory graph learning for next point-of-interest recommendation[J]. Information Processing & Management, 2023, 60(3): 103335.
- [2] Wang L J, Adiga A, Chen J Z, et al. Causalgn: Causal-based graph neural networks for spatio-temporal epidemic forecasting[C]//Proceedings of the AAAI conference on artificial intelligence. Virtual: AAAI Press, 2022, 36(11): 12191-12199.
- [3] 赖清楠,金建栋,周昌令.基于大语言模型的网络威胁情报知识图谱构建技术研究[J].通信学报,2024,45(S2): 33-43.
- [4] Jin W, Qu M, Jin X S, et al. Recurrent event network: Autoregressive structure inference over temporal knowledge graphs[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Virtual: ACL Press, 2020: 6669-6683.
- [5] Li Z X, Jin X L, Li W, et al. Temporal knowledge graph reasoning based on evolutionary representation learning[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. Virtual: ACM Press, 2021: 408-417.
- [6] Li Y J, Sun S L, Zhao J. TiRGN: Time-guided recurrent graph network with local-global historical patterns for temporal knowledge graph reasoning[C]//Proceedings of the 31st International Joint Conference on Artificial Intelligence (IJCAI). Vienna: IJCAI Organization, 2022: 2152-2158.
- [7] Zhang F W, Zhang Z, Zhuang F Z, et al. Temporal knowledge graph reasoning with dynamic memory enhancement[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(11): 7115-7128.
- [8] 王萌,王昊奋,李博涵,等.新一代知识图谱关键技术综述[J].计算机研究与发展,2022,59(9): 1947-1965.
- [9] Bordes A, Usunier N, Garcia-Duran A, et al. Translating embeddings for modeling multi-relational data[C]//Advances in Neural Information Processing Systems. Lake Tahoe: Curran Associates Inc. 2013: 26.
- [10] Wang Z, Zhang J W, Feng J L, et al. Knowledge graph embedding by translating on hyperplanes[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Québec: AAAI Press, 2014, 28(1).
- [11] Yang B S, Yih W, He X D, et al. Embedding entities and relations for learning and inference in knowledge bases[C]//International Confer-

- ence on Learning Representations (ICLR). San Diego: ICLR, 2015.
- [12] Trouillon T, Welbl J, Riedel S, et al. Complex embeddings for simple link prediction[C]//International Conference on Machine Learning (ICML). New York: PMLR Press, 2016: 2071-2080.
- [13] 沈英汉,江旭晖,王元卓,等. 时态知识图谱的推理研究综述[J]. 计算机学报, 2023, 46(6): 1272-1301.
- [14] 王俞涵,陈子阳,赵翔,等. 时序知识图谱表示与推理的研究进展与趋势[J]. 软件学报, 2024, 35(8): 3923-3951.
- [15] Jiang T S, Liu T Y, Ge T, et al. Towards time-aware knowledge graph completion[C]//Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics. Osaka: COLING, 2016: 1715-1724.
- [16] Dasgupta S S, Ray S N, Talukdar P. Hyte: Hyperplane-based temporally aware knowledge graph embedding [C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL Press, 2018: 2001-2011.
- [17] Goel R, Kazemi S M, Brubaker M A, et al. Diachronic embedding for temporal knowledge graph completion[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI Press, 2020, 34 (04): 3988-3995.
- [18] Liang K, Meng L Y, Liu M, et al. Learn from relational correlations and periodic events for temporal knowledge graph reasoning[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. Taipei: ACM Press, 2023: 1559-1568.
- [19] Liu K Z, Zhao F, Xu G D, et al. RETIA: relation-entity twin-interact aggregation for temporal knowledge graph extrapolation[C]// Proceedings of the 2023 IEEE 39th international conference on data engineering (ICDE). Anaheim: IEEE Press, 2023: 1761-1774.
- [20] Dao H, Phan N, Le T, et al. Hgct: Enhancing temporal knowledge graph reasoning through extrapolated historical fact extraction[J]. Knowledge-Based Systems, 2025, 316: 113358.
- [21] Li Z X, Guan S P, Jin X L, et al. Complex evolutionary pattern learning for temporal knowledge graph reasoning[C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin: ACL Press, 2022: 290-296.
- [22] 刘康正,赵峰,金海. FS-Net:面向时序知识图谱推理的频次统计网络[J]. 软件学报, 2023, 34(10): 4518-4532.
- [23] Xu Y, Ou J J, Xu H, et al. Temporal knowledge graph reasoning with historical contrastive learning [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington, D.C.: AAAI Press, 2023, 37(4): 4765-4773.
- [24] Chen W, Wan H Y, Wu Y T, et al. Local-global history-aware contrastive learning for temporal knowledge graph reasoning[C]//In 2024 IEEE 40th International Conference on Data Engineering (ICDE), Utrecht: IEEE Press, 2024: 733-746.
- [25] Liu Y S, Ma Y P, Hildebrandt M, et al. Tlogic: Temporal logical rules for explainable link forecasting on temporal knowledge graphs[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Virtual: AAAI Press, 2022, 36(4): 4120-4127.
- [26] Xiong S H, Yang Y, Fekri F, et al. TILP: Differentiable learning of temporal logical rules on knowledge graphs[C]//The Eleventh International Conference on Learning Representations (ICLR). Kigali: ICLR, 2023.
- [27] Xiong S H, Yang Y, Payani A, et al. Teilp: Time prediction over knowledge graphs via logical reasoning[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI Press, 2024, 38 (14): 16112-16119.
- [28] Huang R K, Wei W, Qu X Y, et al. Confidence is not timeless: Modeling temporal validity for rule-based temporal knowledge graph forecasting[C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. Bangkok: ACL Press, 2024: 10783-10794.
- [29] Mei X, Yang L B, Cai X Y, et al. An adaptive logical rule embedding model for inductive reasoning over temporal knowledge graphs[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi: ACL Press, 2022: 7304-7316.
- [30] Chen K, Zhao X J, Song X, et al. Rsrule: Relation-level semantic-driven rule learning for explainable extrapolation on temporal knowledge graphs[J]. Information Fusion, 2025, 120: 103080.
- [31] Han Z, Chen P, Ma Y P, et al. Explainable subgraph reasoning for forecasting on temporal knowledge graphs[C]//International Conference on Learning Representations (ICLR). Virtual: ICLR, 2020.
- [32] Luo X W, Zhu A J, Zhang J S, et al. HierarT: Multi-hop temporal knowledge graph forecasting with hierarchical reinforcement learning [J]. Knowledge-Based Systems, 2024, 300: 112164.
- [33] Chen K, Wang Y, Li Y T, et al. A unified temporal knowledge graph reasoning model towards interpolation and extrapolation[C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. Bangkok: ACL Press, 2024: 117-132.
- [34] Dong H, Wang P Y, Xiao M, et al. Temporal inductive path neural network for temporal knowledge graph reasoning[C]//Proceedings of the 38th AAAI Conference on Artificial Intelligence. 2024, 329: 10485.
- [35] Chen W, Wu Y T, Wu S H, et al. CognTKE: A Cognitive Temporal Knowledge Extrapolation Framework[C]// Proceedings of the AAAI Conference on Artificial Intelligence, Philadelphia: AAAI Press, 2025: 39(14): 14815 - 14823.
- [36] Wang J P, Sun K, Luo L H, et al. Large language models-guided dynamic adaptation for temporal knowledge graph reasoning[C]// Proceedings of the 38th International Conference on Neural Information Processing System, Vancouver: Curran Associates Inc. 2024: 8384 - 8410.
- [37] Zhang F, Zhang P F, Cheng J W, et al. SRM-LLM: Semantic Relationship Mining with LLMs for Temporal Knowledge Graph Extrapolation [C]// Proceedings of the Findings of the Association for Computational Linguistics: EMNLP 2025. Suzhou: ACL Press, 2025: 16007-16021.
- [38] Shang C, Tang Y, Huang J, et al. End-to-end structure-aware convolutional networks for knowledge base completion[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu: AAAI Press, 2019, 33(01): 3060-3067.
- [39] Schlichtkrull M, Kipf T N, Bloem P, et al. Modeling relational data with graph convolutional networks[C]//European Semantic Web Conference. Heraklion: Springer, 2018: 593-607.
- [40] Xu D, Ruan C W, Korpoglu E, et al. Inductive representation learning on temporal graphs[C]//International Conference on Learning Representations (ICLR). Virtual: ICLR, 2020.
- [41] Garcia-Duran A, Dumančić S, Niepert M. Learning sequence encoders for temporal knowledge graph completion[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL Press, 2018: 4816-4821.

姓名（出生年- ），性别，博士，单位职称
（如西安邮电大学教授），主要研究方向为
公钥加密、云安全和无线网络安全。