

基于异构图注意力网络的实体对齐^{*}

孙琛琛^{1,2}, 金钰媛^{1,2}, 申德荣³, 聂铁铮³, 寇月³

¹(长安大学, 陕西 西安 710018)

²(天津理工大学, 天津 300384)

³(东北大学, 辽宁 沈阳 110189)

通信作者: 孙琛琛, E-mail: suncc_db@163.com



摘要: 实体对齐 (entity alignment, EA) 旨在寻找不同知识图谱 (knowledge graph, KG) 中等价实体。目前, 基于嵌入的 EA 方法存在以下局限性。首先, KG 中的异构结构没有完全建模。其次, 文本信息的使用受限于词嵌入。第三, 对齐推理算法缺乏探索。针对上述限制, 提出基于异构图注意力网络的实体对齐方法 (heterogeneous graph attention network for entity alignment, HGAT-EA)。HGAT-EA 包括两个通道, 一个用于学习结构嵌入, 另一个用于学习字符级语义嵌入。第 1 个通道采用异构图注意力网络 (heterogeneous graph attention network, HGAT)。HGAT 充分利用了异构结构和关系三元组来学习实体嵌入。第 2 个通道是利用字符级字面量来学习字符级语义嵌入。HGAT-EA 通过多通道考虑多个视图, 并通过 HGAT 充分利用异构结构。HGAT-EA 考虑了 3 种不同的对齐推理算法。实验结果证明了该方法的有效性, 进一步结合实验结果对 HGAT-EA 的不同组件进行详细分析, 并给出相应的结论。

关键词: 实体对齐; 知识图谱融合; 异构图注意力网络; 表示学习; 数据集成

中图法分类号: TP18

中文引用格式: 孙琛琛, 金钰媛, 申德荣, 聂铁铮, 寇月. 基于异构图注意力网络的实体对齐. 软件学报, 2025, 36(11): 5197-5212. <http://www.jos.org.cn/1000-9825/7371.htm>

英文引用格式: Sun CC, Jin YY, Shen DR, Nie TZ, Kou Y. Heterogeneous Graph Attention Network for Entity Alignment. Ruan Jian Xue Bao/Journal of Software, 2025, 36(11): 5197-5212 (in Chinese). <http://www.jos.org.cn/1000-9825/7371.htm>

Heterogeneous Graph Attention Network for Entity Alignment

SUN Chen-Chen^{1,2}, JIN Yu-Yuan^{1,2}, SHEN De-Rong³, NIE Tie-Zheng³, KOU Yue³

¹(Chang'an University, Xi'an 710018, China)

²(Tianjin University of Technology, Tianjin 300384, China)

³(Northeastern University, Shenyang 110189, China)

Abstract: Entity alignment (EA) aims to identify equivalent entities across different knowledge graph (KG). Embedding-based EA methods still have several limitations, listed below. First, the heterogeneous structures within KGs are not fully modeled. Second, the utilization of text information is constrained by word embeddings. Third, alignment inference algorithms are underexplored. To address these limitations, this study proposes a heterogeneous graph attention network for entity alignment (HGAT-EA). HGAT-EA consists of two channels: one for learning structural embeddings and the other for learning character-level semantic embeddings. The first channel employs a heterogeneous graph attention network (HGAT), which fully leverages heterogeneous structures and relation triples to learn entity embeddings. The second channel utilizes character-level literals to learn character-level semantic embeddings. HGAT-EA incorporates multiple views through these channels and maximizes the use of heterogeneous structures through HGAT. HGAT-EA introduces three

* 基金项目: 国家自然科学基金 (62002262, 62172082, 62072086, 62072084)

收稿时间: 2024-04-18; 修改时间: 2024-08-26; 采用时间: 2024-12-01; jos 在线出版时间: 2025-05-22

CNKI 网络首发时间: 2025-05-23

alignment inference algorithms. Experimental results validate the effectiveness of HGAT-EA. Following these results, we provide detailed analyses of the various components of HGAT-EA and present the corresponding conclusions.

Key words: entity alignment (EA); knowledge graph (KG) fusion; heterogeneous graph attention network (HGAT); representation learning; data integration

1 引言

知识图谱 (knowledge graph, KG)^[1]是由节点和关系组成的图形模型,本质上可以被视为异构图.知识图谱广泛应用于推荐系统^[2]、信息提取^[3]、问答^[4]等领域.实体对齐 (entity alignment, EA) 识别不同 KG 中指代现实世界同一对象的实体,是 KG 融合的基础.实体对齐^[5]通常分为两步,第 1 步是知识图谱表示学习,将 KG 中的实体转化到向量空间中,使得具有相似语义的实体在向量空间中具有较近的距离.第 2 步是对齐推理,利用学习到的实体嵌入进行实体是否对齐地判断.

目前基于嵌入的 EA 方法取得了可喜的成果,一些方法^[6-8]利用 TransE^[9]的思想来进行对齐,这些方法把关系视作头实体到尾实体的平移,但对多步路径信息处理能力弱.另一些方法^[10-12]基于 GCN 的思想来获取实体的邻域信息辅助对齐,能够有效地处理多步路径信息.但 KG 拥有大量的多视图信息,这些方法在多视图信息探索上仍然存在局限性.首先,目前的方法只考虑了 KG 中的关系信息,而没有考虑 KG 中实体类型信息,没有充分利用 KG 本身携带的异构信息用于 EA.为此需要探索如何系统地将异构结构融入 KG 嵌入中.在图 1 中,KG 包含 3 种实体类型 (“国家”“人”和“公司”) 和两种关系 (“拥有者”和“出生地”). EA 方法不仅需要考虑三元组 (例如, <钢铁侠, 出生地, 美国>), 还需要考虑不同实体类型 (例如, “人”和“国家”) 和不同关系 (例如, “拥有者”和“出生地”) 的特征分布差异.其次,部分方法^[13-16]对实体名称信息的使用局限于将其转换为词嵌入后作为实体嵌入的初始化参数.但这个方式受限于采用的词嵌入模型效果,并且面临着未登录词 (out-of-vocabulary, OOV) 问题.为此需要寻找一个能够更有效地利用实体名称信息的方法.最后,有些方法^[16-22]在进行对齐推理的步骤时,仅进行本地推理,即采用简单的最近邻搜索算法来获取对齐结果.但 EA 过程中会出现个别实体被大量实体判定为最近邻,导致对齐准确度下降.因此对齐推理算法需要进一步探索.一个好的 EA 方法应该采用更可靠的对齐推理算法,以获得准确的对齐结果.




图 1 EA 的例子

为了解决上述问题,本文提出了一个框架: HGAT-EA (heterogeneous graph attention network for entity alignment). HGAT-EA 考虑了 2 个通道,共涉及 4 个不同的视图.为了解决第 1 个限制,本文设计了异构图注意力网络 (heterogeneous graph attention network, HGAT). HGAT 包括元关系三元组 (<源实体类型、关系、目标实体类型>),用于缓解不同类型实体的分布差异.针对第 2 个限制,本文利用 Bi-gram 统计信息避免 OOV 问题.针对最后一个限制,本文引入了 3 种不同的对齐推理算法,包括贪婪搜索 (greedy search)、跨域相似性局部扩展 (cross-domain similarity local scaling, CSLS)^[23]和 Sinkhorn^[24].实验验证了 HGAT-EA 的性能.

本文主要贡献如下.

(1) 提出 HGAT-EA 框架, HGAT-EA 考虑了 4 种不同的视图,即实体名称、实体类型、KG 结构和字符级字面量.此外, HGAT-EA 还提供了 3 种不同的对齐推理算法.

(2) 提出异构图注意力网络, HGAT. HGAT 能有效提取异构结构中已对齐实体的相似性特征.在 HGAT 中,不同类型的实体和边可以保持各自特定的向量空间.同时,不同类型的实体仍然可以交互和传递信息,而不受分布差异的限制.

(3) 使用字符级字面量来学习字符级语义嵌入. 这一通道是处理文本信息的一种简单而有效的方法.

(4) 通过实验验证 HGAT-EA 的有效性. HGAT-EA 在 3 个公开数据集上取得了优异的性能. 本文还进一步对 HGAT-EA 组件进行了详细的实验分析, 并对超参数的影响进行了探索.

本文第 2 节介绍与本文方法相关的研究工作. 第 3 节展示本文提出的方法框架并介绍框架中应用的相关技术. 第 4 节展示实验实现细节以及实验结果, 并对实验结果进行了深入分析. 第 5 节总结本文的主要工作.

2 相关工作

基于嵌入的 EA 方法可分为两类: 仅利用图结构信息的 EA 和使用实体的附加信息的 EA.

仅使用图结构信息的 EA 方法: MTransE^[6]采用 TransE^[9]在单独的嵌入空间中对特定 KG 进行编码, 并学习了跨 KG 实体嵌入转换函数. IPTransE^[7]推断关系和多跳路径之间的等价性, 对关系路径进行建模, 并且通过迭代的方式标记伪对齐种子, 增加训练数据. BootEA^[17]在统一空间内嵌入两个 KG, 迭代地引导标记对齐, 并提供一种降低错误累积的方法. RREA^[10]提出关系反射转换为每个实体获取特定于关系的嵌入. RHGN^[11]提出了关系门控卷积 (relation gated convolution, RGC) 和交叉图嵌入交换 (crossgraph embedding exchange, CEE), 从而统一两个 KG 之间的实体语义. 仅使用图结构信息的 EA 方法仅考虑 KG 中包含的关系三元组, 但 KG 本身包含的其他信息没有被考虑, 如时态知识图谱中包含的时间信息, 多模态知识图谱中包含的图像信息等.

本文提出的 HGAT-EA 通过 2 个通道、4 个视图, 克服了仅使用图结构信息的 EA 方法对 KG 信息利用的局限性, 提高了 KG 信息的利用率.

• 使用附加信息 (additional information) 的 EA 方法: GCN-Align^[12]、JAPE^[8]、AttrE^[18]和 AttrGNN^[19]在 KG 嵌入过程中使用属性三元组来细化结构嵌入. GCN-Align^[12]是首个将 GCN 应用到实体对齐任务上的模型. JAPE^[8]额外利用知识图谱的属性信息, 为实体学习结构嵌入和属性嵌入, 通过属性相似度约束和结构嵌入来找到对齐实体. 不同于 JAPE, AttrE^[18]同时考虑了属性和属性值. AttrGNN^[19]将关系三元组和属性三元组进行统一建模, 能够动态的学习属性和值的重要程度. RDGCN^[13]、NMN^[14]、RAGA^[15]、RPR-RHGT^[16]、GMNN^[20]、BNGNN^[21]、SCMEA^[22]均使用实体名称对应词嵌入进行初始化. RDGCN^[13]巧妙地原始图和对偶关系图之间的交互进行建模. NMN^[14]提出了一种新的基于抽样的实体对齐框架. NMN 旨在精确的选择出包含最多信息量的邻域节点以及准确估计不同 KG 中实体间的邻域相似度. RAGA^[15]考虑关系类型的信息, 提出使用全局推理方法, 而非朴素的贪婪搜索. RPR-RHGT^[16]集成了 KG 中的关系和路径结构信息, 设计了一种可靠路径推理算法. GMNN^[20]提出了一个主题实体图来表示实体的 KG 上下文信息, 并将 EA 任务表述为主题实体图之间的图匹配问题. BNGNN^[21]使用统一的图将关系三元组和属性三元组一起建模, 增强不同邻域特征之间的交互性. SCMEA^[22]集成了拓扑结构、关系、属性和实体名称, 以学习实体融合表示.

目前 EA 方法对于元关系的使用仅限于关系, 对实体类型的利用较少, 本文通过 HGAT 考虑元关系三元组 (<源实体类型、关系、目标实体类型>), 用于缓解不同类型实体的分布差异. 其次, 多数工作对实体名称的使用集中于使用词嵌入模型, 本文额外利用 Bi-gram 统计信息避免 OOV 问题.

3 基于异构图注意力网络的多视图实体对齐框架

3.1 问题定义

• 知识图谱 (KG): 以三元组的形式描述客观世界中概念、实体及其之间的关系, 将互联网的信息表达成更接近人类认知世界的形式, 提供了一种更好地组织、管理和理解互联网海量信息的能力. 知识图谱符号化表示为: $KG = (E, R, T)$, 其中, E 表示 KG 中实体的集合, R 表示 KG 中关系的集合, T 表示 KG 中关系三元组的集合.

• 实体类型 (entity type): 在 KG 的本体中, 类型通常以分层树结构进行存储, 实体通常与一组类型相关联. 如图 1 所示, 给出了部分实体类型的树结构, 其中每一条边都代表“subClassOf”这类关系. 对于法语 DBpedia 中的实体 Barack Obama 对应于图 2 中 4 种类型: Owl#Thing、Agent、Person 和 Politician, 其中 Owl#Thing 是所有类型

的父类, **Politician** 是最具体的类型. 在本文中实体类型选择 Level 2 层级对应的实体类型. 缺少实体类型的实体统一使用 **Owl#Thing** 作为其实体类型.




图2 本体中分层分类示例

● 实体对齐 (entity alignment, EA): 也被称为实体匹配 (entity matching, EM) 或实体解析 (entity resolution, ER), 是知识融合中最基础、关键的技术之一. 实体对齐的目标是从不同知识图谱中识别描述相同真实世界对象的实体. $KG_1 = (E_1, R_1, T_1)$ 和 $KG_2 = (E_2, R_2, T_2)$ 是两个需要对齐的知识图谱, 假设所有实体已知实体类型并且两个 KG 间实体类型已对齐. 设 $S = \{(e_1^i, e_2^i) | e_1^i \in E_1, e_2^i \in E_2, e_1^i \equiv e_2^i\}$ 为预对齐实体集, 其中 $\equiv$ 表示同一个现实世界的对象. 实体对齐任务旨在找到两个 KG 之间剩余的对齐实体.

3.2 HGAT-EA 框架概述

在本节中, 主要介绍了本文提出的框架 HGAT-EA. 如图 3 所示, HGAT-EA 同时考虑了 KG 结构、实体类型、实体名称和字符级字面量 4 个不同视图下的实体特征. HGAT-EA 包括两个通道, 第 1 个通道学习结构嵌入, 第 2 个通道学习字符级语义嵌入. 在学习结构嵌入时, 使用前馈神经网络 (feedforward neural network, FNN) 的实体名称嵌入输出作为初始化嵌入. 最终的结构嵌入通过 HGAT 获得. 对于字符级字面量, 本文使用实体名称的 Bi-gram 统计信息来获取初始特征. 每个实体的字符级语义嵌入通过将字符级字面量输入 FNN 获得. 在获得两个不同通道的实体嵌入后, HGAT-EA 通过加权拼接获得融合实体嵌入. 对于对齐推理步骤, HGAT-EA 提供了 3 种算法: 贪婪搜索 (greedy search)、CSLS 和 Sinkhorn.




图3 基于异构图注意力网络的实体对齐框架

3.3 异构图注意力网络 (HGAT)

3.3.1 HGAT 总体介绍

为了减少不同类型节点和边的分布差异, 本文在设计 HGAT 时考虑了元关系三元组 ($\langle$ 源实体类型、关系、目标实体类型 $\rangle$). 通过元关系三元组, HGAT 可以更好地建模异质性. 因此, 它可以获得更高质量的嵌入来进行对齐.

HGAT 由 4 个部分组成, 即异构图注意力、异构消息、异构聚合和多层特征融合. 如图 4 所示, 异构图注意力、异构消息和异构聚合共同构成了 HGAT 层. 元关系在 HGAT 中得到了充分利用. 多层特征融合利用 HGAT 的输入和 HGAT 各层的输出来丰富实体结构嵌入. 通过元关系, HGAT 可以自动选择更重要的特征, 从而使实体嵌入即使在低维空间中也具有出色的实体对齐表现.




图 4 异构图注意力网络架构

HGAT 层可以定义为公式 (1):

$$\mathbf{E}^{(l)}[t] = \text{HeterAggregate}^{(l)}(\text{HeterAttention}^{(l)}(h, r, t) \cdot \text{HeterMessage}^{(l)}(h, r, t)) \quad (1)$$

其中, $\mathbf{E}^{(l)}[t]$ 表示第 l 层的目标实体 t 的嵌入表示, $\text{HeterAttention}^{(l)}$ 、 $\text{HeterMessage}^{(l)}$ 、 $\text{HeterAggregate}^{(l)}$ 分别代表第 l 层的异构图注意力、异构消息和异构聚合操作, (h, r, t) 是当前考虑的三元组.

下面对 4 个组件进行概括介绍.

(1) 异构图注意力: 该组件估算每个邻域实体对目标实体的重要性. 在计算注意力系数的过程中, 考虑了 KG 丰富的元关系和关系三元组. 在此, 给出异构图注意力的抽象公式 (2), 给定三元组 (h, r, t) , 其中包括源实体 h , 目标实体 t , 以及关系 r . 本文通过函数 Att_{HGAT} 计算目标实体对源实体的注意力系数.

$$\text{HeterAttention}(h, r, t) = \text{Att}_{\text{HGAT}}(h, r, t) \quad (2)$$

本文提出了 3 种实现 Att_{HGAT} 的方法. 1) 第 1 种方法通过实体类型和关系的交互隐式地建模元关系. 该方法能充分处理不同元关系的差异. 2) 第 2 种方法通过简单的拼接减少了第 1 种方法的计算量. 3) 第 3 种方法考虑到 KG 中丰富的关系, 关系信息本身可以反映大部分元信息. 因此可以直接利用关系嵌入来计算注意力系数. 这 3 种不同的异构图注意力方法将在第 3.3.2 节中介绍.

(2) 异构消息: 该组件将消息转换为公共特征空间, 用于异构聚合. 本文提出了基于实体类型生成异构消息的方法, 以缓解不同类型实体的分布差异. 同样, 本文为异构消息定义了一个抽象公式 (3).

$$\text{HeterMessage}(h, r, t) = \text{Msg}_{\text{HGAT}}(h, r) \quad (3)$$

该方法将在第 3.3.3 节中具体介绍.

(3) 异构聚合: 在该步骤中需要将位于公共特征空间的邻域实体特征聚合, 并转换到目标实体类型对应的特征空间中去. 将在第 3.3.4 节中将具体介绍该组件.

(4) 多层特征融合: 通过多层特征融合, 可以得到更高质量的实体嵌入. 本文还提供了两种不同的融合方法, 即求和 (SUM) 和拼接 (CON). 将在第 3.3.5 节中详细介绍.

为了简化描述, 第 3.3.2–3.3.4 节中所有公式均描述第 l 层 HGAT 的计算过程.

3.3.2 异构图注意力

为了在减少参数数量的同时保持不同元关系的特性, 本文分别处理源实体类型、关系和目标实体类型. 本文将源实体 h 映射到键向量 $\mathbf{K}^{(i)}(h)$, 其中 i 代表第 i 个注意力头. 映射方式如公式 (4) 所示:

$$\mathbf{K}^{(i)}(h) = \mathbf{K}_{\text{type}}^{(i)}(\mathbf{E}^{(l-1)}[h]) \quad (4)$$

其中, $\mathbf{K}_{\text{type}}^{(i)}: \mathbb{R}^d \rightarrow \mathbb{R}^{d/n}$ 表示的是将源实体 h 映射为键向量的一个线性变换层, 每一类实体类型对应于一个不同的

线性变化层, 用于最大限度地模拟不同实体类型的分布差异, 其中 n 表示注意力头的总数. $\mathbf{E}^{(l-1)}[h]$ 表示上一层中实体 h 的嵌入.

目标实体 t 被映射到查询向量 $\mathbf{Q}^{(i)}(t)$, 其中 i 代表第 i 个注意力头. 映射方式如公式 (5) 所示:

$$\mathbf{Q}^{(i)}(t) = \mathbf{Q}_{\text{type}}^{(i)}(\mathbf{E}^{(l-1)}[t]) \quad (5)$$

其中, $\mathbf{Q}_{\text{type}}^{(i)}: \mathbb{R}^d \rightarrow \mathbb{R}^{d/n}$ 表示的是将目标实体 t 映射为查询向量的一个线性变换层, 每一类实体类型对应于一个不同的线性变化层. $\mathbf{E}^{(l-1)}[t]$ 表示上一层中实体 t 的嵌入. 获得了键向量和查询向量后, 本文随之提出以下 3 种不同的异构图注意力计算方式.

• **KQ 拼接:** 由于 KG 中元关系三元组数量庞大, 为每个元关系三元组定义参数矩阵是不切实际的. 因此, 本文通过实体类型和关系的交互来隐式地模拟元关系. 交互过程可分为两个步骤. 1) 通过权重矩阵将关系嵌入转换到公共空间. 2) 关系嵌入分别与键向量和查询向量逐元素相乘. 与关系交互后的键向量和查询向量拼接用于计算注意力系数. 第 1 种方法如公式 (6) 所示:

$$\text{Att}_{\text{HGAT}}^i(h, r, t) = \text{Softmax}_{\forall h \in N(t)}((\mathbf{v}^\top [\mathbf{K}^{(i)}(h) * \mathbf{W}^{(i)} \mathbf{R}_r \parallel \mathbf{Q}^{(i)}(t) * \mathbf{W}^{(i)} \mathbf{R}_r]) / \sqrt{d/n}) \quad (6)$$

其中, $\mathbf{v} \in \mathbb{R}^{(2d/n) \times 1}$ 是可训练的特定于关系的权重向量, $*$ 表示按位乘. $\mathbf{R}_r$ 表示为关系 r 的嵌入, 权重矩阵 $\mathbf{W}^{(i)} \in \mathbb{R}^{(d/n) \times d}$ 将关系嵌入 $\mathbf{R}_r$ 转换到和键向量及查询向量相同空间, 方便三者进行交互, 每个注意力头有不同的权重矩阵. 权重矩阵 $\mathbf{W}^{(i)}$ 希望不同头能够自主学习关系不同方面的信息. $N(t)$ 表示的是目标实体 t 周围的邻域实体的集合. 本文选择 KQ 拼接作为异构图注意力的默认实现. KQ 拼接无法充分反映关系的方向, 为此本文提供了以下两种变体.

• **KQR 拼接:** 与 KQ 拼接相比, KQR 拼接采用了一种更直观的方法来整合元关系. 将键向量、查询向量和关系嵌入拼接起来计算注意力系数. 第 2 种方法如公式 (7) 所示:

$$\text{Att}_{\text{HGAT}}^i(h, r, t) = \text{Softmax}_{\forall h \in N(t)}((\mathbf{v}^\top [\mathbf{K}^{(i)}(h) \parallel \mathbf{Q}^{(i)}(t) \parallel \mathbf{W}^{(i)} \mathbf{R}_r]) / \sqrt{d/n}) \quad (7)$$

其中, $\mathbf{v} \in \mathbb{R}^{(3d/n) \times 1}$ 表示可学习的注意力权重向量.

• **关系嵌入:** 因为 KG 相较于异构图, KG 自身具有非常丰富的关系信息, 因此关系可以提供大量异构信息帮助 EA 任务. 关系嵌入利用关系提供的异构信息来计算注意力系数. 这种方法可以减少模型的参数数量, 同时保持模型的性能. 第 3 种方法如公式 (8) 所示:

$$\text{Att}_{\text{HGAT}}^i(h, r, t) = \text{Softmax}_{\forall h \in N(t)}(\mathbf{v}^\top \mathbf{W}^{(i)} \mathbf{R}_r / \sqrt{d/n}) \quad (8)$$

其中, $\mathbf{v} \in \mathbb{R}^{(d/n) \times 1}$ 表示可学习的注意力权重向量.

3.3.3 异构消息

与异构图注意力类似, 本文希望缓解不同类型实体的分布差异. 本文通过下述方法来生成异构消息.

值向量: 该方法首先将源实体 h 对应嵌入 $\mathbf{E}^{(l-1)}[h]$ 通过特定于实体类型的线性变化层 $\mathbf{V}_{\text{type}}^{(i)}$ 得到值向量 $\mathbf{V}^{(i)}(h)$, 然后通过矩阵 $\mathbf{W}_{\text{msg}}^{(i)}$ 将 $\mathbf{V}^{(i)}(h)$ 转换到公共特征空间. 如公式 (9) 所示:

$$\text{Msg}_{\text{HGAT}}^i(h, r) = \mathbf{W}_{\text{msg}}^{(i)} \mathbf{V}^{(i)}(h) = \mathbf{W}_{\text{msg}}^{(i)} \mathbf{V}_{\text{type}}^{(i)}(\mathbf{E}^{(l-1)}[h]) \quad (9)$$

其中, $\mathbf{W}_{\text{msg}}^{(i)}$ 是可训练的权重矩阵, $\mathbf{V}_{\text{type}}^{(i)}$ 表示特定于实体类型的线性变化层.

3.3.4 异构聚合

异构聚合会根据注意力系数对邻域信息进行聚合. 这一步将位于公共特征空间的消息转化至目标实体类型特征分布空间. 对于异构聚合过程, 本文给出的正式定义如公式 (10) 所示:

$$\mathbf{E}^{(l)}[t] = \parallel_{i \in [1, n]} \mathbf{A}_{\text{type}}^i(\text{GELU}(\oplus_{\forall h \in N(t)} (\text{Att}_{\text{HGAT}}^i(h, r, t) \cdot \text{Msg}_{\text{HGAT}}^i(h, r)))) \quad (10)$$

其中, $\oplus$ 表示逐元素按位加操作, $\mathbf{A}_{\text{type}}^i$ 表示第 i 个头中目标实体 t 的实体类型相对应的线性变化层, 最后将 n 个头的输出进行拼接, 获得特定实体类型下的实体表示. $\text{GELU}(\cdot)$ 表示 GELU 激活函数.

3.3.5 多层特征融合

为了进一步结合多阶 HGAT 特征, 本文考虑了两种不同的多层特征融合方法. 本文选择求和作为多层特征融

合的默认实现方法.

求和: 求和在不增加嵌入维度的情况下, 通过简单的线性运算增强重要特征. 它是一种简单有效的融合多个特征的方法. 求和法的形式表达式如公式 (11) 所示:

$$\mathbf{E}^{(S)}[t] = \mathbf{E}^{(0)}[t] + \dots + \mathbf{E}^{(L)}[t] \quad (11)$$

拼接: 拼接能够保留各层输出特征的所有信息. 将每一层的输入和输出进行拼接, 就能得到融合的多层结构嵌入. 具体实现如公式 (12) 所示:

$$\mathbf{E}^{(S)}[t] = [\mathbf{E}^{(0)}[t] \parallel \dots \parallel \mathbf{E}^{(L)}[t]] \quad (12)$$

3.4 多通道特征融合

HGAT-EA 能够通过可训练的权重自动学习不同通道的重要性, 并将其用于多通道特征融合. 第 2 个通道将在第 3.4.2 节中介绍. 接下来, 将首先介绍如何融合结构嵌入和字符级语义嵌入.

3.4.1 结构嵌入与字符级语义嵌入融合

在该步骤中, 首先对每个特征矩阵逐行进行 L_2 归一化, 然后通过可训练加权拼接融合多视图特征.

$$\mathbf{E}^{(F)} = \left[\frac{w^1}{w^1 + w^2} \mathbf{E}^{(S)} \parallel \frac{w^2}{w^1 + w^2} \mathbf{E}^{(C)} \right] \quad (13)$$

其中, w^1 和 w^2 分别代表结构嵌入和字符级语义嵌入的权重, 在与嵌入表示相乘前, 权重需要经过 *Softmax* 层确保两者之和为 1.

3.4.2 字符级语义嵌入

很多工作都利用实体语义信息来完成 EA 任务. 这些工作首先使用机器翻译工具或跨语言词嵌入模型, 将单词映射到统一的向量空间. 然后, 使用词嵌入作为实体的初始特征. 由于 KG 包含大量专有名词 (如人名、城市名), 然而词嵌入模型的词汇量有限, 因此词嵌入模型面临严重的 OOV 问题. 为了缓解 OOV 问题, 一些 EA 方法^[25,26]使用字符级特征. 本文采用英译实体名称的 Bi-gram 统计信息作为字符级字面量, 而不是使用复杂的神经网络.

为了具体说明本文如何生成字符级字面量, 给出下述示例. 给定 2 个实体, 实体名称分别为“henan”“hebei”. “henan”对应的 Bi-gram 为 [‘he’, ‘en’, ‘na’, ‘an’], “hebei”对应的 Bi-gram 为 [‘he’, ‘eb’, ‘be’, ‘ei’]. 将两个实体对应的 Bi-gram 取并集得到 {‘he’, ‘en’, ‘na’, ‘an’, ‘eb’, ‘be’, ‘ei’}. 由此得到“henan”对应的字符级字面量为 [1, 1, 1, 1, 0, 0, 0], “hebei”对应的字符级字面量为 [1, 0, 0, 0, 1, 1, 1].

通过统计得到初始的字符级字面量, 记做 $\tilde{\mathbf{E}}^{(C)} \in \mathbb{R}^{(|E_1|+|E_2|) \times |\text{set}_{\text{bigram}}|}$, 其中 $\text{set}_{\text{bigram}}$ 表示所有实体名称生成的 Bi-gram 集合. 本文将字符级字面量 $\tilde{\mathbf{E}}^{(C)}$ 输入 FNN 来得到用于多视图特征融合的字符级语义嵌入 $\mathbf{E}^{(C)}$. 如公式 (14) 所示:

$$\mathbf{E}^{(C)} = \text{FNN}_c(\tilde{\mathbf{E}}^{(C)}) \quad (14)$$

其中, $\text{FNN}_c: \mathbb{R}^{(|E_1|+|E_2|) \times |\text{set}_{\text{bigram}}|} \rightarrow \mathbb{R}^{(|E_1|+|E_2|) \times d}$ 表示用于将字符级字面量转化到与结构嵌入同一空间的前馈神经网络.

3.5 多通道对齐学习

灵感来自 MCLEA^[25], 本文考虑了通道内对比损失 (ICL) 并提供了一种无需调参的整体优化目标.

3.5.1 通道内的对比损失 (ICL)

ICL 对每一种实体嵌入矩阵单独计算损失函数, 具体公式如公式 (15) 和 (16) 所示.

$$L_{\text{ICL}}^{(x)} = -\mathbb{E}_{i \in \mathcal{B}} \log \left[\frac{1}{2} (q_x(e_1^i, e_2^i) + q_x(e_2^i, e_1^i)) \right], x \in \{S, C, F\} \quad (15)$$

$$q_x(e_1^i, e_2^i) = \frac{\delta_x(e_1^i, e_2^i)}{\delta_x(e_1^i, e_2^i) + \sum_{e_1' \in N_1^i} \delta_x(e_1', e_1^i) + \sum_{e_2' \in N_2^i} \delta_x(e_1^i, e_2')} \quad (16)$$

其中, $\delta_x(a, b) = \exp(\mathbf{E}^{(x)}[a]^\top \mathbf{E}^{(x)}[b] / \tau_1)$, $x \in \{S, C, F\}$ 代表可以选择实体结构嵌入矩阵, 字符级语义嵌入矩阵及最后的多视图融合嵌入矩阵, τ_1 是一个温度参数. 值得注意的是 $q_x(e_1^i, e_2^i)$ 是不对称的, $q_x(e_2^i, e_1^i)$ 的定义与公式 (16) 相似. $\mathcal{B}$ 表示当前批, (e_1^i, e_2^i) 表示为当前批中第 i 个对齐实体对. 本文对每个对齐实体生成两个类型的负例. 第 1 个类型的

负例是来自实体自身所在 KG 的未对齐实体. 第 2 个类型的负例是来自于跨图的未对齐实体. 以实体 e_1^i 为例, 分别定义 $N_1^i = \{e_1^j | \forall e_1^j \in E_1, j \neq i\}$ 和 $N_2^i = \{e_2^j | \forall e_2^j \in E_2, j \neq i\}$. N_1^i 和 N_2^i 均通过当前批 $\mathcal{B}$ 生成. 这两种类型的负样本使得其中来自同一 KG 的语义相似的实体保持一定距离, 而来自不同 KG 的对齐实体映射到附近.

3.5.2 整体损失函数

HGAT-EA 整体损失函数如下所示:

$$\mathbb{L} = L_{\text{ICL}}^{(F)} + \sum_{y \in \{S, C\}} \alpha_y L_{\text{ICL}}^{(y)} \quad (17)$$

其中, α_y 是平衡损失重要性的超参数, $L_{\text{ICL}}^{(F)}$ 表示基于多视图融合嵌入矩阵的 ICL 损失函数, $L_{\text{ICL}}^{(y)}$ 表示基于实体结构嵌入矩阵 ($y=S$) 或基于字符级语义嵌入矩阵 ($y=C$) 的 ICL 损失函数. 为了避免复杂且昂贵的调参过程, 本文将公式 (17) 视为多任务学习范式, 然后使用均方差不确定性^[27]在模型训练期间自动权衡每个损失. 如公式 (18) 所示:

$$\mathbb{L} = L_{\text{ICL}}^{(F)} + \sum_{y \in \{S, C\}} \left(\frac{1}{\alpha_y^2} L_{\text{ICL}}^{(y)} + \log \alpha_y \right) \quad (18)$$

其中, α_y 可在训练中自动学习得到.

3.6 对齐推理

对齐推理是指在测试阶段为每个实体寻找对齐实体的算法, 本文提供了 3 种不同的算法来完成对齐推理. 如图 5 所示, 给定实体间的相似度矩阵, 3 种不同的对齐推理算法将给出不同的对齐结果. 接下来将具体介绍这 3 种对齐推理算法.

	a	b	c	d			
u	0.8	0.2	0.7	0.4	(u, a);	(u, a);	(u, a);
v	0.2	0.5	0.9	0.8	(v, c);	(v, d);	(v, d);
x	0.1	0.2	0.7	0.4	(x, c);	(x, c);	(x, c);
y	0.9	0.4	0.8	0.1	(y, a);	(y, a);	(y, b);
	相似度	贪婪搜索	CSLS	Sinkhorn			

图 5 对齐推理算法示例

3.6.1 贪婪搜索

贪婪搜索是最流行的对齐推理算法^[28]. 它被广泛应用于大多数 EA 方法中. 给定待对齐的 KG_1 和 KG_2 以及一个距离度量 $distance$, 对于每个实体 $e_1 \in E_1$, 通过 $e_2 = \arg \min_{e_2 \in E_2} distance(e_1, e_2)$ 找到对齐实体 e_2 . 本文使用曼哈顿距离作为距离度量 $distance$, 距离越小, 实体对齐的概率越高. 计算候选实体对相似度的函数如下:

$$distance(e_1, e_2) = ||\mathbf{E}^{(F)}[e_1] - \mathbf{E}^{(F)}[e_2]||_{L_1} \quad (19)$$

3.6.2 CSLS (cross-domain similarity local scaling)

为了缓解 Hubness 问题, 本文考虑使用 CSLS^[23]. 给定要对齐的 KG_1 和 KG_2 以及相似度指标 s (即负的曼哈顿距离), CSLS 的计算可分为两步. 第 1 步, 分别计算 KG_1 和 KG_2 中实体 e_1, e_2 的前 k 个近邻的平均相似度 $\Psi_2(e_1), \Psi_1(e_2)$. 第 2 步, 两倍的 $s(e_1, e_2)$ 减去 $\Psi_2(e_1)$ 和 $\Psi_1(e_2)$ 的和. 结果作为 e_1 和 e_2 之间的最终相似度. CSLS 的工作原理是在高密度区域扩展, 在低密度区域收缩, 从而计算出更精确的近邻点. 因此, 它可以缓解高维空间中的 Hubness 问题.

3.6.3 Sinkhorn

EA 本质上是一个分配问题. 分配问题的目标是找到从源分布转移到目标分布同时使整体利润最大化的最优分配 P . 分配问题可以用 Sinkhorn 算法来解决^[24,26]. 与传统的匈牙利算法相比, Sinkhorn 算法的效率提高了 n 倍, 即 $O(n^2)$. 而且 Sinkhorn 算法的结果可以与匈牙利算法相媲美. Sinkhorn 的计算公式如下:

$$\text{Sinkhorn}(X) = \lim_{k \rightarrow \infty} S^k(X) \quad (20)$$

其中, $S^k(\mathbf{X}) = \mathcal{N}_c(\mathcal{N}_r(S^{k-1}(\mathbf{X})))$, $\mathcal{N}_c$ 及 $\mathcal{N}_r$ 分别表示对 $\mathbf{X}$ 进行列归一化及行归一化. k 表示迭代次数. 本文将实体间的余弦相似性矩阵作为利润矩阵 $\mathbf{X}$. 分配方案 P 初始化为 $\exp(50\mathbf{X})$. 本文中选取 $k=10$, 输出即为 EA 结果.

4 实验评估

4.1 实验设置

4.1.1 数据集

本文在 DBP-15K^[8] 的 3 个广泛使用的跨语言数据集上进行了实验. 表 1 给出了数据集的统计数据, 包括知识图谱中包含的实体数, 关系类型数以及三元组的数目. 本文根据 DBpedia 官网 (<https://wiki.dbpedia.org/>) 提供的本体信息获取实体对应类型, 即通过 `rdfs:type` 和 `rdfs:subClassOf` 获得实体较粗粒度的类型. 对于没有查询到实体类型的实体, 均将其实体类型设置为 `Owl#Thing`, 即所有实体类型的父类. 不同 KG 中的实体类型假设已经对齐, 关系及实体未对齐. 对于 DBP15K 中的 3 个不同的数据集实体类型均只考虑如下 5 种类型 {‘Place’, ‘Work’, ‘Agent’, ‘Species’, ‘Owl#Thing’}. 在实验中, 本文统计了实体类型在数据集中的分布情况, 并考虑了实体数量排名前 4 位的实体类型. 然后, 将其他实体类型归类为“Owl#Thing”, 以避免稀疏实体类型训练数据不足. 3 个数据集中均有 15000 个对齐实体, 其中训练集:验证集:测试集=2:1:7, 遵循 RPR-RHGT^[16] 的数据集划分.

表 1 实验数据集

数据集	知识图谱	实体数目	关系数目	实体类型数目	三元组数目
JA-EN (DBP)	JA	65 744	2043	5	164 373
	EN	95 680	2096	5	233 319
FR-EN (DBP)	FR	66 858	1 379	5	192 191
	EN	105 889	2 209	5	278 590
ZH-EN (DBP)	ZH	66 469	2 830	5	153 929
	EN	98 125	2 317	5	237 674

4.1.2 评价指标

在本文中采用常用的评价指标 $Hits@k$ 和 MRR (mean reciprocal rank) 来对模型进行评估. $Hits@k$ 是在前 k 名候选实体中正确对齐的比例, 计算方式如下:

$$Hits@k = \frac{|e \in E | rank(e) \leq k|}{|E|} \cdot 100\% \quad (21)$$

其中, $|E|$ 是进行预测的实体数量, $rank(e)$ 表示预测的 e 的对齐实体排名. 本实验中令 $k=1, 10$.

MRR 是对齐实体的排名倒数的平均值, 计算方式如下:

$$MRR = \frac{1}{|E|} \sum_{e \in E} \frac{1}{rank(e)} \quad (22)$$

$Hits@k$ 和 MRR 得分越高, 说明 EA 的表现越好.

4.1.3 基准模型

本文选取了下述 SOTA 模型与本文所提框架进行对比实验.

(1) MTransE^[6]: 该模型基于 TransE 将知识图谱嵌入到各自对应的向量空间, 在不同向量空间之间构造转换函数将嵌入转化到统一空间进而计算实体相似度.

(2) IPTransE^[7]: 该模型考虑了知识图谱中的多跳路径, 同时使用迭代策略, 在训练过程中产生新对齐实体指导后续对齐.

(3) AlignE^[17]: 该模型是 BootEA 的一个非迭代变体, 使用 ϵ -截断均匀负采样.

(4) RHGN^[11]: 该模型提出了关系门控卷积和交叉图嵌入交换, 从而统一两个 KG 之间的实体语义.

(5) RDGCN^[13]: 该模型设计了对偶关系图, 而后在图与对偶图上交替卷积, 获得最终的实体嵌入.

(6) NMN^[14]: 该模型提出一种邻域采样策略, 为每个实体采样出信息最丰富的邻居, 而后使用注意力机制生成

实体匹配向量,最后使用匹配向量判断实体对齐.

(7) RAGA^[15]: 该模型提出了一个基于关系可知图注意力网络框架来捕获实体和关系之间的交互.

(8) RPR-RHGT^[16]: 该模型设计了一个关系可知异构图 Transformer (RHGT) 来提取对齐实体在其异构结构中的特征,同时开发了一种可靠路径推理算法,从原始关系结构中提取有利于 EA 任务的路径结构.

本文将以上方法分为两类: (1) 仅基于图结构进行实体对齐的方法: MTransE, IPTransE, AlignE, RHGN; (2) 使用图结构与附加信息进行实体对齐的方法: RDGCN, NMN, RAGA, RPR-RHGT.

并且本文设置了 2 种简单的基准模型,分别为 Word-EA 及 Char-EA. Word-EA 直接使用预训练实体名称词嵌入进行 EA. Char-EA 直接使用字符级字面量进行 EA.

4.1.4 实现细节

本研究使用 FastText (<https://fasttext.cc/docs/en/crawl-vectors.html>) 生成实体名称嵌入,词嵌入与 RPR-RHGT^[16] 相同,翻译实体名称选用 MCLEA^[25]中使用的翻译实体名称.为了公平比较所有使用词嵌入进行初始化的模型均使用相同的词嵌入,且所有基线的实体嵌入维度均设为 300.实验默认参数设置为 HGAT 层数 $L=1$,学习率 $lr=0.005$, dropout 率为 0.1,温度系数 $\tau_1=0.1$,注意力头数 $n_heads=4$,嵌入维度 $d=300$,最大 epoch 数为 4000,使用早停机制,选择在验证集上表现最好的 epoch 数进行测试.由于 $L=2$ 和 $L=1$ 时的结果没有明显差异,本文将层数固定为 $L=1$.对于 CSLS 计算近邻数设置为 3, Sinkhorn 的迭代次数设置为 10.本文相关实验运行在 A40 显卡服务器上,本文方法的所有实验结果报告 3 次平均的结果.对 JA-EN, FR-EN 及 ZH-EN 本文均报告 $JA \rightarrow EN$, $FR \rightarrow EN$ 及 $ZH \rightarrow EN$ 方向的结果.值得注意的是本文方法在两个方向上的结果相近,因此只报告一个方向上的结果.

4.2 总体实验结果与分析

在与基线方法进行对比时,本文选用 KQ 拼接+值向量+求和的组合作为 HGAT-EA 框架中采用的 HGAT 变体.对于 HGAT-EA 框架内不同组件将在第 4.3 节进行具体的分析.本节额外比较了直接使用词嵌入进行 EA (Word-EA) 和直接使用字符嵌入进行 EA (Char-EA) 两种基线方法.

观察表 2,可以得到以下几项结论.

表 2 不同方法实体对齐表现

模型名称	JA-EN			FR-EN			ZH-EN		
	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR
MTransE	28.822	60.876	0.396	27.492	59.612	0.384	30.835	65.594	0.425
IPTransE	28.082	64.603	0.407	30.841	71.905	0.446	32.070	66.064	0.437
AlignE	49.686	84.606	0.614	53.397	88.105	0.654	52.184	84.844	0.635
RHGN	51.559	76.565	0.604	54.540	82.908	0.645	51.448	76.067	0.602
RDGCN	80.973	90.363	0.845	81.870	91.653	0.854	63.510	79.887	0.694
NMN	84.230	92.010	0.871	83.780	92.460	0.869	65.440	80.330	0.707
RAGA	81.937	92.960	0.860	87.053	95.830	0.904	72.827	88.437	0.785
RPR-RHGT	88.330	94.873	0.907	87.835	95.667	0.907	67.892	84.600	0.737
Word-EA	70.368	80.152	0.739	70.279	77.546	0.728	48.425	59.267	0.523
Char-EA	75.743	86.225	0.795	85.464	93.006	0.881	63.171	74.486	0.671
HGAT-EA (greedy search)	92.203	97.064	0.941	94.292	98.175	0.958	77.197	88.283	0.812
HGAT-EA (CSLS)	94.753	97.820	0.959	96.273	98.940	0.973	81.380	90.810	0.848
HGAT-EA (Sinkhorn)	96.043	98.193	0.969	97.287	98.963	0.979	82.303	91.410	0.856

(1) 在 3 个数据集上,本文所提出的 HGAT-EA 的表现优于其他基线方法,在 3 个数据集上均取得了最优结果.这个结果说明了 HGAT-EA 的有效性.

(2) 贪婪搜索方法明显弱于 CSLS 及 Sinkhorn,这说明了无论是对 Hubness 问题进行缓解还是通过 Sinkhorn 进行集体对齐都能够明显改善最终的对齐结果.整体来看 Sinkhorn 算法为 EA 结果带来了更多收益.

(3) 与随机初始化的 EA 方法相比,所有基于实体名称进行初始化 EA 方法都取得了明显的优势.这说明了实体名称提供的额外信息显著提升了 EA 效果.本文方法额外考虑字符级语义嵌入获得了更大的优势.

(4) 与 Word-EA 及 Char-EA 相比, HGAT-EA 在 3 个数据集上所有评估指标均取得了较大提升. 体现了 HGAT-EA 能够有效融合多个视图的特征, 取得更好的 EA 结果.

在 JA-EN、FR-EN、ZH-EN 数据集上, HGAT-EA (greedy search) 与最优基线方法相比在 $Hits@1$ 值上分别高出 3.873%、6.457%、4.370%, $Hits@10$ 值上分别高出 2.191%、2.345%、-0.154%, MRR 值上分别高出 0.034、0.051、0.027; HGAT-EA (CSLS) 与最优基线方法相比在 $Hits@1$ 值上分别高出 6.423%、8.438%、8.553%, $Hits@10$ 值上分别高出 2.947%、3.11%、2.373%, MRR 值上分别高出 0.052、0.066、0.063; HGAT-EA (Sinkhorn) 与最优基线方法相比在 $Hits@1$ 值上分别高出 7.713%、9.452%、9.476%, $Hits@10$ 值上分别高出 3.320%、3.133%、2.973%, MRR 值上分别高出 0.062、0.072、0.071. 实验结果表明 HGAT-EA 框架的有效性, 实验结果相比基线方法均有明显提升. 此外, CSLS 和 Sinkhorn 相比与贪婪搜索在 $Hits@1$ 值上的提升明显, 特别是在 ZH-EN 数据集上, CSLS 和 Sinkhorn 与贪婪搜索相比在 $Hits@1$ 值上分别高出 4.183%、5.106%. Sinkhorn 相比与 CSLS 提升更为明显.

上述结果对 HGAT-EA 中一个代表性的解决方案与基线方法进行对比分析, 下面将 HGAT-EA 中包括的所有解决方案进行对比分析.

4.3 HGAT-EA 组件对比与分析

本节对 HGAT-EA 框架内不同组件的组合进行了详细的对比与分析. 在 HGAT-EA 框架中, 异构图注意力计算方式有 3 种: KQ 拼接、KQR 拼接、关系嵌入 (详见第 3.3.2 节); 异构聚合中消息生成有一种方式: 值向量 (详见第 3.3.3 节); 多层特征融合方式有两种: 求和、拼接 (详见第 3.3.5 节). 因此, HGAT-EA 模型有 6 种不同组合方案, 如表 3 所示. 对于每种组合方案, 本文提供了 3 种不同的对齐推理结果, 实体嵌入维度 $d=300$.

表 3 HGAT-EA 的不同组合方案

HGAT-EA组合方案		组合方案名称	HGAT-EA组合方案		组合方案名称
KQ拼接+值向量+求和		HGAT-EA-v1	KQ拼接+值向量+拼接		HGAT-EA-v4
KQR拼接+值向量+求和		HGAT-EA-v2	KQR拼接+值向量+拼接		HGAT-EA-v5
关系嵌入+值向量+求和		HGAT-EA-v3	关系嵌入+值向量+拼接		HGAT-EA-v6

观察表 4-表 6, 可以得到以下几项结论.

表 4 JA-EN 数据集上 HGAT-EA 不同变体实体对齐表现

模型名称	JA-EN (greedy search)			JA-EN (CSLS)			JA-EN (Sinkhorn)		
	$Hits@1$ (%)	$Hits@10$ (%)	MRR	$Hits@1$ (%)	$Hits@10$ (%)	MRR	$Hits@1$ (%)	$Hits@10$ (%)	MRR
HGAT-EA-v1	92.203±0.16	97.064±0.01	0.941±0.001	94.753±0.13	97.820±0.04	0.959±0.001	96.043±0.13	98.193±0.03	0.969±0.001
HGAT-EA-v2	92.283±0.22	97.029±0.07	0.941±0.002	94.687±0.04	97.790±0.09	0.959±0.001	96.083±0.23	98.280±0.06	0.969±0.002
HGAT-EA-v3	92.127±0.13	97.070±0.05	0.940±0.001	94.573±0.13	97.780±0.10	0.958±0.001	96.045±0.17	98.120±0.16	0.968±0.001
HGAT-EA-v4	91.914±0.24	96.816±0.14	0.938±0.002	94.477±0.17	97.627±0.10	0.957±0.002	95.483±0.31	97.870±0.14	0.964±0.003
HGAT-EA-v5	91.727±0.15	96.717±0.10	0.936±0.001	94.300±0.07	97.630±0.12	0.956±0.001	94.693±1.02	97.533±0.54	0.957±0.009
HGAT-EA-v6	92.064±0.25	96.813±0.09	0.939±0.002	94.610±0.13	97.630±0.07	0.958±0.001	95.670±0.17	98.047±0.10	0.966±0.002

注: (1) 加粗代表最优结果, 斜体代表次优结果; (2) 带±符号的数值表示实验过程中多次测量值距离其平均值的浮动范围

表 5 FR-EN 数据集上 HGAT-EA 不同变体实体对齐表现

模型名称	FR-EN (greedy search)			FR-EN (CSLS)			FR-EN (Sinkhorn)		
	$Hits@1$ (%)	$Hits@10$ (%)	MRR	$Hits@1$ (%)	$Hits@10$ (%)	MRR	$Hits@1$ (%)	$Hits@10$ (%)	MRR
HGAT-EA-v1	94.292±0.44	98.175±0.26	0.958±0.004	96.273±0.48	98.940±0.14	0.973±0.004	97.287±0.57	98.963±0.30	0.979±0.005
HGAT-EA-v2	94.114±0.36	98.048±0.24	0.956±0.003	96.130±0.26	98.830±0.11	0.972±0.002	97.143±0.41	98.857±0.28	0.978±0.004
HGAT-EA-v3	93.578±0.02	97.692±0.04	0.951±0.001	95.607±0.08	98.680±0.01	0.968±0.001	96.377±0.07	98.447±0.04	0.971±0.000
HGAT-EA-v4	94.025±0.13	98.041±0.16	0.956±0.001	96.077±0.16	98.870±0.09	0.971±0.002	96.953±0.31	98.820±0.17	0.976±0.003
HGAT-EA-v5	93.978±0.03	98.076±0.07	0.955±0.000	96.043±0.05	98.887±0.02	0.971±0.001	96.893±0.11	98.740±0.01	0.976±0.001
HGAT-EA-v6	94.000±0.13	97.895±0.01	0.955±0.001	96.003±0.09	98.847±0.02	0.971±0.000	96.750±0.01	98.697±0.01	0.975±0.000

注: (1) 加粗代表最优结果, 斜体代表次优结果; (2) 带±符号的数值表示实验过程中多次测量值距离其平均值的浮动范围

表 6 ZH-EN 数据集上 HGAT-EA 不同变体实体对齐表现

模型名称	ZH-EN (greedy search)			ZH-EN (CSLS)			ZH-EN (Sinkhorn)		
	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR
HGAT-EA-v1	77.197±0.19	88.283±0.15	0.812±0.002	81.380±0.07	90.810±0.11	0.848±0.001	82.303±0.28	91.410±0.10	0.856±0.002
HGAT-EA-v2	79.111±0.14	89.702±0.29	0.829±0.002	83.127±0.18	92.333±0.22	0.865±0.002	84.160±0.55	92.697±0.34	0.872±0.004
HGAT-EA-v3	79.289±0.18	90.390±0.12	0.832±0.001	83.917±0.20	93.070±0.39	0.872±0.002	85.153±0.28	93.707±0.19	0.881±0.002
HGAT-EA-v4	75.625±0.44	86.168±0.36	0.794±0.004	79.527±0.43	88.820±0.28	0.829±0.004	78.590±0.84	86.473±1.05	0.815±0.009
HGAT-EA-v5	76.952±0.76	87.746±0.81	0.809±0.008	81.303±0.79	90.470±0.80	0.846±0.009	81.033±1.69	89.290±2.01	0.840±0.018
HGAT-EA-v6	77.346±0.19	88.048±0.07	0.812±0.001	81.457±0.07	90.970±0.12	0.849±0.001	80.530±0.56	88.697±0.62	0.835±0.006

注: (1) 加粗代表最优结果, 斜体代表次优结果; (2) 带±符号的数值表示实验过程中多次测量值距离其平均值的浮动范围

(1) HGAT-EA 框架中包含的 6 种方法在 3 个数据集上均有着优秀的性能. 关系嵌入+值向量+求和解决方案在框架中的表现较为优秀, 在 ZH-EN 数据集上具有明显优势, 在其他两个数据集上与最优结果相近. 关系嵌入+值向量+求和最优的原因有两方面. 一方面, 在异构注意力和异构消息生成过程中都考虑了异构性. 另一方面, 与拼接方法相比, 求和方法生成的实体嵌入维度较低, 不存在会导致维度灾难的高维特征.

(2) 在 3 个数据集上, 3 种不同的异构图注意力方法均有着优异的表现. 在 JA-EN 和 FR-EN 这两个数据集上, KQ 拼接、KQR 拼接、关系嵌入展现出了相似的性能. 在 ZH-EN 数据集上, KQR 拼接及关系嵌入具有更好的性能.

(3) 整体来看, 求和效果优于拼接效果.

(4) 贪婪搜索得到的对齐结果得分明显低于 CSLS 和 Sinkhorn 得到的对齐结果得分. Sinkhorn 在大部分情况下效果比 CSLS 的效果更好.

• 不同异构图注意力方法对比. 相较于 ZH-EN, JA-EN 及 FR-EN 的匹配更加容易, 因此在这两个数据集上无法明显的观察到不同异构图注意力方法的差异性 (多层特征融合方法相同时, Hits@1 分数差异不超过 1%). 为此在分析不同异构图注意力方法性能时, 本文重点关注在 ZH-EN 数据集上. 在 ZH-EN 数据集上, KQ 拼接的效果明显不如其他两种异构图注意力方法. 从整体来看 KQR 拼接和关系嵌入表现相似. 但因为关系嵌入使用的参数量更少, 因此更推荐使用关系嵌入进行注意力计算. 由于 KQ 拼接中的关系分别通过与键向量和查询向量的交互作用被整合到异构图注意力中, 因此 KQ 拼接无法充分反映关系的方向. 因此, KQ 拼接的性能略逊于其他两种方法.

• 不同多层特征融合方法对比. 在 JA-EN 和 FR-EN 数据集上, 最优方法均为使用求和进行多层特征融合的方法. 这些结果证明了求和方法优于拼接方法. 本文推测该现象与实体嵌入维度相关. 采用拼接方法的同时明显增加了实体嵌入维度, 将实体嵌入投入了更高维的空间, 而高维空间会为相似度搜索和距离测量带来困难. 另一个方面, 本身设定实体嵌入维度在 300 维已经可以表达丰富的实体特征, 过高的维度反而带来更多的特征冗余.

• 不同对齐推理方法对比. 从表 4-表 6 中很明显可以发现贪婪搜索相较于 CSLS 和 Sinkhorn 存在明显差距, 而 Sinkhorn 的平均 Hits@1 值均高于 CSLS. 这说明了 CSLS 和 Sinkhorn 均优化了贪婪搜索方法匹配的结果, 而 Sinkhorn 方法优化的效果更好. 但存在部分特例. 在 ZH-EN 数据集上, 所有基于拼接的方法使用 Sinkhorn 进行对齐推理的效果均弱于 CSLS. 因此推断相对于求和方法来说, Sinkhorn 对拼接方法的提升略低. 造成这个现象的原因推断为 CSLS 被用于缓解高维空间的 Hubness 问题, 而 Sinkhorn 本质上是处理最优传输问题, 两者的目标不同. 因此在拼接方法面临着更严重的 Hubness 问题时, CSLS 相较于 Sinkhorn 提升更明显. 同时 Hubness 问题也会一定程度上影响 Sinkhorn 算法效果, 因此相对于求和方法来说, Sinkhorn 对拼接方法的提升略低.

4.4 嵌入维度的影响

本节考虑了不同嵌入维度下 HGAT-EA 框架的不同表现. d 的选择范围为 {20, 40, 60, 80, 100, 300}, 其他参数与默认设置一致. 图 6 中给出了本文提出的方法与两种 SOTA 方法的比较. 可以观察到, 本文方法相较于其他两种基线方法变化相对平稳, 体现了本文方法在低维依旧有着优秀的性能. 特别的, 当维度为 20 时, 本文方法的 Hits@1 值依旧高于在 300 维时基线的 Hits@1 值. 该现象体现了本文方法的优点, 低维嵌入也有强大的表达能力.





图6 KQ 拼接+值向量+拼接与基线方法不同维度下 $Hits@1$ 值变化曲线

图7、图8及图9分别给出了在 JA-EN、FR-EN、ZH-EN 数据集上 HGAT-EA 框架中 6 种 HGAT 变体在 3 种不同对齐推理方法下的 $Hits@1$ 值随维度的变化情况。从图7-图9可以得到以下 3 个结论。

图7 JA-EN 数据集上 HGAT-EA 变体不同维度下 $Hits@1$ 值变化曲线图8 FR-EN 数据集上 HGAT-EA 变体不同维度下 $Hits@1$ 值变化曲线图9 ZH-EN 数据集上 HGAT-EA 变体不同维度下 $Hits@1$ 值变化曲线

(1) 大部分方法的 $Hits@1$ 值随着维度的降低而降低, 而采用拼接的方法是例外。例如, 图8中, 在采用贪婪搜索进行对齐推理时, 值向量+拼接的方法表现最优的维度为 80。这个现象说明了实体嵌入的维度并非越高越好, 虽然较高的维度能够充分学习到实体特征, 但不一定对评估实体间相似度提供帮助。

(2) 300 维时拼接方法表现弱于求和方法, 但随着维度的降低拼接方法的优势逐渐体现。特别是在 20 维时, 拼接方法优于其他方法至少 1% 的 $Hits@1$ 值。拼接方法在实体嵌入维度设置较低时具有明显优势, 推测该现象产生的原因在于拼接这种非线性的处理方式, 在低维情况最大程度保留了特征信息。求和这种线性处理方式在进行特征融合时不可避免地带来特征损失, 在高维情况下这些特征损失并未过多损失对齐精度, 但在低维情况下影响较为严重。

(3) 随着维度变化, 贪婪搜索和 CSLS 的实体对齐效果是正相关的。比较图7-图9中 (a)(b) 两列的折线图, 可以发现所有曲线的变化趋势基本一致。而对于 Sinkhorn 来说, 其效果与其他两种对齐推理方法无明显相关性。

4.5 Epoch 数的影响

本节考虑了在不同 epoch 数下 HGAT-EA 模型的收敛情况。Epoch 数的选择范围为 {10, 20, 30, 40}, 嵌入维度

设置均设为 100, 对齐推理算法均采用贪婪搜索算法, 其他参数与默认设置一致. 图 10 中给出基线方法 (RPR-RHGT 和 RAGA) 最优 Hits@1 值作为参考, 与 x 轴无关.




图 10 HGAT-EA 变体不同 epoch 数下 Hits@1 值变化曲线

观察图 10, 可以得到以下几项结论.

- (1) 本文提出方法在低 epoch 数时就能够取得优异的结果, 特别是拼接方法.
- (2) 即使本文提出的方法只运行了 10 个 epoch, 也能取得超过或接近基线方法的 Hits@1 值.

在 JA-EN 数据集上, 所有基于拼接的方法都在 10 个 epoch 时取得了超过基线的结果. 而求和的方法在 20 个 epoch 时也都能超越基线. 在 FR-EN 及 ZH-EN 数据集上, 本文框架内包含的所有方法均能够在 10 个 epoch 时超过基线方法的 Hits@1 值. 另外在 3 个数据集上都体现了拼接方法在低 epochs 数时的优势, 在 JA-EN 数据集尤为明显.

4.6 消融实验

本节给出了在 3 个数据集上, 只使用单通道模型变体与 HGAT-EA 的对比. 特别地, 保留结构嵌入的结果记为 S(*) (*表示 HGAT 中不同组件的组合方案), 保留字符嵌入结果记为 Char-Channel. 表 7 中均报告嵌入维度设置为 100 时, 对齐推理算法采用 Sinkhorn 的结果.

表 7 异构消息采用值向量对应变体消融实验结果

模型名称	JA-EN			FR-EN			ZH-EN		
	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR	Hits@1 (%)	Hits@10 (%)	MRR
Char-Channel	86.57	92.69	0.888	95.00	97.89	0.961	72.54	81.50	0.758
S(HGAT-EA-v1)	90.15	95.17	0.920	89.54	95.88	0.918	67.35	82.05	0.724
S(HGAT-EA-v2)	89.91	94.89	0.918	89.73	96.00	0.920	71.67	85.21	0.765
S(HGAT-EA-v3)	89.91	95.14	0.919	89.73	95.93	0.919	71.69	85.50	0.765
S(HGAT-EA-v4)	89.78	95.02	0.917	89.82	95.74	0.920	65.81	79.06	0.705
S(HGAT-EA-v5)	89.49	94.77	0.916	89.68	95.68	0.918	65.00	78.47	0.698
S(HGAT-EA-v6)	89.83	94.87	0.917	89.35	95.87	0.916	64.80	78.68	0.695
HGAT-EA-v1	95.79	98.03	0.966	97.10	98.93	0.978	81.98	90.45	0.850
HGAT-EA-v2	95.58	97.91	0.965	97.14	98.94	0.978	84.37	92.46	0.872
HGAT-EA-v3	95.76	97.97	0.966	96.81	98.77	0.975	82.62	91.09	0.857
HGAT-EA-v4	94.13	97.36	0.953	96.71	98.71	0.975	78.54	86.34	0.814
HGAT-EA-v5	94.92	97.71	0.959	96.86	98.79	0.976	81.14	89.07	0.841
HGAT-EA-v6	95.03	97.69	0.960	96.65	98.71	0.974	81.73	89.44	0.845

表 7 结果表明, 本文所有方法相比起仅使用一个通道的模型都有明显提升. 实验结果说明了本文提出多通道融合方法能够有效地融合不同通道下学习到的实体特征. 实验结果也证明了多视图 EA 通过考虑实体不同方面的特征而取得了明显收益. 同时发现单独使用结构嵌入也可以取得较优结果, 这说明了本文提出的 HGAT 的有效性.

5 总 结

本文设计了一个用于实体对齐的异构图注意力网络, 即 HGAT-EA. HGAT-EA 充分利用 4 种不同的视图来执行 EA. HGAT-EA 通过两个通道分别学习实体的结构嵌入和字符级语义嵌入. 第 1 个通道通过 HGAT 学习结构嵌入, 充分利用了异构结构和关系三元组. HGAT 包含元关系三元组 (<源实体类型、关系、目标实体类型>), 用于缓

解不同类型实体的差异. 通过充分利用异质结构, HGAT 可以在低维空间中学习高质量的 KG 嵌入. 第 2 个通道通过字符级字面量来学习字符级语义嵌入. 这样就能有效避免 OOV 问题. 本文分析了 HGAT-EA 不同变体之间的差异, 并进一步探讨了 3 种不同对齐推理算法的性能. HGAT-EA 在实体嵌入维数和 Epoch 数较低的情况下都具有显著优势. 最后, 本文证明了多视图给 EA 带来的巨大好处, 证实异构信息可以有效地帮助嵌入学习.

References:

- [1] Lehmann J, Isele R, Jakob M, Jentzsch A, Kontokostas D, Mendes PN, Hellmann S, Morsey M, van Kleef P, Auer S, Bizer C. DBpedia—A large-scale, multilingual knowledge base extracted from Wikipedia. *Semantic Web*, 2015, 6(2): 167–195. [doi: [10.3233/SW-140134](https://doi.org/10.3233/SW-140134)]
- [2] Cao YX, Wang X, He XN, Hu ZK, Chua TS. Unifying knowledge graph learning and recommendation: Towards a better understanding of user preferences. In: *Proc. of the 2019 World Wide Web Conf.* San Francisco: ACM, 2019. 151–161. [doi: [10.1145/3308558.3313705](https://doi.org/10.1145/3308558.3313705)]
- [3] Han X, Liu ZY, Sun MS. Neural knowledge acquisition via mutual attention between knowledge graph and text. In: *Proc. of the 32nd AAAI Conf. on Artificial Intelligence.* New Orleans: AAAI, 2018. 4832–4839. [doi: [10.1609/aaai.v32i1.11927](https://doi.org/10.1609/aaai.v32i1.11927)]
- [4] Lan YS, He GL, Jiang JH, Jiang J, Zhao WX, Wen JR. A survey on complex knowledge base question answering: Methods, challenges and solutions. In: *Proc. of the 30th Int'l Joint Conf. on Artificial Intelligence.* Montreal: IJCAI, 2021. 4483–4491. [doi: [10.24963/ijcai.2021/611](https://doi.org/10.24963/ijcai.2021/611)]
- [5] Zhang F, Yang LY, Li JW, Cheng JW. An overview of entity alignment methods. *Chinese Journal of Computers*, 2022, 45(6): 1195–1225 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2022.01195](https://doi.org/10.11897/SP.J.1016.2022.01195)]
- [6] Chen MH, Tian YT, Yang MH, Zaniolo C. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment. In: *Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence.* Melbourne: IJCAI, 2017. 1511–1517. [doi: [10.24963/ijcai.2017/209](https://doi.org/10.24963/ijcai.2017/209)]
- [7] Zhu H, Xie RB, Liu ZY, Sun MS. Iterative entity alignment via joint knowledge embeddings. In: *Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence.* Melbourne: IJCAI, 2017. 4258–4264. [doi: [10.24963/ijcai.2017/595](https://doi.org/10.24963/ijcai.2017/595)]
- [8] Sun ZQ, Hu W, Li CK. Cross-lingual entity alignment via joint attribute-preserving embedding. In: *Proc. of the 16th Int'l Semantic Web Conf. on the Semantic Web.* Vienna: Springer, 2017. 628–644. [doi: [10.1007/978-3-319-68288-4_37](https://doi.org/10.1007/978-3-319-68288-4_37)]
- [9] Bordes A, Usunier N, Garcia-Durán A, Weston J, Yakhnenko O. Translating embeddings for modeling multi-relational data. In: *Proc. of the 27th Int'l Conf. on Neural Information Processing Systems.* Lake Tahoe: Curran Associates Inc., 2013. 2787–2795.
- [10] Mao X, Wang WT, Xu HM, Wu YB, Lan M. Relational reflection entity alignment. In: *Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management.* ACM, 2020. 1095–1104. [doi: [10.1145/3340531.3412001](https://doi.org/10.1145/3340531.3412001)]
- [11] Liu XK, Zhang K, Liu Y, Chen EH, Huang ZY, Yue LA, Yan JX. RHGN: Relation-gated heterogeneous graph network for entity alignment in knowledge graphs. In: *Proc. of the 2023 Findings of the Association for Computational Linguistics.* Toronto: Association for Computational Linguistics, 2023. 8683–8696. [doi: [10.18653/v1/2023.findings-acl.553](https://doi.org/10.18653/v1/2023.findings-acl.553)]
- [12] Wang ZC, Lv QS, Lan XH, Zhang Y. Cross-lingual knowledge graph alignment via graph convolutional networks. In: *Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing.* Brussels: Association for Computational Linguistics, 2018. 349–357. [doi: [10.18653/v1/D18-1032](https://doi.org/10.18653/v1/D18-1032)]
- [13] Wu YT, Liu X, Feng YS, Wang Z, Yan R, Zhao DY. Relation-aware entity alignment for heterogeneous knowledge graphs. In: *Proc. of the 28th Int'l Joint Conf. on Artificial Intelligence.* Macao: IJCAI, 2019. 5278–5284. [doi: [10.24963/ijcai.2019/733](https://doi.org/10.24963/ijcai.2019/733)]
- [14] Wu YT, Liu X, Feng YS, Wang Z, Zhao DY. Neighborhood matching network for entity alignment. In: *Proc. of the 58th Annual Meeting of the Association for Computational Linguistics.* Association for Computational Linguistics, 2020. 6477–6487. [doi: [10.18653/v1/2020.acl-main.578](https://doi.org/10.18653/v1/2020.acl-main.578)]
- [15] Zhu RB, Ma M, Wang P. RAGA: Relation-aware graph attention networks for global entity alignment. In: *Proc. of the 25th Pacific-Asia Conf. Advances in Knowledge Discovery and Data Mining.* Springer, 2021. 501–513. [doi: [10.1007/978-3-030-75762-5_40](https://doi.org/10.1007/978-3-030-75762-5_40)]
- [16] Cai WS, Ma WJ, Zhan JY, Jiang YC. Entity alignment with reliable path reasoning and relation-aware heterogeneous graph Transformer. In: *Proc. of the 31st Int'l Joint Conf. on Artificial Intelligence.* Vienna: IJCAI, 2022. 1930–1937. [doi: [10.24963/ijcai.2022/268](https://doi.org/10.24963/ijcai.2022/268)]
- [17] Sun ZQ, Hu W, Zhang QH, Qu YZ. Bootstrapping entity alignment with knowledge graph embedding. In: *Proc. of the 27th Int'l Joint Conf. on Artificial Intelligence.* Stockholm: IJCAI, 2018. 4396–4402. [doi: [10.24963/ijcai.2018/611](https://doi.org/10.24963/ijcai.2018/611)]
- [18] Trisedya BD, Qi JZ, Zhang R. Entity alignment between knowledge graphs using attribute embeddings. In: *Proc. of the 33rd AAAI Conf. on Artificial Intelligence.* Honolulu: AAAI, 2019. 297–304. [doi: [10.1609/aaai.v33i01.3301297](https://doi.org/10.1609/aaai.v33i01.3301297)]
- [19] Liu ZY, Cao YX, Pan LM, Li JZ, Liu ZY, Chua TS. Exploring and evaluating attributes, values, and structures for entity alignment. In: *Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing.* Association for Computational Linguistics, 2020.

- 6355–6364. [doi: [10.18653/v1/2020.emnlp-main.515](https://doi.org/10.18653/v1/2020.emnlp-main.515)]
- [20] Xu K, Wang LW, Yu M, Feng YS, Song Y, Wang ZG, Yu D. Cross-lingual knowledge graph alignment via graph matching neural network. In: Proc. of the 57th Annual Meeting of the Association for Computational Linguistics. Florence: Association for Computational Linguistics, 2019. 3156–3161. [doi: [10.18653/v1/P19-1304](https://doi.org/10.18653/v1/P19-1304)]
- [21] Shi XC, Li B, Chen L, Yang C. Bi-neighborhood graph neural network for cross-lingual entity alignment. Knowledge-based Systems, 2023, 277: 110841. [doi: [10.1016/j.knosys.2023.110841](https://doi.org/10.1016/j.knosys.2023.110841)]
- [22] Zhou YF, Zhu C, Zhu WJ, Li HY. SCMEA: A stacked co-enhanced model for entity alignment based on multi-aspect information fusion and bidirectional contrastive learning. Neural Networks, 2024, 173: 106178. [doi: [10.1016/j.neunet.2024.106178](https://doi.org/10.1016/j.neunet.2024.106178)]
- [23] Lample G, Conneau A, Ranzato MA, Denoyer L, Jégou H. Word translation without parallel data. In: Proc. of the 6th Int'l Conf. on Learning Representations. Vancouver: OpenReview.net, 2018.
- [24] Mena G, Belanger D, Linderman S, Snoek J. Learning latent permutations with Gumbel-Sinkhorn networks. In: Proc. of the 6th Int'l Conf. on Learning Representations. Vancouver: OpenReview.net, 2018.
- [25] Lin ZX, Zhang ZH, Wang M, Shi YH, Wu X, Zheng YF. Multi-modal contrastive representation learning for entity alignment. In: Proc. of the 29th Int'l Conf. on Computational Linguistics. Gyeongju: Int'l Committee on Computational Linguistics, 2022. 2572–2584.
- [26] Mao X, Wang WT, Wu YB, Lan M. From alignment to assignment: Frustratingly simple unsupervised entity alignment. In: Proc. of the 2021 Conf. on Empirical Methods in Natural Language Processing. Punta Cana: Association for Computational Linguistics, 2021. 2843–2853. [doi: [10.18653/v1/2021.emnlp-main.226](https://doi.org/10.18653/v1/2021.emnlp-main.226)]
- [27] Cipolla R, Gal Y, Kendall A. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics. In: Proc. of the 2018 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7482–7491. [doi: [10.1109/CVPR.2018.00781](https://doi.org/10.1109/CVPR.2018.00781)]
- [28] Sun ZQ, Zhang QH, Hu W, Wang CM, Chen MH, Akrami F, Li CK. A benchmarking study of embedding-based entity alignment for knowledge graphs. Proc. of the VLDB Endowment, 2020, 13(12): 2326–2340. [doi: [10.14778/3407790.3407828](https://doi.org/10.14778/3407790.3407828)]

附中文参考文献:

- [5] 张富, 杨琳艳, 李健伟, 程经纬. 实体对齐研究综述. 计算机学报, 2022, 45(6): 1195–1225. [doi: [10.11897/SP.J.1016.2022.01195](https://doi.org/10.11897/SP.J.1016.2022.01195)]



孙琛琛(1987—), 男, 博士, 副教授, CCF 专业会员, 主要研究领域为数据集成, 大数据管理与分析.



聂铁铮(1980—), 男, 博士, 副教授, CCF 高级会员, 主要研究领域为数据集成, 区块链.



金钰媛(1999—), 女, 硕士, 主要研究领域为数据集成, 知识图谱.



寇月(1980—), 女, 博士, 副教授, CCF 高级会员, 主要研究领域为推荐系统, 实体识别.



申德荣(1964—), 女, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为数据集成, 分布式数据管理.