

基于多元事实驱动的时间知识图谱补全模型

孙平¹

SUN Ping

摘要

时间知识图谱能有效地管理和利用数据用于下游应用的分析，但图谱并非完整需通过补全来完整图谱。时间知识图谱具有两类重要的历史事实，分别是基于查询的历史事实和基于实体的历史事实，两种历史事实都有助于模型实现时间知识图谱补全任务。基于此，文章提出一种基于多元事实驱动的时间知识图谱补全模型。结合两类历史事实，预测未来可能发生的事实。实验结果表明，对比现有相关先进模型，在重要 MRR 指标上最高有 6% 的提升。

关键词

时间知识图谱；知识图谱表示；时间知识图谱补全；历史事实；时间信息

doi: 10.3969/j.issn.1672-9528.2025.07.004

0 引言

大数据时代，信息的海量增长使得传统的数据处理方法难以应对。知识图谱作为一个结构化的、可查询的知识网络可用于存储大量知识和事实。它将知识和事实以三元组的形式表示，例如（姚明，国籍，中国）。基于结构化形式，知识图谱提供了丰富的上下文信息和关系数据，强化了数据的语义理解能力，被广泛应用于各种工业领域，如食品工程，通过对食品不同子领域的信息进行有效提取与组织，在食品大数据、食品产业链和供应链中各环节的决策等领域具有广阔的应用场景^[1]；在新型材料方面，知识图谱可以快速集成材料的特性和结构等知识。构建专有的材料知识图谱，结构化表示材料的多种性质，能够深入挖掘和分析材料之间的潜在关联和深层信息，推动新材料的发现和现有材料的改进^[2]；在油气勘探开发领域，知识图谱结合深度学习模型和专家经验，广泛应用于地质数据管理、信息解释、异常检测等，实现了数据质量提升、提高了勘探开发效率^[3]；在工业生产方面，在露天矿产开采领域，边坡安全隐患不容忽视。边坡监测数据随着时间推移形成海量数据，围绕边坡数据构建时序知识图谱，在进行边坡安全事故搜索时，能够发现关联的边坡监测数据、风险识别方法及应急预案知识，为露天煤矿在面对边坡事故时提供技术支撑^[4]。一个完整严密的知识图谱能够在各工业领域中发挥着重要作用，为此构建知识图谱显得尤其重要，也促使知识图谱补全技术的发展。补全的核心目的是在知识图谱中建立实体间未被捕捉的潜在联系。现有的知识图谱补全模型通过学习实体间的潜在联系，得到具有

丰富语义信息的实体和关系嵌入，从而准确地捕捉实体间的复杂联系，完成知识图谱的补全。

时间知识图谱在原有知识图谱基础上增加了时间维度。根据时间戳，将时间知识图谱切分为多个小图谱，又叫子图。每个子图都记录了同一时间下发生的事实。而实体会存在于多个子图中，在不同子图中实体会不同的结构信息，即邻域信息。这种差异显现了实体特征的时序变化。可以利用这种时序特性，从历史中学习相关知识用于预测未来可能发生的事实。这种预测又被称为时间知识图谱补全的外推任务。在时间知识图谱的补全中，通常区分为内推和外推两种不同的任务。内推的任务聚焦于填补历史子图中尚未记录的事实，而外推则致力于预测未来可能显现的事实。外推任务具有广泛的应用前景。可以用于广告推荐实现精准营销，预测股票走势，学习历史洪涝数据预警未来可能发生的灾情等等。

为了更好地完成外推任务。需要让模型更好地学习历史事实，而历史事实是多元化的，不同的类别历史事实对模型进行补全的帮助不尽相同。本文将历史事实大致分为两大类，即与查询相关的历史事实和实体相关的邻域历史事实。前者涉及与特定查询直接相连的历史事件，这些信息直接反映了查询实体和相应关系的历史背景。而后者则包括了知识图谱中各个实体自初始至查询时刻的所有历史记录。不同的类别的历史从不同方面丰富了实体的内涵，提供了与查询紧密相关的背景信息。现有的方法，大都尝试对一类历史信息的研究与应用。本文提出了一种基于多元事实驱动的时间知识图谱补全模型 TKC-MFD，对不同类别的历史信息进行学习，显著提高了模型的预测能力。本文具体的贡献如下：

(1) 尝试同时对两类不同的历史事实进行融合建模。

利用自注意力的方式建模查询相关的历史事实，旨在捕捉查

1. 福州市数字产业互联科技有限责任公司 福建福州 350007

询在时间维度上的历史行为模式；利用分块注意力的方式建模实体相关的历史事实，旨在细粒度捕捉实体和不同关系事实的特征。

(2) 为了有效捕捉实体的时间相关特征，建模实体有关时间的连续性和周期性模式，对实体进行时间显式建模是必要的，设计了一种动态实体嵌入编码方法。旨在将时间信息结合到实体嵌入中，实现更准确地模拟同一实体在不同时刻的时间特征，从而更全面地理解和预测实体的发展趋势。

1 模型

TKC-MFD 的算法框架如图 1 所示，主要模块为：(1) 历史编码器：主要分为查询编码和实体编码两部分；(2) 时间编码器：以显式建模方式建模时间信息；(3) 历史演化：以时间序列对实体特征进行演化，学习实体潜在语义信息；(4) 解码器：计算候选实体得分，给出预测实体。

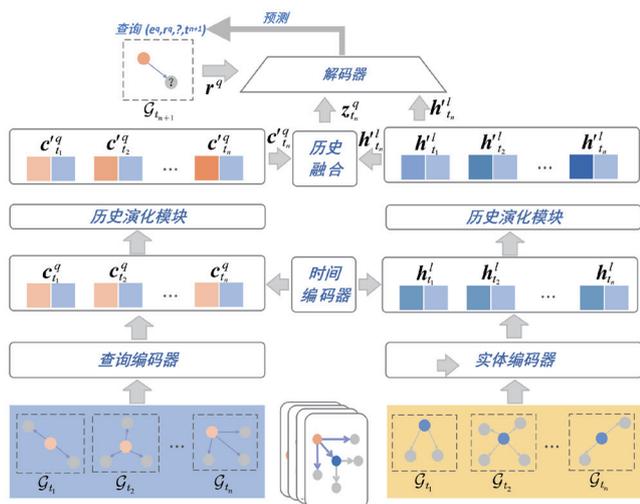


图 1 模型框架图

1.1 历史编码器

1.1.1 查询编码器

该编码器关注的是需进行补全的四元组查询 $(e_q, r_q, ?, t_q)$ 中的查询实体 e_q 采用注意力的方式聚合查询实体 e_q 在 t_q 的 n 个子图中有关于查询关系 r_q 的历史事实 $(e_q, r_q, o_i, t_i), t_i < t_q$ ：

$$N'_{t_i} = (N_{t_i} W_v) \text{Softmax} \left((N_{t_i} W_q)^T (N_{t_i} W_k) \right) \quad (1)$$

式中： $W_q, W_k, W_v \in \mathbb{R}^{d \times d}$ 分别为注意力使用的参数矩阵。

式 (1) 描述了在 t_1 时刻注意力方式分配注意力权重后，得到的有关于查询实体 e_q 和关系 r_q 的得到的邻居信息，

$N'_{t_1} = \{o'_1, o'_2, \dots, o'_m\}$ 将这些邻居嵌入与查询头实体 e_q 嵌入本身相加得到 c^q 。 c^q 表示查询实体 e_q 在 t_1 时刻下基于查询相关历史事实的嵌入。

$$c^q = \sum_{i=1}^m o'_i + e_q \quad (2)$$

1.1.2 实体编码器

该编码器关注的是时间知识图谱中所有实体 e ，包括查询实体，采用分块的图注意力聚合所有实体 e 在 t_q 的 n 个子图中一跳邻居的历史事实。实体嵌入包含了一个实体各个方面的属性特征。一个实体与其他实体之间存在各种关系，不同的关系关注着实体的不同方面，以 (牛顿, 学科, 物理学) 为例，应当关注的是与牛顿这一实体相关的学科信息，而非牛顿的家庭关系等信息。本文的实体编码器将实体按块进行图注意力聚合，以特定关系将实体各个方面语义信息进行有权重的聚合，实现相关属性特征的放大，无关属性特征的弱化。

具体以实体 e 为例，设置了 k 个不同的映射空间将实体 e 拆分为 k 块，以划分实体嵌入的各个属性特征：

$$e_k = e W_k \quad (3)$$

式中： $e \in \mathbb{R}^{1 \times d}$ ， $W_k \in \mathbb{R}^{d \times dk}$ 为 k 个可学习的参数矩阵，通过该参数矩阵尝试将实体映射到不同的向量空间中，从而区分实体的不同属性特征； $e_k \in \mathbb{R}^{1 \times dk}$ 为实体 e 的分块嵌入表示； e_k 为实体 e 不同方面的属性特征。

以 t_1 时刻为例，实体 e 的一个事实表示为 (e, r, o, t_1) ，为了能够准确识别细粒度的聚合实体的属性特征，其消息传递的方式以分块的形式进行：

$$\text{msg}_k = W_1 [r_k \parallel e_k] \quad (4)$$

式中： msg_k 表示传递的消息信息； r_k 表示两个实体间关系的分块嵌入，同样是通过 W_k 映射矩阵得到； W_1 表示参数矩阵。

接着使用图注意力方式计算不同分块的重要性系数 α ，拼接得到完整邻居嵌入表示：

$$\alpha_k = \frac{\exp(\text{LeakeyReLU}(W_2 \cdot \text{msg}_k))}{\sum_{i=1}^k \exp(\text{LeakeyReLU}(W_2 \cdot \text{msg}_i))} \quad (5)$$

$$h_o^{l-1} = [\alpha_1 h_1^{l-1}; \alpha_2 h_2^{l-1}; \dots; \alpha_k h_k^{l-1}] \quad (6)$$

式中： h_o^{l-1} 表示邻居实体 O 第 $l-1$ 分块图注意力嵌入； W_2 表示参数矩阵。接着将所有邻居与实体 e 身相加得到 h^l 表示实体 e 在 t_1 时刻下的实体嵌入。该嵌入包含了实体 e 本身的信息和 t_1 时刻下有关实体 e 的历史事实信息。

$$h^l = \frac{1}{|N_t(e)|} \sum_{o \in N_t(e)} h_o^{l-1} + h^{l-1} \quad (7)$$

式中： $N_t(e)$ 表示实体 e 在 t 的邻居实体集合。

1.2 时间编码器

在时间知识图谱中，实体在时间序列上存在一定的行为模式，即实体事实在时间上的连续性与周期性。本文设计了一种显式建模时间的编码器，生成时间嵌入将作为实体嵌入的一部分，以丰富实体嵌入的属性特征。具体地，首先计算当前时刻 t 与查询时刻 t_q 的间隔 $\Delta t = |t - t_q|$ ，接着使用 SIN，

TANH 函数建模时间的连续性与周期性特征:

$$F(\Delta t) = \text{SIN}(\text{Linear}(\Delta t)) + \text{TANH}(\text{Linear}(\Delta t)) \quad (8)$$

式中: Linear 为线性网络层; F 为输出时间嵌入函数。

将聚合了不同历史事实的嵌入 \mathbf{c}^q 、 \mathbf{h}^l 与时间嵌入相结合, 赋予实体嵌入时间维度的信息, 表示为:

$$\mathbf{c}_t^q = [\mathbf{c}^q \parallel F(\Delta t)] \quad (9)$$

$$\mathbf{h}_t^l = [\mathbf{h}^l \parallel F(\Delta t)] \quad (10)$$

式中: 符号 “ \parallel ” 为向量拼接, $\mathbf{c}_t^q, \mathbf{h}_t^l \in \mathbb{R}^{d+d_t}$ 。

1.3 历史演化编码器

为进一步利用实体在不同历史子图中的信息, 采用 GRU 实现对时间序列上同一实体不同事实的遗忘与记忆, 以捕捉实体在不同子图中的历史演化规律, 用公式表示为:

$$\mathbf{c}_t^{q'} = \text{GRU}(\mathbf{c}_{t-1}^{q'}, \mathbf{c}_t^q) \quad (11)$$

$$\mathbf{h}_t^{l'} = \text{GRU}(\mathbf{h}_{t-1}^{l'}, \mathbf{h}_t^l) \quad (12)$$

式中: $\mathbf{c}_t^{q'}$ 、 $\mathbf{h}_t^{l'}$ 分别表示演化后嵌入表示, 需要注意的是, 在初始时刻 t_0 , $\mathbf{c}_{t_0}^{q'} = \mathbf{c}_{t_0}^q, \mathbf{h}_{t_0}^{l'} = \mathbf{h}_{t_0}^l$ 。

前面介绍了两种历史编码器是如何实现历史事实的聚合。以 t 时刻为例, 对于查询四元组 $(e_q, r_q, ?, t_q)$, 两种编码器对于查询头实体 e_q 分别得到有关查询的历史嵌入和有关实体的历史嵌入 $\mathbf{c}_t^{q'}, \mathbf{h}_t^{l'}$ 本文设计了一个自适应函数以平衡两类历史事实带来的影响, 具体表示为:

$$\mathbf{z}_t^q = \beta \mathbf{c}_t^{q'} + (1 - \beta) \mathbf{h}_t^{l'} \quad (13)$$

$$\beta = \text{sigmoid}(w_g [\mathbf{c}_t^{q'} \parallel \mathbf{h}_t^{l'}]) \quad (14)$$

式中: β 表示自适应函数, 通过模型训练能够自适应调节两类历史事实的权重; “ \parallel ” 表示拼接操作; $\mathbf{h}_t^{l'}$ 表示通过实体编码器得到的查询实体嵌入; \mathbf{z}_t^q 表示为最终融合了两类不同历史事实的多元化查询实体嵌入。

1.4 解码器

本文采用 Conv-TransE 作为解码器计算候选实体的得分情况, 在外推设置下, 对未来时刻 t_{n+1} 的查询 $(e_q, r_q, ?, t_{n+1})$, 计算各个候选实体得分用公式表示为:

$$p(o | e_q, r_q, t_{n+1}) = \sigma(\text{ConvTransE}(\mathbf{z}_n^q, \mathbf{r}_q) \mathbf{h}_n^{l'}) \quad (15)$$

式中: σ 表示 sigmoid; o 表示候选实体; $p(o | e_q, r_q, t_{n+1})$ 表示与查询相关的候选实体预测概率; $\mathbf{z}_n^q, \mathbf{h}_n^{l'}$ 表示经过 n 个时间子图演化得到的融合后的查询实体嵌入表示和实体 o 经过实体编码器演化后的嵌入表示。

1.5 模型训练

对任意查询四元组进行头/尾预测时, 掩盖头/尾实体, 训练目标是最大化降低损失, 旨在让正确的事实得分高, 错

误的事实得分低。损失具体公式为:

$$\text{Loss} = - \sum_{t \in T} \sum_{(e_q, r_q, o', t_n) \in \mathcal{G}_t} \log p(o | e_q, r_q, t_{n+1}) \quad (16)$$

2 实验

2.1 数据集

为了全面评估 TKC-MFD 模型的性能, 本文选取了 3 个公开的数据集进行测试。这些数据集来源于 ICEWS 系列, 从一套大型的危机事件预警系统中提炼而成的。根据数据提取的年份, 被细分为 ICEWS14、ICEWS18 和 ICEWS05-15 三个版本, 各自涵盖了 2014 年、2018 年及 2005—2015 年间的历史事件记录。且各数据集中的事件发生时间间隔均为 1 天。数据的具体统计情况如表 1 所示。

表 1 数据集

数据集	实体	关系	时间戳	训练集	验证集	测试集	时间间隔
ICEWS14	7 128	230	365	74 845	8 514	7 371	24 h
ICEWS18	23 033	256	365	373 018	45 995	49 545	24 h
ICEWS05-15	10 094	251	4 017	368 868	46 302	46 159	24 h

2.2 实验结果

链路预测实验可以评估模型在外推任务的表现, 其本质是对知识图谱的补充。为了模拟模型对未来的事实预测, 本文将数据按时间顺序分割为训练集、验证集、测试集。采用 H@N 和 MRR 作为实验指标, H@N 是评估模型预测准确性的一项指标, 其核心在于对某一个测试样本, 从模型输出的候选实体得分中检查排名前 N 的候选实体中是否存在正确实体。若存在, 则该测试样本的 Hits@N 为 1, 否则为 0。MRR 指标关注每一个正确候选实体的具体排名的倒数, 这是为了防止某个测试样本的排名非常靠后从而影响整体性能指标的准确性。指标公式为:

$$\text{H@N} = \frac{1}{|S|} \sum_{i=0}^S I(\text{rank}_i \leq N) \quad (17)$$

$$\text{MRR} = \frac{1}{|S|} \sum_{i=0}^S \frac{1}{\text{rank}_i} = \frac{1}{|S|} \left(\frac{1}{\text{rank}_1} + \frac{1}{\text{rank}_2} + \dots + \frac{1}{\text{rank}_{|S|}} \right) \quad (18)$$

式中: S 表示测试样本数量; $I(\cdot)$ 表示条件函数, 满足条件为 1, 否则为 0; rank_i 表示第 i 个测试样本的排名; N 为排名。

表 2 总结了本文模型与基线在不同数据集上进行的性能对比, 加粗的数据表示最好, 下划线表示次好。所有基线的结果均直接引用自原始文献。“—” 代表其原始文献中未报告相应实验结果。本文模型在各项指标上都达到了最优或次优的水平。

表 2 ICEWS14 ICEWS05-15 ICEWS18 的链路预测结果

模型	ICEWS14				ICEWS05-15				ICEWS18			
	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10
TiRGN (2022)	<u>44.04</u>	<u>33.83</u>	<u>48.95</u>	<u>63.84</u>	<u>50.04</u>	<u>39.25</u>	<u>56.13</u>	<u>70.71</u>	<u>33.66</u>	<u>23.19</u>	37.99	54.22
CyGNet (2022)	32.73	23.69	36.31	50.67	36.81	26.61	41.63	56.22	27.12	17.21	30.97	46.85
CENET (2023)	41.30	32.58	—	58.22	47.13	37.25	—	69.20	29.65	19.98	—	48.23
TECHS (2023)	42.76	33.39	48.20	61.16	48.38	38.34	54.69	68.92	30.85	21.81	35.39	49.82
TKC-MFD	45.04	35.34	49.94	64.02	53.12	42.31	59.16	73.03	33.76	23.68	<u>37.74</u>	<u>53.91</u>

具体而言，现有外推模型对现有的历史事实利用不充分，只利用了一类历史事实。例如，在基线模型中，CyGNet^[5]、CENET^[6]模型主要集中于探索查询历史事实；而TiRGN^[7]、TECHS^[8]这些模型，则更加专注于实体的历史结构信息；从数据集方面来看，在ICEWS14上，TKC-MFD的H@3和H@10指标与TiRGN相当，在ICEWS18上略逊于TiRGN。这是由于两个数据集保存的是同一年的事实，事实之间的间隔不大，就预测而言，这些历史事实属于近期历史，对预测具有帮助。TiRGN利用全局图编码有效结合两个数据集集中的所有历史事实，获取有效信息。与本文模型具有相当性能表现，然而在ICEWS05-15上，历史事实的跨度长度达10年之久，再以全局的视角去聚合历史事实必然会引入不必要的特征导致性能的下降，而本文模型学习的是从近期的历史事实中学习实体和关系的表示，所利用的事实信息具有一定时效性。因此在ICEWS05-15上相较于TiRGN更具优势，表明TKC-MFD能够处理不同历史尺度的数据集。

2.3 消融实验

在本节中，为验证模型中主要模块对模型的整体预测性能影响，将模型各模块拆分并试验，具体结果如表3所示。

表 3 消融实验

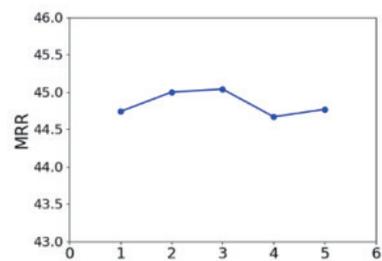
方法	ICEWS14		ICEWS18	
	MRR	H@1	MRR	H@1
查询历史	40.83	<u>32.83</u>	44.55	56.82
实体历史	41.31	30.52	<u>46.73</u>	<u>62.30</u>
无时间建模	<u>42.26</u>	32.55	45.76	59.06
TKC-MFD	45.04	35.34	49.94	64.02

为验证多元化历史事实建模实体表示能够有效地提高模型补全能力。本文将两类历史事实进行拆分。其中，“查询历史”表示仅使用查询历史编码器，即只关注基于查询历史相关的历史事实；“实体历史”表示仅使用实体历史编码器，即只关注基于实体相关的历史事实。将两者与本文模型对比

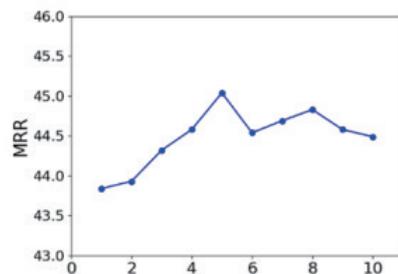
不难发现，建模单一的历史事实其补全性能与多元化建模不同历史事实差距较大。具体而言，对于“查询历史”由于该模块关注与查询直接相关的历史事实，帮助模型识别与查询最相关的实体。从而对模型在H@1指标上的性能有着显著影响；对于“实体历史”，由于其考虑了更广泛的具有复杂关系的邻居信息，通过分块的方法帮助实体有效聚合有关于不同关系的邻居属性特征，在综合指标MRR上有着较好的性能提升；对于时间编码器，在表3中，本文设置了“无时间建模”模块，表示移除时间嵌入的显式建模，仅按时间顺序演化实体表示。可以发现其性能相较于显式的时间建模性能有所下降。由于显式建模实现对时间信息的直接建模，能够更直接有效丰富实体嵌入中有关时间的信息，进而能够更精确地识别同一实体在不同时间点的特征差异。

2.4 参数分析

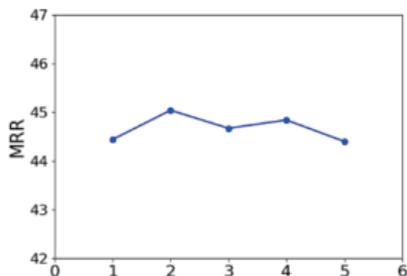
接下来将分析模型中的几个关键超参数对模型预测能力的影响。分析结果如图2所示。该图分别展示了分块数量、历史长度以及注意力层数的在不同的设置下模型性能的变化情况。



(a) 分块数量 k



(b) 历史长度 n



(c) 注意力层数 layer

图 2 参数分析

图 2 (a) 展示了分块数量对 MRR 指标的影响统计结果。分块数量 k 的取值设定为 [1,5], 当 $k=1$ 时, 表示以整体嵌入直接进行聚合操作。当 $k=3$ 时, 模型的性能达到最优。这一发现表明, 适当的分块数量能够帮助模型更好地捕捉和整合实体的邻域信息, 而过多的分块可能会导致信息的碎片化, 从而影响模型的整体性能。因此, 选择合适分块数量对于优化知识图谱补全系统的性能是至关重要的。

图 2 (b) 展示了历史长度对 MRR 指标的影响统计结果。历史长度 n 的取值范围被设置为 [1, 10], 以观察不同历史长度下模型性能的变化趋势。模型性能随历史长度的增加而增加。这表明提高历史长度能够带来丰富的历史事实, 有助于模型丰富实体表示, 预测实体的演化过程。当历史长度超过 5 时, 模型性能发生下降, 并再没有显著提高。这是由于过长的历史, 在引入有用的历史事实同时也带来了更多的噪声, 这些久远的历史事实可能与当前查询的相关性不高, 反而干扰了实体表示的演化, 降低了模型的预测性能。

图 2 (c) 展示了不同注意力层数对 MRR 指标的影响。注意力层数 layer 设定为 [1,5]。随着注意力层数的增加, 模型性能并没有显著提升, 反而在 $l=2$ 时达到了最佳性能。这说明在一定范围内, 增加注意力层数可以帮助模型更好地捕捉和整合邻居节点的信息, 但超过这个范围后, 额外的层数可能会带来过拟合或不必要的计算复杂度, 而对性能提升没有显著帮助。这一发现表明, 在本研究中, 两层注意力机制被证明是最有效的配置, 能够平衡模型的复杂度和预测能力。

3 结论

知识图谱作为一种强大的知识表示和推理工具, 已在多个工业领域展现出其独特的价值。从食品工程到矿产开采, 知识图谱的应用不仅提升了数据的语义理解能力, 还推动了决策支持和风险管理的智能化进程。本文提出了一种基于多元事实驱动的时间知识图谱补全模型——TKC-MFD。实现了对两类历史事实的综合利用, 显式地建模了时间信息, 更准确地地区分不同时间戳上的实体特征, 通过运用门控循环单元

在时间顺序上记忆与遗忘实体的有用与无用信息实现实体的演化, 有助于模型完成外推任务。本文还通过进行的实验证明了 TKC-MFD 模型的先进性。在未来的研究工作中, 可以尝试更好的历史事实聚合方式, 研究新的融合机制以更好地提高模型的外推能力。

参考文献:

- [1] 吴静珠, 李林, 吴宗柠, 等. 基于知识图谱的食品领域数智化研究进展 [J]. 食品科学技术学报, 2024,42(5):24-32.
- [2] 袁扬, 刘祺霖, 陈子逸, 等. 材料领域知识图谱构建与应用研究 [J]. 数据与计算发展前沿 (中英文), 2025,7(1):152-162.
- [3] 和婷婷, 张强. 知识图谱在油气勘探开发中的应用现状与发展趋势 [J]. 天然气工业, 2024,44(9):55-67.
- [4] 储扬静, 张衡, 汤玲, 等. 露天煤矿边坡安全时序知识图谱构建方法研究 [J]. 工矿自动化, 2025,51(2):84-90.
- [5] ZHU C C, CHEN M H, FAN C J, et al. Learning from history: modeling temporal knowledge graphs with sequential copy-generation networks[EB/OL].(2021-03-05)[2024-05-25].<https://doi.org/10.48550/arXiv.2012.08492>.
- [6] XU Y, OU J J, XU H, et al. Temporal knowledge graph reasoning with historical contrastive learning[C]//AAAI'23/IAAI'23/EAAI'23:Proceedings of the Thirty-Seventh AAAI Conference on Artificial Intelligence and Thirty-Fifth Conference on Innovative Applications of Artificial Intelligence and Thirteenth Symposium on Educational Advances in Artificial Intelligence. Palo Alto: AAAI, 2023: 4765-4773.
- [7] 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 Thirty-First International Joint Conference on Artificial Intelligence. Viet: IJCAI, 2022: 2152-2158.
- [8] LIN Q K, LIU J, MAO R, et al. TECHS: temporal logical graph networks for explainable extrapolation reasoning[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. Brussels: ACL, 2023: 1281-1293.

【作者简介】

孙平 (1972—), 女, 福建福州人, 本科, 高级工程师, 研究方向: 工业互联网、知识图谱工业应用、标识解析应用。

(收稿日期: 2025-02-21 修回日期: 2025-07-03)