

Duration-HyTE: 基于持续时间建模的时间感知知识表示学习方法

崔员宁¹ 李 静¹ 沈 力² 申 扬² 乔 林² 薄 珏²

¹(南京航空航天大学计算机科学与技术学院 南京 211106)

²(国网辽宁省电力有限公司 沈阳 110004)

(yuanningcui@163.com)

Duration-HyTE: A Time-Aware Knowledge Representation Learning Method Based on Duration Modeling

Cui Yuanning¹, Li Jing¹, Shen Li², Shen Yang², Qiao Lin², and Bo Jue²

¹(School of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106)

²(State Grid Liaoning Electric Power Supply Co., LTD, Shenyang 110004)

Abstract Knowledge representation learning is the foundation of knowledge acquisition and reasoning. It is widely used in entity extraction, entity alignment, recommendation system and other fields. It has become an important issue throughout the whole process of knowledge graph construction and application. With the development of large-scale knowledge graphs containing time labels, time-aware knowledge representation learning has become one of the research hotspots in this field in recent years. Traditional time-aware knowledge representation learning methods can not effectively use the distribution of knowledge valid duration. In this paper, we propose an improved time-aware knowledge representation learning method combined hyperplane model and duration modeling to solve this problem. Firstly, we divide meta facts into persistent facts and instantaneous facts according to their valid duration. Then we model the valid duration of knowledge, so we get the calculation method of valid reliability. Finally, we propose a new knowledge representation learning method by improving score function with valid reliability. Wikidata12K and YAGO11K are two knowledge graph data sets containing time labels. We extract two new persistent facts datasets from these two datasets. We do a series of comparative experiments on these four data sets. The results show that Duration-HyTE method of link prediction and time prediction performance has been effectively promoted. Especially on Wikidata12K dataset, the accuracy of link prediction of the head entity and tail entity of the Duration-HyTE method is improved by 25.7% and 35.8% respectively compared with other traditional and advanced knowledge representation methods.

Key words knowledge graph; duration models; time aware; knowledge representation; link prediction; valid reliability

摘 要 知识表示学习是知识获取与应用的基础,是贯穿知识图谱构建与应用全过程的重要问题,伴随着有时间标签的大型知识图谱的发展,近几年时间感知的知识表示学习成为该领域研究热点之一.针对传统方法不能有效学习知识持续时长分布规律的问题,融合超平面和有效持续时间建模,提出一种时间

收稿日期:2019-04-23;修回日期:2019-12-26

基金项目:国家电网公司总部科技项目(SGLNXT00YJJS1800110)

This work was supported by the State Grid Corporation Headquarters Science and Technology Project (SGLNXT00YJJS1800110).

通信作者:李静(lijing@nuaa.edu.cn)

感知知识表示学习方法 Duration-HyTE.首先,将元事实按照有效持续时间分类,对知识有效持续时间进行建模,提出知识有效可信度的计算方法,将其作用于训练过程评价函数和损失函数的计算,最后在含有时间标签的数据集 Wikidata12K、YAGO11K 和新建立的持续型关系数据集上进行对比实验,结果表明与其他同类方法相比,Duration-HyTE 方法在实体和关系的链接预测和时间预测上性能得到有效提升,尤其在 Wikidata12K 数据集上,经 Duration-HyTE 训练得到的知识表示模型对于头尾实体的预测效果比当前最优的表示方法分别提升了 25.7% 和 35.8%,有效提高了链接预测准确率.

关键词 知识图谱;持续时间建模;时间感知;知识表示学习;链接预测;有效可信度

中图法分类号 TP391

知识图谱是将人类知识结构化存储的知识系统,其本质是具有有向图结构的知识库,是一种通用的语义知识的形式化描述框架^[1].它用节点表示语义符号,用有向边表示符号之间的语义关系,以结构化三元组的形式存储现实世界中的实体以及实体之间的关系^[2].知识图谱通常表示为 $G=(E,R,S)$,其中 $E=\{e_1, e_2, \dots, e_{|E|}\}$ 表示实体集合, $R=\{r_1, r_2, \dots, r_{|R|}\}$ 表示关系集合, $S=R \times E \times E$ 表示知识图谱中三元组事实的集合,三元组以(head entity, relation, tail entity)的形式存储元事实数据.目前已有大型知识图谱,比如 Freebase^[3], YAGO^[4], WorldNet^[5]等,不仅为研究工作者提供良好的数据资源,也为推动人工智能学科发展和支撑智能搜索、智能问答、个性化推荐等智能信息服务应用提供重要基础.

知识表示学习问题是贯穿知识图谱的构建与应用全过程的关键问题^[6].而知识表示的方法,决定了它的表达能力和语义计算的复杂程度,良好的知识表示方法将给知识应用提供有力的支撑.传统的结构化三元组表示形式虽具有很强的表达能力,但是难以直接利用计算机做语义计算.而数值化表示方法将知识图谱中的离散符号(实体、属性、关系、值等)用连续型数值表示,直接体现语义信息,可以高效地计算实体、关系及其复杂的语义关联,极大地提高知识图谱语义计算的效率,已成为知识图谱研究的重要任务之一.

数值化知识表示方法主要包括基于张量的方法和基于翻译的方法.基于张量的表示学习方法,利用张量表示知识,使用张量分解或张量乘法进行知识表示学习,优点是在编码实体和关系的过程中综合了整个知识图谱的信息,具有较强的表达能力.Nickel 等人^[7]于 2011 年提出 RESCAL 方法将整个知识图谱编码为 3 维张量,张量分解重构结果中的每个元素被看作对应三元组成立的概率.Yang 等人^[8]于

2015 年提出不区分头尾实体的 DistMult 方法; Nickel 等人^[9]于 2016 年提出基于张量乘法的全息表示方法 HolE; Balažević 等人^[10]于 2019 年提出基于张量分解的 TuckER 方法.由于张量分解重构的计算量较大,基于张量分解的方法对大型知识图谱的知识表示学习效率较低.而基于翻译的表示学习方法将三元组中的关系视作从头实体到尾实体的翻译向量,训练的目标是使头实体向量经过关系向量的翻译接近尾实体的向量,克服了学习效率低的问题,能够在大规模知识图谱中快速完成表示学习. Bordes 等人^[11]于 2013 年将关系和实体置于同一语义空间中,提出基于翻译的 TransE 方法, Wang 等人^[12]于 2014 年提出将关系用超平面表示的 TransH 方法; Lin 等人^[13]于 2015 年提出区分实体空间和关系空间的 TransR; Ji 等人^[14]提出基于动态映射矩阵的 TransD 方法; 方阳等人^[15]于 2018 年提出基于自适应权重改进的 TransAH 方法.传统的基于翻译模型的方法假设知识图谱存在于同一个时空条件下,忽视了知识图谱的一项重要隐含语义信息——时间信息.

近几年,将时间信息用于知识表示学习,迅速成为知识表示学习领域研究热点. Jiang 等人^[16]在 2016 年首次将时间信息用于知识图谱表示学习中,提出基于翻译模型的时间感知表示学习方法 t-TransE,取得了较好的效果. Dasgupta 等人^[17]在 2018 年借鉴 TransH 的方法,将时间看作产生 1 对多关系的主要因素,提出基于超平面的时间感知表示学习方法 HyTE. HyTE 方法的核心思想是将实体和关系通过时间信息映射到时间超平面上,计算评价函数,创造性地将时间信息直接嵌入到超平面空间中.实验结果显示,与 TransE, TransH, t-TransE, HolE 等知识表示方法相比, HyTE 对实体和关系链接预测的准确度有了显著提升,引起了广泛关注.

同类知识的有效持续时间长度往往是相近的,

但是由于 HyTE 方法将知识的有效持续时间切割为一个一个独立的时间片,导致时间片之间是割裂的,因此 HyTE 方法训练得到的模型不能有效学习到时间长度的知识.针对这个问题,本文受持续时间模型(duration models)启发,对知识图谱中同类型元事实的有效持续时间进行建模,量化计算知识在不同时间片上的有效可信度,将其作用于评价函数和损失函数计算,提出融合超平面和持续时间建模的时间感知知识表示学习方法 Duration-HyTE.

本文的贡献主要有 3 个方面:

1) 将元事实中的关系分为持续型关系和瞬时型关系,并对知识有效持续时间进行建模,研究知识有效持续时间的分布规律,提出了知识有效可信度.

2) 基于持续时间建模和有效可信度,提出融合超平面和持续时间建模的时间感知知识表示学习方法 Duration-HyTE.

3) 在含有时间标签的知识图谱通用数据集 Wikidata12K, YAGO11K 上设计链接预测对比实验,结果表明 Duration-HyTE 方法实体链接、关系链接与时间预测的准确度较同类知识表示学习方法有了显著提升.

1 相关工作

TransE 将知识图谱的实体和关系集合中的每个实体和关系用 1 个低维向量表示,将三元组集合中的三元组作为训练样本.三元组 (h, r, t) 中的 h, r, t 分别表示头实体、关系和尾实体. TransE 将关系向量 e_r 看作从头实体到尾实体的翻译向量,对于 2 个实体向量 e_h, e_t , 用 $e_h + e_r$ 与 e_t 的差值为翻译效果打分.它的评价函数表示为

$$f(h, r, t) = \|e_h + e_r - e_t\|_{l_1/l_2}. \quad (1)$$

TransE 方法采用负采样方法加速训练.用 D^+ 表示正确三元组的集合,负采样得到的错误样本集合表示为 D^- .负采样方法为

$$D^- = \{(h', r, t) | h' \in E, (h', r, t) \notin D^+\} \cup \{(h, r, t') | t' \in E, (h, r, t') \notin D^+\}. \quad (2)$$

TransH 针对 TransE 方法对于 1 对多和多对 1 的关系预测效果较差的问题,将知识图谱中的关系都用超平面表示,超平面的单位法向量记作 ω_r .在计算评价函数之前,先将头尾实体分别映射到关系超平面上.其中 TransH 方法评价函数表示为

$$f(h, r, t) = \|(e_h - \omega_r^T e_h \omega_r) + d_r - (e_t - \omega_r^T e_t \omega_r)\|_2^2, \quad (3)$$

其中 d_r 表示这对实体间的对应关系.对于同一种关系,可以有多个 d_r ,所以 TransH 能够比 TransE 更好地表示 1 对多和多对 1 的关系.

HyTE 方法是在 TransE 的基础上,受 TransH 的启发而设计的时间感知知识表示学习方法.在一些大型知识图谱中,元事实含有时间标记,这些元事实可以被结构化地表示为四元组 $(h, r, t, [\tau_{\text{start}}, \tau_{\text{end}}])$, $[\tau_{\text{start}}, \tau_{\text{end}}]$ 表示这个元事实有效的时间, $\tau_{\text{start}}, \tau_{\text{end}}$ 分别表示知识有效时间的开始时间点和结束时间点. Dasgupta 等人^[17]认为时间是产生 1 对多和多对 1 关系的主要原因,因此他们提出了 HyTE,将每个时间片都用 1 个超平面表示,超平面的单位法向量记作 ω_r .在计算评价函数之前,先将头尾实体和关系向量映射到时间超平面上,再计算评价函数. HyTE 的评价函数为

$$f_r(h, r, t) = \|P_\tau(e_h) + P_\tau(e_r) - P_\tau(e_t)\|_{l_1/l_2}, \quad (4)$$

其中, $P_\tau(e_h) = e_h - \omega_r^T e_h \omega_r$, $P_\tau(e_r) = e_r - \omega_r^T e_r \omega_r$, $P_\tau(e_t) = e_t - \omega_r^T e_t \omega_r$ 分别表示将头实体、尾实体或关系向量投影到时间点 τ 的时间超平面上得到的结果.

HyTE 最主要的贡献是将三元组有效时间拆分为时间片,将时间超平面的法向量作为训练参数,和实体与关系向量一起训练.其优势是将有效时间信息巧妙地包含到了模型中,所以它对于时间感知的知识图谱的预测效果与 TransE 和 TransH 相比有显著提升.但也正是由于 HyTE 方法将有效时间拆分为独立的时间片,因此模型在训练过程中不能学习到有效持续时间长度的分布知识.本文针对 HyTE 方法的这个问题,对知识有效持续时间建模,改进训练过程并提出融合超平面与持续时间建模的时间感知知识表示学习方法 Duration-HyTE.

2 本文方法

本文针对 HyTE 方法在训练过程中模型不能学习到有效持续时间长度的分布知识的问题,对知识有效持续时间建模,计算知识有效可信度,应用到评价函数和损失函数,提出融合超平面与持续时间建模的时间感知知识表示学习方法 Duration-HyTE.

模型训练算法的流程是:1) 持续时间建模,对包含各类关系的元事实数据进行有效持续时间建模,获得该类元事实有效可信度的模型;2) 将四元组中的时间拆分成时间片,并按照时间点计算有效可信度,插入四元组生成五元组(头实体,关系,尾实体,

时间片,有效可信度);3)初始化训练参数,按照预设维度随机地初始化实体、关系和时间片的向量集;4)从五元组集合中随机抽取1个小型训练集,并由五元组生成负样本;5)将正负样本映射到各自的时间

片后计算评价函数,根据损失函数调整模型训练参数;6)输出训练得到的模型,重复4)5)继续训练,训练次数达到预设的次数时停止.Duration-HyTE方法的框架如图1所示:

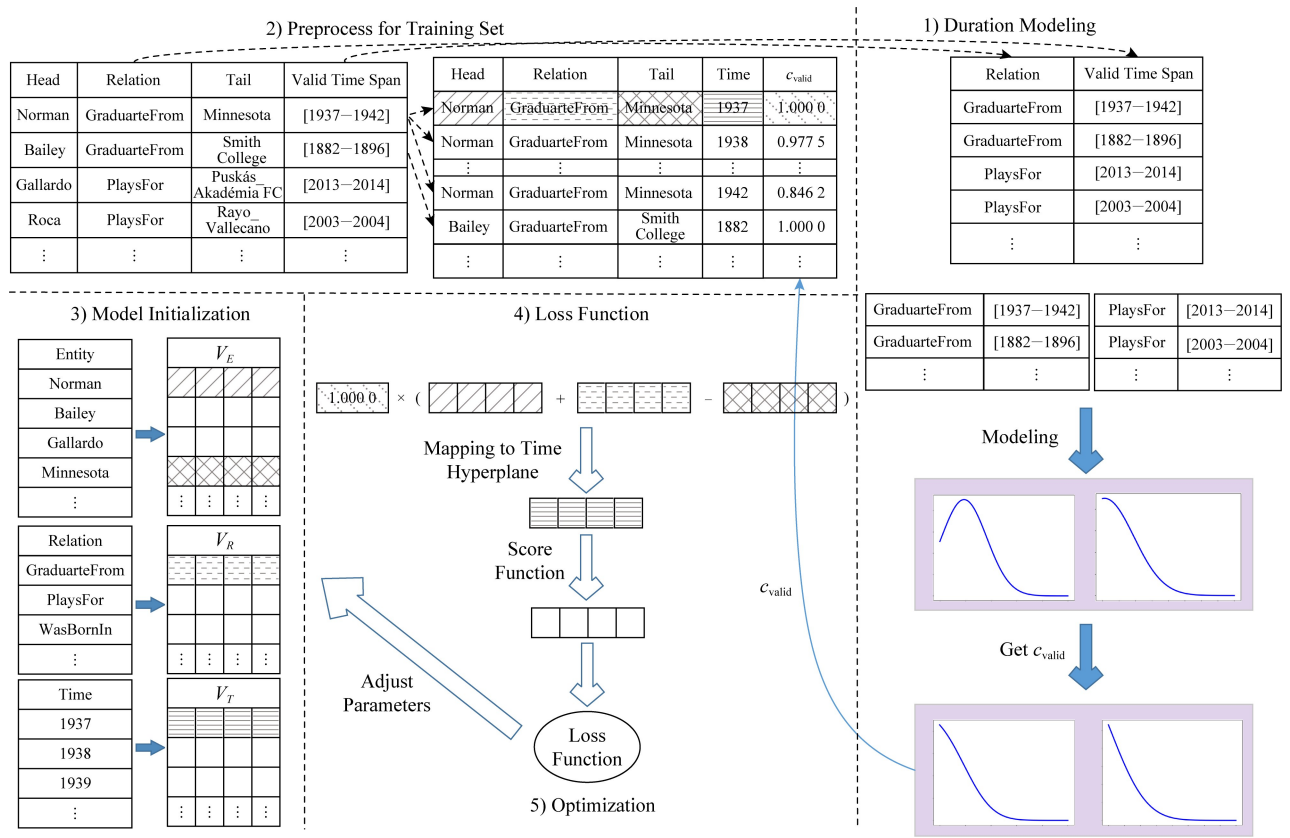


Fig. 1 Framework of the proposed method
图1 所提方法的结构图

2.1 基于持续时长的关系分类

持续时间建模指对某类事件的持续时间建立模型,以方便计算某事件在特定时间点上的危险系数、生存函数(可靠函数)等,对未来的同类事件的持续时间和持续时间上的可靠程度做出预测.

知识图谱中的每个包含时间标签的元事实四元组($h, r, t, [\tau_{start}, \tau_{end}]$)记录对应元事实(h, r, t)在时间维度上从无效到有效再到无效的过程.其中有效的时间段 $[\tau_{start}, \tau_{end}]$ 称为有效持续时间,它本质上也是一种持续时间.包含某种关系 r_x 的三元组


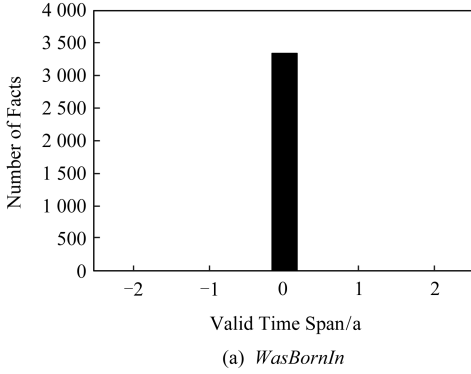


Fig. 2 Distribution of the persistent relation
图2 持续型关系持续时间分布图

(h, r_x, t) 组成的所有元事实三元组是同一类事件. 按照事件的持续时间将关系分为持续型关系和瞬时型关系 2 种类型:

1) 持续型关系. 持续型关系是指在某一时间段内持续有效的关系, 这类关系的特点是持续时间不为 0. 例如从 YAGO11K 数据集中抽取的 2 个持续型关系 $\langle hasWonPrize \rangle$ 和 $\langle graduatedFrom \rangle$ 的持续时间数据, 它们的持续时长不为 0 且满足某种分布



规律, 其分布统计如图 2 所示, 其中横坐标为持续年数, 纵坐标表示持续该年数的四元组元事实总数.

2) 瞬时型关系. 瞬时型关系是指发生在某一时刻, 并且不会持续的关系. 例如从 YAGO11K 数据集中抽取的 $\langle WasBornIn \rangle$ 和 $\langle DeadIn \rangle$ 这 2 个瞬时型关系的持续时间数据, 它们的持续时长为 0, 其持续时间分布统计如图 3 所示, 其中横坐标为持续年数, 纵坐标表示持续该年数的四元组元事实总数.

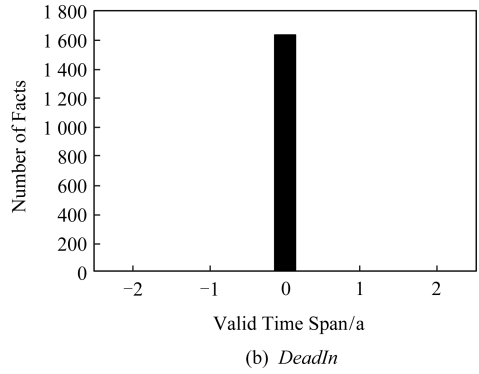


Fig. 3 Distribution of the transient relation

图 3 瞬时型关系持续时间分布图

2.2 融合持续时间建模的改进学习算法

受持续时间建模的启发, 对知识图谱三元组的有效持续时间进行建模, 计算某类事件在特定有效时间点的有效可信度.

持续时间建模的主要对象是含有持续型关系的数据. 文献[18]中介绍了持续时间模型, 并定义了生存函数(survival function), 也称可靠性函数(reliability function), 它表示自事件发生开始, 经过某长度时间后该事件仍在持续的概率. 若 T 是连续型随机变量, 且服从累积分布函数 F , 那么在 $t \in [0, +\infty)$ 上, 可靠函数的公式表示为

$$R(t) = P(T > t) = \int_t^{+\infty} f(u) du = 1 - F(t). \quad (5)$$

式(5)目前多用于交通事故、设备故障等事件的时长估计和风险评估, 可靠函数表示从事件发生开始后时刻 t 事件仍在持续发生的可靠程度. 知识的有效持续时间也是一种特殊的持续时间, 与文献[18]中应用场景不同的是, 知识图谱中包含多种类型的事件, 每种事件的类型由三元组中的关系决定. 对每个事件的持续时间分别建模, 便可以推导每种关系事件的可靠函数, 所以知识有效的可靠程度也可以用持续时间建模来计算. 为方便大型知识图谱中大量元事实的持续时间建模, 本文采用能够快速有效模拟大多数有效持续时长分布的高斯函数对持

续型关系的持续时间建模. 所以不同关系概率密度函数 f 可以表示为

$$f(t) = \frac{1}{\sigma_r \sqrt{2\pi}} e^{-\frac{(t-\mu)^2}{2\sigma_r^2}}, \quad (6)$$

其中, σ_r 指包含关系 r 的所有元事实持续时长的标准差. 与传统持续时间建模不同, 本文有效持续时间建模的目的是计算每个四元组的有效持续时间上, 某个特定时间点上知识有效的可靠程度. 定义在某个四元组的有效时间段内某个时间点的有效可靠程度为有效可信度.

定义 1. 知识图谱中包含有效时间区间的四元组 $(h, r, t, [\tau_{\text{start}}, \tau_{\text{end}}])$, 自开始时间 τ_{start} 经过时间 t 后, 知识仍然有效的概率称为有效可信度, 记作 c_{valid} .

四元组 $(h, r, t, [\tau_{\text{start}}, \tau_{\text{end}}])$ 持续时间为 τ_{present} 时, 累积分布函数 F 表示为

$$F(r, \tau_{\text{start}}, \tau_{\text{end}}, \tau_{\text{present}}) = P(\{T \leq \tau_{\text{present}}\}) = \int_{\tau_{\text{start}}}^{\tau_{\text{present}}} \frac{1}{\sigma_r \sqrt{2\pi}} e^{-\frac{(y-\tau_{\text{end}})^2}{2\sigma_r^2}} dy, \quad (7)$$

其中, σ_r 指包含关系 r 的元事实持续时长的标准差, τ_{end} 指事件的有效时间的结束时间点, τ_{present} 为当前时间点. 式(6)模拟了 2.1 节中持续型关系事件的概率分布情况, 式(7)表示这种持续型关系事件的可靠函数. 根据式(5)(7), 可以推导出包含持续型关系

的元事实四元组 $(h, r, t, [\tau_{\text{start}}, \dots, \tau_{\text{end}}])$ 持续时间为时刻 τ_{present} 的有效可信度:

$$c_{\text{valid}}(r, \tau_{\text{start}}, \tau_{\text{end}}, \tau_{\text{present}}) = 1 - P(\{T \leq \tau_{\text{present}}\}) =$$
$$1 - \int_{\tau_{\text{start}}}^{\tau_{\text{present}}} \frac{1}{\sigma_r \sqrt{2\pi}} e^{-\frac{(y - \tau_{\text{end}})^2}{2\sigma_r^2}} dy. \quad (8)$$

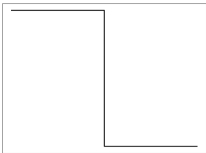
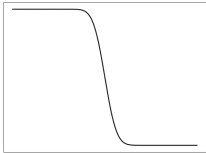
与持续型关系不同, 瞬时型关系的持续时间为 0, 因此包含瞬时型关系的元事实四元组的有效可信度在有效的时间点上为 1, 其余无效的时间点上为 0.

另外, 由于负样本在知识图谱中是不正确的知识, 所以无论何时, 它不正确的有效性都是成立的. 因此负样本作为不正确知识的有效可信度在任何时间点上都为 1.

综合上述对正负样本有效可信度取值问题的讨论, 正负样本的有效可信度计算为

$$c_{\text{valid}}(\tau_{\text{start}}, \tau_{\text{end}}, \tau_{\text{present}}, r) =$$
$$\begin{cases} \int_{\tau_{\text{start}}}^{\tau_{\text{present}}} 1 - \frac{1}{\sigma_r \sqrt{2\pi}} e^{-\frac{(y - \tau_{\text{end}})^2}{2\sigma_r^2}} dy, \\ (h, r, t) \in D^+ \text{ and } r \in R_{\text{persistent}}, \\ 1, (h, r, t) \in D^- \text{ or } r \notin R_{\text{persistent}}, \end{cases} \quad (9)$$

Table 1 Comparison Between HyTE and Duration-HyTE
表 1 HyTE 与 Duration-HyTE 对比表

Model	Valid Reliability	Score Function	Parameters
HyTE		$\ P_{\tau}(e_h) + P_{\tau}(e_r) - P_{\tau}(e_t)\ _{l_1/l_2}$	$O(n_{\text{entity}}k + n_{\text{relation}}k + n_{\text{time}}k)$
Duration-HyTE		$c_{\text{valid}} \times \ P_{\tau}(e_h) + P_{\tau}(e_r) - P_{\tau}(e_t)\ _{l_1/l_2}$	$O(n_{\text{entity}}k + n_{\text{relation}}k + n_{\text{time}}k)$

从表 1 中可以得到信息: 1) Duration-HyTE 与 HyTE 最主要的不同是持续时间上的有效可信度, Duration-HyTE 使有效可信度的变化曲线更加平滑; 2) Duration-HyTE 将有效可信度作用于评价函数, 使可靠性高的样本在训练中的权重更大; 3) Duration-HyTE 与 HyTE 方法相比, 没有增加更多的训练参数, 而训练参数越少, 计算效率就越高, 所以 Duration-HyTE 保持了 HyTE 方法的高计算效率.

2.3 改进模型的损失函数

Duration-HyTE 方法是一种时间感知的知识表示学习方法, 在计算评价函数时, 先将其映射到时间平面上. 将时间用超平面表示, 对于 T 个时间片,

其中, $R_{\text{persistent}}$ 为持续型关系集合. 根据式(9), 可以发现正样本有效可信度的取值在 $[0, 1]$ 上, 而负样本的有效可信度为 1, 即无论在哪个时间点上, 正样本的有效可信度都比负样本的小, 若直接将这样的有效可信度用于训练, 会降低正样本在训练中的作用, 因此实际训练的过程中, 在正样本的有效可信度基础上增加了平衡因子 q (q 作为超参数), 目的是给予有效时间内正样本的有效可信度一定的纠正, 以保持正负样本在训练中的平衡.

通过上述方式, 对知识有效时间段进行了持续时间建模, 使知识有效性的可信程度能够用有效可信度量化计算, 为将有效可靠度用于指导知识的嵌入表示提供了基础.

HyTE 模型中将元事实的有效可信度看作二值分布, 他们认为在有效持续时间上, 元事实的有效可信度都为 1, 其他时间上有效可信度都为 0. 而我们认为在表示学习过程中, 应该给有效可信度更高的训练样本以更高的权重. 基于这种思想, 将有效可信度作用于评价函数, 得到改进的知识表示学习算法 Duration-HyTE. 二者的异同如表 1 所示:

用 T 个不同的时间超平面的法向量来表示. Duration-HyTE 的评价函数为

$$f_{\tau}(h, r, t, c_{\text{valid}}) =$$
$$c_{\text{valid}} \times \|P_{\tau}(e_h) + P_{\tau}(e_r) - P_{\tau}(e_t)\|_{l_1/l_2}, \quad (10)$$

其中, $P_{\tau}(e)$ 表示将头实体、尾实体或者关系向量投影到时间点 τ 的时间超平面上得到的向量.

Duration-HyTE 方法的损失函数为

$$L = \sum_{\tau \in [T]} \sum_{x \in D_r^+} \sum_{y \in D_r^-} \max(0, f_{\tau}(x) - f_{\tau}(y) + \gamma),$$
$$(11)$$

其中, D^+ 表示每个时间点 τ 上的有效三元组集合, 在有效三元组基础上采集负样本, 得到负样本集

合 D^- . 本文针对链接预测任务采用不考虑时间的负采样方法 (time agnostic negative sampling, TANS):

$$D^- = \{(h', r, t, \tau) | h' \in E, (h', r, t) \notin D^+\} \cup \{(h, r, t', \tau) | t' \in E, (h, r, t') \notin D^+\}. \quad (12)$$

式(12)中只是将头和尾实体做替换得到负样本, 是一种不考虑时间维度的负采样方法.

针对时间预测任务采用依赖时间的负采样方法 (time dependent negative sampling, TDNS):

$$D^- = \{(h', r, t, \tau) | h' \in E, (h', r, t) \in D^+, (h', r, t, \tau) \notin D^+_{\tau}\} \cup \{(h, r, t', \tau) | t' \in E, (h, r, t') \in D^+, (h, r, t', \tau) \notin D^+_{\tau}\}. \quad (13)$$

式(13)从时间维度上替换头和尾实体, 在其他时间片有效但在原时间片上无效的元事实作为负样本.

式(12)是一种忽略时间维度的负采样方法, 这种方法采集得到的负样本更侧重于实体和关系向量参数的训练, 有助于区分相近的实体, 是一种适用于实体和关系预测任务的负采样方法; 而式(13)是一种依赖时间的负采样方法, 这种方法采集得到的负样本更侧重于时间超平面参数的训练, 有助于区分相近的时间超平面, 是一种适用于时间预测任务的负采样方法. 所以在实验部分中, 实体和关系预测任务采用的负采样方法是式(12), 时间预测任务采用的负采样方法是式(13).

为了避免负样本数目过大, 防止正负样本比例失衡, 设置超参数 neg_sample 来限制负样本的数目, neg_sample 表示每个正样本对应的负样本数目. 在做负采样时, 每个正样本对应的负样本个数都被限制在 neg_sample 内, 从而限制了负样本的总数目. 而且, 为了提高算法执行效率, 负采样在载入数据集时执行, 即在训练开始之前做负采样并保存, 在训练过程中随对应的正样本一起被抽样. 这样就避免了多次训练中正样本的重复负采样, 提高了算法执行效率.

融合超平面和持续时间建模的知识表示学习的模型训练算法如算法 1 所示:

算法 1. Duration-HyTE 模型训练算法.

输入: 训练集 S 、实体集 E 、关系集 R 、时间集 T 、边界 γ 、调整因子 q 、维度数 dim 、迭代数 N ;

输出: 实体向量集 V_E 、关系向量集 V_R 、时间法向量集 V_T .

① E 中每个 e 随机初始化 dim 位向量, 得到 V_E , R 中每个 r 随机初始化 dim 位向量,

得到 V_R , T 中每个 τ 随机初始化 dim 位向量, 得到 V_T ;

- ② 正则化 V_R 中每个向量;
- ③ 创建正样本集合 S_{pos} 、负样本集合 S_{neg} ;
- ④ FOR EACH $(h, r, t, [\tau_{start}, \tau_{end}]) \in S$
- ⑤ FOR EACH $\tau \in [\tau_{start}, \tau_{end}]$
- ⑥ 计算时刻 τ 时 (h, r, t) 的 C_{valid} ;
- ⑦ S_{pos} 插入正样本 $(h, r, t, \tau, C_{valid})$;
- ⑧ FOR 迭代次数 $j=1, 2, \dots, neg_sample$
- ⑨ 负采样并插入负样本集 S_{neg} ;
- ⑩ END FOR
- ⑪ END FOR
- ⑫ END FOR
- ⑬ FOR 迭代次数 $i=1, 2, \dots, N$
- ⑭ 正则化 V_E, V_T 中每个向量;
- ⑮ 正采样获得正样本集 D^+ ;
- ⑯ 获取正样本集对应的负样本集 D^- ;
- ⑰ 据式(10)(11)计算损失函数;
- ⑱ 调整参数集 V_E, V_R, V_T ;
- ⑲ END FOR
- ⑳ 输出表示模型参数集 V_E, V_R, V_T .

3 实验结果与分析

为了验证 Duration-HyTE 方法的有效性, 分别在目前通用的含有时间标签的数据集 Wikidata12K, YAGO11K 上进行了实体链接预测实验、关系链接预测实验与时间预测实验, 并与同类算法比较.

为了进一步验证 Duration-HyTE 在持续型关系型数据集上的预测效果, 在新建的 2 个持续型关系数据集 WDP12K, YGP10K 上做了进一步的实体和关系链接预测实验.

3.1 数据集

Wikidata^[19] 和 YAGO 是 2 个大型的知识图谱, 也是知识表示学习领域通用的数据集. YAGO11K, Wikidata12K 是从这 2 个数据集中抽取了包含时间标记信息的元事实组成的时间感知的频繁关系知识图谱数据集. YAGO11K 数据集是从 YAGO 数据集包含时间标记的事实中抽取得到的, 其中含有时间标签的元事实以 $(\# factID, occurSince, ts)$, $(\# factID, occurUntil, te)$ 的形式保存. 其中包含 20500 个三元组、10623 个实体和 10 个频繁关系. 与 YAGO11K 类似, Wikidata12K 是从 Wikidata 数据

集中抽取得到的,其中包含 24 个频繁关系、40 621 个三元组和 12 554 个实体.

为了进一步证明本文提出模型训练算法在持续型关系数据集上的有效性,我们对 Wikidata12K, YAGO10K 数据中包含持续型关系的数据进行进一步抽取,从 YAGO 数据集的四元组数据中抽取了四元组中包含持续型关系的 15 525 条元事实数据,然后将元事实中包含的 10 143 个实体和 8 个关系抽取出来,形成新的持续型关系数据集 YGP10K.对 Wikidata 数据集采样同样的抽取方法,抽取得到 WDP12K,其中共有 20 种关系、11 943 个实体和 34 496 条元事实数据.实验所用数据集如表 2 所示:

Table 2 Test Datasets
表 2 实验数据集

Dataset	# <i>R</i>	# <i>E</i>	# Train	# Test	# Valid
Wikidata12K	24	12 554	32 497	4 062	4 062
YAGO11K	10	10 623	16 408	2 051	2 046
WDP12K	20	11 943	27 666	3 398	3 432
YGP10K	8	10 143	12 608	1 444	1 473

3.2 实验设定

1) 评价指标.为了准确地评估我们的模型方法,我们采用了知识图谱表示学习链接预测通用的评价指标^[20].对于每一个需要测试的三元组,分别将头和尾实体去掉,然后用数据集中的所有实体来代替,映射到时间超平面后用评价函数打分,将所有的实体评价结果进行排序.同样地,将三元组中的关系向量删除,然后用数据集中所有的关系来代替,并用评价函数来打分.评价指标主要有 3 个:

- ① 平均排名(mean rank, MR).统计正确实体或关系在所有实体或关系中的平均排名作为实体或关系链接预测评价指标.
- ② Hits@10.统计正确实体在所有实体中排名

前 10 的数据所占百分比作为实体链接预测的评价指标.

③ Hits@1.统计正确关系在所有关系中排名第 1 的数据所占的百分比作为关系链接预测评价指标.

2) 基线设置.第 1 个基准方法是 TransE,这是基于翻译模型中第 1 个被提出的方法,它不考虑时间标记信息,将三元组集作为训练集,每个实体和每个关系都会输出 1 个向量.HolE 是一种知识表示学习的方法,它的预测效果是目前的知识表示学习方法中比较突出的,它也是一种不考虑时间标记的方法.TransH 是在 TransE 基础上改进的一种知识表示学习方法,它首次将超平面应用到知识表示学习中,HyTE 方法的灵感也来自于此.t-TransE 也是一种基于翻译的模型,它首次将时间信息应用于知识表示学习.HyTE 是在 TransE 和 TransH 的基础上改进的时间感知的知识表示学习方法.最后, Duration-HyTE 是本文提出的方法.

3) 参数设定.对于所有的方法,在 2 个数据集上都保持 $b=50\,000$,嵌入维度 $dim \in \{64, 128, 256\}$,边界 $\gamma \in \{1, 2, 5, 10\}$,学习率 $l \in \{0.01, 0.001, 0.000\,1\}$,调整 $q \in \{0.5, 0.6, 0.7\}$,负采样数 $neg_sample \in \{1, 2, 5\}$.实验中超参数设定为: $dim=128, \gamma=10, l=0.000\,1$,评价函数使用 l_1 -norm 范式, $q=0.6$ 或 $q=0.7$ (Wikidata12K 数据集为 0.6, YAGO11K 数据集为 0.7), $neg_sample=5$.

3.3 实体链接预测实验

为了验证模型对于实体链接预测的效果,在 Wikidata12K, YAGO11K 数据集上,分别作了头实体和尾实体的链接预测实验,测试的方法是用每种方法训练得到的模型对测试集中的三元组做头尾实体预测,测试结果的评价指标是正确头尾实体的 MR 和 Hits@10.Duration-HyTE 与其他方法的实验性能对比,结果如表 3 所示:

Table 3 Results of Entity Prediction
表 3 实体预测结果表

Metric	Wikidata12K				YAGO11K			
	MR		Hits@10/%		MR		Hits@10/%	
	Tail	Head	Tail	Head	Tail	Head	Tail	Head
HolE ^[9]	734	808	25.0	12.3	1 828	1 953	29.4	13.7
TransE ^[11]	520	740	11.0	6.0	504	2 020	4.4	1.2
TransH ^[12]	423	648	23.7	11.8	354	1 808	5.8	1.5
t-TransE ^[16]	283	413	24.5	14.5	292	1 692	6.2	1.3
HyTE ^[17]	179	237	41.6	25.0	107	1 069	38.4	16.0
Duration-HyTE	115	176	47.0	31.4	110	816	39.6	20.6

Note: The best values are in bold.

如表 3 所示,在 2 个数据集上,Duration-HyTE 的实验性能都优于基准方法,其中 YAGO11K 上的头实体预测效果提升了 23.7%,尾实体的链接预测基本持平,Wikidata12K 上的头尾实体链接效果分别提升了 25.7%和 35.8%.说明 Duration-HyTE 时间感知知识表示学习算法对于包含时间标签的知识图谱数据集的学习比其他方法更有效.

为了进一步分析本文的方法对 HyTE 的改进效果,我们给出了 HyTE 和 Duration-HyTE 在 Wikidata12K 上前 500 个 epoch 上得到的模型的实体链接预测结果.图 4 直观地展示了 2 种方法随着循环的进行,尾实体预测效果的变化情况.




Fig. 4 Comparison chart of prediction mean rank of tail entities

图 4 尾实体预测平均排名的变化曲线图

从图 4 可以发现,HyTE 和 Duration-HyTE 尾实体预测的变化曲线相似,HyTE 在第 320 个 epoch 时得到最佳表示模型,Duration-HyTE 在第 280 个 epoch 时得到最佳表示模型,Duration-HyTE 方法得到的模型预测结果一直优于 HyTE 方法得到的模型.

另一项评价指标尾实体预测结果的 Hits@10 的变化曲线如图 5 所示:

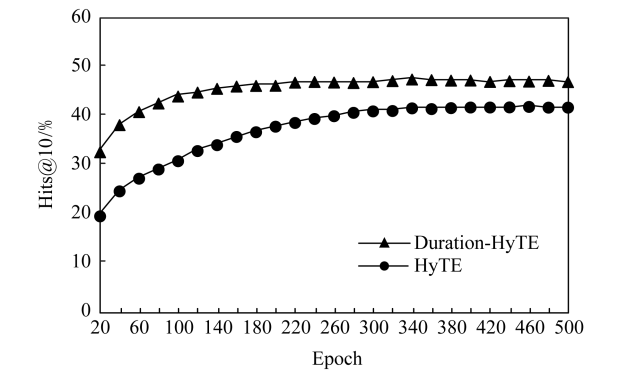


Fig. 5 Comparison chart of prediction Hits@10 of tail entities

图 5 尾实体预测 Hits@10 变化曲线图

3.4 关系链接预测实验

在 Wikidata12K, YAGO11K 数据集上,对 Duration-HyTE 方法训练得到的模型进行关系的链接预测,测试方法是用每种方法训练得到的最佳模型对测试集中的三元组做关系链接预测,实验的评价指标是正确关系向量的平均排名(MR)和命中第 1 的百分比 Hits@1.将实验结果与基准方法对比,实验结果如表 4 所示:

Metric	Wikidata12K		YAGO11K	
	MR	Hits@1/%	MR	Hits@1/%
HolE	2.23	83.96	2.57	69.3
TransE	1.35	88.4	1.7	78.4
TransH	1.4	88.1	1.53	76.1
t-TransE	1.97	74.2	1.66	75.5
HyTE	1.13	92.6	1.23	81.2
Duration-HyTE	1.10	92.9	1.14	86.1

Note: The best values are in bold.

表 4 的结果对比显示,在 Wikidata12K, YAGO11K 数据集上,Duration-HyTE 算法的关系预测都比基准方法更加准确,关系的预测效果分别提升了 2.7%和 7.3%.

图 6 绘制了 HyTE 和本文方法训练得到的模型对于关系预测的结果随 epoch 变化的曲线.尽管 HyTE 方法对于关系的预测排名已经接近 1,优化的空间很小,但是 Duration-HyTE 方法对于关系的预测效果仍略优于 HyTE.




Fig. 6 Comparison chart of prediction mean rank of relation

图 6 关系预测平均排名的变化曲线图

关系链接预测的另一项评价指标 Hits@1 的对比结果如图 7 所示,与尾实体的预测的 Hits@10 变化曲线相似,Duration-HyTE 方法训练得到模型的预测结果优于 HyTE 方法.

为了更清晰地展示 2 个模型关系预测测试结果的不同,我们从关系的预测结果中提取了实验结果中的一些典型例子来对比 HyTE 和 Duration-HyTE 对不同关系的预测,如表 5 所示.

表 5 中列 1 是删除关系后的四元组,列 2,3 分别是 HyTE 和 Duration-HyTE 对缺失关系的预测排名的前 2 名,其中加粗的关系为正确的预测值.




Fig. 7 Comparison chart of prediction Hits@1 of relation
图 7 关系预测 Hits@1 变化曲线图

Table 5 Comparison of Relation Prediction Between HyTE and Duration-HyTE

表 5 关系预测对比表

Test Quadruples	HyTE	Duration-HyTE
Norman_Borlaug,?,University_of_Minnesota,[1937—1942]	isMarriedTo , graduatedFrom	graduatedFrom ,wasBornIn
Francisco_Gallardo,?,Puskás_Akadémia_FC,[2013—2014]	isMarriedTo , playsFor	playsFor ,isMarriedTo
Konstantinos_Tsatsos,?,Independent_politician,[1967—1974]	isMarriedTo , isAffiliatedTo	isAffiliatedTo ,isMarriedTo
Donovan_Leitch_(actor),?,London,[1946—1967]	diedIn, wasBornIn	wasBornIn ,diedIn
Kate_O'Mara,?,Leicester,[1939—1939]	isMarriedTo , wasBornIn	wasBornIn ,diedIn
Ida_Halpern,?,University_of_Vienna,[1938—#####]	hasWonPrize, graduatedFrom	graduatedFrom ,worksAt
Luis_Walter_Alvarez,?,Berkeley,_California,[1988—1988]	wasBornIn, diedIn	diedIn ,wasBornIn
Shohei_Ōoka,?,Asahi_Prize,[1976—#####]	Created, hasWonPrize	hasWonPrize ,created
Ahn_Hyo-yeon,?,South_Korea_national_under_20_football_team[1997—#####]	isMarriedTo , playsFor	playsFor ,isMarriedTo
Shields_Warren,?,Harvard_Medical_School,[1923—#####]	isMarriedTo , graduatedFrom	graduatedFrom ,hasWonPrize
Shafi_Goldwasser,?,IEEE_Emanuel_R._Piore_Award[2011—#####]	isMarriedTo , hasWonPrize	hasWonPrize ,isMarriedTo
Florence_Augusta_Merriam_Bailey,? Smith_College[1882—1896]	hasWonPrize, graduatedFrom	graduatedFrom ,worksAt
Martha_Smith,?,Cleveland[1953—1953]	isMarriedTo , wasBornIn	wasBornIn ,diedIn

Note: The right relations are in bold.

3.5 持续型关系数据链接预测实验

2.1 节介绍了基于持续时长的关系分类,其中将关系按照持续时间分为持续型关系和瞬时型关系 2 类.而有效持续时间建模的对象主要是针对持续型关系,所以本节将在持续型关系型数据集上对 Duration-HyTE 方法做进一步的验证.3.1 节中介绍了我们从

Wikidata12K,YAGO11K 中抽取了所有包含持续型关系的数据,新建了 2 个持续型关系数据集 WDP12K,YGP10K.HyTE,Duration-HyTE 训练算法在数据集 WDP12K,YGP10K 上进行对比实验,用知识表示学习得到的模型做链接预测,得到的实体链接预测结果如表 6 所示,关系链接预测结果如表 7 所示.

Table 6 Results of Entity Prediction in Persistent Relation Dataset

表 6 持续型关系数据集实体预测结果表

Metric	WDP12K				YGP10K			
	MR		Hits@10/%		MR		Hits@10/%	
	Tail	Head	Tail	Head	Tail	Head	Tail	Head
HyTE	224	329	34.6	18.4	112	298	43.1	22.4
Duration-HyTE	194	286	38.7	21.0	102	258	42.9	27.3

Note: The best values are in bold.

Table 7 Results of Relation Prediction in Persistent Relation Dataset

表 7 持续型关系数据集关系预测结果表

Metric	WDP12K		YGP10K	
	MR	Hits@1/%	MR	Hits@1/%
HyTE	1.17	94.4	1.14	94.2
Duration-HyTE	1.15	95.4	1.04	97.1

Note: The best values are in bold.

Duration-HyTE 方法得到的模型在持续型关系数据集上取得了比 HyTE 更好的结果,在 2 个数据集上的尾实体预测分别提升了 13.1%和 13.4%,头实体链接预测性能分别提升了 13.4%和 8.9%,关系链接预测性能分别提升了 1.7%和 8.8%.这进一步验证了我们的模型训练算法在持续型关系数据集上的有效性.

3.6 时间预测实验

目前,知识图谱中的时间标注不够完整,缺失情况严重,因此知识有效时间预测是一项重要任务.时间预测任务就是给定测试的对象(h, r, t, τ_x),在所有时间超平面上投影三元组的关系和实体,计算评价函数,并以此计算每个时间超平面的排名.如果被测对象是持续型关系三元组,那么考虑有效时间间隔中最低的正确时间超平面排名.在此任务的训练过程中我们采用了式(12)(13)这 2 种负采样方法,其他的训练过程与链接预测实验一致.对比实验结果如表 8 所示:

Table 8 Mean Rank of Time Prediction

表 8 时间预测平均排名结果表

Method(Sampling Method)	Wikidata12K	YAGO11K
HyTE (TANS)	29.3	14.0
HyTE (TDNS)	17.6	9.9
Duration-HyTE (TANS)	22.0	13.6
Duration-HyTE (TDNS)	11.4	9.4

Note: The best values are in bold.

表 8 展示了 HyTE 和 Duration-HyTE 在采用 2 种负采样方法时在时间预测任务上的对比实验结果.实验结果表明依赖时间的负采样方法(TDNS)更适合用在时间预测任务上,这是因为它更专注于使模型的时间超平面分离,从而提升了时间预测效果.

2 种方法在 Wikidata12K 数据集上采用 TDNS 负采样方法的平均排名的变化曲线对比结果如图 8 所示:

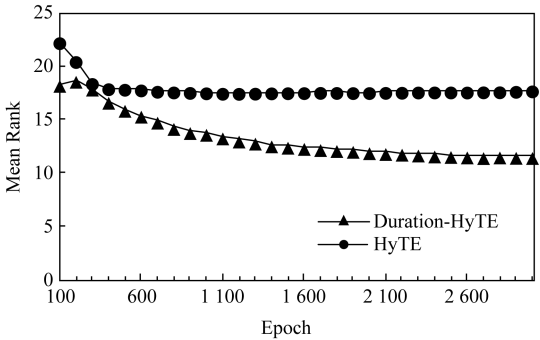


Fig. 8 Comparison chart of prediction mean rank of time

图 8 时间预测平均排名的变化曲线图

4 总 结

本文受持续时间模型启发,针对知识有效持续时长的分布问题,对知识的有效持续时间进行建模,计算知识在不同时间片上的有效可信度,将其作用于训练过程评价函数和损失函数的计算,提出了融合超平面和持续时间建模的时间感知知识表示学习方法 Duration-HyTE.并在 2 个通用数据集和新建的 2 个持续型关系数据集上设计了对比验证实验.实验结果表明 Duration-HyTE 算法训练得到的模型对于实体和关系的链接预测与时间预测效果都有显著提升,尤其是在 Wikidata 数据集上的头尾实体预测准确度分别提高了 25.7%和 35.8%.

含有时间标签的知识图谱有大量的缺失值,目前已有的方法大多将其默认为最大或最小值,这给模型正确地学习时间知识造成了阻碍.因此,我们将会继续研究含时间标签的大型知识图谱时间标签的预测和迭代补全问题,提高知识标签的数据质量,更好地训练模型,提高链接预测的准确度.目前流行的知识表示学习都采用随机的负采样方法,本文链接预测任务所采用的 TANS 方法也是一种随机的负采样方法,如何改进负采样方法,获得更高质量的负样本也是一个很好的研究点.另外,如何将 Duration-HyTE 等时间感知的知识表示学习方法应用于时间相关的关系抽取、知识融合和推理等,也是值得深入研究的方向.

参 考 文 献

[1] Zhao Jun. Knowledge Graph [M]. Beijing: Higher Education Press, 2018 (in Chinese)

(赵军. 知识图谱[M]. 北京: 教育出版社, 2018)

[2] Liu Qiao, Li Yang, Duan Hong, et al. Knowledge graph construction techniques [J]. Journal of Computer Research and Development, 2016, 53(3): 582-600 (in Chinese)
(刘峤, 李杨, 段宏, 等. 知识图谱构建技术综述[J]. 计算机研究与发展, 2016, 53(3): 582-600)

[3] Bollacker K, Evans C, Paritosh P, et al. Freebase: A collaboratively created graph database for structuring human knowledge [C] //Proc of the 2008 ACM SIGMOD Int Conf on Management of Data. New York: ACM, 2008: 1247-1250

[4] Suchanek F M, Kasneci G, Weikum G. YAGO: A core of semantic knowledge [C] //Proc of the 16th Int Conf on World Wide Web. New York: ACM, 2007: 697-706

[5] Miller G A. WorldNet: A lexical database for English [J]. Communications of the ACM, 1995, 38(11): 39-41

[6] Liu Zhiyuan, Sun Maosong, Lin Yankai, et al. Knowledge representation learning: A review [J]. Journal of Computer Research and Development, 2016, 53(2): 247-261 (in Chinese)
(刘知远, 孙茂松, 林衍凯, 等. 知识表示学习研究进展[J]. 计算机研究与发展, 2016, 53(2): 247-261)

[7] Nickel M, Tresp V, Krieger H P. A three-way model for collective learning on multi-relational data [C] //Proc of Int Conf on Machine Learning. New York: ACM, 2011: 809-816

[8] Yang Bishan, Yih W, He Xiaodong, et al. Embedding entities and relations for learning and inference in knowledge bases [C/OL] //Proc of the 3rd Int Conf on Learning Representations. 2015 [2020-05-09]. <https://arxiv.org/abs/1412.6575>

[9] Nickel M, Rosasco L, Poggio T. Holographic embeddings of knowledge graphs [C] //Proc of the 30th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2016: 1955-1961

[10] Balažević I, Allen C, Hospedales T M. TuckER: Tensor factorization for knowledge graph completion [J]. arXiv preprint, arXiv:1901.09590, 2019

[11] Bordes A, Usunier N, Garcia-Duran A, et al. Translating embeddings for modeling multi-relational data [C] //Proc of Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2013: 2787-2795

[12] Wang Zhen, Zhang Jianwen, Feng Jianlin, et al. Knowledge graph embedding by translating on hyperplanes [C] //Proc of the 28th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2014: 1112-1119

[13] Lin Yankai, Liu Zhiyuan, Sun Maosong, et al. Learning entity and relation embeddings for knowledge graph completion [C] //Proc of the 29th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2015: 2181-2187

[14] Ji Guoliang, He Shizhu, Xu Liheng, et al. Knowledge graph embedding via dynamic mapping matrix [C] //Proc of the 53rd Annual Meeting of the Association for Computational

Linguistics and the 7th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2015: 687-696

[15] Fang Yang, Zhao Xiang, Tan Zhen, et al. A revised translation-based method for knowledge graph representation [J]. Journal of Computer Research and Development, 2018, 55(1): 139-150 (in Chinese)
(方阳, 赵翔, 谭真, 等. 一种改进的基于翻译的知识图谱表示方法[J]. 计算机研究与发展, 2018, 55(1): 139-150)

[16] Jiang Tingsong, Liu Tianyu, Ge Tao, et al. Encoding temporal information for time-aware link prediction [C] //Proc of the 2016 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2016: 2350-2354

[17] Dasgupta S S, Ray S N, Talukdar P. Hyte: Hyperplane-based temporally aware knowledge graph embedding [C] //Proc of the 2018 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2018: 2001-2011

[18] Haughton D, Haughton J. Living Standards Analytics: Development through the Lens of Household Survey Data [M]. New York: Springer, 2011: 289-291

[19] Leblay J, Chekol M W. Deriving validity time in knowledge graph [C] //Proc of ACM Press Companion of the The Web Conf 2018. New York: ACM, 2018: 1771-1776

[20] Bordes A, Weston J, Collobert R, et al. Learning structured embeddings of knowledge bases [C] //Proc of the 25th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2011: 301-306



Cui Yuanning, born in 1996. Master candidate of Nanjing University of Aeronautics and Astronautics. His main research interests include knowledge graph and data mining.



Li Jing, born in 1976. Associate professor of Nanjing University of Aeronautics and Astronautics. Her main research interests include computer vision, distributed computing and data mining.



Shen Li, born in 1968. PhD. His main research interests include smart power grids, image processing and data mining.



Shen Yang, born in 1965. Senior engineer. His main research interests include anomaly detection and cloud computing.



Qiao Lin, born in 1977. Senior engineer. His main research interests include computer software, computer applications.



Bo Jue, born in 1986. Deputy senior engineer. She is working in the Communications Department of Liaoning State Grid. Her main research interests include data governance and data mining.

2018 年《计算机研究与发展》高被引论文 TOP10

排名	论文信息
1	李然, 林政, 林海伦, 王伟平, 孟丹. 文本情绪分析综述[J]. 计算机研究与发展, 2018, 55(1): 30-52 Li Ran, Lin Zheng, Lin Hailun, Wang Weiping, Meng Dan. Text Emotion Analysis: A Survey [J]. Journal of Computer Research and Development, 2018, 55(1): 30-52
2	吕华章, 陈丹, 范斌, 王友祥, 乌云霄. 边缘计算标准化进展与案例分析[J]. 计算机研究与发展, 2018, 55(3): 487-511 Lü Huazhang, Chen Dan, Fan Bin, Wang Youxiang, Wu Yunxiao. Standardization Progress and Case Analysis of Edge Computing [J]. Journal of Computer Research and Development, 2018, 55(3): 487-511
3	赵梓铭, 刘芳, 蔡志平, 肖依. 边缘计算: 平台、应用与挑战[J]. 计算机研究与发展, 2018, 55(2): 327-337 Zhao Ziming, Liu Fang, Cai Zhiping, Xiao Nong. Edge Computing: Platforms, Applications and Challenges [J]. Journal of Computer Research and Development, 2018, 55(2): 327-337
4	陈珂, 梁斌, 柯文德, 许波, 曾国超. 基于多通道卷积神经网络的中文微博情感分析[J]. 计算机研究与发展, 2018, 55(5): 945-957 Chen Ke, Liang Bin, Ke Wende, Xu Bo, Zeng Guochao. Chinese Micro-Blog Sentiment Analysis Based on Multi-Channels Convolutional Neural Networks [J]. Journal of Computer Research and Development, 2018, 55(5): 945-957
5	余永红, 高阳, 王皓, 孙栓柱. 融合用户社会地位和矩阵分解的推荐算法[J]. 计算机研究与发展, 2018, 55(1): 113-124 Yu Yonghong, Gao Yang, Wang Hao, Sun Shuanzhu. Integrating User Social Status and Matrix Factorization for Item Recommendation [J]. Journal of Computer Research and Development, 2018, 55(1): 113-124
6	贺海武, 延安, 陈泽华. 基于区块链的智能合约技术与应用综述[J]. 计算机研究与发展, 2018, 55(11): 2452-2466 He Haiwu, Yan An, Chen Zehua. Survey of Smart Contract Technology and Application Based on Blockchain [J]. Journal of Computer Research and Development, 2018, 55(11): 2452-2466
7	齐彦丽, 周一青, 刘玲, 田霖, 石晶林. 融合移动边缘计算的未来 5G 移动通信网络[J]. 计算机研究与发展, 2018, 55(3): 478-486 Qi Yanli, Zhou Yiqing, Liu Ling, Tian Lin, Shi Jinglin. MEC Coordinated Future 5G Mobile Wireless Networks [J]. Journal of Computer Research and Development, 2018, 55(3): 478-486
8	谢振平, 金晨, 刘渊. 基于建构主义学习理论的个性化知识推荐模型[J]. 计算机研究与发展, 2018, 55(1): 125-138 Xie Zhenping, Jin Chen, Liu Yuan. Personalized Knowledge Recommendation Model Based on Constructivist Learning Theory [J]. Journal of Computer Research and Development, 2018, 55(1): 125-138
9	陈伟利, 郑子彬. 区块链数据分析: 现状、趋势与挑战[J]. 计算机研究与发展, 2018, 55(9): 1853-1870 Chen Weili, Zheng Zibin. Blockchain Data Analysis: A Review of Status, Trends and Challenges [J]. Journal of Computer Research and Development, 2018, 55(9): 1853-1870
10	邓晓衡, 关培源, 万志文, 刘恩陆, 罗杰, 赵智慧, 刘亚军, 张洪刚. 基于综合信任的边缘计算资源协同研究[J]. 计算机研究与发展, 2018, 55(3): 449-477 Deng Xiaoheng, Guan Peiyuan, Wan Zhiwen, Liu Enlu, Luo Jie, Zhao Zhihui, Liu Yajun, Zhang Honggang. Integrated Trust Based Resource Cooperation in Edge Computing [J]. Journal of Computer Research and Development, 2018, 55(3): 449-477