

基于动态图注意力聚合多跳邻域的实体对齐*

汪浣沙^{1,2}, 黄瑞阳^{1,2}, 宋旭晖³, 余诗媛³, 胡楠³

(1.国家数字交换系统工程技术研究中心,河南 郑州 450002;

2.中国人民解放军战略支援部队信息工程大学,河南 郑州 450002;3.郑州大学 软件学院,河南 郑州 450001)

摘要:实体对齐是实现对不同来源知识库进行融合的重要技术方法,在知识图谱、知识补全领域具有广泛应用。现有基于图注意力的实体对齐模型多使用静态图注意力网络且忽略了实体属性中的语义信息,导致模型存在有限注意、难以拟合、表达能力不足等问题。针对这些问题,开展基于动态图注意力结构建模实体对齐方法研究,首先使用图卷积层建模目标实体的单跳节点表示,其次应用动态图注意力网络获得多跳节点注意力系数并建模,再次利用逐层门控网络聚合图卷积层与动态图注意力层输出的单跳、多跳节点信息,最后拼接通过外部知识预训练自然语言模型提取的实体名称属性嵌入并进行相似度计算。该方法在 DBP15K 的三类跨语言数据集中都获得了一定的提高,证明了应用动态图注意力网络与融入实体属性语义在提高实体表示能力上的有效性。

关键词:动态图注意力;图卷积网络;实体对齐;知识图谱;表示学习

中图分类号: TP393

文献标识码: A

DOI:10.16157/j.issn.0258-7998.222717

中文引用格式: 汪浣沙,黄瑞阳,宋旭晖,等. 基于动态图注意力聚合多跳邻域的实体对齐[J].电子技术应用,2022,48(11):51-56.

英文引用格式: Wang Huansha, Huang Ruiyang, Song Xuhui, et al. Entity alignment based on dynamic graph attention aggregation in multi-hop neighborhood[J]. Application of Electronic Technique, 2022, 48(11): 51-56.

Entity alignment based on dynamic graph attention aggregation in multi-hop neighborhood

Wang Huansha^{1,2}, Huang Ruiyang^{1,2}, Song Xuhui³, Yu Shiyuan³, Hu Nan³

(1. National Digital Switching System Engineering & Technological R&D Center, Zhengzhou 450002, China;

2. Information Engineering University, Zhengzhou 450002, China; 3. Software College, Zhengzhou University, Zhengzhou 450001, China)

Abstract: Entity alignment is an important technical method to realize the fusion of knowledge bases from different sources. It is widely used in the fields of knowledge graph and knowledge completion. The existing entity alignment models based on graph attention mostly use static graph attention network and ignore the semantic information in entity attributes, resulting in the problems of limited attention, difficult fitting and insufficient expression ability of the model. To solve these problems, this paper studies the entity alignment method based on the structure modeling of dynamic graph attention. Firstly, the single hop node representation of the target entity is modeled by GCN. Secondly, the multi hop node attention coefficient is obtained and entity modeled by using the dynamic graph attention network, and then the single hop and multi hop node information output by GCN and dynamic graph attention layer is aggregated by layer-wise gating network. Finally, the entity attribute semantic extracted by external knowledge pre training natural language model is embedded and concatenated to calculate similarity. This method has been improved in three types of cross language datasets of DBP15K, which proves the effectiveness of applying dynamic graph attention network and integrating entity attribute semantics in improving entity representation ability.

Key words: dynamic GAT; graph convolution network; entity alignment; knowledge graph; representation learning

0 引言

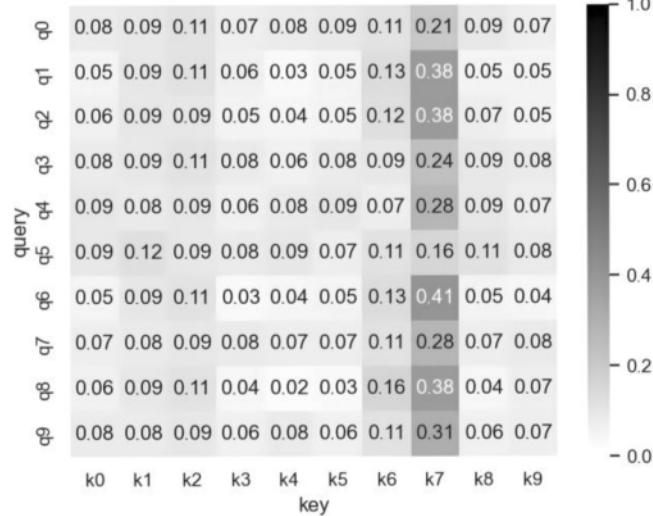
实体对齐任务指利用模型或算法判断多个不同表示的实体是否指代现实世界中的同一对象,随着知识图谱因其结构性表示知识等优势而在各大自然语言处理与计

算机视觉领域任务中广泛应用,实体对齐作为知识图谱补全任务的重要组成部分受到越来越多研究者的关注。

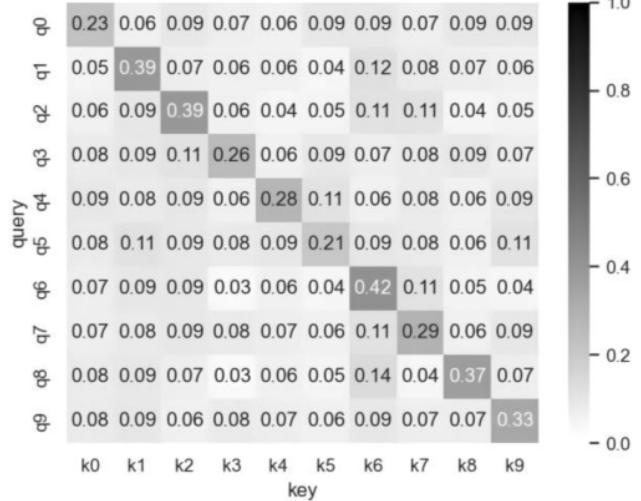
现有实体对齐方法主要分为基于转移距离模型与基于图卷积网络模型,即利用转移距离模型或图卷积网络将多源实体表示为低维向量并计算相似性以找到对齐实体对。目前主流的基于图卷积网络的实体对齐模型

* 基金项目:国家自然科学基金项目(62002384);中国博士后科学基金面上项目(2020M683760)

常使用传统的静态图注意力网络对实体进行特征提取与语义建模,但静态图注意力网络注意力函数存在单调性,即对于任意查询节点 i ,图注意力网络都倾向给予同一节点 j 更高的注意力权重,这将会严重影响网络的特征提取能力。而文献[1]所提出的动态图注意力网络中每个查询(Query)对键(Key)的注意系数都有不同的排序,因此具有更强的表示能力。图1展示了静态与动态图注意力网络注意力倾向示意。



(a) 静态图注意力网络注意力可视化示意图



(b) 动态图注意力网络注意力可视化示意图

图1 静态、动态图注意力网络注意力倾向对比

针对该问题,本文提出了一种基于动态图注意力聚合多跳邻域的实体对齐方法,基于AliNet架构,方法首先使用图卷积层建模目标实体的单跳节点表示,其次应用动态图注意力网络获得多跳节点注意力系数并建模,再次利用逐层门控网络聚合图卷积层与动态图注意力层输出的单跳、多跳节点信息,最后拼接通过外部知识预训练自然语言模型提取的实体名称属性嵌入并进行相似度计算。

本文的主要贡献如下:

(1)基于AliNet模型架构,应用动态图注意力网络于实体对齐任务中,使模型获得了更强表示能力的同时提高了模型的鲁棒性;

(2)模型使用逐层门控网络改进AliNet模型中所使用的门控机制,使其更为全面合理地聚合节点的单多跳特征;

(3)利用经外部知识预训练的类BERT模型翻译提取实体名称属性语义嵌入,并与结构嵌入进行拼接,以寻求目标实体的更优表示;

(4)通过实验验证了应用动态图注意力网络、翻译、提取、拼接实体名称属性语义嵌入的有效性。

1 相关工作

早期开源知识图谱主要利用众包手工标注或基于实体符号特征的相似度计算机制进行实体对齐,该机制效率低下、泛化能力差。随着表示学习展现出其对语义特征的优秀建模能力,部分研究者尝试应用知识图谱表示学习技术于实体对齐任务中,其核心思想是通过算法在低维向量空间寻求实体与关系的低维向量表示,并对该向量进行相似度计算从而获得潜在的对齐实体对。

基于表示学习的实体对齐技术按照知识图谱表示学习机制可分为基于转移距离与基于图卷积模型两种。基于转移距离模型的核心思想是将实体与关系映射到同一向量空间后将关系视为低维向量空间中头尾实体向量的平移,如TransE^[2]、TransH^[3]、TransR^[4]、RotatE^[5]、HAKE^[6]等模型。随着图卷积网络的不断发展,部分研究者尝试利用图卷积网络在学习图结构节点、边表示上的优势,从而更好地学习知识图谱的实体、关系嵌入,进而提高实体对齐的准确率与效率,如GCN-Align^[7]、GMNN^[8]、MuGNN^[9]、NAEA^[10]、HMAN^[11]等模型。实体属性作为实体的重要组成,在早期实体对齐任务中大多仅视为属性三元组以优化通过关系三元组所训练获得的实体特征。而利用文本预训练模型可较好地获取文本深层语义信息,因此基于对齐实体属性语义相似性以优化知识图谱表示学习嵌入已成为重要的研究方向。

为了克服静态图注意力网络的局限性并利用实体属性语义信息,本文提出了一种基于动态图注意力聚合多跳邻域的实体对齐模型(Entity Alignment Based on Dynamic Graph Attention Aggregation in Multi-hop Neighborhood, DGAT-EA)。该模型受AliNet^[12]的模型架构启发,首先使用图卷积层建模目标实体的单跳节点表示,其次应用动态图注意力网络获得多跳节点注意力系数并建模,再次利用逐层门控网络聚合图卷积层与动态图注意力层输出的单跳、多跳节点信息,最后拼接通过外部知识预训练自然语言模型提取的实体名称属性嵌入并进行相似度计算。经在DBP15K中的3个大规模跨语言数据集上评估,该模型与使用静态图注意力模型相比获得了一定

的提升,证明了应用动态图注意力及融入实体语义信息对实体对齐任务的积极效果。

2 基于动态图注意力聚合多跳邻域的实体对齐模型

本文受 AliNet 模型以端到端的方式缓解对应实体邻域结构的非同构问题的启发,提出了一种基于动态图注意力聚合多跳邻域的实体对齐模型 DGAT-EA, 模型架构主要分为图卷积层、动态图注意力层与属性嵌入层。图卷积层负责聚合表示实体单跳节点特征, 动态图注意力层则利用动态图注意力机制获取多跳邻域的注意力系数并聚合实体的多跳节点特征表示, 属性嵌入层利用预训练模型获取实体属性嵌入, 最后利用逐层门控网络对单跳与多跳信息进行聚合并拼接实体属性嵌入以获得最终的实体表示, 其训练过程如图 2 所示。

2.1 图卷积层

模型的图卷积层负责对输入的节点特征及其单跳邻域特征向量进行递归聚合从而学习该节点的单跳特征表示。其核心思想是通过对于每个实体迭代增加其邻域节点的特征信息以提高实体特征的表示能力。

基于该思想, 在本模型中实体在图卷积第 l 层的隐含特征表示可以表示为^[13]:

$$h_i^l = \sigma \left(\sum_{j \in N_i \cup \{i\}} \frac{1}{c_i} W^l h_j^{l-1} \right) \quad (1)$$

式中, N_i 指代实体 i 的一跳邻域节点集, c_i 为归一化常数, 本模型图卷积层中不使用激活函数。

2.2 动态图注意力层

模型的动态图注意力层负责计算目标实体的两跳

邻域节点的注意力权重, 以突出有用的多跳邻居节点, 并对其特征进行聚合, 从而更好地表征目标实体特征。

传统图注意力网络的输入为节点特征矩阵 $\mathbf{h} = \{\vec{h}_1, \vec{h}_2, \dots, \vec{h}_N\}, \vec{h}_i \in R^F$, 其中 N 为节点的个数, F 为特征的维度, 并输出经过特征提取与注意力系数计算的新节点特征矩阵 $\mathbf{h}' = \{\vec{h}_1', \vec{h}_2', \dots, \vec{h}_N'\}, \vec{h}_i' \in R^F$ 。节点 i, j 间注意力机制的计算公式如下:

$$e_{ij} = \text{LeakyReLU}(\vec{a}^T [\mathbf{W} \vec{h}_i || \mathbf{W} \vec{h}_j]) \quad (2)$$

$$\alpha_{ij} = \text{softmax}(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})} \quad (3)$$

式中, \mathbf{W} 为共享权重矩阵, \vec{a} 为单层前馈神经网络, $||$ 表示矩阵拼接操作。

通过对所有邻居节点进行加权求和便可得节点经过图注意力网络后得到的输出特征:

$$\vec{h}_i' = \sigma \left(\sum_{j \in N_i} \alpha_{ij} \mathbf{W} \vec{h}_j \right) \quad (4)$$

式中, σ 为激活函数。

对于实体对齐任务, 传统图注意力网络的局限性主要体现在共享权重矩阵与静态性两方面。

在实体对齐任务中, 知识图谱中的实体节点与其邻接节点通常具有较大差异, 因此若应用共享的权重矩阵 \mathbf{W} 将导致模型难以正确区分实体节点与邻接节点, 从而降低模型的表示能力。为了解决该问题, 模型使用两个

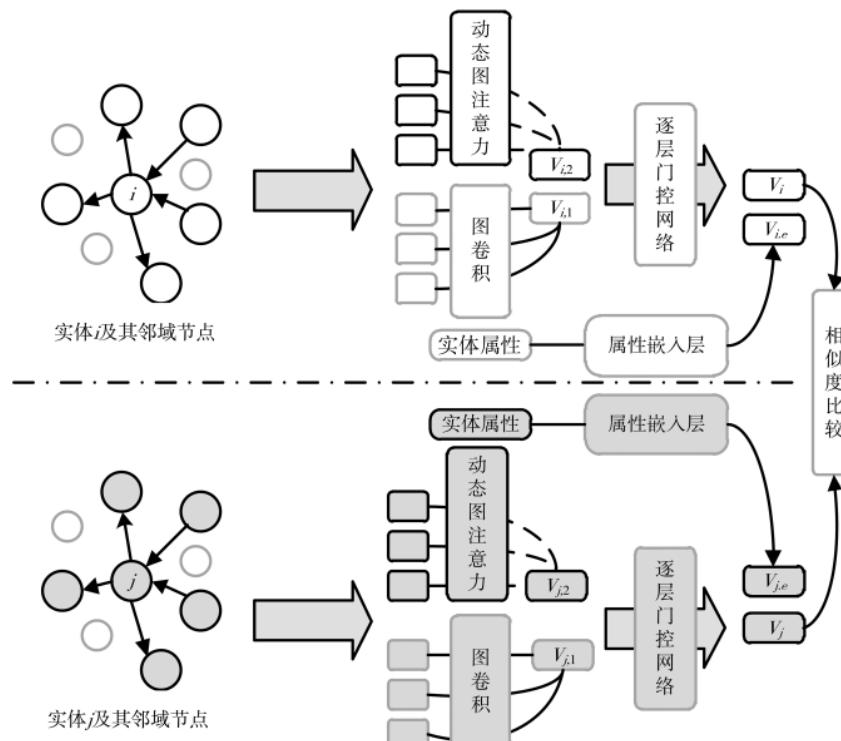


图 2 基于动态图注意力聚合多跳邻域的实体对齐模型架构及训练流程

不同的矩阵 W_1, W_2 分别对实体节点与邻接节点进行线性变换, 其修改后的注意力系数计算公式如下:

$$e_{ij} = \text{LeakyReLU}([\vec{W_1} \vec{h}_i || \vec{W_2} \vec{h}_j]) \quad (5)$$

而传统图注意力网络的静态性则体现为给定一组节点和一个训练过的图注意力层, 对于任意查询节点 i , 注意函数 α 都有相同最大倾向节点 j 。由邻接节点与实体关系的有限性以及 softmax 函数与 LeakyReLU 函数的单调性可知, 针对任意节点 i 都存在节点 j 使得 $\vec{a}^T [\vec{W} \vec{h}_j]$ 最大化, 以至于静态图注意力网络总是倾向于赋予节点 j 最大的注意力系数而忽视不同输入节点 i 与节点 j 的不同关系。因此静态图注意力对于实体对齐任务中不同查询输入 i 与不同节点 j 具有不同相关性的情况, 难以较好建模。

为了解决传统图注意力网络由于其静态性所导致的表示能力不足等问题, 本文尝试将文献[1]所提出的动态图注意力模型应用于实体对齐任务中。动态图注意力网络在注意力机制计算时先对拼接后的多跳节点特征应用非线性函数 LeakyReLU 再输入前馈神经网络 \vec{a}^T , 其表达式如下所示:

$$e_{ij} = \vec{a}^T \text{LeakyReLU}([\vec{W_1} \vec{h}_i || \vec{W_2} \vec{h}_j]) \quad (6)$$

动态图注意力网络避免了连续使用可学习矩阵 \vec{a} 与 W , 从而防止前馈神经网络与权重矩阵退化为单个线性层, 在获得了更强表示能力的同时提高了模型的鲁棒性。对于节点间关系更为复杂、不同邻域节点排名需求不同的实体对齐任务, 动态图注意力网络可以显著优化节点间权重关系的获取, 从而提高实体对齐效果。

综上, 模型的动态图注意力层通过对目标节点与邻接节点使用不同权重矩阵增强了图注意力网络对于节点的辨别能力, 并应用更适合实体对齐任务的动态图注意力机制, 增强了传统图注意力机制的特征提取能力, 因此能够更好地获得目标节点的多跳特征聚合。

2.3 逐层门控网络

逐层门控网络负责对图卷积层输出的单跳节点特征与动态图注意力层输出的多跳节点特征进行聚合从而获得目标实体更为全面的特征表示。AliNet 中的门控机制函数可以表示为:

$$g(h_{i,2}^l) = \text{ReLU}(\text{dropout}(\tanh(Mh_{i,2}^l))) \quad (7)$$

式中, M 为门控网络权重矩阵, 实际训练时 dropout 率为 0, g 为门控机制函数, $h_{i,2}^l$ 表示动态图注意力层的输出。

为了更为全面合理地聚合节点的单多跳特征, 同时为了增强门控网络的拟合能力以及提高网络在多跳节点小范围变化时的敏感性, 模型改进 AliNet 模型中所使用的门控机制。逐层门控机制函数如下所示:

$$g(h_{i,1}^l, h_{i,2}^l) = \tanh(M_1 h_{i,1}^l + M_2 h_{i,2}^l + b) \quad (8)$$

式中, $h_{i,1}^l$ 为图卷积层的输出, b 为偏移矩阵。

逐层门控网络使用两个不同的权重矩阵分别获取节点的单跳与多跳信息, 全面聚合节点特征, 且增加了偏移矩阵 b 以增强门控网络的表征能力。增加非线性因素时使用 tanh 函数代替 ReLU 函数以提高输出对节点特征变化的敏感性, 且扩展值域以更灵活地平衡单多跳特征的不同权重, 其最终节点特征如下所示:

$$h_i^l = \tanh(g(h_{i,1}^l, h_{i,2}^l)h_{i,1}^l + (1-g(h_{i,1}^l, h_{i,2}^l))h_{i,2}^l) \quad (9)$$

2.4 属性嵌入层

模型的属性嵌入层负责将实体的属性信息转化为相应的语义嵌入, 并与经门控网络聚合而得的结构特征进行拼接, 进而进行相似度计算。本模型基于 huggingface^[14] 库中的 bert-base-multilingual-cased、opus-mt-zh-en、opus-mt-ja-en 模型分别处理来自 DBP15K 的 3 个跨语言数据集中的实体名称属性, 并利用模型输出的 pooler_output 获取属性嵌入并进行拼接。

3 实验

3.1 实验数据集

本文实验使用来自 DBP15K^[15] 的 3 个大规模跨语言数据集, 此数据集基于中文、英语、日语和法语的 DBpedia 建立, 表 1 给出了数据集的统计数据。

表 1 DBP15K 数据集具体数据统计

数据集	语种	实体数	关系数	三元组数
DBP15KZH-EN	汉语	66 469	2 830	153 929
	英语	98 125	2 317	237 674
DBP15KJA-EN	日语	65 744	2 043	164 373
	英语	95 680	2 096	233 319
DBP15KFR-EN	法语	66 858	1 379	192 191
	英语	105 889	2 209	278 590

3.2 实验配置

本文基于 TensorFlow 深度学习框架进行实验研究, 深度学习平台为 TensorFlow2.0, 编译环境为 Python3.7.11, 操作系统为 Ubuntu18.04。实验硬件配置: CPU 为 Intel® Xeon® Gold 6132 2.60 GHz, 内存为 256 GB, GPU 为 Nvidia Geforce 3090 24 GB。

3.3 评测指标

本文实验采用在实体对齐任务中常用的 Hits@ n 、平均倒数排序 (Mean Reciprocal Rank, MRR)、平均秩 (Mean Rank, MR) 来客观评价各模型的实体对齐准确率。Hits@ n 、MRR 越大, MR 越小表示模型性能越好。其计算公式分别为:

$$\text{Hits}@n = \frac{1}{|S|} \sum_{i=1}^{|S|} \mathbb{I}(\text{rank}_i \leq n) \quad (10)$$

$$\text{MRR} = \frac{1}{|S|} \sum_{i=1}^{|S|} \frac{1}{\text{rank}_i} \quad (11)$$

$$\text{MR} = \frac{1}{|S|} \sum_{i=1}^{|S|} \text{rank}_i \quad (12)$$

式中, S 为总三元组集合, rank_i 为第 i 个三元组的实体对齐预测排名, $\mathbb{I}(x)$ 表示 Indicator 函数。

3.4 实验结果与分析

3.4.1 DGAT-EA 有效性分析

为了验证在实体对齐模型中融合实体属性语义信息、应用动态图注意力网络以及改良逐层门控网络的有效性, 本文对 DGAT-EA 与相似架构的 AliNet 模型在相同实验配置与环境下进行了对比实验, 并与其他实体对齐模型在 DBP15K 数据集上的对齐结果进行比较。实验结果如表 2 所示, 其中最好结果加黑标注。

从表 2 可得, 在 DBP15K 的 3 个大规模跨语言数据集上 DGAT-EA 模型与相似架构的 AliNet 模型相比, 各指标都获得了一定的提升, 证明了融合实体属性语义信息、应用动态图注意力机制与逐层门控机制对提高实体对齐任务效果的积极作用。

3.4.2 消融实验

为了验证不同数据集效果优劣原因及各模型改进对效果的具体提升, 本文将仅应用动态图注意力的模型、仅改用逐层门控网络的模型、未添加实体语义信息的模型与原模型作比较, 结果如表 3 所示, 最好结果加黑表示, 次好结果下划线表示。

如表 3 所示, 模型添加语义信息、应用动态图注意力网络或逐层门控机制后, 各指标相比相似架构模型 AliNet 均获得了一定的提高, 充分地证明了添加实体属性语义信息、动态图注意力机制及逐层门控机制聚合单多跳节点特征对于实体对齐任务的有效性。

在添加实体属性语义信息后, 模型在 DBP15KFR-EN 数据集上收获了较高的指标提升, 实体对齐受属性语义信息提升程度与特征提取模型的语义理解能力有较高相关性, 因此实验尝试应用 bert-base-multilingual-cased 提取中文、日语实体属性。

由表 4 可得, 改用 bert-base-multilingual-cased 提取属性嵌入后, 在 DBP15K_{ZH-EN}、DBP15K_{JA-EN} 数据集上指标并没有收获提高。本文猜测原因可能是相较日语、中文, 法语与英语在形式和语法上更为相似, 因此对于指代现实中相同实物的跨语言实体更易获得相似的语义嵌入, 从而提高实体对齐效果。

表 4 使用不同属性嵌入提取模型实体对齐效果对比

属性嵌入提取模型	DBP15K _{ZH-EN}			DBP15K _{JA-EN}		
	Hits@1	MR	MRR	Hits@1	MR	MRR
bert-base-multilingual-cased	0.569	223.685	0.650	0.558	313.667	0.639
opus-mt-zh-en	0.571	201.682	0.659	—	—	—
opus-mt-fr-en	—	—	—	0.569	266.186	0.649

4 结论

为了解决实体对齐任务中传统图注意力机制存在的难以拟合、有限注意及忽略实体属性信息等问题, 本文尝试应用动态图注意力机制于实体对齐模型中, 并使用 RDGCN 模型中的逐层门控网络机制聚合目标实体的单跳与多跳节点特征, 进而拼接经过外部知识预训练的 BERT 类预训练模型所获得的实体属性嵌入, 从而提出了基于动态图注意力聚合多跳邻域的实体对齐模型。

表 2 实体对齐模型性能对比

模型	DBP15K _{ZH-EN}			DBP15K _{JA-EN}			DBP15K _{FR-EN}		
	Hits@1	MR	MRR	Hits@1	MR	MRR	Hits@1	MR	MRR
MTransE	0.308	—	0.364	0.279	—	0.349	0.244	—	0.335
IPTTransE	0.406	—	0.516	0.367	—	0.474	0.333	—	0.451
JAPE	0.412	—	0.490	0.363	—	0.476	0.324	—	0.430
GCN-Align	0.413	—	0.549	0.399	—	0.546	0.373	—	0.532
SEA	0.424	—	0.548	0.385	—	0.518	0.400	—	0.533
RSN	0.508	—	0.591	0.507	—	0.590	0.516	—	0.605
GCN	0.487	—	0.559	0.507	—	0.618	0.508	—	0.628
GAT	0.418	—	0.508	0.446	—	0.537	0.442	—	0.546
R-GCN	0.463	—	0.564	0.471	—	0.571	0.469	—	0.570
AliNet	0.547	282.760	0.628	0.549	362.110	0.633	0.556	276.225	0.644
DGAT-EA	0.571	201.682	0.659	0.569	266.186	0.649	0.618	99.019	0.707

表 3 消融实验模型效果对比表

模型	DBP15K _{ZH-EN}			DBP15K _{JA-EN}			DBP15K _{FR-EN}		
	Hits@1	MR	MRR	Hits@1	MR	MRR	Hits@1	MR	MRR
AliNet	0.547	282.760	0.628	0.549	362.110	0.633	0.556	276.225	0.644
DGAT-EA(仅修改动态图注意力)	0.562	278.372	0.644	0.551	341.427	0.634	0.558	267.285	0.645
DGAT-EA(仅修改逐层门控机制)	0.558	249.450	0.640	0.564	331.113	0.640	0.553	228.314	0.645
DGAT-EA(未添加语义信息)	0.566	241.832	0.648	0.565	333.217	0.640	0.562	223.448	0.650
DGAT-EA	0.571	201.682	0.659	0.569	266.186	0.649	0.618	99.019	0.707

DGAT-EA, 最后通过实验证明了融入实体属性信息、应用动态图注意力对于实体对齐任务的有效性。在后续的工作中, 希望能优化传统图卷积网络对实体单跳节点特征的学习能力, 同时为关系事先对齐建模从而提高模型的对齐效果, 并通过优化代码实现过程以提高训练效率。

参考文献

- [1] BRODY S, ALON U, YAHAV E. How attentive are graph attention networks? [C]// International Conference on Learning Representations, 2021: 1–10.
- [2] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data [J]. Advances in Neural Information Processing Systems, 2013(1): 26.
- [3] WANG Z, ZHANG J. Knowledge graph embedding by translating on hyperplanes [C]// Proceedings of the 28th AAAI Conference on Artificial Intelligence, 2014: 1112–1119.
- [4] MOON C, JONES P, SAMATOVA N F. Learning entity type embeddings for knowledge graph completion [C]// Proceedings of the 2017 ACM on Conference on Information and Knowledge Management, 2017: 2215–2218.
- [5] SUN Z, DENG Z H, NIE J Y, et al. RotatE: knowledge graph embedding by relational rotation in complex space [C]// International Conference on Learning Representations, 2018: 3–5.
- [6] ZHANG Z, CAI J, ZHANG Y, et al. Learning hierarchy-aware knowledge graph embeddings for link prediction [C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 3065–3072.
- [7] WANG Z, LV Q, LAN X, et al. Cross-lingual knowledge graph alignment via graph convolutional networks [C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 351–354.
- [8] XU K, WANG L, YU M, et al. Cross-lingual knowledge graph alignment via graph matching neural network [C]// Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics(ACL), 2019: 3157–3159.
- [9] CAO Y, LIU Z, LI C, et al. Multi-channel graph neural network for entity alignment [C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 1452–1461.
- [10] ZHU Q, ZHOU X, WU J, et al. Neighborhood-aware attentional representation for multilingual knowledge graphs [C]// Twenty-Eighth International Joint Conference on Artificial Intelligence(IJCAI-19), 2019: 1943–1947.
- [11] YANG H W, ZOU Y, SHI P, et al. Aligning cross-lingual entities with multi-aspect information [J]. arXiv: 1910.06575, 2019.
- [12] SUN Z, WANG C, HU W, et al. Knowledge graph alignment network with gated multi-hop neighborhood aggregation [C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34: 222–229.
- [13] WELLING M, KIPF T N. Semi-supervised classification with graph convolutional networks [C]// International Conference on Learning Representations(ICLR 2017), 2016.
- [14] WOLF T, DEBUT L, SANH V, et al. Transformers: state-of-the-art natural language processing [C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations, 2020: 38–45.
- [15] SUN Z, HU W, LI C. Cross-lingual entity alignment via joint attribute-preserving embedding [J]. arXiv: 1708.05045, 2017.

(收稿日期: 2022-03-08)

作者简介:

汪浣沙(1999-), 男, 硕士研究生, 主要研究方向: 图像识别、知识图谱。

黄瑞阳(1986-), 通信作者, 男, 博士, 副研究员, 主要研究方向: 网络大数据处理与分析、自然语言处理, E-mail: gisexpert@163.com。

宋旭晖(1999-), 女, 硕士研究生, 主要研究方向: 自然语言处理。



扫码下载电子文档

京: 北京科技大学, 2020.

- [26] 何安瑞, 张清东, 徐金梧, 等. 热轧工作辊磨损模型的遗传算法 [J]. 钢铁, 2000, 35(2): 56–59.

(收稿日期: 2022-07-23)

作者简介:

高山凤(1983-), 女, 博士, 讲师, 主要研究方向: 热轧板带综合智能控制。

刘美红(1984-), 通信作者, 女, 博士, 副教授, 主要研究方向: 智能算法的研究与应用, E-mail: 380528274@qq.com。

范秋霞(1981-), 女, 博士, 副教授, 主要研究方向: 现代机械设计方法。



扫码下载电子文档

(上接第 50 页)

- [21] Linghu Kezhi, Jiang Zhengyi, Zhao Jingwei, et al. 3D FEM analysis of strip shape during multi-pass rolling in a 6-high CVC cold rolling mill [J]. International Journal of Advanced Manufacturing Technology, 2014, 74: 1733–1745.
- [22] 姚驰寰. 基于准三维差分法的热轧带钢板形预测模型研究 [D]. 北京: 北京科技大学, 2020.
- [23] 尚飞, 李洪波, 张杰, 等. CVC 工作辊非对称磨损分析与预报模型建立 [J]. 钢铁, 2016, 51(6): 59–64.
- [24] 宋光义. 热轧带钢平整机工作辊磨损与工艺参数优化研究 [D]. 北京: 北京科技大学, 2019.
- [25] 何海楠. 硅钢热轧轧辊磨损和断面精准控制研究 [D]. 北

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所