

融合路径语义的结构感知注意力实体对齐

刘慧¹, 邵玉斌¹, 杜庆治¹, 朵琳¹, 张赅涛²

(1.昆明理工大学信息工程与自动化学院, 云南 昆明 650500; 2.云南省媒体融合重点实验室, 云南 昆明 650228)

摘要: 实体对齐 (Entity Alignment, EA) 是实现多源知识图谱融合的关键任务, 目的是识别两个异构知识图谱中语义相同的实体。现有方法通常依赖实体的邻域结构或预训练语义信息进行表示学习, 但在复杂异构场景下表现不佳, 且普遍缺乏对多跳路径信息的有效利用。针对这一问题, 提出一种融合路径语义的结构感知注意力实体对齐模型 (Entity Alignment with Path-Integrated Structure-Aware Attention, PISA)。该模型首先通过挖掘实体之间具有语义代表性的多跳路径, 构造出路径三元组扩展图结构; 随后引入结构感知多头注意力机制, 从融合图中学习实体表示, 使得模型能够在复杂结构与多类型关系场景中更全面地捕捉实体间的语义信息。在 DBP-15K 的法文-英文、日文-英文、中文-英文子集上, PISA 的 Hits@1 相较于基线模型分别提升了 1.90%、0.76% 和 1.79%。在 WK31-15K 的英文-德文 (V1) 英文-德文 (V2)、英文-法文 (V1) 和英文-法文 (V2) 子集上, PISA 的 Hits@1 相较于基线模型分别提升了 1.78%、2.01%、1.46% 和 1.27%, 表明其在异构知识图谱对齐任务中的有效性和稳定性。

关键词: 实体对齐; 知识图谱; 多跳路径; 路径语义; 结构感知注意力

中图分类号: TP 391

文献标志码: A

文章编号:

Entity alignment with path-integrated structure-aware attention

LIU Hui¹, SHAO Yubin¹, DU Qingzhi¹, DUO Lin¹, ZHANG Zetao²

(1.Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Yunnan Province Key Laboratory of Media Convergence, Kunming 650228, China)

Abstract: Entity alignment is a critical task for integrating multi-source knowledge graphs, aiming to identify semantically equivalent entities across heterogeneous graphs. Existing methods typically rely on an entity's neighborhood structure or pretrained semantic information for representation learning, but they perform poorly in complex heterogeneous scenarios and generally fail to effectively utilize multi-hop path information. To address these limitations, we propose the entity alignment with path-integrated structure-aware attention (PISA). This model first extracts semantically representative multi-hop paths between entities to construct a path-triple-based extended graph structure. Then, a structure-aware multi-head attention mechanism is introduced to learn entity representations from the fused graph, enabling the model to more comprehensively capture semantic relations between entities across complex structures and diverse relations. On the DBP-15K FR-EN, JA-EN, and ZH-EN subsets, PISA's Hits@1 improves over the baseline by 1.90%, 0.76%, and 1.79%, respectively. On the WK31-15K EN-DE (V1), EN-DE (V2), EN-FR (V1), and EN-FR (V2) subsets, PISA's Hits@1 improves over the baseline by 1.78%, 2.01%, 1.46%, and 1.27%, respectively, which demonstrates its effectiveness and stability in heterogeneous knowledge-graph entity alignment.

Key words: Entity Alignment; Knowledge Graph; Multi-hop Path; Path Semantics; Structure-aware Attention

知识图谱 (Knowledge Graph, KG) 是一种以图结构形式存储数据的知识库, 通常采用三元组 (头实体, 关系, 尾实体) 的形式描述现实世界中的语义关系^[1-3], 其中头实体和尾实体对应图结构中的节点, 关系表示连接节点的边。随着人工智能技术的发展, 知识图谱作为结构化表达实体及实体间关系的重要载体, 已广泛应用于文本生成^[4]、推荐系统^[5]、问答系统^[6]等领域。近年来, 知识图谱在多模态学习^[7]、大语言模型增强^{[8][9]}和自动化构建^[10]等方向中也展现出优势, 并在知识推理^[11]、可解释性与迁移学习^[12]等任务

中发挥着关键作用。

由于知识图谱具备强大的结构化知识表达能力, 不同组织、平台和语言社区纷纷构建了各自的知识图谱, 全球范围内涌现出大量不同主题、结构和语言的图谱资源, 如 DBpedia、Wikidata 和 YAGO 等。然而, 多源知识图谱之间普遍存在结构异构、语义不一致和实体冗余等问题^[13], 因此有必要对这些异构知识图谱进行融合^[14], 以提高知识图谱的覆盖率与准确性, 进而增强下游任务的性能。

不同知识图谱在构建过程中通常采用不同的

收稿日期: 20XX-XX-XX; 接收日期: 20XX-XX-XX

基金项目: 云南省媒体融合重点实验室项目 (220245201)

命名规范、属性语义体系与图结构拓扑，导致在**实体名称、属性描述及邻域结构上呈现明显的异构性**。例如，在中文知识图谱中，“乔布斯”作为实体，其属性包括“出生地：美国”“职业：企业家”；而在英文知识图谱中，对应的实体为“Steve Jobs”，属性为“place of birth: San Francisco”“occupation: business magnate, industrial designer”，**属性描述细粒度更高**。在邻域结构上，中文图谱中实体连接的邻居有限，如：“苹果公司”、“配偶：劳伦·鲍威尔”，而英文图谱中则包含“Apple Inc.”、“Pixar”、“NeXT”、“Lisa Brennan-Jobs”和“Reed College”等更丰富的邻接实体。这些差异显然增加了跨图谱知识融合的难度，为了解决这个问题，实体对齐任务被提出。

实体对齐的目标是识别并链接异构知识图谱中**等价的实体节点**，建立跨图谱映射对，从而提升知识图谱的完整性和一致性。早期实体对齐方法多基于嵌入学习，通过将不同图谱中的实体投射到同一向量空间并计算相似度实现对齐，如多语种知识图谱嵌入模型（Multilingual Knowledge Graph Embeddings for Cross-lingual Knowledge Alignment, MTransE）^[15]和自举实体对齐模型（Bootstrapping Entity Alignment with Knowledge Graph Embedding, BootEA）^[16]。为更好地利用结构信息，图神经网络（Graph Neural Network, GNN）^[17]方法被引入，如图卷积对齐模型（Cross-lingual Knowledge Graph Alignment via Graph Convolutional Networks, GCN-Align）^[18]基于图卷积提取邻域结构特征，关系感知双图卷积网络（Relation-aware Dual-Graph Convolutional Networks for Entity Alignment, RDGCN）^[19]利用对偶图构建关系感知的结构表征，邻域感知对齐网络（Knowledge Graph Alignment Network with Gated Multi-hop Neighborhood Aggregation, AliNet）^[20]和双重注意力匹配网络（Dual Attention Matching Network with Normalized Hard Sample Mining, Dual-AMN）^[21]进一步引入跨图匹配机制与多粒度注意力，提升了异构图谱下的对齐性能。

尽管近年来已有多种实体对齐方法取得了显著进展，但仍面临若干关键挑战。一方面，早期基于嵌入的方法（如 MTransE^[15]和 BootEA^[16]）将实体映射到统一的向量空间，采用静态的结构偏移建模，难以捕捉复杂语境下的结构交互信息；另一方面，图神经网络类方法（如 GCN-Align^[18]、RDGCN^[19]和 AliNet^[20]等）虽引入了邻居信息建模结构，然而，这类方法通常局限于固定一跳或两跳邻域聚合，未能充分挖掘多跳路径中的深层语义关联。此外，由于缺乏有效的路径筛选机制，这类方法在融合结构与语义信息时易引入冗余路径和语义噪声，降低实体表示质量，最终影响对齐效果。

为解决上述问题，本文提出一种融合路径语

义的结构感知注意力实体对齐（Entity Alignment with Path-Integrated Structure-Aware Attention, PISA）模型。该方法首先设计路径语义构建模块，结合路径频率与路径相似度筛选二跳路径，随后引入结构感知的多头注意力机制，在融合图上动态建模实体间的结构交互，提升对齐鲁棒性。

1 相关工作

1.1 基于嵌入的实体对齐方法

早期的实体对齐方法主要依赖于向量空间的表示学习。平移嵌入模型（Translating Embeddings for Modeling Multi-relational Data, TransE）^[22]最早提出以向量平移方式对三元组进行建模，并假设关系可以看作实体之间的向量平移，这为基于嵌入的实体对齐提供了基本框架。MTransE^[15]使用 TransE^[22]对实体和关系进行嵌入，首先将不同知识图谱分别映射到独立的向量空间，随后通过学习跨语言嵌入空间的映射函数，将源图谱的实体表示投射到目标图谱空间，实现跨图谱对齐。联合属性保持嵌入模型（Joint Attribute-Preserving Embedding for Cross-lingual Entity Alignment, JAPE）^[23]提出了一个用于跨语言实体对齐的联合属性保持嵌入模型，该模型将两个知识图谱的结构联合嵌入到统一向量空间中，并进一步利用知识图谱中的属性关联性进行优化。BootEA^[16]引入了自举机制，通过迭代地标记高置信度的对齐实体对作为伪标签参与训练，以缓解标注数据稀疏的问题。在每一轮迭代中，模型根据当前学习状态，动态扩充训练数据，从而实现对齐导向的嵌入表示学习。

1.2 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主要利用图卷积网络（Graph Convolutional Network, GCN）和图注意力网络（Graph Attention Network, GAT）对实体进行邻域特征聚合来构建实体表示。GCN-Align^[18]引入 GCN 对实体邻域结构进行建模，该方法利用预对齐实体对集合，通过训练 GCN 模型将各语言实体嵌入到统一向量空间中，并基于嵌入空间中的实体间距离发现对齐实体对。RDGCN^[19]在此基础上提出了一种关系感知双图卷积网络，该网络通过知识图谱及其对偶关系图之间的注意力交互来整合关系信息，并进一步捕捉邻域结构以学习更好的实体表示。AliNet^[20]引入了远距离邻居这一概念，在 GCN 的基础上采用了注意力机制来突出有用的远距离邻居并减少噪声，采用门控机制对直接邻域信息和远距离邻域信息进行有效聚合。邻域匹配网络（Neighborhood Matching Network for Entity Alignment, NMN）^[24]提出了一种邻域匹配网络，该网络先是采用判别式邻域采样方法为每个实体

提炼出具有区分性的邻域，再采用跨图邻域匹配模块联合编码给定实体对的邻域差异，构建更有效的实体表示。关系感知图注意力网络（Relation-Aware Graph Attention Networks for Global Entity Alignment, RAGA）^[25]在 GAT 的基础上提出了基于关系感知的注意力机制，首先采用基本的邻居聚合获得实体表示，再通过关系感知注意力模块将关系信息融合到实体中，生成增强后的实体表示。双视图门控图神经网络（Dual-view Graph Neural Network with Gating Mechanism for Entity Alignment, DvGNet）^[26]提出了一种双视角图神经网络，首先使用注意力机制分别进行实体交互和关系交互，再通过门控机制对这两个视角的信息进行聚合，得到更准确的实体表示。

近年来，部分研究开始关注二跳邻居或二跳路径信息在实体对齐中的作用。AliNet^[20]在 GCN 的基础上引入远距离邻居（包括二跳邻居），并结合注意力机制突出有效邻居、抑制无关信息，同时利用门控机制融合直接邻居和远距离邻居信息。基于可靠路径推理与关系感知异构图 Transformer 实体对齐模型（Entity Alignment with Reliable Path Reasoning and Relation-Aware Heterogeneous Graph Transformer, RPR-RHGT）^[27]引入了二跳路径，并结合可靠路径推理机制及关系感知异构图 Transformer 增强了实体的表示能力。此外，一些方法开始关注关系表示的独立性和方向性。基于线图的独立关系表示实体对齐模型（Independent Relation Representation With Line Graph for Cross-Lingual Entity Alignment, RALG）^[28]提出基于异构线图的独立关系表示学习框架，并设计三元组聚合机制加强实体与关系的关联。方向感知关系表示实体对齐模型（Directed Relation-Aware Representation Learning for Entity Alignment, DRAEA）^[29]提出双模块框架与方向增强线图模块，联合 GAT 建模结构与定向关系。尽管上述方法在利用二跳路径和远距离邻居方面取得了一定进展，但总体来看，这些方法通常局限于固定一跳或两跳邻域聚合，未充分评估路径的语义一致性，在融合结构与语义信息时易引入冗余路径和语义噪声，从而降低实体表示质量。因此，本文提出了一种融合路径语义的结构感知注意力实体对齐模型，通过融合一跳和筛选后更具有代表性的二跳路径信息，在提升鲁棒性的同时生成更具区分性的实体表示，从而在现有方法基础上进一步提升实体对齐效果。

2 模型设计与实现

2.1 二跳路径的信息价值

跨知识图谱的二跳路径向量相似性可作为实体对齐的强指示信号。以图 1 中的中文图谱路径

“阿里巴巴”→“开发”→“支付宝”→“创始人”→“马云”和英文图谱路径“Alibaba”→“product”→“Taobao”→“CEO”→“Jack Ma”为例，“阿里巴巴”与“Alibaba”是强对齐的头实体，“马云”和“Jack Ma”是强对齐的尾实体。两个路径的关系对具有语义兼容性，即“开发”和“product”相似，“创始人”和“CEO”相似。这种相似性可以在数学形式上量化，基于此可以从二跳路径信息中挖掘出对齐实体。而即使中间实体不同（“支付宝”≠“Taobao”），路径向量仍会收敛至相似表示空间。这种相似性并非偶然，而是因为在不同语言的知识图谱中同一实体的关系结构在向量空间中呈现相似的分布。




图 1 二跳路径示例
Fig.1 Two-hop path example

尽管多跳路径在理论上都可能为实体对齐提供有效信息，但更长的路径并不一定能带来性能上的提升。假设单个知识图谱包含 $|E|$ 个实体，实体平均邻居数为 n ，路径向量嵌入维度为 d 。从计算复杂度来看，当路径长度从二跳扩展至三跳时，时间复杂度和空间复杂度分别由 $O(|E|n^2)$ 与 $O(|E|n^3)$ 膨胀至 $O(|E|n^2d)$ 与 $O(|E|n^3d)$ ，计算和存储开销呈指数级增长，使得模型在大规模知识图谱上难以兼顾效率与可扩展性。同时，二跳路径已能有效补充一跳邻居语义不足的问题，多项研究（如 AliNet^[20]和 RPR-RHGT^[27]等）表明，二跳邻居或二跳路径提升对齐效果方面发挥了关键作用。AliNet^[20]中的实验比较了 1-4 层 GCN 对实体对齐效果的影响，结果表明层数为 2 时模型性能最佳，这表明二跳邻居在信息增益与噪声控制之间取得了较好平衡，三跳及以上路径往往引入了更多冗余和噪声，导致模型整体性能下降。因此本文采用二跳路径信息提升实体嵌入质量。

然而，两跳关系集合中并不是所有的信息都有利于对齐，其中相当一部分包含了冗余信息甚至噪声，而许多稀疏路径、长尾路径往往只在极少数边缘实体附近出现，不适用于大多数邻域信息略为丰富的实体。因此在引入路径信息之前，需要筛选出具备有效信息的二跳路径。而在预对齐实体附近频繁出现的路径往往反映了两个图谱结构的共性，其通用性较强。因此可以采用频率筛选机制保留预对齐实体对之间出现频率较高的路径，并通过计算余弦相似度捕捉信息密度更高

的路径对。

2.2 实体对齐模型框架

为捕捉更多有效信息，我们基于实体邻接三元组，为每个实体构建了所有二跳路径，形成知识图谱的二跳路径集合。我们基于预训练的 fastText 词向量模型对每个词进行嵌入，得到初始的词向量表示。对于词表中未包含的低频词项，我们进一步采用字符级别的 Word2Vec 模型进行补全。在此基础上，通过实体向量推导出关系向量 $\mathbf{r}$ 。

$$\mathbf{r} = [a_1, a_2, \dots, a_{300}] \quad (1)$$

对每一个二跳路径的第一条关系向量和第二条关系向量进行向量拼接，得到知识图谱数据集的全部二跳路径集合：

$$\begin{aligned} P &= \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n\} \\ &= \{[\mathbf{r}_1^1, \mathbf{r}_2^1], [\mathbf{r}_1^2, \mathbf{r}_2^2], \dots, [\mathbf{r}_1^n, \mathbf{r}_2^n]\} \end{aligned} \quad (2)$$




图 2 PISA 模型框架总览图
Fig.2 PISA framework overview

2.3 基于余弦相似度的路径推理

知识图谱中二跳路径数量庞大，直接使用全部路径会引入噪声，降低实体表示的准确性。本文首先基于路径在训练集中的出现频率进行初步筛选，保留结构上具有代表性的候选路径。随后引入语义一致性评估模块，利用余弦相似度衡量不同图谱中候选路径之间的语义相似度，进一步筛选对语义对齐贡献有限的路径，从而提升路径集的质量。

首先对知识图谱中出现的所有路径，统计每条路径出现的次数，选择出现次数高的路径，其余舍弃，则有路径选择函数：

$$\phi([\mathbf{r}_1^i, \mathbf{r}_2^i]) = \begin{cases} 1, & c_i \geq t \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

其中， c_i 为路径 $[\mathbf{r}_1^i, \mathbf{r}_2^i]$ 的累计出现频率， t 为

其中， $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n$ 代表第 $1, 2, \dots, n$ 个二跳路径， $[\mathbf{r}_1^i, \mathbf{r}_2^i]$ 为关系路径向量，下标为 1 代表第一跳路径，下标为 2 代表第二跳路径，上标代表路径序号。

图 2 为 PISA 模型框架总览图。我们首先将两个知识图谱的实体映射到统一的向量空间，为后续对齐提供基础表示；接着对从知识图谱中提取的二跳路径三元组进行语义评估与筛选，通过初步筛选和计算路径的语义相似度，得到信息较为丰富的二跳路径集合；随后将经过筛选的路径三元组以及原始图谱的初始实体嵌入和关系三元组输入到结构感知注意力模块，经过关系嵌入、结构感知注意力、异构消息聚合和聚合实体输出等步骤，综合考虑邻域结构和语义信息生成实体表示；最终，通过训练损失函数更新实体表示，经过不断迭代优化，使跨图谱对应实体在嵌入空间中的相似度最大化，实现精确对齐。

频次阈值，由实验主观确定其经验值，决定频率筛选阶段的筛选条件，初步筛选后，得到二跳路径集合 P_{valid} ：

$$P_{valid} = \{[\mathbf{r}_1^i, \mathbf{r}_2^i] \mid \phi([\mathbf{r}_1^i, \mathbf{r}_2^i]) = 1\} \quad (4)$$

接着对于来自 KG1 的二跳路径 $\mathbf{p}_i^1 = [\mathbf{r}_1^{1,i}, \mathbf{r}_2^{1,i}]$ 和来自 KG2 的二跳路径 $\mathbf{p}_j^2 = [\mathbf{r}_1^{2,j}, \mathbf{r}_2^{2,j}]$ ，计算相似度 $S(\mathbf{p}_i^1, \mathbf{p}_j^2)$ ：

$$S(\mathbf{p}_i^1, \mathbf{p}_j^2) = \frac{1}{2} \left(\frac{\mathbf{p}_i^1 \cdot \mathbf{p}_j^2}{\|\mathbf{p}_i^1\| \|\mathbf{p}_j^2\|} + 1 \right) \quad (5)$$

得到的相似度是仅针对这两个单体二跳路径对的评估，不具代表性，所以在语义价值推理模块中，图谱中每个二跳路径需要和对立图谱中多个路径

进行相似度计算，并综合评估。在实际实践中，由于图谱中的关系信息丰富，得到路径向量集合规模大，带来很大的计算成本，所以该方法在不影响分布特征的情况下进行了采样处理。另外，我们追求二跳路径的价值潜力，因此结果做 Top-K 平均，以关注最佳表现。

如图 3 所示，筛选过程分别对 KG1 和 KG2 两个图谱中每个二跳路径进行语义价值评估。以图谱 1 中的某个路径 p_i^1 为例，首先对 KG2 简单随机抽样得到图谱 2 的二跳路径抽样集合 P_{sample}^2 ， p_i^1 和 P_{sample}^2 中每个二跳路径向量计算余弦相似度 S ，再对得到的多个相似度以上偏率 p_k 进行上偏估计，可得到路径 p_i^1 的评分值 $\text{score}(p_i^1)$ ：

$$\text{score}(p_i^1) = \frac{1}{k_1} \sum_{j=1}^{k_1} \text{TopK}_j(S(p_i^1, P_{sample}^2)) \quad (6)$$

其中 $\frac{1}{k_1} \sum_{j=1}^{k_1} \text{TopK}_j(\cdot)$ 表示取前 k 个数值并求取平均值，即上偏估计， k_1 按 $k_1 = p_k \cdot \dim(P_{sample}^2)$ 确定。

$\text{score}(p_i^1)$ 作为二跳路径 p_i^1 在语义一致上的评估指标。KG1 和 KG2 中的每个路径向量都完成上诉评估后，依据 KG1 二跳路径集合 P^1 和 KG2 二跳路径集合 P^2 中每个路径向量的得分，以筛出率 p_o 筛选出可靠二跳路径集合：

$$P_o = \text{TopK}_{k_2}(P^1 \cup P^2, \text{score}(\cdot)) \quad (7)$$

其中筛出数目 k_2 按 $k_2 = p_o \cdot \dim(P^1 \cup P^2)$ 确定，

$\text{TopK}_{k_2}(A, \text{score}(\cdot))$ 表示对集合 A 中的按 $\text{score}(\cdot)$ 排序，取前 k_2 得到新集合。




图 3 基于余弦相似度的路径推理流程图

Fig.3 Cosine similarity-based path reasoning flowchart

2.4 结构感知注意力网络

该方法使用一种结构感知注意力网络，对实体的邻域信息进行聚合。该网络采用端到端的训练方式，能够自适应地学习实体在不同关系上下文中的动态表示。基于异构图 Transformer (Heterogeneous Graph Transformer, HGT) [30]，本方法将经过路径筛选的二跳路径三元组与原始关系三元组作为输入，使模型能够在实体对齐任务中充分利用路径信息，增强实体对齐能力。当输入是关系三元组时，输出是基于单跳关系的实体嵌入，当输入是路径三元组时，输出是基于两跳关系路径的实体嵌入。该网络架构主要由 4 部分构成：

1) 关系表示构造

传统方法通常直接引入独立的关系嵌入向量，本文则是先基于关系 r 连接的实体特征动态构造关系表示，再将其用于后续注意力计算。关系 r 泛指单跳关系或二跳关系。首先分别对关系 r 连接的所有头实体和尾实体都生成一个聚合实体表示：

$$\tilde{h}_r = \frac{1}{n_r^{(h)}} \sum_{h \in H_r} \beta_h \square e_h^{(l-1)} \quad (8)$$

$$\tilde{t}_r = \frac{1}{n_r^{(t)}} \sum_{t \in T_r} \beta_t \square e_t^{(l-1)} \quad (9)$$

其中， $\tilde{h}_r$ 为聚合后的头实体表示， $n_r^{(t)}$ 为关系 r 连接的头实体集合大小， $e_h^{(l-1)} \in \mathbb{R}^d$ 为第 $(l-1)$ 层输出的头实体嵌入表示，也是第 l 层的输入头实体嵌入表示， H_r 为关系 r 连接的头实体集合， β_h 为权重向量， $\square$ 为逐元素加权操作， e_h 为关系 r 连接的头实体； $\tilde{t}_r$ 为聚合后的尾实体表示， $n_r^{(t)}$ 为关系 r 连接的尾实体集合大小， e_t 为关系 r 连接的尾实体， T_r 为关系连接的尾实体集合， β_t 为权重向量， $e_t^{(l-1)} \in \mathbb{R}^d$ 为第 $(l-1)$ 层的尾实体嵌入表示。

最后获得关系的最终表示：

$$r^{(l)} = \text{ReLU}(\text{Concat}(\tilde{h}_r, \tilde{t}_r)) \quad (10)$$

其中，表示 $\text{Concat}(\cdot)$ 表示向量拼接操作。

2) 结构感知注意力计算

通过每个注意力头独立的线性映射线性变换将 h 和 t 的嵌入表示分别映射为 Key 向量 K_h^i 与 Query 向量 Q_t^i 。

$$K_h^i = W_K^i e_h^{(l-1)} \quad (11)$$

$$Q_t^i = W_Q^i e_t^{(l-1)} \quad (12)$$

其中 W_K^i , W_Q^i 为第 i 个头的投影矩阵, W_K^i , W_Q^i 是投影矩阵, $i \in [1, h_n]$, h_n 为注意力头数。

随后, 将两者拼接后与公式(10)中的 $r^{(i)}$ 在第 i 个头中的嵌入 R_r^i 做逐元素乘积, 以捕捉三元组之间的联合语义模式, 再利用一个共享的注意力向量 a 对上述结果进行投影, 并以 $\sqrt{d_h}$ 执行缩放, $d_h = d/h_n$ 是每个头的维度。再对结果经 LeakyReLU 激活函数处理, 得到公式(13)中未归一化的注意力分数 $\tilde{\alpha}_t^i$; Softmax 函数对 $\tilde{\alpha}_t^i$ 进行归一化, 获得公式(14)中的注意力权重 α_t^i 。

$$\tilde{\alpha}_t^i = -\text{LeakyReLU} \left(\frac{a^T ([K_h^i \parallel Q_r^i] \square R_r^i)}{\sqrt{d_h}} \right) \quad (13)$$

$$\alpha_t^i = \text{Softmax}(\tilde{\alpha}_t^i) \quad (14)$$

3) 异构消息聚合

在构建实体 h 的最终表示前, 融合 h 的邻接实体 t 及边关系 r 包含的语义信息。具体来说, 对于任意一个三元组, 首先将尾实体 t 的第 $l-1$ 层表示 $e_t^{(l-1)} \in \mathbb{R}^d$ 投影为消息向量 V_t^i :

$$V_t^i = W_V^i e_t^{(l-1)} \quad (15)$$

然后将消息向量 V_t^i 与关系嵌入 R_r^i 进行拼接, 构造联合消息表示:

$$m^i = \text{Concat}(V_t^i, R_r^i) \quad (16)$$

再以公式(17)做加权和来更新实体嵌入 $\tilde{e}_h$ 。

$$\tilde{e}_h = \sum_{t \in T_r} \alpha_t^i \cdot m^i \quad (17)$$

通过上述机制, 获得基于单跳关系的实体嵌入 $\tilde{e}_{h,rel}$ 与基于二跳路径更新后的实体嵌入 $\tilde{e}_{h,path}$, 将二者融合得到基于关系和路径信息的实体表示 $\tilde{e}_{h,f}$ 。

$$\tilde{e}_{h,f} = \text{Concat}(\tilde{e}_{h,rel}, \tilde{e}_{h,path}) \quad (18)$$

4) 聚合实体输出

对更新后的实体嵌入 $\tilde{e}_{h,f}$, 先通过 ReLU 激活函数引入非线性变换, 然后通过权重矩阵 W_o 进行线性变换, 应用 Dropout 正则化以减少过拟合的风险, 得到第 i 个注意力头的输出 e_h^i 。

$$e_h^i = \text{Dropout}(W_o \cdot \text{ReLU}(\tilde{e}_{h,f})) \quad (19)$$

将来自 h_n 个注意力头的输出进行拼接, 得到当

前层的实体嵌入表示 e_h 。

$$e_h = \text{Concat}(e_h^1, \dots, e_h^{h_n}) \quad (20)$$

模型在各层引入加权残差连接, 以保留实体的原始结构表示, 同时缓解深层网络中的梯度消失问题。该机制将当前层的实体表示 e_h 与输入层初始嵌入 $e_h^{(0)}$ 进行融合, 形成第 l 层的最终实体表示:

$$e_h^{(l)} = w^{(l)} \cdot e_h + (1 - w^{(l)}) \cdot e_h^{(0)} \quad (21)$$

其中, $w^{(l)}$ 是第 l 层的可学习残差融合权重。

2.5 对齐学习

本文选取曼哈顿距离来衡量候选实体对的相似性。欧氏距离容易在维度增加时出现“集中化效应”, 而曼哈顿距离在高维空间中对单个维度的异常值不敏感, 能够保持正负样本之间更显著的差异性, 增强区分能力。且已经在多项对齐研究(如 NMN^[24]、AliNet^[20]和 RAGA^[25]等)中采用。

给定一个跨图候选对齐实体对, 其嵌入向量分别为 e^1 和 e^2 , 其距离定义如下:

$$d(e^1, e^2) = \|e^1 - e^2\|_{L_1} \quad (22)$$

其中, e^1 为 KG1 中基于关系三元组 P_{rel} 和路径三元组 P_{path} 得到的实体嵌入, e^2 为 KG2 中基于关系三元组 P_{rel} 和路径三元组 P_{path} 得到的实体嵌入。

采用基于负采样的对比损失函数训练模型判别正负对齐样本。损失函数的设计包括关系嵌入损失 L_{rel} 和路径嵌入损失 L_{path} 。 L_{rel} 和 L_{path} 分别定义为:

$$L_{rel} = \sum_{\substack{(p,q) \in L, \\ (p',q') \in L_{rel}'}} \max\{0, \delta_{rel}\} \quad (23)$$

$$L_{path} = \sum_{\substack{(p,q) \in L, \\ (p',q') \in L_{path}'}} \max\{0, \delta_{path}\} \quad (24)$$

$$\delta_{rel} = d_{rel}(p, q) - d_{rel}(p', q') + \gamma_1 \quad (25)$$

$$\delta_{path} = d_{path}(p, q) - d_{path}(p', q') + \gamma_1 \quad (26)$$

其中, L_{rel} 和 L_{path} 分别是基于关系嵌入和基于

路径嵌入的正对集合, L_{rel}' 和 L_{path}' 分别是基于关系嵌入和基于路径嵌入的负对集合,

γ_1, γ_2 为超参数且为正数。

设定一个平衡参数 λ (0 到 1) 调整 L_{rel} 和

L_{path} 两部分损失的权重:

$$L = L_{rel} + \lambda L_{path} \quad (27)$$

通过最小化损失函数 L ，模型能够学习到在嵌入空间中拉近真实对齐实体对、远离错误对齐对的表示。训练完成后，在测试阶段，模型根据测试集中待对齐实体对的嵌入向量间的距离进行匹配预测，再采用 Hits@k 等指标评估对齐性能。

3 实验

3.1 数据集和评价指标

本文使用公开的跨语言数据集 DBP-15K^[31]（基于 DBpedia 构建）和 WK31-15K（基于 Wikidata 构建）来评估本文所提模型在实体对齐任务上的有效性。各子数据集包含的实体数量，关系总数，关系三元组总数如表 1 所示。其中，DBP-15K 有 3 对跨语言数据子集：日文-英文、法文-英文和中文-英文。WK31-15K 有 4 对跨语言子数据集：英文-德文（V1）、英文-德文（V2）、英文-法文（V1）、英文-法文（V2）。V1 是稀疏集，V2 是 V1 的两倍密度。另外，每对子集都包含已经对齐的 15K 对实体对。

表 1 数据集资料统计
Tab.1 Dataset statistics

数据集	语言	实体数量	关系总数	三元组总数
日文-英文 (DBP)	日文	65 744	2 043	164 373
	英文	95 680	2 096	233 319
法文-英文 (DBP)	法文	66 858	1 379	192 191
	英文	105 889	2 209	278 590
中文-英文 (DBP)	中文	66 469	2 830	153 929
	英文	98 125	2 317	237 674
英文-德文 (WK31 V1)	英文	15 000	215	47 676
	德文	15 000	131	50 419
英文-德文 (WK31 V2)	英文	15 000	169	84 867
	德文	15 000	96	92 632
英文-法文 (WK31 V1)	英文	15 000	267	47 334
	法文	15 000	210	40 864
英文-法文 (WK31 V2)	英文	15 000	193	96 318
	法文	15 000	166	80 112

为了更加全面地评估所提模型在实体对齐任务中的性能，本文使用当前实体对齐领域中常用的两类评价指标：Hit@k 和平均倒数排名（Mean Reciprocal Rank, MRR）。Hit@k 衡量目标实体是否出现在预测结果的前 k 名之内，计算方式为：

$$\text{Hit@k} = \frac{1}{N} \sum_{i=1}^N I(\text{rank}_i \leq k) \quad (28)$$

其中， N 是测试样本的总数， rank_i 表示第 i 个样本中目标实体在预测排序列表中的排名，Hit@k 表示在所有测试样本中，有 Hit@k 的

样本在前 k 个预测结果中找到了正确的实体。

$I(\cdot)$ 是指示函数，当条件为真时取值为 1，否则为 0。Hit@k 越高，模型对目标实体的命中能力越强，特别是 Hits@1 能反映模型是否能将正确实体置于首位。MRR 则更注重排序质量，MRR 计算方式为：

$$\text{MRR} = \frac{1}{N} \sum_{i=1}^N \frac{1}{\text{rank}_i} \quad (29)$$

其中， $\text{rank}_i \leq k$ 表示第 i 个测试实体对中，正确对齐实体在预测排序列表中的排名， N 为测试集的实体对总数。MRR 更加关注正确实体在整体排序中的相对位置，排名越靠前得分越高。因此，MRR 能综合反映模型的排序性能。Hit@k 和 MRR 两者结合能够更全面地评估模型在实体对齐任务中的效果。

3.2 实验设置

本研究的实验配置相关信息如表 2 所示。对于 DBP-15K 和 WK31-15K 每个子集已经对齐的 15k 种子对实体对，其 20% 用于训练，10% 用于验证，70% 用于测试，其他实体作为负样本参与训练。我们为每对预对齐实体对均匀分布随机采样 50 个负样本对，学习率设置为 0.001，transformer 注意力头数为 4，最大训练轮次为 4000，设早停机制，对于路径训练，超过 40 轮次效果没有提升，触发早停，非路径设为 30。使用 Adam 优化器对参数进行优化。服务器详情：GPU 为 NVIDIA GeForce RTX 4070，CPU 为第 12 代 Intel(R) Core(TM) i5- 12600KF 处理器。本文实验在 PyTorch 3.9 深度学习框架下实现。实验的运行效率和内存占用情况上，单进程的路径筛选预处理大概耗时 5 分 30 秒，内存占用大概 10GB；训练阶段大概耗时 2 分钟，显存占用大概 12GB。

表 2 模型参数及实验环境配置

Tab.2 Hyperparameters and experimental environment	
项目	参数
种子实体对	15 000
单次负样本采样对	50
学习率	0.001
注意力头数 h_n	4
最大 epoch	4 000
Early stop	True
优化器	Adam
GPU	NVIDIA GeForce RTX 4070
CPU	Intel(R) Core(TM) i5- 12600KF
Python 版本	3.9
深度学习框架	PyTorch 2.4

3.3 实验结果

对于和 DBP-15K 和 WK31-15K，我们将所提模型与目前的几种最先进的实体对齐模型进行了比较。在这些实体对齐的基线模型中：MTransE^[15]、JAPE^[23]、BootEA^[16]、属性嵌入模型（Entity Alignment between Knowledge Graphs

using Attribute Embeddings, AttrE) [32]都是基于 TransE[22]扩展的翻译模型，主要通过引入多语言映射函数、联合编码实体的属性与结构信息、或采用自监督学习框架等来增强实体表示；RDGCN[19]、NMN[24]都是基于图神经网络扩展的模型，通过图卷积或跨图注意机制等充分挖掘实体邻域拓扑结构中的潜在关联；RAGA[25]和 RPR-RHGT[27]则是引入了关系感知注意力，有效提升了模型在异构图谱中的实体表示能力与对齐性能。

表 3 和表 4 分别展示了所提模型 PISA 和其

他实体对齐模型在 DBP-15K 和 WN31-15K 两个公开实体对齐数据集上的实验结果。带“*”的 RPR-RHGT[27]为统一实验环境下复现所得，AliNet结果数据取自原文，PISA 为本文提出的模型，RALG 提出独立的关系表示学习模块来提高实体与关系的关联并利用，其余基线模型结果源自 RPR-RHGT[27]论文中的结果。表格中加粗的数据为最优结果，加下划线的为次优结果。评估指标包括 Hits@1、Hits@5 和 MRR，分别用于衡量模型在精确对齐、候选匹配和排序整体性能方面的表现。

表 3 PISA 在 DBP-15K 上的性能表现
Tab.3 PISA performance on DBP-15K

模型	法文-英文			日文-英文			中文-英文		
	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR
MTransE	19.74	40.37	0.297	20.41	40.52	0.303	20.89	42.09	0.311
JAPE	22.98	45.22	0.336	23.86	44.50	0.340	26.46	50.30	0.378
BootEA	57.61	77.27	0.666	52.71	71.89	0.616	55.45	73.72	0.639
AttrE	40.21	66.09	0.522	35.96	60.31	0.475	16.02	33.29	0.250
RDGCN	80.88	88.08	0.842	81.22	87.98	0.844	62.11	73.88	0.676
NMN	83.46	90.01	0.864	84.29	90.47	0.870	65.16	76.64	0.702
AliNet	55.20	\	0.657	62.80	\	0.831	53.90	\	0.628
RAGA	85.27	93.17	0.889	79.29	89.12	0.838	<u>68.72</u>	82.55	<u>0.750</u>
*RPR-RHGT	85.87	<u>93.76</u>	0.894	86.92	<u>92.04</u>	0.900	65.53	80.49	0.724
RALG	94.83	\	0.964	<u>87.23</u>	\	0.906	83.54	\	0.876
PISA	<u>87.77</u>	95.28	<u>0.911</u>	87.68	93.95	<u>0.904</u>	67.32	<u>81.52</u>	0.739

表 4 PISA 在 WK31-15K 上的性能表现
Tab.4 PISA performance on WK31-15K

模型	英文-德文 (V1)			英文-德文 (V2)			英文-法文 (V1)			英文-法文 (V2)		
	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR
MTransE	30.7	51.8	0.407	19.3	35.2	0.274	24.7	46.7	0.351	24.0	43.6	0.336
JAPE	28.8	51.2	0.394	16.7	32.9	0.250	26.2	49.7	0.372	29.2	52.4	0.402
BootEA	67.5	82.0	0.740	83.3	91.2	0.869	50.7	71.8	0.603	66.0	85.0	0.745
AttrE	51.7	68.7	0.597	65.0	81.6	0.726	48.1	67.1	0.569	53.5	74.6	0.631
RDGCN	81.98	87.65	0.846	81.61	86.98	0.841	80.53	87.66	0.837	87.12	92.88	0.898
NMN	85.57	90.45	0.877	85.18	89.57	0.871	85.12	90.74	0.876	89.29	94.28	0.915
RAGA	87.90	94.28	0.908	81.34	89.15	0.849	82.71	91.55	0.867	88.95	95.36	0.919
*RPR-RHGT	<u>89.05</u>	<u>94.72</u>	0.916	<u>91.69</u>	<u>96.20</u>	<u>0.938</u>	<u>86.89</u>	<u>94.03</u>	0.900	<u>92.62</u>	<u>96.82</u>	<u>0.945</u>
PISA	90.83	95.86	0.932	93.70	97.78	0.947	88.35	94.23	0.914	93.89	97.77	0.954

分析表 3 可知，PISA 相较于基于嵌入的 (MtransE, JAPE, BootEA, AttrE) 和基于 GNN (RDGCN, NMN, RAGA) 的几种方法有显著优势。在法文-英文数据集中，PISA 在 Hits@1、Hits@5、MRR 指标上相较于 RPR-RHGT 分别提高了 1.90%、1.52%、0.017；在日文-英文数据集中，分别提高了 0.76%、1.91%、0.004；在中文-英文数据集中，分别提高了 1.78%、1.14%、0.016。相比于 RALG，PISA 的精确对齐性能 (Hit@1) 在日文-英文数据集中分别提高了 0.45%。从语言特点来看，法文-英文子集中实体命名方式差异尤为明显，因为法语实体常包含括号消歧信息、冠词与修饰语顺序差异，例如“Louis XIV (roi de France)”与英文的“Louis XIV of France”，这类命名冗余和结构变异增加了对齐的难度，但 PISA 在法文-英文子集上仍然取得了显著的指标提升，表明该方法在语言差异较大、命名方式不一致的情形下，依然能够构建出具有语义一致性的实体表示。相比之下，日文-英文与中文-英文子集中的实体名称虽然语言差异较大，但多采用标准译名或音译形式，如

“乔布斯”-“Steve Jobs”，表面命名异构程度较低。但是在日文-英文与中文-英文子集中，图谱结构相对稀疏，实体邻居信息不充分，路径上下文信息受限，而 PISA 依然维持了领先的对齐效果，显示出其路径筛选与结构融合机制在处理异构图谱方面的稳定性。RALG 在法文-英文、中文-英文数据集表现优异，但这是在专门设计独立模块来对关系路径表征学习的成果，而 PISA 仅在预处理阶段需要对二跳路径预先筛选，规避了模型训练成本。

分析表 4 可知，在英文-德文(V1)数据集中，PISA 在 Hits@1、Hits@5、MRR 指标上比 RPR-RHGT 模型分别提高了 1.78%、1.14%、0.016；在英文-德文 (V2) 数据集中，分别提高了 2.01%、1.58%、0.009；在英文-法文 (V1) 数据集中，分别提高了 1.46%、0.20%、0.014；在英文-法文 (V2) 数据集中，PISA 在 Hits@1、Hits@5、MRR 指标上比 RPR-RHGT 模型分别提高了 1.27%、0.95%、0.009。PISA 在四个子集实现了全面领先，该数据集中实体数量较少、语义路径分布不均，图谱结构差异，PISA 在此场景

下依然表现稳定，表明其具有良好的结构适应能力。

表 5 和表 6 为余弦相似度筛选对 PISA 在 DBP-15K 和 WK31-15K 上数据集上的影响。PISA w/o fs ss 表示“随机筛选 50%”，即不采用频次筛选

和余弦相似度路径筛选而是直接保留 50% 的路径；PISA w/o fs 为随机筛选 50% 后再经历一次余弦相似度路径筛选，我们提出的路径语义评估与筛选机制。

表 5 余弦相似度筛选对 PISA 在 DBP-15K 上的影响
Tab 5 Impact of cosine similarity-based filtering on PISA performance (DBP-15K)

模型	法文-英文			日文-英文			中文-英文		
	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR
PISA w/o fs ss	82.74	90.43	0.889	86.13	92.29	0.887	65.21	78.19	0.713
PISA w/o fs	84.43	91.59	0.892	86.48	92.40	0.891	66.92	80.82	0.727
PISA	87.77	95.28	0.911	87.68	93.95	0.904	67.32	81.52	0.739

表 6 余弦相似度筛选对 PISA 在 WK31-15K 上的影响
Tab 6 Impact of cosine similarity-based filtering on PISA performance (WK31-15K)

模型	英文-德文 (V1)			英文-德文 (V2)			英文-法文 (V1)			英文-法文 (V2)		
	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR	Hit@1	Hit@5	MRR
PISA w/o fs ss	88.36	93.08	0.907	<u>91.48</u>	<u>95.26</u>	<u>0.924</u>	86.61	<u>93.68</u>	0.898	92.12	95.80	<u>0.943</u>
PISA w/o fs	90.32	95.49	0.926	89.37	94.38	0.920	88.34	93.27	0.908	90.22	94.69	0.915
PISA	90.83	95.86	0.932	93.70	97.78	0.947	88.35	94.23	0.914	93.89	97.77	0.954

总体来看，PISA 在所有语言对上均优于 PISA w/o fs ss 及 PISA w/o fs，表现出显著提升。如表 5 所示，DBP-15K 在法文-英文，Hit@1 分别提升了 5.03%、3.34%，Hit@5 分别提升了 4.85%、3.69%，MRR 分别提升了 0.022、0.019；在日文-英文任务中，Hit@1 提升了 1.55%、1.20%，Hit@5 分别提升了 1.66%、1.55%，MRR 分别提升了 0.017、0.013；而在中文-英文任务中，Hit@1 分别提升了 2.11%、0.40%，Hit@5 分别提升了 3.33%、0.70%，MRR 分别提升了 0.026、0.012，说明 PISA 在不同语言场景下均能保持有效性。如表 6 所示，在 WK31-15K 对齐任务中，PISA 同样取得了稳定改进。英文-德文 (V1) 中，Hit@1 分别提升了 2.47%、0.51%，Hit@5 分别提升了 2.78%、0.37%，MRR 分别提升了 0.025、

0.006；英文-德文 (V2) 中，Hit@1 分别提升了 2.22%、4.33%，Hit@5 分别提升了 2.52%、3.40%，MRR 提升了 0.023、0.027；英文-法文 (V1) 中，Hit@1 分别提升了 1.74%、0.01%，Hit@5 提升了 0.55%、0.96%，MRR 分别提升了 0.016、0.006；英文-法文 (V2) 中，Hit@1 分别提升了 1.77%、3.67%，Hit@5 分别提升了 1.97%、3.08%，MRR 提升了 0.011、0.039。这些结果表明，引入基于余弦相似度的路径筛选机制可以有效提升实体对齐性能，增强模型对邻居路径采样率变化的鲁棒性，同时在不同语言对和资源条件下均能取得稳定的性能增益。

图 4 和图 5 分别展示了 PISA 在不同的 p_k 和 p_o 下的对齐性能 (Hit@1)。




图 4 不同 p_k 预设时 PISA 对齐性能
Fig.4 PISA alignment performance under different p_k




图 5 不同 p_o 预设时 PISA 对齐性能
Fig.5 PISA alignment performance under different p_o

整体来看, PISA 在多数语言对上对 p_k 和 p_o 的变化表现出较强的稳定性, 说明该方法对邻居路径采样率的鲁棒性较高。具体如图 4 所示, 在 DBP-15K 数据集上, 三个子集的 Hit@1 得分随 p_k 的变化波动较小, 整体保持稳定: 法文-英文和日文-英文子集均维持在约 88%, 中文-英文子集约为 67.5%。在 WK31-15K 数据集中, 法文-英文 (V1) 表现较为平稳, 其他子集随 p_k 的变化有轻微波动。其中, 法文-英文 (V1) 维持在约 88%, 德文-英文 (V1) 在 $p_k=0.3$ 时取得较高对齐性能 90.63%, 德文-英文 (V2) 在 $p_k=0.2$ 时表现最佳, 达到 93.70%, 法文-英文 (V2) 在 $p_k=0.2$ 时取得最佳性能 93.89%。图 5 显示, 在 DBP-15K 上, 三种子集下的对齐性能随 p_o 保持稳定: 法文-英文维持在约 88%, 日文-英文维持在约 88%, 中文-英文在约 67.5%。在 WK31-15K 数据集上, 法文-英文 (V1) 和德文-英文 (V2) 的 Hit@1 得分表现较为平稳, 其他子集的随 p_o 的变化稍有波动。其中, 法文-英文 (V1) 维持在约 88%, 德文-英文 (V2) 维持在约 93.50%。德文-英文 (V1) 在 $p_o=0.8$ 时取得较高对齐性能 90.63%, 法文-英文 (V2) 在 $p_o=0.8$ 时表现最佳, 达到 93.89%。

综上所述, PISA 在多数跨语言数据集对齐任务中展现出较强的稳定性, 并在适当的采样率设置下能够取得更优的性能。

如图 6, 本文比较了使用平均值, 最大值和 Top-K 平均来计算路径语义评分时的性能, Top-K 平均相比其他有较明显优势, 验证了使用 Top-K 平均来做路径价值评估估计的优势。




图 6 不同路径语义评估方式的性能对比
Figure 6 Performance comparison of different path semantic evaluation methods

进一步分析表明, 路径语义筛选模块通过对频次与嵌入语义的一致性联合评估, 有效过滤了冗余路径和低价值关系组合, 提升了结构语义的辨识度; 结构感知注意力模块则在融合邻域与路径信息时, 强化了高相关路径对实体表示的贡献。这两个机制的协同作用, 不仅提高了实体语义表示的判别能力, 也增强了模型对复杂结构的适应能力。

综上所述, PISA 模型在多个语言对与结构

分布场景中均展现出稳定的对齐效果, 验证了其在提升跨图谱实体语义表达、增强上下文感知能力以及应对图谱异构性方面的综合优势。

4 结论

提出了一种融合路径语义的结构感知注意力机制的实体对齐模型 PISA, 通过引入基于路径频率与语义相似度的路径筛选策略, 有效挖掘了实体邻域中的高质量多跳语义路径; 同时, 结构感知的多头注意力机制进一步整合了实体的邻接结构与语义上下文信息, 获得了更具判别性的实体表示。实验结果表明, PISA 在跨语言数据集 DBP-15K 和 WK31-15K 上的表现优于多个对比方法。例如, 在 DBP-15K 日文-英文任务中, PISA 的 Hits@5 达到 93.95%, 较表现最好的 RPR-RHGT 提升 1.91%; 在 WK31-15K 英-德 (V2) 任务中, Hits@1 达到 93.70%, 优于所有基线模型, 较以往最优模型提升 2.01%, 进一步验证了所提方法的有效性。

本研究在一定程度上解决了路径冗余和语义不一致等挑战, 但仍存在路径挖掘成本较高、模型训练效率有待提高等问题。此外, 本文方法主要在 15K-100K 规模的跨语言实体对齐数据集上进行了验证, 其在百万级及以上大规模知识图谱, 以及增量式实体对齐场景下的运行效率与扩展性仍有待进一步评估。未来的研究可从以下几个方面展开: (1) 引入图神经网络的稀疏化机制或可学习路径采样策略, 以提高大规模图谱上的路径筛选效率; (2) 探索面向增量式实体对齐场景的路径更新与模型快速调整机制, 降低重复计算成本; (3) 在保证语义相关性与可计算性的前提下, 尝试将路径长度扩展至三跳, 并引入置信度评估机制, 进一步挖掘深层次结构信息, 增强实体表示, 提高在异构知识图谱中的实体对齐效果。

参考文献 (References):

- [1] CAO J, FANG J, MENG Z, et al. Knowledge graph embedding: A survey from the perspective of representation spaces[J]. ACM Computing Surveys, 2024, 56(6): 1-42.
- [2] 张天成, 田雪, 孙相会, 等. 知识图谱嵌入技术研究综述[J]. 软件学报, 2023, 34(1): 277-311.
ZHANG Tiancheng, TIAN Xue, SUN Xianghui, et al. Overview on knowledge graph embedding technology research[J]. Journal of Software, 2023, 34(1): 277-311.
- [3] GE X, WANG Y C, WANG B, et al. Knowledge graph embedding: An overview[J]. APSIPA Transactions on Signal and Information Processing, 2024, 13(1).
- [4] YU W, ZHU C, LI Z, et al. A survey of knowledge-enhanced text generation[J]. ACM Computing Surveys, 2022, 54(11s): 1-38.
- [5] ZHANG J, ZAIN A M, ZHOU K, et al. A review of recommender systems based on knowledge graph embedding[J]. Expert Systems With Applications, 2024, 250: 123876.

- [6] WANG Z, YU Q, WANG N, et al. Survey of intelligent question answering research based on knowledge graph[J]. Computer Engineering and Applications, 2020, 56(23): 1-11.
- [7] CHEN Z, ZHANG Y, FANG Y, et al. Knowledge graphs meet multi-modal learning: A comprehensive survey[EB/OL]. <https://arxiv.org/abs/2402.05391>, 2024-02-16.
- [8] CAO Y, ZHAO H, CHENG Y, et al. Survey on large language model-enhanced reinforcement learning: Concept, taxonomy, and methods[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024.
- [9] 郑强, 许振彬. 面向特种设备的大语言模型-知识图谱双向推理优化与幻觉抑制方法[J]. 数据采集与处理, 2025, 40(3): 647-658.
- [10] ZHENG Qiang, XU Zhenbin. LLM-KG bidirectional inference optimization and hallucination suppression for special equipment[J]. Journal of Data Acquisition and Processing, 2025, 40(3): 647-658.
- [11] ZHONG L, WU J, LI Q, et al. A comprehensive survey on automatic knowledge graph construction[J]. ACM Computing Surveys, 2024, 56(4): 1-62.
- [12] VERGARA I V, LEE L C. A schematic review of knowledge reasoning approaches based on the knowledge graph[J]. Journal of Enterprise and Business Intelligence, 2023, 3(3): 179-189.
- [13] ZHANG M, LI Y, LI S, et al. Knowledge graph-enhanced hierarchical reinforcement learning for interactive and explainable recommendation[J]. IEEE Access, 2024.
- [14] 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): 229.
- [15] LIU J, LAN R, DU Y, et al. Big data fusion with knowledge graph: A comprehensive overview[J]. Applied Intelligence, 2025, 55(7): 672.
- [16] CHEN M H, TIAN Y T, YANG M H, et al. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne: IJCAI, 2017: 1511-1517.
- [17] 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. Stockholm: IJCAI, 2018: 4396-4402.
- [18] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24.
- [19] 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: 349-357.
- [20] WU Y T, LIU X, FENG Y S, et al. Relation-aware entity alignment for heterogeneous knowledge graphs[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao: IJCAI, 2019: 5278-5284.
- [21] 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(01): 222-229.
- [22] MAO X, WANG W, WU Y, et al. Boosting the speed of entity alignment 10x: Dual attention matching network with normalized hard sample mining[C]//Proceedings of the Web Conference 2021. 2021: 821-832.
- [23] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data[J]. Advances in Neural Information Processing Systems, 2013, 26.
- [24] SUN Z, HU W, LI C. Cross-lingual entity alignment via joint attribute-preserving embedding[C]//International Semantic Web Conference. Cham: Springer International Publishing, 2017: 628-644.
- [25] WU Y, LIU X, FENG Y S, et al. Neighborhood matching network for entity alignment[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020: 6477-6478.
- [26] ZHU R, MA M, WANG P. RAGA: Relation-aware graph attention networks for global entity alignment[C]//Pacific-Asia Conference on Knowledge Discovery and Data Mining. Cham: Springer International Publishing, 2021: 501-513.
- [27] LI L, DONG J, QIN X. Dual-view graph neural network with gating mechanism for entity alignment[J]. Applied Intelligence, 2023, 53(15): 18189-18204.
- [28] CAI W S, MA W J, ZHAN J Y, et al. Entity alignment with reliable path reasoning and relation-aware heterogeneous graph transformer[C]//Proceedings of the 31st International Joint Conference on Artificial Intelligence. Vienna: IJCAI, 2022: 1930-1937.
- [29] ZHANG Y, WU J, YU K, et al. Independent relation representation with line graph for cross-lingual entity alignment[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(11): 11503-11516.
- [30] LI M, DU Z, LIU H, et al. DRAEA: Directed relation-aware representation learning for entity alignment [EB/OL]. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5360291, 2025-07-21.
- [31] HU Z, DONG Y, WANG K, et al. Heterogeneous graph transformer[C]//Proceedings of the web conference 2020. 2020: 2704-2710.
- [32] 张富, 杨琳艳, 李健伟, 等. 实体对齐研究综述[J]. 计算机学报, 2022, 45(6): 1195-1225.
- [33] ZHANG Fu, YANG Linyan, LI Jianwei, et al. An overview of entity alignment methods[J]. Chinese Journal of Computers, 2022, 45(6): 1195-1225.
- [34] TRISEDA B D, QI J, ZHANG R. Entity alignment between knowledge graphs using attribute embeddings[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019, 33(01): 297-304.

作者简介:



刘慧 (1999-), 女, 硕士研究生, 研究方向: 自然语言处理。
Email: 15374382170@163.com。



邵玉斌 (1970-), 通信作者, 男, 教授, 研究方向: 无线通信技术, 自然语言处理, 信号处理。
Email: 12309070@kust.edu.cn。



杜庆治 (1977-), 男, 高级实验师, 研究方向: 通信与信息系统。



朵琳(1974-), 女, 副教授, 研究方向: 智能信息处理、智能通信。



张贻涛(1981-), 男, 高级工程师, 研究方向: 媒体融合、数字文化。