

文章编号: 2096-1618(2024)05-0534-06

基于行为修饰嵌入的时序知识图谱嵌入研究

王润峰, 李彤岩, 谷丽萍, 罗飞

(成都信息工程大学通信工程学院, 四川 成都 610225)

摘要:随着时序知识图谱的不断发展与应用,时序知识图谱的嵌入作为时序知识图谱应用的桥梁,在时序知识图谱的研究中有着较高的地位。时序知识图谱嵌入模型也越来越受重视。根据词语间的修饰关系与修饰方式提出一种基于行为修饰实体的嵌入模型,并利用这一模型将时间嵌入到实体使四元组转变为三元组。之后将其与 DistMult 模型结合形成新的时序知识图谱嵌入模型,即 BME-DistMult。在 ICEWS14 与 GDELT 数据集上进行实验,与现有的静态知识图谱嵌入模型和其他时序知识图谱嵌入模型进行对比,该模型有较好的效果。

关键词:时序知识图谱;知识嵌入;嵌入方法

中图分类号:TP391.1

文献标志码:A

doi:10.16836/j.cnki.jcuit.2024.05.003

0 引言

随着知识图谱的不断发展,时序知识图谱的研究被提出来。时序知识图谱采用四元组的形势储存了大量与时间信息相关的事实。这些事实通过由头实体(h)、关系(r)、尾实体(t)、时间戳(ti)所组成的四元组($\langle h, r, t, ti \rangle$)表示。如: \langle 刘禅,继位,蜀汉皇帝,223 \rangle 四元组表达的事实为:刘禅在公元223年继位为蜀汉皇帝。而不包含时间信息的三元组只能表达出刘禅成为过蜀汉皇帝,却无法了解刘禅何时成为、在位时间以及退位时间等信息。

与知识图谱一样,时序知识图谱在表示结构化数据方面有极高的效果。同样的时序知识图谱依旧无法摆脱底层符号特性带来的影响。通过时序知识图谱的嵌入能够将时序知识图谱所描述的事实部分进行嵌入,以达到消除底层符号特性所带来的负面影响。时序知识图谱嵌入是将实体和关系以及时间信息加载到连续的向量空间中,既能保留时序知识图谱的原有结构又能便于进一步的应用。

近年来时序知识图谱嵌入补全的研究得到了极大的发展,参照静态知识图谱嵌入补全模型的研究思路,对时序知识图谱嵌入补全进行研究。时序知识图谱嵌入补全的研究思路则主要分为时间四元组模型和四元组转三元组模型。其中时间四元组模型是基于传统知识图谱嵌入模型,通过添加时间向量并扩展原始基础模型来嵌入时序知识图谱;而四元组转三元组模型是使用变换模型将四元组转换为三元组,然后与传统知

识图谱嵌入模型合成,完成时序知识图谱的嵌入。根据上述研究思路提出了许多时序知识图谱嵌入模型。其中时间四元组模型较多,对四元组转三元组模型的研究较少,而四元组转三元组模型的嵌入效果要好于时间四元组模型,因此在时序知识图谱嵌入的研究中要更多地研究四元组转三元组模型。

对前面提到的四元组 \langle 刘禅,继位,蜀汉皇帝,223 \rangle 而言,若将行为看作实体的修饰词,用“继位”修饰刘禅和蜀汉皇帝后,可以将上述四元组转变为形如 \langle 刘禅在继位,223,继位成蜀汉皇帝 \rangle 的三元组,如此为时序知识图谱的嵌入模型提供了新的思路。本文提出基于行为修饰实体的时序知识图谱嵌入模型。主要工作如下:

利用函数对四元组中的行为与实体进行嵌入,该函数以行为与实体为输入,以矩阵或者向量作为输出。将这一嵌入方法称为行为修饰嵌入(behavior modification embedding BME)。

将 BME 与静态知识图谱的嵌入模型 DistMult 相结合,以形成新的时序知识图谱嵌入模型,并将其命名为 BME-DistMult。

该模型在两个通用数据集 ICEWS14^[1] 和 GDELT^[2] 上进行测试,并取得了良好的效果。

1 相关工作

知识图谱的嵌入模型包含两大类:一种是静态知识图谱嵌入模型,这类嵌入模型主要用于嵌入由三元组所组成的传统知识图谱;另一种则是时序知识图谱的嵌入模型,这类模型则是用于对包含时间信息的知

识图谱进行嵌入。

1.1 静态知识图谱模型

TransE^[3]模型将三元组翻译为3个首尾能够相连的向量,其评分函数为

$$\varphi(h, r, t) = -\|z_h + z_r - z_t\| \quad (1)$$

RESICAL^[4]模型,利用张量分解的方法去完成关系学习,其评分函数为

$$\varphi(h, r, t) = z_h^T z_r z_t \quad (2)$$

DistMult^[5]模型是一种 RESICAL 变体模型,这一模型简化了其中的关系矩阵,将关系信息存放到矩阵的对角线上,其评分函数为

$$\varphi(h, r, t) = (z_h \cdot z_t \cdot z_t) \quad (3)$$

Poole 等^[6]发现 \vec{z} 与 \vec{z} 间存在信息流问题,并利用逆关系来解决这一问题,从而提出了 SimplE 模型,其评分函数分为以下两部分的平均值为

$$\varphi(h, r, t) = 1 - (\vec{z}_h \cdot \vec{z}_t \cdot \vec{z}_t) \quad (4)$$

$$\varphi(h, r, t) = 2 - (\vec{z}_h \cdot \vec{z}_t \cdot \vec{z}_t) \quad (5)$$

1.2 时序知识嵌入模型

TTransE^[7]模型是在 TransE 模型的基础上添加了一个嵌入函数将时间戳进行嵌入,同时 TTransE 将 TransE 评分函数进行拓展为

$$\varphi(h, r, ti, t) = -\|z_h + z_r + z_{ti} - z_t\| \quad (6)$$

Lacroix 等^[8]参照 ComplEx 提出了 TComplEx 模型,该模型将每个时间戳作为复向量后对其进行嵌入,并将评分函数定义为

$$\varphi(h, r, ti, t) = \text{Re}(\langle z_h, z_r, z_{ti}, z_t \rangle) \quad (7)$$

Ma 等^[9]将几种静态知识图谱嵌入模型进行扩展,其中表现最好的模型是 ConT。该模型是将每个时间戳“ti”嵌入为 z_{ti} ,并定义评分函数为:

$$\varphi(h, r, ti, t) = (z_{ti}, z_h \otimes z_r \otimes z_t) \quad (8)$$

HyTE^[10]通过将不同的时间戳映射到不同的超平面中,在每个超平面上进行建模时就能够通过传统的三元组建模方式进行建模,其评分函数为:

$$\varphi(h, r, ti, t) = -\|\bar{z}_h + \bar{z}_r - \bar{z}_t\| \quad (9)$$

其中 $\bar{z}_h = z_h - z_{ti}^T z_h z_{ti}$, \bar{z}_r, \bar{z}_t 也是如此转换而来。

Temp^[11]则是将知识图用离散的时间戳分隔为多个子图,将这些子图通过 GNN 对其进行卷积后采用 RNN 进行时间上的串联。

ATiSE3^[12]通过将时间信息合并到实体和关系中,将四元组转换为三元组,然后将时间知识图映射到多维高斯分布空间。

TA-DistMult^[13]作为 DistMult 模型的拓展,它将 r

和 ti 作为一个时间关系序列中 $z_{r,ti}$,之后更改 DistMult 模型的评分函数为

$$\varphi(h, r, ti, t) = (z_h \cdot z_{r,ti} \cdot z_t) \quad (10)$$

通过函数将时间信息嵌入到实体中定义了历时嵌入(diachronic embedding, DE),将四元组转换为三元组,并将其与传统模型相结合,形成了 DE-DistMult 模型^[14]。

Wang 等^[15]提出时间修饰关系的模型(modifier embedding, ME)将四元组转换为三元组,并将其与 DistMult 结合形成 ME-DistMult,将评价函数更改为

$$z_{ti}^r[n] = \begin{cases} z_r[n]y(w_r[n]) + b_r[n] & \text{if } \gamma d < n \leq d \\ z_r[n] & \text{if } 1 \leq n \leq \gamma d \end{cases} \quad (11)$$

$$\varphi(h, r, ti, t) = (z_h \cdot z_{ti}^r \cdot z_t) \quad (12)$$

2 基于行为修饰的嵌入模型

2.1 行为修饰模型

对于知识图谱的嵌入函数,通常将需要嵌入的内容作为输入经过嵌入函数之后输出一个隐藏的向量。据此,其将关系作为输入经过嵌入函数后输出一个隐藏的向量。受上述方法启发,本文重新定义了时序知识图谱的嵌入函数,行为修饰实体部分的嵌入函数是以行为与实体同时作为函数的输入,用行为去修饰实体,从而获得实体行为的嵌入结果,并称这种方式为行为修饰型嵌入。下面是行为修饰型嵌入的正式定义。

定义1:行为修饰型嵌入 BME: $(E, R) \rightarrow \varphi$ 。这个函数将每一对 (E, R) 映射到 φ 中,其中 E 为实体, R 为行为或关系, φ 则是矩阵。

这种方法可以将时序知识图谱的四元组转变为三元组,利用这一方式将传统的静态知识图谱嵌入模型进行拓展,从而达到对时序知识图谱嵌入的目的。但如何将实体与行为进行嵌入,本文提出一种 BMEMB 函数,这一函数将实体作为主体,行为作为修饰体。为保留主体的信息,引入了一个嵌入系数 γ 对 φ 进行比例嵌入使其一部分保留实体的全部属性,另一部分则是经过行为修饰之后的实体,最终将实体行为定义为 z_e^r ,公式如下:

$$z_e^r[n] = \frac{\gamma}{1-\gamma} [z_e[n]y(w_r[n])] + b_e[n], 0 < \gamma < 1 \quad (13)$$

式中,在 $b_e[n]$ 部分,保留了实体特征的全部信息,只对实体部分进行词嵌入。这是由于实体在产生行为或关系时,自身的部分特征不会发生变化,这一部分应当不与行为产生关联。 $\frac{\lambda}{1-\lambda} [z_e[n]y(w_r[n])]$ 部分则是

通过行为修饰过的实体, $\frac{\gamma}{1-\gamma}$ 能够根据修饰部分与保留信息之间的嵌入比例进行调整。

关系与实体的嵌入结果 z_e^r 的结构如图1所示。




图1 z_e^r 的结构

2.2 时间嵌入

在四元组中时间戳一般表示为 x 年 x 月 xx 日, 在时间跨度较大时一个时间戳对应一个嵌入向量会加大时间嵌入部分的计算量。本文在对时间进行嵌入时, 将时间依照年月日进行拆分, 并利用信息量的多少对其进行嵌入, 最终将时间嵌入部分定义为 z_{ti} , 公式如下:

$$z_{ti} = z_y[n]y(z_m[n]) + z_d[n] \quad (14)$$

在时间定义式中, 由于确定一个时间戳 x 年 y 月 z 日, 其中 x 大小是依据年限的跨度进行确定; y 的大小为 12; z 的大小为 30。根据信息量的公式^[16]

$$f(x) = -\log_2 x \quad (15)$$

可以确定, 时间戳中信息量最多的是 z; x 和 y 较少, 因此在定义中将储存“日”信息的嵌入向量 z_d 不做处理独立相加; 将储存“年”、“月”信息的嵌入向量 z_y 和 z_m 利用激活函数连接起来。时间嵌入的流程如图2所示。




图2 z_{ti} 的流程

2.3 模型融合

在通过行为修饰嵌入模型将实体与行为两部分进行融合嵌入后, 时序知识图谱的嵌入向量的数量由 4 个变为 3 个。这使时序知识图谱的嵌入向量的数量符合传统知识图谱嵌入方法, 因此在经过上述操作后可以将 BME 模型与静态知识图谱嵌入模型进行融合。

DistMult 模型作为一种静态知识图谱的嵌入模型, 它将静态知识图谱三元组中的实体嵌入为向量; 将

关系或者行为嵌入为矩阵的主对角线。DistMult 模型的评价函数为

$$\varphi(h, r, t) = (z_h \cdot z_r \cdot z_t) \quad (16)$$

DistMult 的结构图如图3所示。




图3 DistMult 的结构

在 BME 模型与 DistMult 模型的融合过程中, 将 z_{ti}^r 替换原始模型中的 z_h ; 将 z_{ti}^r 替换原始模型中的 z_t ; 将 z_{ti} 替换原始模型中的 z_r 。评分函数定义为

$$\varphi(h, r, t, ti) = (z_h^r \cdot z_{ti} \cdot z_t^r) \quad (17)$$

其结构如图4所示。




图4 BME-DistMult 的结构

3 实验结果与分析

3.1 数据集

为验证模型有效性, 在公共的时序知识图谱数据集 ICEWS14 与 GDELT 进行实验。综合危机预警系统 (ICEWS) 是用来检测、评估和预测国家地方和内部危机, 其中的事实由 BBN ACCENT 事件编码器所提取。ICEWS14 是 ICEWS 的一个子集, 记录的是 2014 年所发生的事实。全球事件、语言和语气数据库 (GDELT) 包含了 100 多种语言新闻、人类社会相关的实时信息的数据集, 该数据集是由 Trivedi 等创建的, 实验的数据集包含 2015 年 4 月至 2016 年 3 月的事实。其基本信息如表 1 所示。其中 h、r、t 表示实体关系与时间的数量。train、val、test 表示训练集、验证集、测试集的数量。G 表示数据集所有事实的数量。

表 1 ICEWS14,GDELT 基本信息

NAME	h	r	t	train	val	test	G
ICEWS-14	7128	230	356	72826	8941	8963	90730
GDELT	500	20	366	2735685	341961	341961	3419607

3.2 数据预处理

在实验过程中将时序知识图谱中的事实分为训练集、验证集以及测试集 3 部分。模型参数的学习采用随机梯度下降。在训练时为了获取负样本对训练集进行处理,对于训练集中的每个事实四元组 fact=(h,r,ti,t),通过替换事实中的 h,t 的方式形成了两类不同种类的错误事件。分别为(h',r,ti,t)和(h,r,ti,t'),并生成相应的后选答案集。然后采用最小化交叉熵损失对其进行训练。

3.3 评价指标

在进行时序知识图谱的嵌入与时序知识图谱的补全,本文设计一个程序将测试集中的事实 fact=(h,r,ti,t)进行如下操作:将事实替换为(i,r,ti,t)和(h,r,ti,i)包括正确的事实,之后将其用模型进行嵌入获得到对应评分,并对其进行排序获取正确事实的排名为rank。之后通常采用 MRR(mean reciprocal ranking)、Hit@1、Hit@3、Hit@10 作为评价指标对其进行统计并与其他模型进行对比。

MRR 表示正确事实的评分在所有事实中的平均排名。公式如下:

$$MRR = \sum_0^N \frac{rank_i}{N} \tag{18}$$

Hit@1 表示正确事实在所有事实中评分排名第一的占比;Hit@3 表示正确事实在所有事实评分排名在前三的占比;Hit@10 表示正确事实在所有事实评分排名在前 10 的占比。Hit@k 系列的公式为

$$Hit@k = \sum_0^N \frac{i}{N} \begin{cases} \text{if rank} \leq k; i=1 \\ \text{if rank} > k; i=0 \end{cases} \tag{19}$$

3.4 实验过程

在 PyTorch 上对 BME-DistMult 模型进行训练和测试实验。并使用 ADAM 优化器,设置学习率为0.001,用迭代的方式进行训练,每次操作 512 组数据,一个正样本包含 500 个负样本,嵌入大小为 100。在与静态知识图谱嵌入模型进行对比训练时,抹除时序知识图谱中的时间信息从而达到训练目的。

3.5 实验结果

ICEWS14 数据集下训练的结果见表 2,GDELT 数

据集下的训练结果见表 3。在实验中设定 γ 为0.5。根据实验结果可以得出时序知识图谱嵌入模型的嵌入效果比静态知识图谱嵌入模型更好。结果表明时序知识图谱的嵌入模型有更好的预测效果。

在 ICEWS14 数据集的实验结果中,BME-DistMult 模型相较于 DistMult 这一原始模型有较为明显的提高,对比 DistMult 的其他变种模型亦有所提高。与 DE-DistMult 相比 BME-DistMult 在 MRR 上提高了 4.79%,在 Hit@1、Hit@3、Hit@10 上分别提高了 6.63%、3.89%、2.40%。

表 2 ICEWS14 训练结果

Model	MRR	Hit@1	Hit@3	Hit@10
TransE	0.280	9.4	—	63.7
DistMult	0.439	32.3	—	67.2
ConT	0.185	11.7	20.5	31.5
TTransE	0.255	7.4	—	60.1
HyTE	0.297	10.8	41.6	65.5
TA-DistMult	0.471	36.3	—	68.2
ME-DistMult	0.491	37.7	55.0	70.5
DE-DistMult	0.501	39.2	56.9	70.8
BME-DistMult	0.525	41.8	59.1	72.5

在 GDELT 数据集的实验结果中,BME-DistMult 模型相较于静态知识图谱嵌入模型与其他时序知识图谱的嵌入模型的嵌入效果有一定的提高,BME-DistMult 模型的嵌入效果相较于 ConT、TTransE 等模型在 MRR 上有显著提高;与其他 DistMult 的变种模型的嵌入效果相比 BME-DistMult 模型的效果在 MRR、Hit@1、Hit@3评价指标中表现最好。

表 3 GDELT 训练结果

Model	MRR	Hit@1	Hit@3	Hit@10
TransE	0.113	0.0	15.8	31.2
DistMult	0.194	11.7	20.8	34.8
ConT	0.144	8.0	15.6	26.5
TTransE	0.115	0.0	16.0	31.8
HyTE	0.118	0.0	16.5	32.6
TA-DistMult	0.201	12.3	21.8	36.1
ME-DistMult	0.211	13.0	22.8	35.9
DE-DistMult	0.213	13.0	22.8	37.6
BME-DistMult	0.216	13.6	23.0	36.9

3.6 模型变换

在实验中对于 BME 模型定义公式除了式(13)外,还有一种定义:

$$\mathbf{z}_e^r[n] = \begin{cases} \mathbf{z}_e[n]y(\mathbf{w}[n]) + \mathbf{b}_e[n], & \text{if } \gamma d < n \leq d \\ \mathbf{z}_e[n] & \text{if } 0 \leq n \leq \gamma d \end{cases} \quad (20)$$

式(20)与式(13)定义的参数均在 0~1,式(20)参数为 0 时和式(13)参数为 0.5 时相互等价。

在 ICEWS14 数据集上对式(13)与式(20)进行参数实验,结果见表 4。

表 4 参数实验

定义	γ	MRR	Hit@1	Hit@3	Hit@10
式(13)	0.167	0.520	41.2	58.7	72.2
	0.2	0.521	41.4	59.0	72.1
	0.33	0.525	41.8	59.1	72.5
	0.50	0.524	41.7	58.5	72.1
	0.66	0.519	41.3	58.4	71.7
	0.90	0.479	36.2	54.6	70.1
	0.80	0.494	38.0	56.0	71.5
	0.70	0.506	39.3	57.4	71.9
式(20)	0.5	0.512	40.3	57.8	71.6
	0.3	0.518	41.3	58.2	71.5
	0.2	0.517	41.2	57.8	71.6
	0.1	0.52	41.6	57.9	71.3
	0.01	0.518	41.7	58.0	70.9
	0	0.524	41.7	58.5	72.1

对比表 2,式(13)与式(20)的参数实验嵌入效果较好,式(13)的参数实验结果可以看出当嵌入系数为 0.33 时效果最好,此时修饰部分的比例为本体部分的一半。观察式(20)的参数实验结果可以看到嵌入效果与参数大小呈负相关,在参数较小时基本趋于稳定。这是因为在定义中 $\gamma d < n \leq d$ 的部分,本身就包含了修饰部分与实体部分,因此单独保留实体信息的向量在功能上有所重复。

4 结束语

本次实验基于四元组转变三元组的时序知识图谱嵌入思路,提出更为合理的转换方式:行为修饰嵌入(BME)模型,并将其与 DistMult 这一基本模型结合提出时序知识图谱的嵌入模型 BME-DistMult,这一模型将行为关系融合到实体后替换 DistMult 中的实体嵌入向量;将时间通过信息量的差异进行嵌入后替换 DistMult 中的关系嵌入向量。通过对比实验,证明了本模型在时序知识图谱的嵌入与补全任务中的有效性。在

未来的工作中,可以尝试将 BME 模型与其他静态知识图谱嵌入模型进行融合。

参考文献:

- [1] Alberto García-Durán, Sebastian Dumancic, Mathias Niepert. Learning Sequence Encoders for Temporal Knowledge Graph Completion [C]. Conference on Empirical Methods in Natural Language Processing, 2018: 4816–4821.
- [2] Kalev Leetaru, Philip A Schrod. Gdelt: Global data on events, location, and tone [C]. ISA annual convention, 2013: 1–49.
- [3] Antoine Bordes, Nicolas Usunier, Alberto Garcia-Duran, et al. Translating embeddings for modeling multi-relational data [C]. 27th Annual Conference on Neural Information Processing Systems, NIPS 2013, 2013: 2787–2795.
- [4] Maximilian Nickel, Volker Tresp, Hans-Peter Kriegel. A three-way model for collective learning on multi-relational data [C]. ICML 2011, 2011: 809–816.
- [5] Bishan Yang, Wen-tau Yih, Xiaodong He, et al. Embedding entities and relations for learning and inference in knowledge bases [C]. 3rd International Conference on Learning Representations, ICLR 2015, 2015.
- [6] Seyed Mehran Kazemi, David Poole. Simple embedding for link prediction in knowledge graphs [C]. 32nd Conference on Neural Information Processing Systems (NIPS), 2018: 4289–4300.
- [7] Tingsong Jiang, Tianyu Liu, Tao Ge, et al. Towards time-aware knowledge graph completion [C]. 26th International Conference on Computational Linguistics, COLING 2016, 2016: 1715–1724.
- [8] Lacroix Timothee, Obozinski Guillaume, Usunier Nicolas. Tensor decompositions for temporal knowledge base completion [J]. arXiv:2020.
- [9] Yunpu Ma, Volker Tresp, Erik A Daxberger. Embedding models for episodic knowledge graphs [J]. Journal of Web Semantics, 2019, 59.
- [10] Shib Sankar Dasgupta, Swayambhu Nath Ray, Partha Talukdar. Hyte: Hyperplane-based temporally aware knowledge graph embedding [C]. Conference on Empirical Methods in Natural Language Processing (EMNLP), 2018: 2001–2011.

- [11] Wu Jiapeng, Cao Meng, Cheung Jackie Chi Kit, et al. TEMP: Temporal Message Passing for Temporal Knowledge Graph Completion [C]. 2020 Conference on Empirical Methods in Natural Language Processing, EMNLP 2020, 2020: 5730–5746.
- [12] Leblay Julien, Melisachew Wudage Chekol, Xin Liu. Towards Temporal Knowledge Graph Embeddings with Arbitrary Time Precision [C]. 29th ACM International Conference on Information and Knowledge Management (CIKM), 2020: 685–694.
- [13] Alberto García-Durán, Sebastijan Dumančić, and Mathias Niepert. Learning sequence encoders for temporal knowledge graph completion [C]. Conference on Empirical Methods in Natural Language Processing (EMNLP), 2018: 4816–4821.
- [14] Goel Rishab, Kazemi Seyed Mehran, Brubaker Marcus, et al. Diachronic embedding for temporal knowledge graph completion [C]. AAAI 2020-34th AAAI Conference on Artificial Intelligence, 2020: 3988–3995.
- [15] Runfeng Wang, Tongyan Li, Fei Luo, et al. Modifier Embedding for Temporal Knowledge Graph Embedding [C]. JCICE 2023, 2023.
- [16] 陈运, 周亮, 陈新, 等. 信息论与编码 [M]. 3 版. 北京: 电子工业出版社, 2016: 10–11.

Behavior Modifier Embedding for Temporal Knowledge Graph Embedding

WANG Runfeng, LI Tongyan, GU Liping, LUO Fei

(College of Communication Engineering, Chengdu University of information Technology, Chengdu 610225, China)

Abstract: With the continuous development and application of temporal knowledge graph, the research direction of embedding of temporal knowledge graph is a bridge for the application of temporal knowledge graph to various applications and has a high position in the research of temporal knowledge graph. The embedding model of the temporal knowledge graph has been paid more and more attention. This paper proposes an embedding model based on behavior modifiers based on modifying entities according to the modification relationship and modification mode between words and uses this model to embed time into entities to transform quadruples into triples. It is then combined with the DistMult model to form a new temporal knowledge graph embedding model, which is called BME-DistMult. Experiments are carried out on ICEWS14 and GDELT datasets, and compared with the existing static knowledge graph embedding model and other temporal knowledge graph embedding models, our model has good results.

Keywords: temporal knowledge graph; knowledge embedding; embedding method