计算机科学
COMPUTER SCIENCE

基于图神经网络的多信息优化实体对齐模型

陈富强, 寇嘉敏, 苏利敏, 李克

引用本文

陈富强, 寇嘉敏, 苏利敏, 李克.基于图神经网络的多信息优化实体对齐模型[J]. 计算机科学, 2023, 50(3): 34-41.

CHEN Fuqiang, KOU Jiamin, SU Limin, LI Ke. Multi-information Optimized Entity Alignment Model Based on Graph Neural Network [J]. Computer Science, 2023, 50(3): 34-41.

相似文章推荐（请使用火狐或 IE 浏览器查看文章）

Similar articles recommended (Please use Firefox or IE to view the article)

文档增强型知识库问答

Document-enhanced Question Answering over Knowledge-Bases

计算机科学, 2023, 50(3): 266-275. https://doi.org/10.11896/jsjkx.220300022

异构信息网络的注意力感知多通道图卷积评分预测模型

Attention-aware Multi-channel Graph Convolutional Rating Prediction Model for Heterogeneous Information Networks

计算机科学, 2023, 50(3): 129-138. https://doi.org/10.11896/jsjkx.220300004

基于表示学习的知识图谱推理研究综述

Survey of Knowledge Graph Reasoning Based on Representation Learning

计算机科学, 2023, 50(3): 94-113. https://doi.org/10.11896/jsjkx.220900136

医学知识图谱研究与应用综述

Survey of Medical Knowledge Graph Research and Application

计算机科学, 2023, 50(3): 83-93. https://doi.org/10.11896/jsjkx.220700241

细粒度语义知识图谱增强的中文OOV词嵌入学习

Fine-grained Semantic Knowledge Graph Enhanced Chinese OOV Word Embedding Learning

计算机科学, 2023, 50(3): 72-82. https://doi.org/10.11896/jsjkx.220700249

计算机科学 COMPUTER SCIENCE
http://www.jsjkx.com
DOI:10.11896/jsjkx.220700242

基于图神经网络的多信息优化实体对齐模型

陈富强　寇嘉敏　苏利敏　李　克
北京联合大学智慧城市学院　北京 100101
(cfq2828@163.com)

摘　要　实体对齐是知识融合中的一个关键步骤,旨在发现知识图谱间存在对应关系的实体对。知识图谱融合后可以为下游提供更加广泛而准确的服务。现有的实体对齐模型对实体名称和关系的利用往往不足,在得到实体的向量表示后通过单一的迭代策略或者直接计算得出实体的对齐关系,忽略了部分有用信息,导致实体对齐的结果欠佳。针对上述问题,提出了一种基于图神经网络的多信息优化实体对齐模型。首先,模型的输入融合了实体名称中的单词信息和字符信息,通过注意力机制学习关系的向量表示并利用关系传递信息。在利用实体和关系的预对齐结果修正实体对齐矩阵的基础上,使用延迟接受算法修正部分错误对齐的结果。所提模型在 DBP15K 的 3 个子数据集上进行了对比和消融实验。结果表明,相比基线模型,其 Hits@1 指标分别提高了 4.47%,0.82%和 0.46%,Hits@10 和 MRR 指标也取得了良好的结果。通过消融实验进一步验证了所提模型的有效性,总体上可以获得更加准确的实体对齐结果。

关键词:实体对齐;知识图谱;图神经网络;注意力机制;全局对齐
中图法分类号　TP391

Multi-information Optimized Entity Alignment Model Based on Graph Neural Network

CHEN Fuqiang,KOU Jiamin,SU Limin and LI Ke
Smart City College,Beijing Union University,Beijing 100101,China

Abstract　Entity alignment is a key step in knowledge fusion,which aims to discover entity pairs with corresponding relations between knowledge graphs. Knowledge fusion enables a more extensive and accurate services for further knowledge graph applications. However,the entity names and relations are used insufficiently by most of the state-of-the-art models of entity alignment. After obtaining the vector representation of the entity,generally the alignment relations among the entities are obtained through single iterative strategy or direct calculation,while ignoring some valuable information,so that the result of entity alignment is not ideal. In view of the above problems,a multi-information optimized entity alignment model based on graph neural network (MOGNN) is proposed. Firstly,the input of the model fuses word information and character information in the entity name,and the vector representation of relations is learnt through attention mechanism. After transmitting the information by utilizing relations,MOGNN corrects the initial entity alignment matrix based on the pre-alignment results of entities and relations,and finally employs the deferred acceptance algorithm to further correct the misaligned results. The proposed model is validated on three subsets of DBP15K,and compared with the baseline models. Compared with the baseline models,Hits@1 increases by 4.47%,0.82% and 0.46%,Hits@10 and MRR have also achieved impressive results,and the effectiveness of the model is further verifies by ablation experiments. Therefore,more accurate entity alignment results can be obtained with the proposed model.

Keywords　Entity alignment,Knowledge graph,Graph neural network,Attention mechanism,Global alignment

1　引言

近年来,知识图谱作为一种有效的知识存储方式被广泛应用于知识推理[1]、推荐系统[2-3]以及问答系统[4-5]等。现有的知识图谱通常是基于特定的应用场景或者单一的数据源进行构建,数据源的内容有限以及分布不均匀导致构建出的知识图谱难以支撑复杂的应用场景。知识融合可以将不同来源的知识图谱融合为一个统一的知识图谱,其关键在于实体对齐,通过实体对齐识别出不同来源的知识图谱中指向同一对象的实体,从而实现实体的融合。

实体对齐一般有以下 3 个步骤:首先生成初始的实体向量表示,然后将其输入到模型中得到融合了信息的实体表示,最后将不同来源的实体向量表示嵌入到相同的向量空间中实现实体的对齐。现有的方法首先将实体名称输入到预训练的

到稿日期:2022-07-25　返修日期:2022-12-11
基金项目:国家自然科学基金(61972040)
This work was supported by the National Natural Science Foundation of China(61972040).
通信作者:李克(like@buu.edu.cn)

语言模型中得到实体名称的向量表示，然后使用 TransE[6] 中基于平移的方法或者基于图神经网络（Graph Neural Network，GNN）的方法[7]学习实体的有效表示，根据得到的实体向量表示计算实体之间的距离，按照距离排序得到对齐的实体对。

早期的方法大多使用 TransE 学习有效的实体表示。此类方法基于三元组的语义关系学习实体的向量表示，因此实体向量无法感知更多全局的信息。同时，此方法在建模复杂关系和三角结构时存在一定缺陷，随后提出的模型也对其进行了修正，但是实体对齐的效果依然不够理想。随着图神经网络的兴起，学者们开始使用图卷积学习实体的向量表示。由于图卷积在整个图中进行计算，实体的表示中可以融入更多邻域的信息，因此使用图神经网络的方法逐渐得到了重视。基于图卷积神经网络的方法（Graph Convolutional Network，GCN）在无向同构图中进行计算，忽略了实体间丰富的关系，模型的能力受到了一定的限制。

针对以上问题，本文提出了一种基于图神经网络的多信息优化实体对齐模型（Multi-information Optimized Entity Alignment Model Based on Graph Neural Network，MOGNN）。该模型充分利用已知的信息进行实体的对齐，在实体初始表示中融合了实体名称单词在语言模型下的向量表示和实体名称字符独热向量表示，提升了实体初始向量表示中的语义信息；使用注意力机制学习和融合关系的信息，通过有效的关系表示在实体间传递更多有效的信息；根据实体和关系对齐的一致性，利用关系和实体预对齐的结果优化对齐矩阵，使用延迟接受算法[8]（Deferred Acceptance Algorithm，DAA）调整对齐的结果，实现更加准确的对齐。本文的主要贡献在于：

（1）提出了一种基于实体名称的语义信息挖掘方法，充分挖掘实体名称中单词和字符序列中包含的语义信息。

（2）提出了一种基于图神经网络的多信息优化模型，能够充分利用实体名称、关系，以及实体和关系中的对齐信息，有效改善实体对齐效果。

（3）在 DBP15K 的 3 对跨语言知识图谱中验证了本文方法的有效性，使用 Hits@1，Hits@10 和 MRR（Mean Reciprocal Rank，MRR）3 种指标进行评估，其中 Hits@1 指标提高了 4.47%，0.82% 和 0.46%，其他指标也取得了较好的结果。

2 相关工作

传统的实体对齐方法主要依赖人工的选择，通过手动标注对齐[9]或者使用人工定义的规则进行实体对齐[10]。实体嵌入表示技术的发展，极大地减少了人工的参与，推动了下游任务的发展。文献[11]将其用于定义域约束补全任务，提出的方法明显优于一般类型预测方法。针对知识图谱自动补全中数据稀疏的问题，文献[12]通过嵌入表示模型抽取未知关系，采用长短时记忆网络模型自动补全缺失数据，有效提升了自动补全的效率。将实体的表示映射到向量空间中，在统一的向量空间中学习实体的对齐关系，通过衡量向量之间的距离得出对齐的实体对。文献[13]中使用语言模型学习非结构化属性的语义特征向量，通过余弦相似度计算文本属性特征的语义相似度。

面向实体对齐的实体嵌入表示方法主要有两种：第一种是以 TransE 为代表的基于翻译的方法，此种方法根据三元组的语义关系学习低维的实体向量表示；另一种是基于图神经网络的方法，该方法使用图卷积操作融合邻域的信息得到低维的实体向量表示。

2.1 基于翻译的方法

按照 TransE 中的定义，关系可以看作头实体和尾实体之间的翻译，对于一个三元组 $(\boldsymbol{h},\boldsymbol{r},\boldsymbol{t})$，其中，$\boldsymbol{h},\boldsymbol{r},\boldsymbol{t}$ 分别表示三元组中的头实体、关系和尾实体的向量表示，满足如下公式：

$$\boldsymbol{h}+\boldsymbol{r}=\boldsymbol{t} \tag{1}$$

此类方法根据知识图谱的三元组结构学习实体的低维向量表示，通过预对齐的实体对将不同的表示空间融合为一个统一的表示空间，从而得出实体的对齐关系。MTransE[14] 是最早使用此方法进行跨语言实体对齐的模型。IPTransE[15] 中限制预对齐的实体对具有相同的嵌入表示，使用 PTransE[16] 在统一的向量空间中迭代学习实体的对齐。PTransE 是基于 TransE 改进的模型。BootEA[17] 针对预对齐实体对数量有限的问题，通过迭代的策略不断选择可能的实体对来增强模型的训练，从而提高模型对齐的准确率。

Trans 家族的方法主要关注三元组内的约束，没有着眼于全局的结构，因而存在一定的局限性。基于图神经网络的方法通过全图的图卷积操作传递全局的信息，在实体的嵌入表示中融入了更多邻域实体的信息，使得对齐的结果更加准确。

2.2 基于图神经网络的方法

图神经网络是使用在图数据上的神经网络，将邻域的信息融入实体的表示中，图中实体的嵌入表示会受到相邻实体嵌入表示的影响，因此模型可以感知全局的信息。基于 GNN 的模型在实体对齐任务中获得了良好的效果，GCN-Align[7] 是第一个利用图神经网络进行实体对齐的模型，其使用图卷积网络学习实体的向量表示，编码不同知识图谱的 GCN 使用了同一套参数，利用知识图谱的空间结构传播实体之间的对齐关系。

早期的方法通过随机初始化得到实体的向量表示，如 GCN-Align，KECG[18]，MuGNN[19]，NAEA[20] 和 AliNet[21] 等，再把向量送到 GCN 模型中聚合邻域的信息，通过邻域负采样的损失学习实体的向量表示。但此类方法也暴露出了一些问题：使用 GCN 进行邻域信息的融合过程中没有考虑实体间不同的关系，不能满足异构图的需要；同时，随着 GCN 模型深度的加深，实体的表示也会趋于相同；模型使用随机初始化的向量表示作为原始输入得到的结果欠佳；根据最终实体的嵌入表示计算实体之间的距离，直接按照距离对候选实体进行排序得到最终匹配的实体对会产生部分错误的局部对齐。针对以上可能存在的问题，研究人员也进行了探索研究。

2.2.1 改进的 GNN 模型

为了满足异构图的结构，研究人员从不同的方向进行了探究。一些模型在信息传播的过程中考虑不同的关系，在实体表示中融入关系的表示。HGCN[22] 通过学习关系的表示

帮助实体进行对齐；RDGCN[23]使用关系注意下的对偶图卷积网络感知复杂的关系信息，从而更好地学习实体的表示；RNM[24]通过关系进行邻域匹配来增强实体对齐的结果。还有一些模型在信息传递的过程中通过扩大实体感知的范围从而获取更有效的实体的表示。RSNs[25]将递归神经网络和残差的学习相结合，以捕获实体之间的长距离依赖关系；LDSD[26]通过对邻居实体进行采样得到具有一定语义信息的路径，在实体表示中融入了路径中实体的信息，增强了对多跳邻居的感知。

2.2.2 模型输入信息的扩展

在一些模型中，实体的初始表示通过随机初始化的方法获得，利用有限的结构信息学习到有效的实体表示比较困难，实体对齐的结果也不够理想。针对跨语言知识图谱，后来的一些模型[27-30]多采用机器翻译的方法。首先使用机器翻译将跨语言的实体名称翻译为英文，再将实体名称的英文表示输入到预训练的语言模型中得到实体的初始表示。在使用了机器翻译方法后，实体的初始表示已经具有了一定的语义信息，再利用 GNN 模型则更容易学习到有效的实体表示，更有利于实体的对齐。还有模型使用附加的信息来增强实体的嵌入表示。一些模型使用了实体的属性信息，JAPE[30]使用属性信息细化结构信息传递下的实体表示；EMGCN[31]使用属性信息辅助实体的对齐。文献[32]使用决策树选择出划分正负例的最优划分属性，基于联合学习得到实体的向量表示，根据语义相似度和最优属性的相似度得到对齐的实体对。文献[33]针对缺乏标注数据的问题，使用了课程学习的迭代方法来扩增标注数据的规模。

2.2.3 对齐结果的优化

针对实体对齐结果中出现的错误对齐的问题，一些模型将匹配问题转化为分配问题，使用分配算法对实体对齐的结果进行调整，DGMC[29]，SEU[34]和 ERMC[35]中使用了 sinkhorn 算法[36]对实体对齐结果进行迭代优化，RAGA[37]中使用延迟接受算法促进对齐的准确性。

3 问题描述

一个知识图谱可以被定义为 $\boldsymbol{G}=(\boldsymbol{E},\boldsymbol{R},\boldsymbol{T})$，其中 $\boldsymbol{E}$ 是实体的集合，$\boldsymbol{R}$ 是关系的集合，$\boldsymbol{T}$ 是三元组的集合。给定两个知识图谱 $\boldsymbol{G}_1$ 和 $\boldsymbol{G}_2$，$\boldsymbol{G}_1$ 是源知识图谱，$\boldsymbol{G}_2$ 是目标知识图谱，实体对齐的任务是找出 $\boldsymbol{G}_1$ 和 $\boldsymbol{G}_2$ 中存在对应关系的实体对 $\mathbb{L}$，其可以表示为 $\mathbb{L}=\{e_i\equiv e_j \mid e_i\in\boldsymbol{G}_1, e_j\in\boldsymbol{G}_2\}$，其中 e_i 是 $\boldsymbol{G}_1$ 中的第 i 个实体，e_j 是 $\boldsymbol{G}_2$ 中的第 j 个实体，$\equiv$ 表示实体相互对齐。

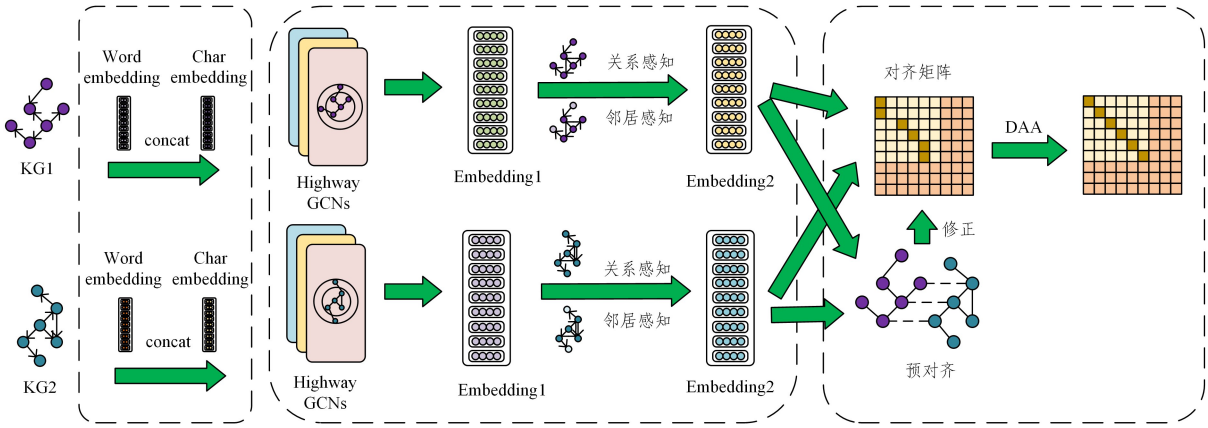

图 1 MOGNN 模型工作流程图

Fig. 1 Flowchart of MOGNN

4 实体对齐模型

针对语义信息挖掘不充分的问题，我们在实体的初始表示中尝试加入实体名称单词级别的语义信息以及实体名称字符序列中的语义信息，将其进行有效融合以增强初始实体表示中的语义信息。针对信息传递过程中信息利用不充分的问题，我们在利用邻域传递信息的基础上充分考虑关系在语义传递中的作用，通过不同的关系传递实体间隐含的重要信息；通过计算实体距离得到初步的实体对齐结果，考虑到对齐结果不是最优的，利用实体和关系对齐的一致性对对齐结果进行优化。在此基础上，本文提出了一种基于图神经网络的多信息优化实体对齐模型(MOGNN)。

图 1 给出了 MOGNN 模型的总体架构和工作流程。该模型主要包括 3 个模块，即实体语义挖掘模块、语义信息传递模块以及对齐调整模块。在第一个模块中将实体名称通过预训练语言模型 Glove[38]得到的向量和实体名称字符表示向量进行融合，得到实体的初步向量表示；第二个模块中参考了 RAGA 中的方法，使用 Highway GCNs 进行实体信息的传递，通过融合关系和实体的信息增强实体的表示；第三个模块中根据实体的向量表示计算两两实体的距离得到对齐矩阵 $\boldsymbol{S}$，根据实体和关系的向量表示得到实体预对齐对和关系预对齐对，根据预对齐对调整对齐矩阵 $\boldsymbol{S}$ 中实体之间的距离，最后使用延迟接受算法优化对齐的结果。本文模型与传统 GNN 模型主要的不同之处在于关系的表示和利用。本文模型根据关系连接的实体得出关系的表示，使用注意力机制将信息融入到实体的表示中；同时，模型充分挖掘已有的信息，在模型输入中融入实体名称的字符信息，根据已知的对齐结果对模型对齐结果进行优化，进一步提升了模型对齐的准确性。

4.1 实体语义挖掘模块

知识图谱中的实体一般都有一个明确的实体名称，为了获得跨语言知识图谱中实体的初始表示，现有的模型大多先将非英文实体名称通过机器翻译转换为英文，再将英文的名称

表示输入到预训练语言模型中获得实体的初始表示，使得实体的表示具有一定的语义信息。然而，这样的做法也带来了一些问题。实体名称的表述方式不统一和一些孤立名称的存在，导致实体名称的初始表示中会有较大的噪声。

为了减少实体初始表示中的噪声，本模型在实体的初始表示中融入了实体名称的语言模型向量以及实体名称的字符表示向量。实体名称的语言模型向量$\boldsymbol{x}_{\text{word}}^{k}$通过累加实体名称中每个单词 word 在 Glove 模型下的向量表示 $\boldsymbol{p}$ 再求平均获得。为了得到实体名称的字符表示向量$\boldsymbol{x}_{\text{char}}^{k}$，先使用窗口值为 2 的滑动窗口生成字符序列片段 token，然后将其映射为独热向量 $\boldsymbol{q}$，将所有序列片段 token 的独热向量 $\boldsymbol{q}$ 累加并进行 L2 范数归一化后得到实体名称的字符向量表示$\boldsymbol{x}_{\text{char}}^{k}$。由于不同字符序列的重要性不同以及字符表示向量的维度较高，因此其需要通过神经网络学习有效的实体名称字符表示向量，将实体名称的语言模型向量以及实体名称的字符表示向量进一步融合后得到实体的初始向量表示。具体公式如下所示：

$$\boldsymbol{e}_{\text{word}}^{k}=\{word_1,word_2,\cdots,word_m\} \tag{2}$$

$$\boldsymbol{e}_{\text{char}}^{k}=\{token_1,token_2,\cdots,token_n\} \tag{3}$$

$$\boldsymbol{x}_{\text{word}}^{k}=\frac{\sum_{i=1}^{m}\boldsymbol{p}_i}{m} \tag{4}$$

$$\boldsymbol{x}_{\text{char}}^{k}=\frac{\sum_{j=1}^{n}\boldsymbol{q}_j}{\left\|\sum_{j=1}^{n}\boldsymbol{q}_j\right\|_2} \tag{5}$$

$$\boldsymbol{X}^{(0)}=[\boldsymbol{X}_{\text{word}};\boldsymbol{X}_{\text{char}}\boldsymbol{W}_{\text{char}}] \tag{6}$$

其中，$\boldsymbol{e}_{\text{word}}^{k}$是第 k 个实体名称中单词的集合，$\boldsymbol{e}_{\text{char}}^{k}$是第 k 个实体名称字符序列片段的集合，m 是一个实体名称中单词的数量，n 是一个实体名称字符串中的 token 的数量，$\boldsymbol{X}_{\text{word}}$是由$\boldsymbol{x}_{\text{word}}$组成的矩阵，$\boldsymbol{X}_{\text{char}}$是由$\boldsymbol{x}_{\text{char}}$组成的矩阵，$\boldsymbol{W}_{\text{char}}$是参数矩阵，$\boldsymbol{X}^{(0)}$是得出的第 0 层的实体表示。

4.2 语义信息传递模块

在本模型中，我们首先通过 GCN 进行实体信息的传递。为了控制噪声的传播，在不同层之间使用了 HighwayNetwork，同时为了防止训练过程中的过拟合，去掉了 GCN 公式中的参数矩阵 $\boldsymbol{W}$，计算公式如下所示：

$$\boldsymbol{X}^{(l')}=\text{ReLU}(\hat{\boldsymbol{D}}^{-\frac{1}{2}}\hat{\boldsymbol{A}}\hat{\boldsymbol{D}}^{-\frac{1}{2}}\boldsymbol{X}^{(l)}) \tag{7}$$

$$\boldsymbol{T}(\boldsymbol{X}^{(l)})=\sigma(\boldsymbol{X}^{(l)}\boldsymbol{W}^{(l)}+\boldsymbol{b}^{(l)}) \tag{8}$$

$$\boldsymbol{X}^{(l+1)}=\boldsymbol{T}(\boldsymbol{X}^{(l)})\cdot\boldsymbol{X}^{(l')}+(1-\boldsymbol{T}(\boldsymbol{X}^{(l)}))\cdot\boldsymbol{X}^{(l)} \tag{9}$$

其中，$\boldsymbol{X}^{(l)}$是实体在第 l 层的向量表示，$\hat{\boldsymbol{A}}$是加了自连接后的邻接矩阵，$\hat{\boldsymbol{D}}$是邻接矩阵$\hat{\boldsymbol{A}}$的度矩阵，$\boldsymbol{X}^{(l')}$是通过 GCN 后的向量表示，$\boldsymbol{W}^{(l)}$是第 l 层的权重矩阵，$\boldsymbol{b}^{(l)}$是第 l 层的偏置向量，$\boldsymbol{X}^{(l+1)}$是实体在第 $l+1$ 层的向量表示，ReLU(·)是 GCN 中使用的激活函数，$\sigma(\cdot)$是 sigmoid 函数，$\boldsymbol{T}(\boldsymbol{X}^{(l)})$是第 l 层 GCN 输出的实体向量的权重向量。

关系是知识图谱的一个重要组成部分，它揭示了实体间特殊的作用关系，因此在实体表示学习的过程中还需要增加对实体关联关系的学习。关系存在于实体之间，因而关系的表示可以通过关系所连接的头尾实体来表示。模型中首先使用实体注意力机制得出关系在头实体和尾实体作用下的关系表示，然后将两种向量表示相加得出关系的向量表示。

$$a_k^{ht}=\frac{\exp(\text{LeakyReLU}(\boldsymbol{\beta}_1^{\text{T}}[\boldsymbol{x}_h\boldsymbol{W}_h;\boldsymbol{x}_t\boldsymbol{W}_t]))}{\sum_{h'\in H}\sum_{t'\in T}\exp(\text{LeakyReLU}(\boldsymbol{\beta}_1^{\text{T}}[\boldsymbol{x}_{h'}\boldsymbol{W}_h;\boldsymbol{x}_{t'}\boldsymbol{W}_t]))} \tag{10}$$

$$\boldsymbol{r}_k^{h}=\text{ReLU}(\sum_{h\in H}\sum_{t\in T}a_k^{ht}\cdot\boldsymbol{x}_h\boldsymbol{W}_h) \tag{11}$$

$$\boldsymbol{r}_k=\boldsymbol{r}_k^{h}+\boldsymbol{r}_k^{t} \tag{12}$$

其中，$\boldsymbol{r}_k$是第 k 个关系的向量表示，$\boldsymbol{r}_k^{h}$是头实体作用下关系的表示，$\boldsymbol{r}_k^{t}$是尾实体作用下关系的表示，a_k^{ht}是不同实体的注意力系数，$\boldsymbol{H}$是关系连接的头实体的集合，$\boldsymbol{T}$是关系连接的尾实体的集合，$\boldsymbol{\beta}_1$是用于降维的向量，$\boldsymbol{W}_h$和$\boldsymbol{W}_t$是参数矩阵，$\boldsymbol{x}$是实体的向量表示，LeakyReLU(·)是激活函数。

为了弥补 GCN 的不足，本文模型在实体的表示中融入了关系的信息，考虑到不同方向上不同关系传递的信息的重要程度不同，我们引入了关系注意力机制，得出不同方向关系作用下的实体表示，然后将实体表示、入度关系作用下的实体表示以及出度关系作用下的实体表示进行拼接得到新的实体表示。

$$a_k^{e}=\frac{\exp(\text{LeakyReLU}(\boldsymbol{\beta}_2^{\text{T}}[\boldsymbol{x};\boldsymbol{r}_k]))}{\sum_{e\in T}\sum_{r\in R}\exp(\text{LeakyReLU}(\boldsymbol{\beta}_2^{\text{T}}[\boldsymbol{x};\boldsymbol{r}_k]))} \tag{13}$$

$$\boldsymbol{x}_{\text{in}}=\text{ReLU}(\sum_{e\in T}\sum_{k\in R}a_k^{e}\cdot\boldsymbol{r}_k) \tag{14}$$

$$\boldsymbol{x}_{\text{rel}}=[\boldsymbol{x}_{\text{gcn}};\boldsymbol{x}_{\text{in}};\boldsymbol{x}_{\text{out}}] \tag{15}$$

其中，$\boldsymbol{x}_{\text{rel}}$是融合了关系的信息的实体向量表示，$\boldsymbol{x}_{\text{gcn}}$是上一步得到的实体向量表示，$\boldsymbol{x}_{\text{in}}$是入度关系作用下的实体表示，$\boldsymbol{x}_{\text{out}}$是出度关系作用下的实体表示，$\boldsymbol{T}$是入度关系作用下的头实体的集合，$\boldsymbol{R}$是两个实体间关系的集合，$\boldsymbol{r}_k$是头实体和目标实体间的关系，$a_k^{e}$是关系的注意力系数，$\boldsymbol{\beta}_2$是用于降维的向量。

在以入度关系为基础的信息正向传播过程中，实体融入了邻域实体和关系的信息。为了进一步增强实体的信息，将有向图转换为无向图，使用注意力机制进行实体信息的再次传播，使得实体可以融入更多邻居的信息，从而扩大了信息感知的范围。

$$a_k=\frac{\exp(\text{LeakyReLU}(\boldsymbol{\beta}_3^{\text{T}}[\boldsymbol{x};\boldsymbol{x}_k]))}{\sum_{k\in\boldsymbol{H}}\exp(\text{LeakyReLU}(\boldsymbol{\beta}_3^{\text{T}}[\boldsymbol{x};\boldsymbol{x}_k]))} \tag{16}$$

$$\boldsymbol{x}_{\text{ehc}}=[\boldsymbol{x}_{\text{rel}};\text{ReLU}(\sum_{k\in\boldsymbol{H}}a_k\cdot\boldsymbol{x}_k)] \tag{17}$$

其中，$\boldsymbol{H}$是实体连接的头实体的集合，a_k是不同实体的注意力系数，$\boldsymbol{x}_k$是对应的头实体的向量表示，$\boldsymbol{\beta}_3$是用于降维的向量，$\boldsymbol{x}_{\text{ehc}}$是经过信息增强的实体向量表示。

4.3 预对齐调整模块

在得到实体的最终向量表示后，通常根据实体间距离的排序确定对齐的实体对，但是直接排序得到的结果往往是局部最优的，可能会产生多对一的实体对齐结果，因此需要对结果进行调整，使对齐结果达到全局最优。基于阈值对实体和关系进行预对齐，按照对齐的一致性原则，如果实体对应的邻居实体和关系都预对齐，那么这两个实体应该预对齐，因此实体之间的距离应该更小，在实体距离矩阵上对该实体对的距离进行调整，减去相应分值，具体公式如下所示：

$$d_{ij}^{e}=\|\boldsymbol{x}_i-\boldsymbol{x}_j\|_1-\theta_e\cdot\frac{|\mathcal{M}|}{|\mathcal{N}_i|+|\mathcal{N}_j|} \tag{18}$$

$$d_{ij}^{r}=\|\boldsymbol{r}_i-\boldsymbol{r}_j\|_1-\theta_r\cdot\frac{|\mathcal{P}|}{|\mathcal{S}_i|+|\mathcal{S}_j|} \tag{19}$$

其中，d_{ij}^{e}是经过计算得到的新的实体之间的距离值，d_{ij}^{r}是经过计算得到的新的关系之间的距离值；$\boldsymbol{x}_i$和$\boldsymbol{x}_j$表示不同的

实体向量，$\boldsymbol{r}_i$和$\boldsymbol{r}_j$表示不同的关系向量；$\mathcal{N}_i$是实体i的邻域实体关系集合，$\mathcal{N}_j$是实体j的邻域实体关系集合，$\mathcal{N}$是满足预对齐关系的实体关系集合；$\mathcal{S}_i$是关系i对应的实体集合，$\mathcal{S}_j$是关系j对应的实体集合，$\mathcal{S}$是满足预对齐关系的实体集合；θ_e和θ_r是两个超参数。

具体步骤如算法1所示。

算法1 预对齐调整算法

输入：实体表示$\mathbf{X}_e$，关系表示$\mathbf{X}_r$，迭代次数T，实体集合$\mathbf{E}_1$，关系集合$\mathbf{R}_1$，实体集合$\mathbf{E}_2$，关系集合$\mathbf{R}_2$，实体距离阈值λ_e，关系距离阈值λ_r

输出：实体对齐矩阵$\mathbf{S}_e$

1. 根据$\mathbf{X}_e$计算实体对齐矩阵$\mathbf{S}_e$
2. 根据$\mathbf{X}_r$计算关系对齐矩阵$\mathbf{S}_r$
3. 实体预对齐对$\mathbb{L}_e \leftarrow \emptyset$
4. 关系预对齐对$\mathbb{L}_r \leftarrow \emptyset$
5. for t$\leftarrow$ 1 to T do
6. for e_i in $\mathbf{E}_1$
7. $j=\mathrm{argmin}_j d_{ij}^e$
8. if $d_{ij}^e < \lambda_e$
9. $\mathbb{L}_e \leftarrow \mathbb{L}_e \cup (e_i, e_j)$
10. end if
11. end for
12. for r_i in R_1
13. $j=\mathrm{argmin}_j d_{ij}^r$
14. if $d_{ij}^r < \lambda_r$
15. $\mathbb{L}_r \leftarrow \mathbb{L}_r \cup (r_i, r_j)$
16. end if
17. end for
18. 根据实体预对齐对$\mathbb{L}_e$和关系预对齐对$\mathbb{L}_r$使用式(18)更新实体对齐矩阵$\mathbf{S}_e$
19. 根据实体预对齐对$\mathbb{L}_e$使用式(19)更新关系对齐矩阵S_r
20. end for

针对可能存在的一对多、多对一的问题，使用DAA延迟接受算法调整对齐矩阵，保证实体一对一的对齐，提高对齐的准确性。

4.4 损失函数

本模型中使用了负采样损失，如式(20)所示。实体对齐中为了保证实体对齐的准确性，会生成一定的负采样实体对促进实体的对齐。为了使负采样实体对更好地发挥作用，在对齐的种子周围找出最近的k个实体替代这个实体作为负实体对。如式(21)所示，本模型使用曼哈顿距离衡量实体之间的距离。

$$L=\sum_{(p,q)\in\mathbb{L}}\sum_{(p',q')\in\mathbb{L}'}\max\{0,d(p,q)-d(p',q')+\gamma\} \tag{20}$$

$$d(e_i,e_j)=\|\boldsymbol{x}'_{e_i}-\boldsymbol{x}'_{e_j}\|_1 \tag{21}$$

其中，e_i和e_j是两个不同的实体，$\boldsymbol{x}'_{e_i}$和$\boldsymbol{x}'_{e_j}$是实体的最终向量表示，γ是超参数，(p,q)是预对齐的正例种子对，$\mathbb{L}$是实体预对齐的种子对集合，(p',q')是负采样的负例种子对，$\mathbb{L}'$是通过负采样得到的实体对的集合。

5 实验结果以及分析

5.1 数据集

本实验使用了实体对齐研究中普遍使用的数据集DBP15K，如表1所列，此数据集是大规模数据集DBpedia的一个子集，其中包含ZH-EN(中-英)、JA-EN(日-英)、FR-EN(法-英)3个跨语言的知识图谱数据集。每个子集均包含两种不同语言的知识图谱，不同语言的知识图谱的实体和关系存在交集，在每个数据集中含有标注好的15000个对齐的实体对。

表1 DBP15K数据集的统计数据

Table 1 Statistical data of DBP15K

数据集		实体数量	关系类别	关系三元组
$\mathrm{DBP15K_{ZH\text{-}EN}}$	汉语	19388	1701	70414
	英语	19572	1323	95142
$\mathrm{DBP15K_{JA\text{-}EN}}$	日语	19814	1299	77214
	英语	19780	1153	93484
$\mathrm{DBP15K_{FR\text{-}EN}}$	法语	19661	903	105998
	英语	19993	1208	115722

5.2 基线模型

将本文提出的模型与以下9个不同的实体对齐模型进行实验对比。

BootEA：针对训练集有限导致的嵌入表示不够准确的问题，该模型使用一种迭代的策略标记训练数据，从而提高实体嵌入的准确性。

RDGCN：为了进一步捕获实体的邻域信息，该模型使用关系注意下的对偶图卷积网络感知复杂的关系信息，从而更好地学习实体的表示。

HGCN：该模型根据实体表示得出关系的表示，在实体表示中融入关系的信息，利用关系的信息促进实体对齐。

EMGCN：为了进一步促进实体对齐，该模型综合实体向量距离、属性和属性值的信息得出实体对齐矩阵，提高了实体对齐的准确性。

DGMC：使用双阶段的神经网络结构，通过监督或半监督的方式促进实体的对齐。

ERMC：该模型在DGMC的基础上增加了关系的学习，在实体表示中融入关系的信息以提高对齐的准确性。

RAGA：该方法使用了关系感知注意力模块，通过注意力机制学习关系的表示，再通过注意力机制将关系表示融入实体表示，使用DAA算法调整对齐的结果。

RNM：该方法使用基于阈值的对齐优化策略来优化实体对齐矩阵。

SEU：该方法使用实体名称向量和名称字符向量作为模型的输入，使用sinkhorn算法优化实体对齐矩阵$\boldsymbol{S}$。

5.3 评价指标

本文选择了3种常用的实体对齐的评价指标：Hits@1，Hits@10以及MRR。Hits@k表示对于所有目标实体，与其所对应的前k个备选实体中存在正确对齐实体的有效实体对所占比例。MRR为匹配到正确实体的排名的倒数的平均值，计算式如下：

$$MRR=\frac{1}{|N|}\sum_{i=1}^{|N|}\frac{1}{rank_i} \tag{22}$$

其中，$rank_i$表示对齐到正确的实体的排名，N为对齐实体对的数量。

5.4 实验设置

本文实验中使用30%的预对齐的实体对作为训练集，剩余的70%的实体对作为测试集。Highway GCN的层数为2，

使用 50 个 epoch 进行训练，优化迭代次数为 3。

5.5　实验结果

本文在表 1 所列的公开数据集 DBP15K 中进行实验测试，验证所提模型的有效性。

5.5.1　对比实验

本文提出的模型 MOGNN 和基线模型的对比结果如表 2 所列，每列中最好的结果加粗标注。BootEA，RDGCN，HGCN，EMGCN，DGMC 和 ERMC 的各项指标均来自原论文中的实验结果，RAGA，RNM 和 SEU 是经过复现模型进行实验得出的结果。RAGA 和 RNM 没有充分挖掘实体名称的信息；RAGA 对于对齐结果只使用了 DAA 算法，没有充分利用已有的对齐结果；SEU 没有充分利用实体的关系传递信息，只是通过迭代策略优化对齐的结果。本模型针对以上问题进行了优化，由结果可以看出，所提模型的 Hits@1 结果优于上述所有基线模型。Hits@10 和 MRR 在 ZH-EN 数据集中效果最佳，均优于其他基线模型；在 JA-EN 和 FR-EN 中虽然没有达到最优效果，但是实际测试结果仅次于 SEU[31] 中的实验结果，仍然领先于其他模型。

表 2　不同模型的实体对齐结果对比

Table 2　Comparison of entity alignment results of different models

Model	ZH-EN			JA-EN			FR-EN		
	Hits@1/%	*Hits*@10/%	*MRR*	*Hits*@1/%	*Hits*@10/%	*MRR*	*Hits*@1/%	*Hits*@10/%	*MRR*
BootEA	62.94	84.75	0.703	62.23	85.39	0.701	65.30	87.44	0.731
RDGCN	70.75	84.55	—	76.74	89.54	—	88.64	95.72	—
HGCN	72.03	85.70	—	76.62	89.73	—	89.16	96.11	—
EMGCN	86.25	94.62	—	86.63	95.19	—	93.95	98.89	—
DGMC	80.12	87.47	—	84.80	89.74	—	93.34	96.03	—
ERMC	90.31	94.60	0.899	94.17	96.44	0.925	96.18	98.23	0.973
RAGA	87.05	—	—	90.97	—	—	96.53	—	—
RNM	84.75	92.07	0.875	86.45	94.16	0.894	93.69	97.92	0.953
SEU	89.98	**96.40**	0.923	95.82	**98.85**	**0.970**	98.80	**99.86**	**0.993**
MOGNN	**94.45**	**96.40**	**0.924**	**96.64**	97.96	0.949	**99.26**	99.42	0.982

5.5.2　消融实验

为了进一步验证模型中不同模块的有效性，通过消融实验进行对比分析。在模型的输入中融合了两种不同的信息，分别是实体名称的单词表示信息以及实体名称的字符信息。为了验证这两种不同的信息对模型最终对齐结果的影响，分别将语言模型下的实体名称单词向量表示以及实体名称的字符向量表示输入到模型中，得出不同输入下的 Hits@1，Hits@10 和 MRR 的值，如图 2 所示。

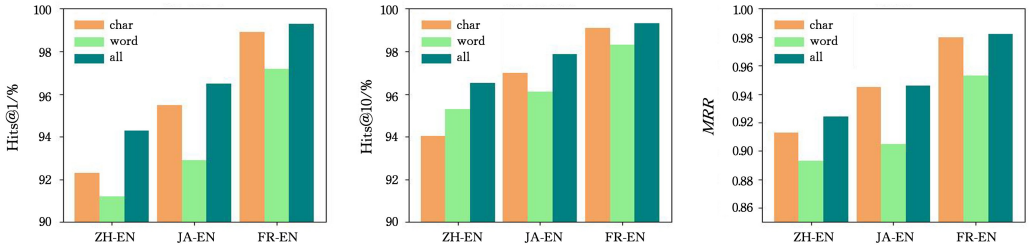

注：all 代表融合输入，word 代表单词向量输入，char 代表字符向量输入

(a) Hits@1　(b) Hits@10　(c) MRR

图 2　不同的模型输入下的实体对齐性能对比

Fig. 2　Comparison of results with different model inputs

从结果可以看出，使用融合的输入(all)模型的 Hits@1，Hits@10 和 MRR 均高于单独使用语言模型下的实体单词向量表示(word)以及实体名称的字符向量(char)表示，同时也验证了使用融合信息作为输入的有效性，进一步提高了模型的对齐结果。

在得出实体的向量表示后，计算不同实体之间的距离，按照距离进行排序就可以得出可能对齐的实体对的排序。由于直接使用排序的结果作为最终对齐的结果可能导致错误，因此需要利用实体和关系进行预对齐，调整不同实体之间的距离，通过 DAA 算法对多对一的结果进行再次调整。为了验证这两种方法的有效性，在 DBP15K 的 3 个不同的数据集中测试实体对齐的 Hits@1 指标。

图 3 中第一种变型(none)是在得出实体的向量表示后，计算不同实体之间距离，按照距离进行排序直接得出实体对的对齐结果，此时的效果最差；在使用预对齐对(iter)进行对齐调整之后，模型的 Hits@1 值均高于 none 的值；当单独使用 DAA 算法时，模型的 Hits@1 优于前两种方法；当使用了两种优化策略后，模型效果最佳，验证了优化算法的有效性。

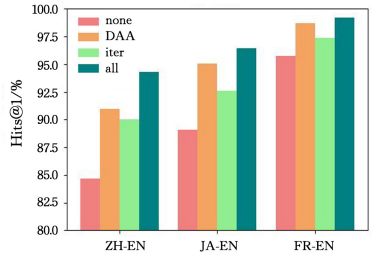

图 3　不同优化方法的 Hits@1 实验结果对比

Fig. 3　Hits@1 comparison of different optimization methods

为了进一步验证模型的有效性，分别使用 10%，20%，30%和 40%的预对齐种子对作为训练集进行训练，如图 4

所示。可以看出，模型具有较强的稳定性。使用 10%的种子对作为训练集仍表现出较好的效果，随着训练集不断扩大，模型的效果也在不断提升。

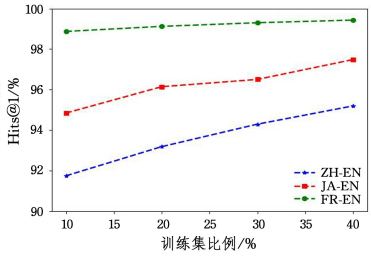

图 4 不同比例训练集的对比

Fig. 4 Comparison of training sets with different proportions

本文提出的模型经过有效的信息挖掘和传递后，实体的信息得到了有效提取，得到的实体向量表示更有利于实体的对齐，模型准确对齐的概率得到了有效的提高，尤其是 Hits@1 指标。但随着模型的复杂化，原有的实体表示中存在的噪声信息不可避免地有了进一步传播，从而影响了对齐的整体效果。而 SEU 中仅仅通过简单的传播策略，然后使用迭代优化方法就避免了噪声信息的传播，使得模型在 Hits@10 中的效果更加突出，这也是本文模型的不足之处。随着模型复杂度的提升以及对齐策略的细化，在提高对齐准确率的同时使模型的运行速度变慢，在之后的研究中将探究更加高效的实体对齐方法。

结束语 针对现有的实体对齐模型对实体名称信息、关系信息以及实体和关系中可能的对齐信息使用不充分的问题，本文提出了一种更加完备的基于图神经网络的多信息优化实体对齐模型。在模型输入中充分挖掘实体名称的信息，促进有效信息的提取；通过关系注意力模块进行关系的学习，在实体中融入关系的信息充分传递图中实体连接的信息；在得出实体对齐矩阵后，利用已知信息进一步促进实体的对齐，提高了实体对齐的准确性。本文模型的 Hits@1 指标均高于其他基线模型，获得了更好的对齐效果；模型的 Hits@10 和 MRR 指标优于大多数基线模型，但还没有超越 SEU 中的结果，在之后的研究中将会探索更加有效的实体对齐模型，充分挖掘图中隐含的多跳邻居的信息，进一步促进实体的对齐，同时还将探索实体属性在实体对齐中的作用。

参 考 文 献

[1] WANG H W, ZHANG F Z, ZHAO M, et al. Multi-task feature learning for knowledge graph enhanced recommendation[C]// Proceedings of the World Wide Web Conference. New York: ACM, 2019: 2000-2010.

[2] CAO Y X, WANG X, HE X G, et al. Unifying knowledge graph learning and recommendation: Towards a better understanding of user preferences[C]// Proceedings of the World Wide Web Conference. New York: ACM, 2019: 151-161.

[3] SHEN J, QIAO S J, HAN N, et al. Personalized Recommendation Model with Multiple Information Fusion[J]. Journal of Chongqing University of Technology (Natural Science), 2021, 35(3): 128-138.

[4] LIU J H, LIN Y K, LIU Z Y, et al. XQA: A Cross-lingual Open-domain Question Answering Dataset[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 2358-2368.

[5] CHEN X J, XIANG Y. Construction and Application of Enterprise Risk Knowledge Graph [J]. Computer Science, 2020, 47(11): 237-243.

[6] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating Embeddings for Modeling Multi-relational Data[C]// Proceedings of Neural Information Processing Systems 26. New York: Curran Associates Inc, 2013: 2799-2807.

[7] WANG Z C, LV Q S, LAN X H, et al. Cross-lingual knowledge graph alignment via graph convolutional networks[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Tokyo: IEICE, 2018: 349-357.

[8] ROTH A E. Deferred acceptance algorithms: History, theory, practice, and open questions[J]. International Journal of Game Theory, 2008, 36(3/4): 537-569.

[9] 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.

[10] JIMENEZ R E, CUENCA G B. Logmap: ogic-based and scalable ontology matching[C]// Proceedings of International Semantic Web Conference. Berlin: Springer, 2011: 273-288.

[11] LEI J P, OUYANG D T, ZHANG L M. Relation domain and range completion method based on knowledge graph embedding [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(1): 154-161.

[12] WANG W J, YU Y F. Automatic completion algorithm for missing links in knowledge graph considering data sparsity[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(6): 1428-1433.

[13] WANG S Y, LI X, LI R, et al. Knowledge Fusion Method of High Speed Train Based on Knowledge Graph[J/OL]. (2022-07-11) [2022-09-14]. https://kns.cnki.net/kcms/detail/51.1277.U.20220711.1502.002.html.

[14] CHEN M H, TIAN Y T, YANG M H, et al. Multilingual Knowledge Graph Embeddings for Cross-lingual Knowledge Alignment[C]// Proceedings of International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 1511-1517.

[15] ZHU H, XIE R B, LIU Z Y, et al. Iterative Entity Alignment via Joint Knowledge Embeddings[C]// Proceedings of International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 4258-4264.

[16] LIN Y K, LIU Z Y, LUAN H B, et al. Modeling Relation Paths for Representation Learning of Knowledge Bases[C]// Proceedings of the 2014 Conference on Empirical Methods on Natural Language Processing. Tokyo: IEICE, 2015: 705-714.

[17] SUN Z Q, HU W, ZHANG Q H, et al. Bootstrapping Entity Alignment with Knowledge Graph Embedding[C]// Proceedings of International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018: 4396-4402.

[18] LI C J, CAO Y X, HOU L, et al. Semi-supervised entity align-

ment via joint knowledge embedding model and cross-graph model[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2019: 2723-2732.

[19] CAO Y X, LIU Z Y, LI C J, et al. Multi-channel graph neural network for entity alignment[C]// Proceedings of the 57th Conference of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 1452-1461.

[20] ZHU Q N, ZHOU X F, WU J, et al. Neighborhood-Aware Attentional Representation for Multilingual Knowledge Graphs [C]// Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2019: 1943-1949.

[21] SUN Z Q, WANG C M., HU W, et al. Knowledge graph alignment network with gated multi-hop neighborhood aggregation [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020, 34(1): 222-229.

[22] WU Y T, LIU X, FENG Y S, et al. Jointly learning entity and relation representations for entity alignment[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2019: 240-249.

[23] WU Y T, LIU X, FENG Y S, et al. Relation-Aware Entity Alignment for Heterogeneous Knowledge Graphs[C]// Proceedings of Twenty-Eighth International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2019: 5278-5284.

[24] ZHU Y, LIU H Z, WU Z H, et al. Relation-Aware Neighborhood Matching Model for Entity Alignment[C]// Proceedings of Database Systems for Advanced Applications — 25th International Conference. Berlin: Springer, 2021: 432-447.

[25] GUO L B, SUN Z Q, HU W. Learning to exploit long-term relational dependencies in knowledge graphs[C]// Proceedings of the 36th International Conference on Machine Learning[C]// Proceedings of the 36th International Conference on Machine Learning. New York: PMLR, 2019: 2505-2514.

[26] CHEN J, LI Z X, ZHAO P P, et al. Learning Short-Term Differences and Long-Term Dependencies for Entity Alignment[C]// Proceedings of the International Semantic Web Conference. Berlin: Springer, 2020: 92-109.

[27] XU K, WANG L W, YU M, et al. Cross-lingual knowledge graph alignment via graph matching neural network[C]// Proceedings of the 57th Conference of the Association for Computational Linguistics. Stroudsburg: ACL, 2019: 3156-3161.

[28] ZENG W X, ZHAO X, WANG W, et al. Degree-aware alignment for entities in tail[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 811-820.

[29] FEY M, LENSSEN J E, MORRIS C, et al. Deep graph matching consensus[C]// Proceedings of the 8th International Conference on Learning Representations. 2020: 26-30.

[30] SUN Z Q, HU W, LI C K. Cross-lingual entity alignment via joint attribute-preserving embedding[C]// Proceedings of the International Semantic Web Conference. Berlin: Springer, 2017: 628-644.

[31] NGUYEN T T, HUYNH T T, YIN H Z, et al. Entity Alignment for Knowledge Graphs with Multi-order Convolutional Networks[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(9), 4201-4214

[32] ZENG W X, ZHAO X, TANG J Y, et al. Iterative Entity Alignment via Re-Ranking [J]. Journal of Computer Research and Development, 2020, 57(7): 1460-1471.

[33] SU J L, WANG Y Z, JIN X L, et al. Entity alignment method based on adaptive attribute selection[J]. Journal of Shandong University(Engineering Science), 2020, 50(1): 14-20.

[34] MAO X, WANG W T, WU Y B, et al. From Alignment to Assignment: Frustratingly Simple Unsupervised Entity Alignment [C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2021: 2843-2853.

[35] YANG J Z, WAGN D, ZHOU W, et al. Entity and Relation Matching Consensus for Entity Alignment[C]// Proceedings of the 30th ACM International Conference on Information and Knowledge Management. New York: ACM, 2021: 2331-2341.

[36] SINKHORN R. A relationship between arbitrary positive matrices and doubly stochastic matrices[J]. The Annals of Mathematical Statistics, 1964, 35(2): 876-897.

[37] ZHU R B, MA M, WANG P. RAGA: Relation-Aware Graph Attention Networks for Global Entity Alignment[C]// Proceedings of Pacific-Asia Conference on Knowledge Discovery and Data Mining. Berlin: Springer, 2021: 501-513.

[38] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014: 1532-1543.

CHEN Fuqiang, born in 1998, postgraduate. His main research interests include data mining, knowledge graph and machine learning.

LI Ke, born in 1972, Ph. D, professor, master supervisor, is a senior member of China Computer Federation. His main research interests include AIOps, machine learning and knowledge graph.

（责任编辑：何杨）