

王丹. 多源知识图谱事件知识融合方法研究[J]. 智能计算机与应用, 2024, 14(5): 157-163. DOI: 10.20169/j.issn.2095-2163.240521

多源知识图谱事件知识融合方法研究

王丹

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 以事件为中心的动态知识对事件预测等应用至关重要, 但现有知识图谱主要关注以实体为中心的静态知识, 难以满足需求。本文提出一种融合多源知识的高质量事件知识图谱构造方法, 首先定义全局事件模式, 利用标签类别从源知识图谱中提取事件知识并构造临时事件知识图, 提出关系扩充规则对临时事件知识图进行扩充, 改进实体对齐 Attce 模型, 基于 TransD 模型对多个临时事件知识图进行联合嵌入学习, 以提高实体对齐和冲突发现的效率; 利用事件描述完整度计算源知识图谱可信度, 发生冲突时作为判别标准进行处理。经过在真实数据集上的实验, 验证了该方法的准确性和有效性。

关键词: 事件知识图谱; 知识融合; 全局事件模式; 实体对齐; 知识图谱嵌入

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)05-0157-07

Research on event knowledge fusion from multi-source knowledge graphs

WANG Dan

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Event-centered dynamic knowledge is crucial for applications such as event prediction. Existing knowledge graphs mainly focus on entity-centered static knowledge, which can not meet the requirements. This paper proposes a high-quality event knowledge graph construction method that integrates multi-source knowledge. Firstly, the global event pattern is defined. The label category is used to extract event knowledge from the source knowledge graphs and temporary event knowledge graphs are constructed. Relation augmentation rules are used to expand the temporary event knowledge graph, the entity alignment Attce model is improved by using the TransD model for joint embedding learning of multiple temporal event knowledge graphs to improve the efficiency of entity alignment and conflict discovery. The credibility of the source knowledge graph is calculated by using the completeness of the event description, which is used as the criterion for conflict processing. The accuracy and validity of the method are verified on real data sets.

Key words: event knowledge graph; knowledge fusion; global event pattern; entity alignment; knowledge graph embedding

0 引言

当前, 知识图谱在多领域引发广泛关注^[1], 如事件预测^[2]、推荐系统^[3]、自然语言处理^[4]等。现有知识图谱包含以实体为中心的静态知识, 较少关注以事件为中心的动态知识^[5]。对未来事件进行预测可为社会带来巨大利益并减少一定的损失, 因此, 构造完整且正确的高质量事件知识图谱至关重要。

目前, 研究主要集中在从文本中提取事件知识, 构建以事件为中心的事件知识图谱。文献[6]提出从非结构化文本数据中提取知识组成大规模事件知

识图谱, 利用基于依存语法的句法模式进行事件知识提取。文献[7]、文献[8]都提出了利用众包技术提取常识事件知识。文献[7]先构造种子事件知识图谱, 再用基于规则的方法进行事件知识补充, 由于需要对种子事件进行人工筛选, 因此该方式成本较高且规模较小, 只注重事件之间的关系却忽略了事件的属性。文献[8]主要构造涵盖因果关系和条件关系的社会性常识事件知识图谱, 然而利用众包技术获取的事件知识通常不能保证其正确性; 另外, 文献[8]强调事件之间的推理, 缺乏对除因果关系以外的其它类型关系以及事件属性的处理。文献[9]

基金项目: 上海理工大学自然科学基金培育项目(20ZRPY08)。

作者简介: 王丹(1996-), 女, 硕士研究生, 主要研究方向: 知识图谱。Email: wd1455194687@163.com

收稿日期: 2023-04-11

哈尔滨工业大学主办 ◆ 专题设计与应用

提出基于新闻语料库中的叙事事件形成叙事事件进化图(NEEG)。NEEG是一个有向循环图,节点是叙事事件,边是叙事事件之间的关系,但是其覆盖的常识事件知识范围较小。文献[10]进一步考虑事件-事件、事件-实体、实体-实体关系,但对于事件-事件关系只考虑了事件之间的时间关系,未关注其它类型的关系。文献[11]首次提出事件图模式归纳,着重于事件组件和事件之间的关系,但这项工作只关注一对事件之间的关系,未考虑事件之间关系的多样性和事件的属性。

随着知识图谱的进一步发展,出现了将异构且互补的知识图谱进行融合的研究。如:文献[12]提出以事件为中心的多语言知识图谱(EventKG),EventKG集成半结构化和结构化数据源中的事件知识和事件关系,并对其结构化表示,重点关注的是事件知识图谱的完整度,不关注事件知识的正确性,未对冲突知识进行处理。融合多源知识图谱的关键是进行实体对齐,文献[13]基于文献[14]中TransE模型,提出对多个知识图谱进行嵌入学习方法。TransE模型通常只适用于一对一的关系,而大部分事件知识存在一对多的关系,因此用于事件知识嵌入学习效果并不理想。

现有知识图谱中的事件知识遵循相对规律的模式^[15-17]。一个事件往往有事件参与者、发生地点、发生时间等属性,事件与事件之间存在不同类型的关系。因此,本文提出一种融合多源知识的全局事件知识图谱构造方法。首先定义全局事件模式,利用标签类别从源知识图谱中识别并提取出事件知识,用以构造临时事件知识图;再对属性和关系进行联合嵌入学习,得到不同临时事件知识图中的对齐事件实体对以及事件知识的向量化表示;最后,根据向量距离发现冲突,对于存在冲突的事件知识,根据源知识图谱可信度进行冲突处理。

1 问题定义及方法流程

1.1 相关定义及符号

定义1 源知识图谱 提供事件知识的知识图谱称为源知识图谱,源知识图谱可表示为 $G = \{G_1, G_2, \dots, G_n\}$ 。其中, $G_k = (E, R, L) \in G$, 这里 E 为节点集, $\forall e \in E$ 是节点集中的任意节点; R 为边集, 表示实体之间的关系; L 为标签集, 表示节点或者边的所属类型, L_e 为节点标签, 表示实体节点的类型, L_r 为边标签, 表示实体之间的关系类型。

定义2 全局事件模式 全局事件模式 P 表示

为 $P = \{E_g, R_g, L_g\}$ 。其中, E_g 表示模式节点集; R_g 表示模式边集; L_g 表示模式标签集。模式边类型分为属性边和关系边, 属性边集合 A 表示为 $A = \{beginTime, endTime, place, actor\}$, 其中 $beginTime$ 表示开始时间, $endTime$ 表示结束时间, $place$ 表示发生地点, $actor$ 表示参与者。关系边集合 R 则可表示为 $R = \{hasCause, hasEffect, hasPrevious, hasNext, hasSub\}$ 。其中, $hasCause$ 表示原因关系, $hasEffect$ 表示结果关系, $hasPrevious$ 和 $hasNext$ 用来表示先后关系, $hasSub$ 表示子事件。

定义3 临时事件知识图 临时事件知识图表示为 $TEKG = \{TEKG_1, TEKG_2, \dots, TEKG_n\}$, $TEKG_k = \{E_{tem}, R_{tem}, L_{tem}\}$ 由源知识图谱 G_k 通过与全局事件模式的映射提取出的事件知识构成。同理, E_{tem} 为节点集, R_{tem} 为关系边集, L_{tem} 为标签集。

定义4 实体对齐 给定2个源知识图谱 $G_1 = (E_1, R_1, L_1)$ 、 $G_2 = (E_2, R_2, L_2)$, 其中事件三元组 $(h_1, r_1, t_1) \in G_1$ 、 $(h_2, r_2, t_2) \in G_2$, 将2个源知识图谱中的三元组投影到同一向量空间进行向量化。如果 h_1 向量与 h_2 向量之间的距离在一定阈值范围内, 则 h_1 和 h_2 指向同一实体。

定义5 源知识图谱可信度 $Cre(G)$ 源知识图谱可信度为事件属性描述完整度和关系描述完整度的加权和。

1.2 方法流程

本文提出的多源知识图谱事件知识融合方法的处理过程如图1所示,实现步骤如下。

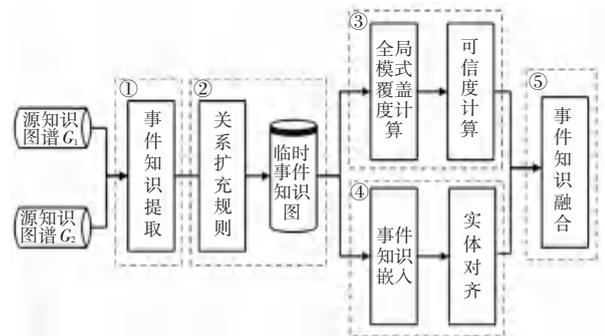


图1 事件知识融合处理流程

Fig. 1 Flow chart of event knowledge fusion

(1)构造临时事件知识图。首先定义全局事件模式,利用全局事件模式从给定的源知识图谱中提取出事件知识三元组实例,构成临时事件知识图TEKG。

(2)根据关系扩充规则,对构造的临时事件知识图中的事件关系进行自补充。

(3)源知识图谱可信度计算。利用事件的属性

描述完整度和关系描述完整度的加权和,计算源知识图谱可信度。出现冲突时,以该可信度为依据进行冲突处理。

(4) 实体对齐。对得到的临时事件知识图中的事件实体利用 Attce-D 模型进行联合嵌入学习,得到临时事件知识图中对齐的实体对和事件知识的向量化表示。

(5) 融合临时事件知识图。通过计算事件三元组的向量距离,判别事件的属性值是否冲突。若产生冲突,根据源知识图谱的可信度进行冲突处理,选取可信度最高的源知识图谱提供的事件知识作为最终结果进行融合。

2 事件知识提取

2.1 事件实体的识别与提取

现有知识图谱中存储的实体都使用明确的类别标签进行标识,如在 Wikidata^[18] 中将事件标识为“event”类及其子类。为了尽可能多地提取出源知识图谱中的事件知识,本文使用标识事件的类别及其子类标签,从源知识图谱中识别并提取事件实例。

2.2 事件关系的识别与提取

不同的源知识图谱中对事件之间的相同关系可能会有不同的语义描述,本文利用全局事件模式中定义的关系与源知识图谱中语义相同的关系进行映射。例如:全局事件模式中定义的 *hasNext* 关系与 DBpedia^[19] 中的关系类别 *dbo:nextEvent* 进行映射,提取出符合映射的事件实例。

从源知识图谱中识别出事件实体与事件关系,将识别出的事件实例提取出来形成临时事件知识图。

2.3 关系扩充

以事件为中心的知识图谱中,关于事件关系的描述是有限的,利用关系扩充规则推导临时事件知识图中存在的隐式关系,可以对事件知识进行自补充。关系扩充规则适用于多跳关系,本文提出的单跳关系扩充规则如图 2 所示。图 2 中, *relation* 为全局事件模式中的任一关系。如:当图 2 中 *relation* 为 *hasCause* 时,如果存在事件三元组 $(e_1, hasCause, e_2)$ 和 $(e_2, hasCause, e_3)$, 那么根据关系扩充规则产生事件知识三元组 $(e_1, hasCause, e_3)$ 。

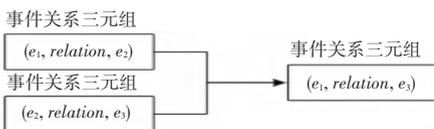


图 2 关系扩充规则

Fig. 2 Relation augmentation rules

3 事件知识融合

同一实体可能以不同的表现形式存在于不同的源知识图谱中,融合不同临时事件知识图中的事件知识,先要对齐不同临时事件知识图中表示同一事件的实体。

3.1 基于 Attce-D 模型的实体对齐方法

Attce 模型^[13] 提出基于嵌入的方法,学习不同知识图谱中的实体相似性进行实体对齐。基于 TransE 的嵌入模型只适用于处理一对一的关系,而事件知识在同一关系或属性下通常存在多个值,TransD 模型可以对不同类型关系下的实体和属性进行不同的语义表达。本文对 Attce 进行改进,提出基于 TransD 的 Attce-D 模型,对临时事件知识图进行嵌入学习。实体对齐过程如图 3 所示,实现步骤如下:

(1) 合并临时事件知识图。将 2 个临时事件知识图合并为 $TEKG_{12}$, 使得对临时事件知识图的嵌入学习可以在相同的向量空间进行。

(2) 嵌入学习。将 $TEKG_{12}$ 中的事件知识三元组分为事件属性三元组集合 T_{ea} 和事件关系三元组集合 T_{er} , 利用 TransD 模型对 T_{ea} 和 T_{er} 分别进行嵌入。对于属性事件三元组 $(h_{ia}, r_{ia}, t_{ia}) \in T_{ea}$, 通过 TransD 向量化后,表示形式见公式(1)、式(2):

$$h_{ia_{\perp}} = M_{ra_{ia}ha_{ia}} h_{ia} \quad (1)$$

$$t_{ia_{\perp}} = M_{ra_{ia}ta_{ia}} t_{ia} \quad (2)$$

其中, $M_{ra_{ia}ha_{ia}}$ 和 $M_{ra_{ia}ta_{ia}}$ 分别为 h_{ia} 和 t_{ia} 的映射矩阵。嵌入后的事件知识三元组,满足关系式(3):

$$h_{ia_{\perp}} + r_{ia} = t_{ia_{\perp}} \quad (3)$$

通过权重 β 控制关系三元组嵌入,使得关系嵌入更加关注谓词相同的三元组。关系三元组嵌入的目标函数可由式(4)来描述:

$$L_{RE} = \sum_{t_{er} \in T_{er}} \sum_{t'_{er} \in T'_{er}} \max(0, \gamma + \beta(f(t_{er}) - f(t'_{er}))) \quad (4)$$

其中, T_{er} 表示有效关系三元组的集合; T'_{er} 表示损坏的关系三元组集合; β 表示关系 r_{er} 出现的次数与 $TEKG_{12}$ 中三元组总数的比值。

属性字符嵌入的目标函数为:

$$L_{AE} = \sum_{t_{ea} \in T_{ea}} \sum_{t'_{ea} \in T'_{ea}} \max(0, \gamma + \beta(f(t_{ea}) - f(t'_{ea}))) \quad (5)$$

其中, $f(t_{ea}) = \| h_{ea_{\perp}} + r_{ea} - t_{ea_{\perp}} \|_2^2$ 表示属性三元组得分函数; T_{ea} 表示有效属性三元组集合; T'_{ea} 表示损坏的属性三元组集合。

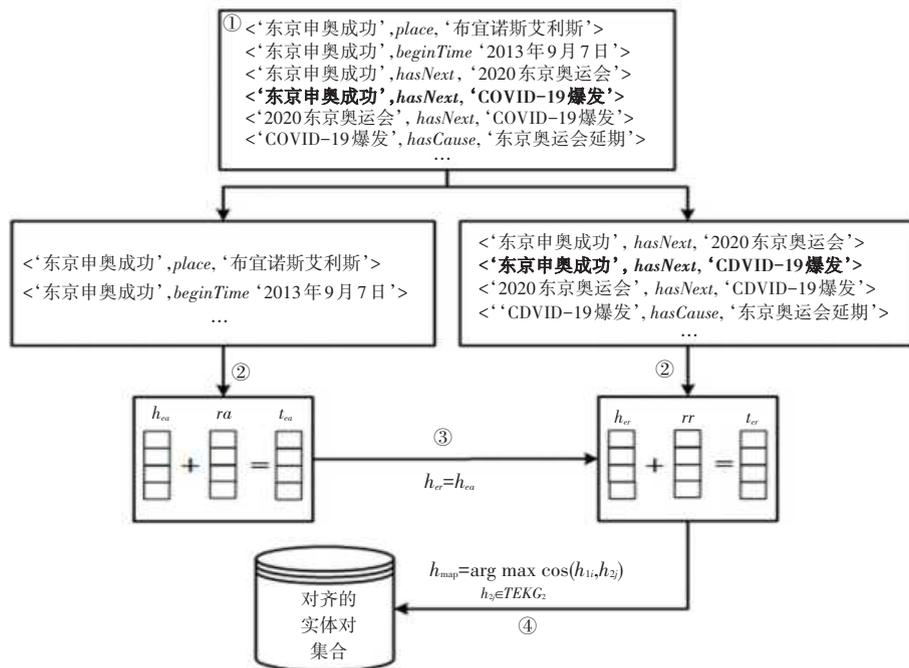


图3 实体对齐流程

Fig. 3 Flow chart of entity alignment

(3)联合学习。关系三元组嵌入基于实体关系,学习2个临时事件知识图中实体的相似性;属性三元组嵌入基于属性值,学习实体的相似性。将属性和关系嵌入到相同的向量空间进行联合学习,目标函数的公式如下:

$$L_{SUM} = \sum_{h \in TEKG_{12}} [1 - \cos(h_{er}, h_{ea})] \quad (6)$$

其中, h_{er} 表示关系三元组的头实体向量; h_{ea} 表示属性三元组中的头实体向量; $\cos(h_{er}, h_{ea})$ 表示 h_{er} 和 h_{ea} 的余弦相似度。

(4)实体对齐。联合学习实体的属性嵌入和关系嵌入,使得不同临时事件知识图中相似的事件实体具有相似的向量,根据式(7)计算向量的余弦相似度,判断实体是否对齐,最后得到对齐的实体对集合 $E_h = \{E_{h_{i1}}, E_{h_{i2}}\}$:

$$h_{map} = \arg \max_{h_2 \in TEKG_2} \cos(h_{i1}, h_{i2}) \quad (7)$$

其中, h_{i1} 和 h_{i2} 分别表示临时事件知识图 $TEKG_1$ 和 $TEKG_2$ 中的事件实体。

3.2 源知识图谱可信度计算

本文在融合临时事件知识图时,利用源知识图谱可信度进行冲突处理,选取可信度高的源知识图谱提供的知识作为正确知识。由于事件的参与者往往不止一个,当参与者属性值产生冲突时本文不作处理,直接融合。

由于现有的大规模知识图谱中关于事件知识的

描述并不完整,为了更准确地判别给定的源知识图谱可信度,本文提出以事件属性完整度和事件关系完整度综合计算源知识图谱可信度,计算公式具体如下:

$$Cre(G) = \alpha \cdot \frac{|TEKG_a|}{|TEKG|} + (1 - \alpha) \cdot \frac{|TEKG_r|}{|TEKG|} \quad (8)$$

其中, $|TEKG|$ 表示临时事件知识图中事件实体的个数; $|TEKG_a|$ 表示临时事件知识图中属性描述完整的事件实体个数; $|TEKG_r|$ 表示临时事件知识图中关系描述完整的事件实体个数; α 表示权重。

3.3 冲突发现与处理

由于不同的源知识图谱对同一事件的相同属性或关系的描述可能存在冲突,文献[20]采用基于图卷积网络的实体对齐方法,提出基于冲突知识相似度计算(SC模型)的方法进行冲突处理。在处理冲突时,根据相似度得分选取其中一个事件知识作为融合结果。EventKG对多源事件知识进行集成,并未对实体进行对齐,在集成时提出采用多数投票的方法,在处理冲突事件知识时,选取源知识图谱中票数高的事件知识为正确知识。

本文提出基于向量距离和源知识图谱可信度计算的方法对冲突事件知识进行判别并处理。

根据 Atce-D 模型的实体对齐方法,得到各个临时事件知识图中的对齐实体对集合 $E_h = \{E_{h_1}, E_{h_2}\}$ 后,根据实体对齐时得到的事件知识向量,计算对齐实体对在特定关系类型下首尾实体之间的向

量距离,设置向量距离阈值 ε , 根据式(9)计算尾实体之间的向量距离:

$$dist(e_1, e_2) = \sqrt{\sum_{i=1}^n (e_{1i}, e_{2i})^2} \quad (9)$$

其中, e_1, e_2 分别表示实体 e_1 和 e_2 的向量化表示, $e_1 = (e_{11}, e_{12}, \dots, e_{1n})$; $e_2 = (e_{21}, e_{22}, \dots, e_{2n})$ 。

若尾实体之间的向量距离大于 ε , 则认为 2 个源知识图谱对于该事件的描述存在冲突。

以源知识图谱可信度作为判定标准, 选取可信度最高的源知识图谱描述的属性值作为正确的属性值。

基于向量距离计算的冲突处理方法实现步骤如下:

(1) 将 2 个临时事件知识图中的事件三元组进行向量化表示, 并对事件三元组中的实体和关系打标签。

(2) 依次遍历对齐实体对集合, 从临时事件知识图中选取与当前遍历的实体对相关的事件知识三元组; 如果临时事件知识图中存在关系标签类型相同、且关系标签属于时间或地点, 利用式(9)计算 2 个事件知识三元组中尾实体向量的距离差。当距离差大于等于阈值 ε 时, 函数 *hasConflict()* 返回 true, 即存在冲突。

(3) 通过式(8)计算并返回可信度最高的源知识图谱提供的事件知识作为正确的事件知识放入全局事件知识图 G_g 中。遍历结束后, 临时事件知识图中剩余的事件知识三元组全部放入全局事件知识层中。

4 实验

4.1 数据集及实验设计

实验选取 Wikidata 和 DBpedia 两个数据集作为源知识图谱, 从 Wikidata 中提取了 26 358 个事件实体, 从 DBpedia 中提取了 60 198 个事件实体, 从源知识图谱提取出的事件知识以及经关系扩充后的事件知识见表 1。将 80% 的数据作为实体对齐的训练集, 20% 的数据作为事件知识融合的测试集。为了对实体对齐模型进行训练, 本文还对 30% 的训练集中的尾实体进行注错处理。使用 M-EventKG 模型在训练集上进行训练并对模型的参数进行调优, 最后在测试集上进行测试。

表 1 事件知识扩充结果

Table 1 Expansion results of event knowledge

源知识图谱	Wikidata	DBpedia
属性三元组个数	87 325	16 548
关系三元组个数	69 245	9 854
扩充后关系三元组个数	90 987	18 546

4.2 评价指标

本文通过精确率 (*Precision*)、召回率 (*Recall*) 和 *F1* 值等评价指标来检验该模型的性能。融合结果混淆矩阵见表 2。各指标的定义及公式详见如下。

表 2 融合结果混淆矩阵

Table 2 Confusion matrix of fusion results

数据集	实际为正确	实际为错误
判断为正确	<i>TP</i>	<i>FP</i>
判断为错误	<i>FN</i>	<i>TN</i>

(1) *Precision*。判断为正确且实际也为正确占判断为正确的比例, 即:

$$Precision = \frac{TP}{(TP + FP)} \quad (10)$$

(2) *Recall*。判断为正确且实际也为正确占实际为正确的比例, 即:

$$Recall = \frac{TP}{(TP + FN)} \quad (11)$$

(3) *F1 - measure*。该值是精确率和召回率的加权调和平均值, 即:

$$F1 = \frac{2 \times precision \times recall}{(precision + recall)} \quad (12)$$

4.3 实验结果分析

4.3.1 向量间距离阈值 ε 调节分析

向量间的距离阈值影响冲突事件知识判别的准确度, 对向量间距离阈值 ε 的调节, 能够优化冲突事件知识判别时的精准率、召回率以及 *F1*。向量阈值对精确率、召回率和 *F1* 值的影响曲线如图 4 所示。由图 4 分析可知, 召回率随着距离阈值的增大而增长, 而精确率随着距离阈值的增大而减小。当 ε 为 0.16 时, 可以在保证召回率的前提下, 提高精确率和 *F1*, 此时判别效果能够达到最佳。

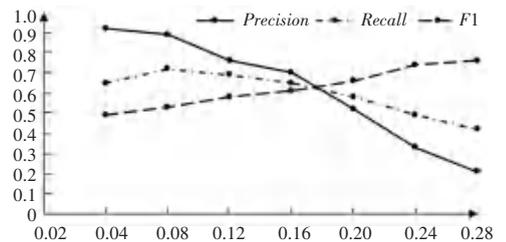


图 4 向量阈值对精确率、召回率和 *F1* 值的影响

Fig. 4 Influence of vector threshold on *Precision*, *Recall* and *F1*

4.3.2 对比实验

(1) 融合必要性分析。通过融合多源知识图谱事件知识, 解决现有知识图谱中事件知识描述不完整的问题。为了检验融合结果的有效性, 本文提出

在相同的实验环境下,将融合后的全局事件知识图 G_g 与 2 个源知识图谱 Wikidata 和 DBpedia 组成的

临时事件知识图 W-Event 和 D-Event 进行对比。检测结果如图 5 所示。

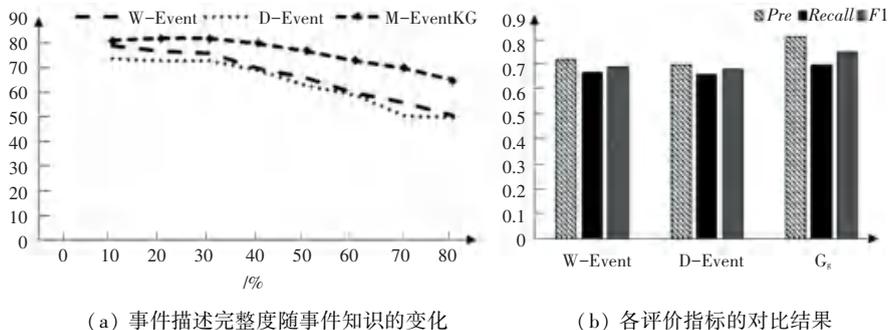


图 5 融合结果分析图

Fig. 5 Fusion result analysis

图 5(a) 为临时事件知识图中事件描述完整度随事件知识的变化趋势。由图 5(a) 可知,随着事件知识的增多,三者的事件描述完整度逐渐下降,但融合后的全局事件知识图中事件知识的完整度均高于未融合的源知识图谱。在图 5(b) 中, M-EventKG 的精确率上比 W-Event 和 D-Event 分别增长了 12.5% 和 15.7%; 召回率分别提高了 4.5% 和 6.1%; $F1$ 值上分别提高了 8.7% 和 10.2%。

(3) 不同融合方案对比分析。为了评估模型性能,在同一实验环境下,将本文的融合模型 M-EventKG 与 EventKG、SC 模型进行事件知识融合比较,对比结果如图 7 所示。

(2) 不同嵌入方法对比分析。不同的嵌入方法会影响实体对齐的质量,从而影响精确率、召回率以及 $F1$ 值。将基于 TransE 模型嵌入的 Attce 方法与 M-EventKG 模型在相同实验环境下进行对比,对比结果如图 6 所示。

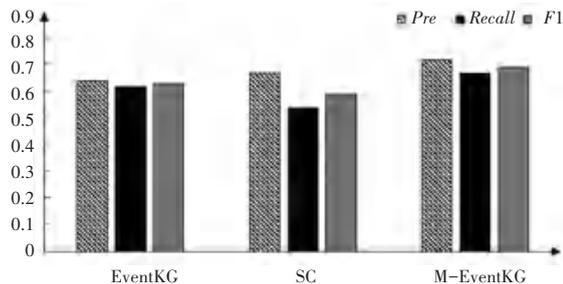


图 7 不同融合方案结果对比

Fig. 7 Comparison of the results of different fusion schemes

由图 7 可见,与 EventKG 和 SC 方法相比,本文提出的 M-EventKG 方法在精确率、召回率和 $F1$ 值指标上都提升,精确率指标分别提高了 12.5% 和 7.4%,召回率指标分别提高了 8.1% 和 18%, $F1$ 值分别提高了 9.5% 和 16.9%。由此可知,本文提出的 M-EventKG 方法在多源知识图谱融合均能有效地提高了召回率及 $F1$ 值。实验表明,以事件描述完整度作为源知识图谱可信度的判定标准的方法,更有效地提高了事件知识完整度和正确度。

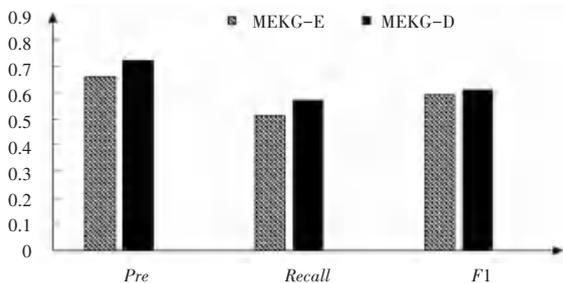


图 6 不同嵌入模型对比分析

Fig. 6 Comparison of different embedding models

由图 6 可知,与 Attce 方法相比,利用 M-EventKG 模型进行事件知识嵌入时,精确率提高了约 9.1%,召回率提高了 11.7%, $F1$ 值则提高了约 3.4%。Attce 方法利用基于 TransE 模型进行嵌入学习,而事件知识通常是一对多的关系,TransE 模型只适用于一对一的关系,利用 TransD 模型可以使得同一事件实体在不同的属性或关系下具有不同的向量表示,能够提高实体对齐的召回率。实验表明,本文提出使用 M-EventKG 模型对事件知识进行嵌入学习可以保证实体对齐的质量。

5 结束语

本文提出基于多源知识图谱的事件知识融合模型,该模型通过类别标签从给定的异构源知识图中提取事件知识构造临时事件知识图,利用关系扩充规则对临时事件知识图做补充;利用 TransD 模型对临时事件知识图中的事件三元组进行向量化表示;提出基于 TransD 的 Attce-D 模型,提高了实体对齐的效率,利用全局事件模式计算源知识图谱可信度,当事件知识发生冲突时,根据源知识图谱可信度进

行冲突处理,最后得到全局事件知识图。实验结果表明,该模型提高了事件知识的完整度以及事件知识融合的准确率。后续研究工作将对事件的时间属性嵌入进行改进,挖掘更多的扩充规则提高事件知识的完整度,进一步考虑动态知识的融合,使得融合后的事件知识更好地服务于下游任务。

参考文献

- [1] 赵军,刘康,何世柱,等. 知识图谱[M]. 北京: 高等教育出版社, 2018.
- [2] LI Z, FENG S, SHI J, et al. Future event prediction based on temporal knowledge graph embedding [J]. *Computer Systems Science and Engineering*, 2023, 44: 2411-2423.
- [3] 王传庆,李阳阳,费超群,等. 知识图谱平台综述[J]. *计算机应用研究*, 2022, 39(11): 3201-3210.
- [4] 赵博,王宇嘉,倪骥. 知识图谱的增强 CP 分解链接预测方法 [J]. *计算机应用研究*, 2023, 40(5): 1396-1401.
- [5] GUAN Saiping, CHENG Xueqi, BAI Long, et al. What is event knowledge graph: A survey [J]. *arXiv preprint arXiv: 2112.15280*, 2022.
- [6] ZHANG Hongming, LIU Xin, PAN Haojie, et al. ASER: A large-scale eventuality knowledge graph [C]//*Proceedings of the Web Conference*. Taipei, China; ACM, 2020: 201-211.
- [7] WANG Ya, CAO Cungen, CHEN Zhiwen, et al. ECCKG: An eventuality - centric commonsense knowledge graph [C] // *Knowledge Science, Engineering and Management: 15th International Conference, KSEM 2022, Part I*. Cham; Springer International Publishing, 2022: 568-584.
- [8] SAP M, BRAS L R, ALLAWAY E, et al. Atomic: An atlas of machine commonsense for if-then reasoning [C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Hawaii, USA; AAAI, 2019, 33(1): 3027-3035.
- [9] LI Zhongyang, DING Xiao, LIU Ting. Constructing narrative event evolutionary graph for script event prediction [C]//*Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*. Stockholm, Sweden; ACM, 2018: 4201-4207.
- [10] LI Manling, ZENG Qi, LIN Ying, et al. Connecting the dots: Event graph schema induction with path language modeling [C]//*Proceedings of EMNLP. ACL, 2020*: 684-695.
- [11] JIN Xiaomeng, LI Manling, JI Heng. Event schema induction with double graph autoencoders [C]//*Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies*. Seattle, USA; ACL, 2022: 2013-2025.
- [12] GOTTSCHALK S, DEMIDOVA E. Eventkg: A multilingual event - centric temporal knowledge graph [C]//*The Semantic Web: 15th International Conference, ESWC 2018*. Crete, Greece; Springer International Publishing, 2018: 272-287.
- [13] BORDES A, USUNIER N, GARCIA - DURAN A, et al. Translating embeddings for modeling multi-relational data [C]//*Advances in Neural Information Processing Systems*. Nevada, USA; NIPS Foundation, 2013, 26: 2787-2795.
- [14] TRISEIDYA B D, QI Jianzhong, ZHANG Rui. Entity alignment between knowledge graphs using attribute embeddings [C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Hawaii, USA; AAAI, 2019, 33(1): 297-304.
- [15] QI Song, WU Yinghui, LIN Peng, et al. Mining summaries for knowledge graph search [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(10): 1887-1900.
- [16] JI Guoliang, HE Shizhu, XU Liheng, et al. Knowledge graph embedding via dynamic mapping matrix [C]//*Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (volume 1: Long papers)*. Chicago, USA; ACL, 2015: 687-696.
- [17] HAGEV W R, MALAIS'E V, SEGERS R, et al. Design and use of the simple event model (SEM) [J]. *Web Semant*, 2011, 9(2): 128-136.
- [18] ERXLEBEN F, GÜNTHER M, KRÖTZSCH M, et al. Introducing wikidata to the linked data web [C]//*The Semantic Web-ISWC 2014: 13th International Semantic Web Conference*. Riva del Garda, Italy; Springer International Publishing, 2014: 50-65.
- [19] LEHMANN J, ISELE R, JAKOB M, et al. Dbpedia-a large-scale, multilingual knowledge base extracted from wikipedia [J]. *Semantic Web*, 2015, 6(2): 167-195.
- [20] GAO Yuqi, SANG Jitao, FU Chengpeng, et al. Metadata connector: Exploiting hashtag and tag for cross-OSN event search [J]. *IEEE Transactions on Multimedia*, 2021, 23: 510-523.