



# 计算机科学

COMPUTER SCIENCE

## 基于变体注意力的关系与属性感知实体对齐

李志康, 邓怡辰, 余敦辉, 肖奎

引用本文

李志康, 邓怡辰, 余敦辉, 肖奎. [基于变体注意力的关系与属性感知实体对齐](#)[J]. 计算机科学, 2025, 52(11): 230-236.

LI Zhikang, DENG Yichen, YU Dunhui, XIAO Kui. [Relationship and Attribute Aware Entity Alignment Based on Variant-attention](#) [J]. Computer Science, 2025, 52(11): 230-236.

---

## 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)**

### [基于图文知识融合的常识问答模型](#)

Commonsense Question Answering Model Based on Graph-Text Integrating  
计算机科学, 2025, 52(11): 237-244. <https://doi.org/10.11896/jsjcx.240900081>

### [利用语义增强提示和结构信息知识图谱补全模型](#)

Knowledge Graph Completion Model Using Semantically Enhanced Prompts and Structural Information  
计算机科学, 2025, 52(9): 282-293. <https://doi.org/10.11896/jsjcx.240700201>

### [基于多轮LLM和犯罪知识图谱的多被告人法律判决预测](#)

Multi-defendant Legal Judgment Prediction with Multi-turn LLM and Criminal Knowledge Graph  
计算机科学, 2025, 52(8): 308-316. <https://doi.org/10.11896/jsjcx.240900170>

### [基于知识感知的图优化推荐模型](#)

Knowledge-aware Graph Refinement Network for Recommendation  
计算机科学, 2025, 52(7): 103-109. <https://doi.org/10.11896/jsjcx.240600120>

### [面向软件生态演化的操作系统兼容性研究综述](#)

Survey on Research of Compatibility Issues in Operating System for Software Ecology Evolution  
计算机科学, 2025, 52(7): 1-12. <https://doi.org/10.11896/jsjcx.240900097>

# 基于变体注意力的关系与属性感知实体对齐

李志康<sup>1</sup> 邓怡辰<sup>3</sup> 余敦辉<sup>1,2</sup> 肖奎<sup>1,2</sup>

1 湖北大学计算机学院 武汉 430062

2 大数据智能分析与行业应用湖北省重点实验室 武汉 430062

3 武昌首义学院信息科学与工程学院 武汉 430064

(maplecm@163.com)

**摘要** 现有的实体对齐方法在区分不同邻居对中心实体的表示作用时,大多利用特征相似性或实体间关系的局部特征信息来计算注意力系数,忽略了关系的全局信息,且不能很好地区分不同信息对实体对齐的作用。为此,提出一种实体对齐模型,根据(关系,邻居)在全图中出现的频率为不同类型的关系分配不同权重,并将该方法融入 GAT(Graph Attention Mechanism)中,得到一种变体注意力机制以聚合不同邻居。同时,考虑(属性,属性值)在全图中的频率信息,以类似的方法聚合不同属性值,并将结构和实体名嵌入分别与两种信息结合,得到中心实体的两种嵌入表示。最后,根据实体对在两种嵌入表示上距离的加权进行实体对齐,以考虑关系和属性信息对实体对齐结果的不同影响。实验结果表明,所提模型在 DBP15K 的 3 个跨语言数据集上的表现优于其他主流方法,相比最优方法,Hit@1 指标最高提升了 2.15%,且 Hit@10 和 MRR 也均有明显提升,表明该模型能够有效提高实体对齐的准确性。

**关键词:** 实体对齐;知识图谱;变体注意力机制;属性感知

**中图分类号** TP391

## Relationship and Attribute Aware Entity Alignment Based on Variant-attention

LI Zhikang<sup>1</sup>, DENG Yichen<sup>3</sup>, YU Dunhui<sup>1,2</sup> and XIAO Kui<sup>1,2</sup>

1 School of Computer Science, Hubei University, Wuhan 430062, China

2 Hubei Key Laboratory of Big Data Intelligent Analysis and Application (Hubei University), Wuhan 430062, China

3 School of Information Science and Engineering, Wuchang Shouyi College, Wuhan 430064, China

**Abstract** When distinguishing the different representation effects of different neighbors on the central entity, existing entity alignment methods mostly use feature similarity or local feature information of the relationships between entities to calculate attention coefficients. Those methods ignore the global information of relationships, and cannot effectively distinguish the effect of different information on entity alignment. To address this problem, this paper proposes an entity alignment model, which assigns different weights to different types of relationships based on the frequency of (relationship, neighbor) appearing in the entire graph, then integrates the weights into GAT to obtain a variant attention mechanism for aggregating different neighbors. Meanwhile, different attribute values are aggregated in a similar way by using the frequency information of (attributes, attribute values) in the entire graph. After that, combining the structure and entity name embedding with two types of information respectively to obtain two embedding representations of the central entity. Finally, entity alignment is performed based on the weighted distance between the two embedding representations, aims to distinguish the different effects of relationship and attribute information on the entity alignment. Experimental results show that this model is superior to other methods in the three cross lingual datasets of DBP15K, Hit@1 increases by a maximum of 2.15% compare to the optimal method, besides, results also show significant improvement in both Hit@10 and MRR, which indicate that the proposed model can effectively enhance the accuracy of entity alignment.

**Keywords** Entity alignment, Knowledge graph, Variant attention mechanism, Attribute-aware

到稿日期:2024-08-26 返修日期:2024-11-26

基金项目:国家自然科学基金(62377009)

This work was supported by the National Natural Science Foundation of China(62377009).

通信作者:邓怡辰(104238327@qq.com)

## 1 引言

知识图谱(Knowledge Graph, KG)是由一系列知识构建而成的一个机器与人都能理解的关系网络,其使用可视化图有效地描述了概念和实体之间的复杂关系。随着深度学习的发展,知识图谱在知识推理<sup>[1]</sup>、推荐系统<sup>[2]</sup>、知识问答<sup>[3]</sup>等领域有着广泛应用。但是,随着数据集的扩大,知识图谱愈发呈现出跨领域、知识细分的特性,增加了融合多源知识图谱的难度。

知识图谱融合的一个重要步骤是实体对齐,最早的实体对齐模型主要基于符号表示<sup>[4]</sup>生成对齐规则,以进行实体对齐,但需要大量的人工成本。随着表示学习和知识图谱嵌入技术<sup>[5]</sup>的发展,基于表示学习的实体对齐模型代替传统模型成为主流,并取得优异的效果。现有表示学习模型多采用图神经网络(Graph Neural Network, GNN)<sup>[6]</sup>或其变体进行特征学习,并基于得到的实体嵌入之间的相似度完成实体对齐。不同表示模型对实体嵌入的获取方法各不相同。例如,EA-MI<sup>[7]</sup>通过多层图卷积神经网络(Graph Convolutional Networks, GCN)<sup>[8]</sup>学习结构表示,再融入属性和实体名信息来更新实体嵌入表示;RHGN<sup>[9]</sup>通过迭代融合的方法来增强实体和关系之间的交互,以得到更精确的实体嵌入表示。然而,这些模型在利用关系和属性信息计算实体嵌入时,大多基于实体间的特征相似性或局部特征信息来区分不同邻居实体或属性对中心实体嵌入的表示作用,忽略了其全局信息。同时,也不能有效地区分关系和属性信息对实体对齐的不同作用。

为解决上述问题,本文提出了一种基于变体注意力的关系与属性感知实体对齐模型(Relationship and Attribute Aware Entity Alignment Based on Variant-attention, RAEA-V)。该模型将实体间关系的全局信息融入对应邻居实体的注意力权重计算中,根据(关系,邻居)在全图中出现的频率对中心实体的关系进行分类,基于该频率为不同类型的关系分配权重,并采用类似的方法对不同属性进行权重分配。同时,考虑到关系和属性信息对实体对齐结果的不同影响,分别计算中心实体在两种信息嵌入上的距离,并基于两种距离的加权完成实体对齐。本文的主要贡献总结如下:

1)设计了一种权重分配方法,该方法充分利用关系的全局信息,基于(关系,邻居)在全图中出现的频率给不同的关系设置不同的权重,从而更好地区分不同邻居对中心实体在对齐时的不同重要度,同时采用类似的方法对不同属性进行权重分配。

2)提出了一种实体对齐模型,该模型将结构、实体名嵌入分别与关系和属性信息结合,分别得到中心实体的两种嵌入表示,并根据实体对在两种嵌入表示上距离的加权进行实体对齐,更充分地考虑了关系和属性信息对实体对齐的不同作用。

3)在DBP15K的3个不同数据集上进行了对比实验,实验结果表明,所提模型相比于其他主流模型取得了更优效果,证明了所提模型的有效性。

## 2 相关工作

实体对齐技术可以追溯到20世纪中后期。传统的实体对齐方法大多专注于知识图谱的句法和结构,主要侧重于计算实体之间标签和字符的距离,并依赖于人工构建特征和外部信息。知识表示学习<sup>[10]</sup>将描述对象表示为低维向量,并利用两个向量之间的距离来表示它们之间的语义关系。研究者根据这一特征,提出了许多基于知识表示学习的实体对齐方法<sup>[11]</sup>。目前基于知识表示学习的实体对齐方法可以分为基于翻译模型和基于图神经网络的实体对齐方法两类。

### 2.1 基于翻译模型的实体对齐方法

基于翻译模型的实体对齐方法通过知识图谱的三元组结构来学习实体的低维向量表示,并基于预对齐的实体对将不同的表示空间融合为一个统一的空间,以此完成实体对齐。MTransE<sup>[12]</sup>模型在独立的嵌入空间中对每种语言的三元组信息进行编码,为跨语言的知识图谱对齐提供空间映射关系,但其只利用了结构化的信息。BootEA<sup>[13]</sup>采用翻译模型进行嵌入,通过预对齐结果反复训练分类器,将那些预对齐的实体对齐结果添加到下一次迭代中进行训练。相比传统的实体对齐模型,基于翻译模型的方法有一定的泛化能力,但其仅考虑了实体和关系三元组,难以保留知识图谱的全局结构信息。

### 2.2 基于图神经网络的实体对齐方法

基于图神经网络的实体对齐方法通过聚合实体多源信息的方式,动态地学习每个实体在知识图谱上的嵌入表示。例如,SSEA<sup>[14]</sup>使用GCN来学习实体的结构和属性表示,并联合关系信息得到最终的实体嵌入表示。为了更好地聚合关系和属性信息,研究者加入了注意力机制来对关系和属性进行建模。例如,MRAEA<sup>[15]</sup>考虑了实体之间关系的类型、方向和可逆性,并使用关系的局部信息对不同关系分配权重。AttrGNN<sup>[16]</sup>对结构信息和属性信息进行了联合编码,并采用注意力机制为不同属性设置不同的权重。此外,也有研究者注意到实体的不同信息具有不同特征,考虑对其分别进行嵌入再聚合。例如,BNGNN<sup>[17]</sup>设计了一种双邻域图神经网络来分别得到实体和属性两种类型的邻域特征嵌入,再聚合两种嵌入得到最终的实体嵌入表示。

综上,基于图神经网络的实体对齐模型在聚合多源信息时具有明显的优势,但现有模型在利用注意力机制给不同邻居或属性分配权重时,大多只考虑其局部特征,而忽略了全局信息。同时,在融入实体不同信息的过程中,大多将各信息嵌入直接聚合得到最终嵌入,未能充分考虑不同信息对实体对齐的不同作用。

## 3 实体对齐模型

本文提出一种融合多源信息的RAEA-V实体对齐模型,其整体结构如图1所示。该模型主要由关系感知嵌入模块和属性感知嵌入模块组成。在关系感知嵌入模块中,首先充分利用关系的全局信息,基于(关系,邻居)在全图中的频率信息定义一种注意力权重分配方法,并将该方法融入图注意力



其中,  $\beta_1$  为权衡参数,  $x_i^{e-init}$  为实体名初始嵌入。

### 3.2 属性感知嵌入

实体的属性信息在实体对齐过程中起着重要的辅助作用。本文认为,当属性为一个实体独有或其属性值与其他实体的同名属性不相同,该属性具有唯一性,能更好地表示中心实体。类似于关系感知嵌入模块,提出一种属性权重计算方法,不同的是,属性不需要区分前向和后向。如图2所示,实体“詹姆斯”和“普林斯”都有属性“职业”和“全名”,其中两个实体的“职业”属性值均为“篮球运动

员”,而“全名”的属性值具有唯一性,故“全名”的属性值相比“职业”能更好地表示中心实体“詹姆斯”,应被分配更大权重。将(职业,篮球运动员)这类属性视为  $1:n$  类型,(全名,勒布朗·詹姆斯)这类属性视为  $1:1$  类型。类似于关系感知嵌入模块,用  $\eta_2$  表示属性权重分配函数的超参,  $w_{Att}$  表示属性频率权重,  $x_i^{att}$  表示属性聚合嵌入,  $\beta_2$  表示属性聚合嵌入与实体名嵌入的权衡参数,并采用相同的步骤,计算得到属性感知的初步嵌入表示  $x_i^{Att}$ 。两个初步嵌入向量的具体生成过程如图3所示。

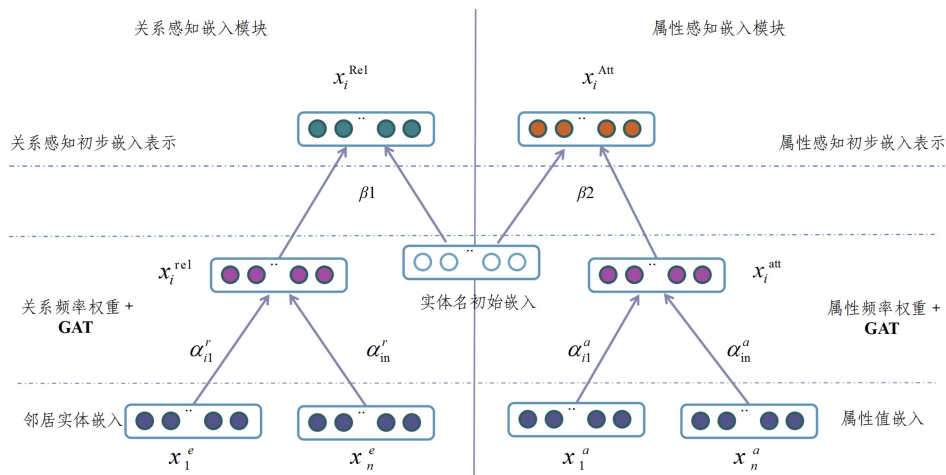


图3 嵌入生成过程

Fig. 3 Embedded generation process

### 3.3 结构嵌入

将中心实体的两个初步嵌入表示分别经过 GCN 层进行结构嵌入,并在神经网络中加入高速路门控机制以控制多层图卷积网络传输中的噪声,最终的 GCN 层定义为:

$$X^{(h,l)} = \text{ReLU}(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} X^{(h,l-1)} \mathbf{W}^{(h,l)}) \quad (5)$$

$$T(X^{(h,l)}) = \sigma(X^{(h,l)} \mathbf{W}_H^{(h,l)} + \mathbf{b}_H^{(h,l)}) \quad (6)$$

$$X^{(h,l+1)} = T(X^{(h,l)}) \cdot X^{(h,l)} + (1 - T(X^{(h,l)})) \cdot X^{(h,l-1)} \quad (7)$$

其中,  $h = \{Rel, Att\}$  表示关系感知或属性感知嵌入,  $\mathbf{W}^{(h,l)}$  表示第  $l$  层的可学习参数,  $X^{(h,l)}$  表示第  $l$  层的嵌入表示输出,  $\mathbf{W}_H^{(h,l)}$  和  $\mathbf{b}_H^{(h,l)}$  分别为权重矩阵和偏置向量,  $\sigma(\cdot)$  为 sigmoid 函数。

为了更好地获得知识图谱关系和属性结构上的不同特征,在两个模块上使用不同的  $\mathbf{W}, \mathbf{W}_H$  和  $\mathbf{b}_H$  参数参与训练,并由此得到中心实体的两个最终嵌入表示  $X^{Rel}$  和  $X^{Att}$ 。

### 3.4 实体对齐

为了捕捉实体各个方面的特征,现有方法通常连接实体的多个嵌入作为总体嵌入来计算实体对的距离。但本文认为实体的关系与属性信息对实体对齐结果的作用不同,因此,分别计算候选实体对在  $X^{Rel}$  和  $X^{Att}$  上的距离:

$$d_h(e_i, e_j) = \|x_{e_i}^h - x_{e_j}^h\|_1 \quad (8)$$

其中,  $e_i$  和  $e_j$  分别来自两个知识图谱,  $\|\cdot\|_1$  表示向量的一范式,  $h = \{Rel, Att\}$ ,  $x_c^h$  为实体嵌入。

基于上述两种距离,在两个模块上分别设置损失函数,采

用不同的参数进行训练,并在总体损失函数中使用参数平衡两个损失部分:

$$L1 = \sum_{(p,q) \in \mathbb{N}, (p',q') \in \mathbb{N}_{Rel}} [d_{Rel}(p,q) - d_{Rel}(p',q') + \gamma_2]_+ \quad (9)$$

$$L2 = \sum_{(p,q) \in \mathbb{N}, (p',q') \in \mathbb{N}_{Att}} [d_{Att}(p,q) - d_{Att}(p',q') + \gamma_2]_+ \quad (10)$$

$$L = \theta \cdot L1 + (1 - \theta) \cdot L2 \quad (11)$$

其中,  $[\cdot]_+ = \max\{0, \cdot\}$ ,  $\mathbb{R}$  表示对齐实体集,  $\mathbb{R}_{Rel}'$  和  $\mathbb{R}_{Att}'$  分别表示关系感知和属性感知的负样本实体对,  $L1$  表示关系感知损失函数,  $L2$  表示属性感知损失函数,  $L$  表示总的损失函数,  $\gamma_1, \gamma_2 > 0$  是用于分离正负样本实体对的超参数,  $\theta$  是平衡两个损失部分的权衡参数。

模型训练完成后,对于给定的候选实体对,分别计算其在基于关系和基于属性感知嵌入上的距离  $d_{Rel}$  和  $d_{Att}$ ,并利用训练后损失函数  $L$  中的参数  $\theta$  进行加权,得到最终嵌入距离:

$$d = \theta \cdot d_{Rel} + (1 - \theta) \cdot d_{Att} \quad (12)$$

其中,  $d$  为候选实体对的最终嵌入距离。在知识图谱实体对齐中,基于该距离对候选实体集进行排序,距离越小的候选实体排名越高。

## 4 实验

### 4.1 数据集

为评估 RAEA-V 模型,本文在 DBP15K 数据集上进行实验。表1列出了数据集的统计数据,该数据集包含4个分别从英语、汉语、法语和日语 DBpedia<sup>[21]</sup>中提取的特定语言的知

识图谱,并构造出3组跨语言数据集:汉语-英语(ZH-EN)、法语-英语(FR-EN)和日语-英语(JA-EN)。每个数据集中含有标注好的15000个已对齐的实体对。

表1 DBP15K数据集的统计信息

Table 1 Statistics of DBP15K dataset

数据集	语种	实体	关系	属性	关系三元组	属性三元组
DBP15K <sub>ZH-EN</sub>	汉语	66469	2830	8113	153929	379684
	英语	98125	2317	7173	237674	567755
DBP15K <sub>JA-EN</sub>	日语	65744	2043	5882	164373	354619
	英语	95680	2096	6066	233319	497230
DBP15K <sub>FR-EN</sub>	法语	66858	1379	4547	192191	528665
	英语	105889	2209	6422	278590	576543

## 4.2 评价指标

本文使用前 $k$ 命中率 $Hits@k$ 和平均倒数排名(Mean Reciprocal Rank, MRR)作为评估指标来评估实体对齐的性能。这两项指标值均是越大,则表示效果越好。

$Hits@k$ 表示所有目标实体中,正确对齐实体存在于前 $k$ 个备选实体中的实体对占总预对齐实体对的比例,其计算式如下:

$$Hits@k = \frac{|\{e_i \in N \mid rank_i \leq k\}|}{|N|} \quad (13)$$

其中, $Hit@k \in [0, 1]$ , $rank_i$ 表示对齐到正确的实体的排名, $N$ 为对齐实体对, $||$ 为取个数运算,本文的 $k$ 分别取1和10。

MRR定义为匹配到正确实体排名的倒数的平均值,其计算式如下:

$$MRR = \frac{1}{|N|} \sum_{i=1}^{|N|} \frac{1}{rank_i} \quad (14)$$

其中, $MRR \in (0, 1]$ 。

## 4.3 实验设置

对于跨语言数据集DBP15K,先通过谷歌翻译将非英文部分翻译成英文,再使用预训练模型得到各个特征的初始嵌入向量。将数据集中30%的种子实体对作为训练模型的训练集 $P_{Train}$ ,剩余70%的种子实体对作为测试集 $P_{Test}$ 。设置学习率为0.01,Batch\_size为1024,Highway GCNs层数为2, $\beta_1$ 和 $\beta_2$ 为1,总训练轮数设为500。

对于参数 $\eta_1$ , $\eta_2$ 和 $\theta$ ,采用逐步优化策略。首先将 $\eta_1$ 和 $\eta_2$ 固定,确定 $\theta$ 初值,然后通过实验调整 $\eta_1$ 和 $\eta_2$ 的值,最后对 $\theta$ 进行微调。其中, $\eta_1$ 和 $\eta_2$ 在 $(0, 0.4]$ 内选择, $\theta$ 在 $[0.4, 0.8]$ 内选择。在统计频率信息时发现,属性频率中出现的最高频率较高,且高频属性较多,故考虑将 $\eta_2$ 固定为较小的0.1,以避免高频属性权重过高;同理,关系频率中出现的最高频率相比属性频率有所降低,考虑将 $\eta_1$ 固定为0.15。 $\eta_1$ 和 $\eta_2$ 的参数设置实验详见4.4节。最终在3个数据集上将 $\theta$ 值分别设置为0.65,0.6和0.7。

## 4.4 参数设置实验

针对关系和属性频率权重超参数 $\eta_1$ 和 $\eta_2$ ,通过实验在 $(0, 0.4]$ 中进行选择,研究其在3个数据集上对模型性能的不同影响。在汉语-英语数据集上实验的具体结果如图4和图5所示。



图4 参数 $\eta_1$ 分析实验结果Fig. 4 Results of parameter  $\eta_1$  analysis experiment

图4中,固定 $\eta_2 = 0.1$ ,不断调整 $\eta_1$ 。分析实验结果发现,当 $\eta_1$ 取值过小时,高频率的关系几乎被忽略,不能对中心实体的表示起到作用,实验效果有所下降;当 $\eta_1$ 取值过大时,会给高频率关系分配过高的权重,实验效果下降明显。当 $\eta_1$ 取0.2时,获得最佳的实验效果。

图5中,固定 $\eta_1$ 为上一步实验得到的0.2,不断调整 $\eta_2$ 。分析实验结果发现,当 $\eta_2$ 取0.15时,获得最佳的实验效果。因此,在汉语-英语数据集上进行实验时,分别将 $\eta_1$ 和 $\eta_2$ 的值设为0.2和0.15。同样,通过实验确定 $\eta_1$ 和 $\eta_2$ 在日语-英语数据集上的取值为0.2和0.15,在法语-英语数据集上的取值为0.15和0.1。

图5 参数 $\eta_2$ 分析实验结果Fig. 5 Results of parameter  $\eta_2$  analysis experiment

## 4.5 对比实验

为验证RAEA-V模型的有效性,本文选取6种主流实体对齐方法进行对比。

1) BootEA<sup>[13]</sup>:提出了一种基于嵌入的实体对齐的自扩展方法,迭代地将可能的实体对齐标记为训练数据,用于学习KG嵌入。

2) RDGCN<sup>[22]</sup>:通过构建关系对偶图获取关系信息,并基于关系的注意力权重更新实体的关系嵌入。

3) HGCN<sup>[23]</sup>:同时学习实体和关系谓词的嵌入,在实体嵌入的过程中隐式地利用关系的表示来改善对齐过程。

4) Dual-AMN<sup>[24]</sup>:提出了一种新型的双注意力匹配网络KG编码器,降低了图内和图间信息建模的复杂度。

5) RNM<sup>[25]</sup>:借用关系对齐来辅助实体对齐,在匹配子图时考虑相邻的实体,同时利用链接关系的语义信息和映射属性进行实体对齐。

6) DATTI<sup>[26]</sup>:专注于改进实体对齐解码过程,提出一种解码方法,利用KG的邻接和内相关同构来增强实体对齐的解码过程。

由表 2 的对比实验结果可以看出,本文模型在 DBP15K 的 3 个数据集上均取得了较好的结果,整体优于其他基线模型。其中基于图神经网络的实体对齐方法的各指标均大幅优于基于翻译模型的实体对齐方法 BootEA,这是因为传统的翻译模型对知识图谱的信息利用不够充分。而在基于图神经网络的方法中,RAEA-V 相比其他方法的 Hits@1, Hits@10 和 MRR 指标基本都有明显的提升,特别是在汉语-英语数据集

的实验中,RAEA-V 的 Hit@1 指标相比 RNM 模型提升了 2.15%。这是因为本文模型利用关系和属性的全局信息得到了更准确的实体嵌入表示,同时也更好地考虑了关系和属性信息对实体对齐结果的不同影响。唯一比本文模型效果好的是 DATTI 模型在汉语-英语和日语-英语数据集上的 Hits@10 指标,这可能是由于 DATTI 模型中提出的解码方法能够捕捉较为宽泛的实体集之间的特征关系。

表 2 RAEA-V 模型与 6 种主流模型在 DBP15K 数据集上的对比实验结果

Table 2 Comparative experimental results of RAEA-V model and six mainstream models on DBP15K dataset

模型	DBP15K <sub>ZH-EN</sub>			DBP15K <sub>JA-EN</sub>			DBP15K <sub>FR-EN</sub>		
	Hit@1/%	Hit@10/%	MRR	Hit@1/%	Hit@10/%	MRR	Hit@1/%	Hit@10/%	MRR
BootEA	62.94	84.75	0.703	62.23	85.39	0.701	65.30	87.44	0.731
RDGCN	70.80	84.60	0.746	76.70	89.50	0.812	88.60	95.70	0.911
HGCN	72.03	85.70	—	76.62	89.73	—	89.16	96.11	—
Dual-AMN	80.80	94.00	0.857	80.10	94.90	0.855	84.00	96.50	0.888
RNM	84.00	91.90	0.870	87.20	94.40	0.899	93.80	98.10	0.954
DATTI	83.50	<b>95.30</b>	0.880	83.60	<b>96.90</b>	0.884	87.30	97.90	0.913
RAEA-V	<b>86.15</b>	93.36	<b>0.887</b>	<b>88.90</b>	95.22	<b>0.903</b>	<b>94.57</b>	<b>98.85</b>	<b>0.959</b>

#### 4.6 消融实验

为了评估 RAEA-V 模型的变体注意力机制中的频率权重对两个模块的有效性,本文进行了消融实验,分别在两个模块的注意力机制中去除关系和属性频率权重。其中,RAEA-V/RM 表示在两个模块的注意力机制中均去除,RAEA-V/R 表示单独在关系感知模块的注意力机制中去除,RAEA-V/M 表示单独在属性感知模块的注意力机制中去除。将各个消融模型的实验效果与本文模型进行

对比。由表 3 的实验结果可以得出,单独去除任一模块注意力机制中的频率权重,实体对齐结果在各项指标上均低于完整的 RAEA-V 模型;当在两个模块中同时去除时,模型的效果下降明显,特别是在中文-英语数据集的实验中,相较于完整模型,其 Hit@1 下降了 2.88%。这说明关系和属性的全局频率信息对中心实体的表示发挥着重要作用,也进一步地说明了本文提出的变体注意力机制能够有效提高实体对齐的准确性。

表 3 RAEA-V 模型在 DBP15K 数据集上的消融实验结果

Table 3 Ablation experimental results of RAEA-V model on DBP15K dataset

模型	DBP15K <sub>ZH-EN</sub>			DBP15K <sub>JA-EN</sub>			DBP15K <sub>FR-EN</sub>		
	Hit@1/%	Hit@10/%	MRR	Hit@1/%	Hit@10/%	MRR	Hit@1/%	Hit@10/%	MRR
RAEA-V /RM	83.27	90.24	0.861	86.85	93.18	0.853	93.40	97.55	0.948
RAEA-V /R	84.58	92.63	0.875	87.60	94.66	0.899	93.98	98.10	0.952
RAEA-V /M	85.23	92.48	0.886	88.21	94.65	0.902	94.25	98.54	0.955
RAEA-V	<b>86.15</b>	<b>93.36</b>	<b>0.887</b>	<b>88.90</b>	<b>95.22</b>	<b>0.903</b>	<b>94.57</b>	<b>98.85</b>	<b>0.959</b>

**结束语** 本文充分考虑关系和属性的全局信息,提出了一种基于变体注意力的关系与属性感知实体对齐模型,根据不同的关系或属性在全图中出现的频率,分别给不同的关系或属性设置不同的权重,进而聚合不同的邻居实体或属性值。同时,将两种信息分别与结构和实体名嵌入相融合,得到中心实体的两种嵌入表示,并基于实体对在两种嵌入表示上距离的加权完成实体对齐。在 DBP15K 数据集上的结果表明,除了 DATTI 模型的少数指标,本文模型的效果均优于其他主流模型。未来将探索设计更加准确的权重分配函数,以及优化频率信息的获取方法,以更好地运用在大型知识图谱中。

#### 参考文献

[1] WANG J, WANG W, MENG F, et al. A Review of Knowledge Reasoning Based on Neural Network[C]// 2023 IEEE 12th International Conference on Communication Systems and Network Technologies(CSNT). 2023:580-584.

[2] TAHA K, YOO P D, YEUN C, et al. Empirical and experimental perspectives on big data in recommendation systems: a com-

prehensive survey[J]. Big Data Mining and Analytics, 2024, 7(3):964-1014.

[3] WANG Y, LIPKA N, ROSSI R A, et al. Knowledge graph prompting for multi-document question answering[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2024:19206-19214.

[4] JIANG T, BU C, ZHU Y, et al. Combining embedding-based and symbol-based methods for entity alignment[J]. Pattern Recognition, 2022, 124:108433.

[5] FANOURAKIS N, EFTHYMIU V, KOTZINOS D, et al. Knowledge graph embedding methods for entity alignment: experimental review[J]. Data Mining and Knowledge Discovery, 2023, 37(5):2070-2137.

[6] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2008, 20(1):61-80.

[7] ZHU B, BAO T, HAN R, et al. An effective knowledge graph entity alignment model based on multiple information[J]. Neural Networks, 2023, 162:83-98.

- [8] ZHANG S, TONG H, XU J, et al. Graph convolutional networks: a comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1-23.
- [9] ZHANG Z, YANG Y, CHEN B. Relation-aware heterogeneous graph neural network for entity alignment[J]. *Neurocomputing*, 2024, 592: 127797.
- [10] ZHANG F, YANG L Y, LI J W, et al. A Review of Entity Alignment Research [J]. *Journal of Computer Science*, 2022, 45(6): 1195-1225.
- [11] ZHU B, WANG R, WANG J, et al. A survey: knowledge graph entity alignment research based on graph embedding[J]. *Artificial Intelligence Review*, 2024, 57(9): 1-58.
- [12] CHEN M, TIAN Y, YANG M, et al. Multilingual Knowledge Graph Embeddings for Cross-lingual Knowledge Alignment [C]//*Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*. 2017: 1511-1517.
- [13] SUN Z, HU W, ZHANG Q, et al. Bootstrapping entity alignment with knowledge graph embedding[C]//*Proceedings of the 27th International Joint Conference on Artificial Intelligence*. 2018: 4396-4402.
- [14] ZHU B, BAO T, HAN J, et al. Cross-lingual knowledge graph entity alignment by aggregating extensive structures and specific semantics[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14(9): 12609-12616.
- [15] MAO X, WANG W, XU H, et al. MRAEA: an efficient and robust entity alignment approach for cross-lingual knowledge graph[C]//*Proceedings of the 13th International Conference on Web Search and Data Mining*. 2020: 420-428.
- [16] LIU Z, CAO Y, PAN L, et al. Exploring and Evaluating Attributes, Values, and Structures for Entity Alignment[C]//*Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing*. 2020: 6355-6364.
- [17] SHI X, LI B, CHEN L, et al. Bi-Neighborhood Graph Neural Network for cross-lingual entity alignment [J]. *Knowledge-Based Systems*, 2023, 277: 110841.
- [18] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph Attention Networks[C]//*International Conference on Learning Representations*. 2018.
- [19] RAHIMI A, COHN T, BALDWIN T. Semi-supervised user geolocation via graph convolutional networks[C]//*Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*. 2018: 2009-2019.
- [20] LIN Y, LIU Z, LUAN H, et al. Modeling relation paths for representation learning of knowledge bases[C]//*Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*. 2015: 705-714.
- [21] FORMICA A, TAGLINO F. Semantic relatedness in DBpedia: A comparative and experimental assessment[J]. *Information Sciences*, 2023, 621: 474-505.
- [22] WU Y, LIU X, FENG Y, et al. Relation-aware entity alignment for heterogeneous knowledge graphs[C]//*Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. 2019: 5278-5284.
- [23] WU Y, LIU X, FENG Y, 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*. 2019: 240-249.
- [24] MAO X, WANG W, WU Y, et al. Boosting the speed of entity alignment  $10\times$ : Dual attention matching network with normalized hard sample mining[C]//*Proceedings of the Web Conference*. 2021: 821-832.
- [25] ZHU Y, LIU H, WU Z, et al. Relation-aware neighborhood matching model for entity alignment[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. 2021: 4749-4756.
- [26] MAO X, MA M, YUAN H, et al. An effective and efficient entity alignment decoding algorithm via third-order tensor isomorphism[C]//*Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*. 2022: 5888-5898.



**LI Zhikang**, born in 2000, postgraduate. His main research interest is knowledge graph.



**DENG Yichen**, born in 1993, postgraduate, lecturer. Her main research interest is embedded development.

(责任编辑:何杨)