

基于知识监督的标签降噪实体对齐

苏丰龙, 景宁
国防科技大学, 长沙, 410073
xueshu2021@qq.com

摘要

大多数现有的实体对齐解决方案都依赖于干净的标记数据来训练模型, 很少关注种子噪声。为了解决实体对齐中的噪声问题, 本文提出了一个标签降噪框架, 在实体对齐中注入辅助知识和附带监督, 以纠正标记和引导过程中的种子错误。特别是, 考虑到以前基于邻域嵌入方法的弱点, 本文应用了一种新的对偶关系注意力匹配编码器来加速知识图谱的结构学习, 同时使用辅助知识来弥补结构表征的不足。然后, 通过对抗训练来执行弱监督标签降噪。对于误差累积的问题, 本文进一步使用对齐精化模块来提高模型的性能。实验结果表明, 所提的框架能够轻松应对含噪声环境下的实体对齐问题, 在多个真实数据集上的对齐准确性和噪声辨别能力始终优于其他基线方法。

Keywords: 图对齐, 标签精化, 降噪算法, 多模态监督

Refined De-noising for Labeled Entity Alignment from Auxiliary Evidence Knowledge

Fenglong Su, and Ning Jing
National University of Defense Technology, Changsha, 410073, China
xueshu2021@qq.com

Abstract

Most existing entity alignment solutions rely on clean labeled data to train models, with little attention to seed noise. To address the noise problem in entity alignment, this paper proposes a labeling noise reduction framework that injects auxiliary knowledge and incidental supervision in entity alignment to correct the seed errors in the labeling and bootstrapping process. In particular, considering the weaknesses of previous neighborhood-based embedding approaches, this paper applies a new dual relational attention-matching encoder to accelerate the structure learning of the knowledge graph while using auxiliary knowledge to compensate for the lack of structural representations. Then, weakly supervised label noise reduction is performed by adversarial training. For the problem of error accumulation, this paper further uses the label refinement module to improve the performance of the model. Experimental results show that the proposed framework can easily cope with the entity alignment problem in noise-laden environments and consistently outperforms other baseline methods in terms of alignment accuracy and noise discrimination on multiple real datasets.

Keywords: Graph Alignment, Label Refinement, De-noising Algorithm, Multi-modal Enhanced

1 引言

实体对齐(Entity Alignment, EA)旨在识别不同知识图谱中的等效实体,是知识图谱融合的关键步骤,并且在过去几年中得到了深入研究。最近,越来越多的人开始关注利用知识图谱(Knowledge Graph, KG)嵌入技术来解决EA问题,其关键思想是学习KG的向量表示并根据嵌入之间的相似性找到等效实体。具体来说,他们应用TransE(Bordes et al., 2013)或GCN(Kipf and Welling, 2016)来获得每个实体的密集嵌入,然后通过对齐模块将这些嵌入映射到统一的向量空间,最后,实体之间的成对距离决定它们是否对齐。总的来说,这些方法通常包括以下三个步骤:(i)将预先标注的实体种子对指定为锚;(ii)训练由锚种子和伪标签引导的EA模型;(iii)根据训练好EA模型去对齐剩余实体对。尽管过去的工作取得了一定的成绩,但是本文仍然从当前的EA研究中观察到了以下几个问题:

(1).对于干净种子的依赖。大多数方法依靠预先对齐的锚来连接两个KG,并使用统一的KG结构嵌入来对齐实体。在实践中,这种干净的标记数据的获取成本非常高。如果仅仅依靠结构学习的低质量引导也可能给模型带来额外的错误,从而促使半监督的方法无法获得准确的嵌入来进行对齐。更重要的是,在现实世界的标注过程中,噪声的参与是一个常见的且不可避免的问题。因此,训练数据中存在的标签噪声不应该忽视。

(2).低效的拓扑编码器。以前基于邻域嵌入的EA方法其拓扑编码模块并不稳健,例如, RDGCN(Wu et al., 2019), NMN(Wu et al., 2020), HMAN(Yang et al., 2019)和RNM(Zhu et al., 2021)],当在没有名称嵌入的情况下初始化这些网络时,它们在EA任务中几乎没法工作。GMNN(Xu et al., 2019)的运行效率低下,甚至需要5天才能生成结果(Zhao et al., 2020)。这些方法计算复杂度高,一般为 $\mathcal{O}(|E_1||E_2|)$,在大型数据集上更是无法运行。因此,当前EA任务中的拓扑编码效率需要提高。

(3).不灵活的降噪技术。当前EA主要基于等效实体具有相似邻居结构的假设。然而,现实生活中的KG只有少数实体与其他实体紧密相连,其余大多数实体只拥有相当稀疏的邻域结构。也就是说,通过拓扑连接来描述实体的特征是非常片面的,仅仅依靠结构信息来进行实体对齐也是不合理的,因此EA降噪技术不应当局限于三元组噪声(Chen et al., 2019; Huang et al., 2022; Jia et al., 2019)。此外,现有的标记降噪方法并不能很好地解决误差累积的问题。但是,如果从其他模态中学习节点的信息却能够使用更多对齐证据来自动纠正错误从而进一步精细化标签。

为了克服以上问题,本文探讨了如何将噪声检测与EA模型结合起来训练,提出了一个知识辅助的EA降噪框架以纠正标签错误。特别是考虑到以前基于邻域嵌入方法的弱点,本文应用了一种新的对偶关系匹配编码器来加速KG的结构学习。然后通过对抗强化学习来执行辅助知识的弱监督降噪,接着进一步地使用标签精化模块来改善误差累积的问题。最后,本文在抗噪声的环境下实现了EA任务。本文工作的主要贡献可以总结如下:

- 据本文所知,这是第一个将辅助知识引入标签降噪EA的工作。此外,本文还利用对齐精化模块来解决误差累积的问题。
- 针对以往图编码器效率低下的问题,本文通过新的对偶匹配图编码以更加有效的方式充分考虑了关系信息,同时降低了计算复杂度。
- 通过进行全面的实验评估,本文所提的附带监督的噪声感知EA框架在对齐精度和噪声辨别能力方面始终优于其他最先进的方法。

本文的组织结构如下:第2节介绍了相关工作。在第3节中,本文正式定义了降噪EA的任务。第4节详细阐述了本文的LDEA的框架。在第5节中,本文介绍了实验结果并进行了详细的分析。第6节总结了这篇文章。

2 相关工作

关于EA任务,现有的大部分研究都集中在研究如何高效地构建嵌入模型,这些方法试图将KG的实体嵌入到潜在空间中,并计算实体向量之间的距离来作为对齐的证据。这些技术使用的种子都是无噪声的标记数据,很少关注EA中标记和引导过程中的种子错误。本节将介绍与之相关的一些研究。

知识图谱对齐。 知识图谱对齐是扩增知识图谱覆盖范围的最基本任务之一。早期技术利用手工制作特征、众包和基于OWL的等价推理来解决EA问题。由于耗费大量的人力和时间，逐渐被基于嵌入的模型所取代。这些方法应用结构学习来获得每个实体的密集嵌入，然后通过对齐模块将这些嵌入映射到统一的向量空间，最后，实体之间的成对距离决定它们是否对齐。

现有工作主要研究如何学习高质量的实体嵌入表示。根据使用的实体特征，可以分为两类：基于关系的方法和属性增强方法。前者使用知识图谱的关系结构进行表示学习，主流技术主要包括翻译模型(Zhu et al., 2017; Chen et al., 2016; Sun et al., 2019a)、循环神经网络模型(Guo et al., 2019)和图神经网络模型(Wang et al., 2018; Sun et al., 2020; Mao et al., 2020; Wu et al., 2020)。除了基于关系结构的表示学习外，属性增强的方法通过引入实体额外的属性信息来帮助对齐，如实体摘要(Chen et al., 2018)、实体名称向量(Zeng et al., 2020)、图像(Liu et al., 2021)、时间知识(Xu et al., 2021)、实体属性知识(Trisedya et al., 2019; Sun et al., 2017)等。最近也有一些工作有考虑将本体技术与传统实体匹配技术(Xiang et al., 2021)相结合，通过优化表示学习效率(Mao et al., 2021)，并引入主动学习技术(Nayyeri et al., 2021)来辅助对齐等。

知识图谱错误检测。 知识图谱中的错误会对相关应用和知识获取产生负面影响。为了解决这个问题，错误检测最近引起了广泛关注。更具体地说，相关工作包括数值错误检测(Li et al., 2015)，通过来自外部KG的三元组查询进行验证(Wang et al., 2020)，研究KG嵌入学习稀疏性和不可靠性(Pujara et al., 2017)，错误感知的少样本知识图谱补全(Wang et al., 2021)等。但是，以上这些现有方法都是对单个KG开展的研究，在多个KG的融合方面并没有涉及，只涵盖了一些不确定性KG的补全(Chen et al., 2019; Huang et al., 2022)和包含三元组噪声的KG补全(Jia et al., 2019)，并且很少有工作专注于KG对齐过程中的标签错误。

在同质图的相关研究中，错误检测也被广泛关注。如，对稀疏和含噪同质图的分类(Dai et al., 2021; Dai et al., 2022)，基于含噪数据的网络对齐(Huynh et al., 2020)，部分正确种子的子图匹配(Yu et al., 2021)，分布式渗入图匹配(Davalas et al., 2019)，不确定度感知的同质图网络对齐(Zhou et al., 2021)等。值得注意的是，同质图中的结构噪声是通过随机删除边来模拟的，例如，常见的社交网络和人工合成图，这与KG的应用和背景有很大的不同。此外，还有一些工作专注于图上的标签精化，例如，图主动学习(Zhang et al., 2022)、精化邻域的一致性(Heimann et al., 2021)、伪标签精化(Li and Song, 2022)和软标签编辑(Xin et al., 2022)等。

3 问题定义

形式上，一个KG可以表示为 $\mathcal{G} = (E, R, T, M)$ ，其中， E 和 R 分别是实体和关系的集合。 $T \subset E \times R \times E$ 是事实三元组的集合。 M 是实体附加的模态信息，如实体的图片，描述和属性等。假设 $\mathcal{G}_1 = (E_1, R_1, T_1, M_1)$ 和 $\mathcal{G}_2 = (E_2, R_2, T_2, M_2)$ 是两个KG，并且 $\mathcal{L}\mathcal{S} = \{(e_i^1, e_j^2), AS | e_i^1 \in E_1, e_j^2 \in E_2\}$ 是标记种子的集合。因此，常规EA的任务旨在基于预先对齐的标记种子 $\mathcal{L}\mathcal{S}$ 和已知的多模态知识 M 找到新的对齐实体对。在本文中，本文将 $AS(e_1, e_2) \in \{0, 0.5, 1\}$ 用来指示实体对能否对齐的概率。

而降噪EA是给定有噪声的实体对 $\mathcal{L}\mathcal{S}^U$ 和可信的实体对 $\mathcal{L}\mathcal{S}^T$ ，模型通过学习能够意识到 $\mathcal{L}\mathcal{S}^U$ 中的噪声存在($AS = 0$)，然后找到可信的样本($AS = 1$)并对齐剩余的实体对。本文的研究目标是验证所提的框架能够很好地检测标签错误并在抗噪声的环境下对齐实体。

4 本文的框架

本文框架提取了实体的拓扑、视觉、文字和属性信息，来相互补充实体特征的缺失并且辅助实体对齐。在本节中，首先讨论了如何为这四个方面构建原始特征，然后将其输入到框架以促进KG结构学习。

4.1 多模态知识

不同类型的特征从各个方面表征了实体身份。直观地说，融合多模态知识的EA模型优于单模态模型，因为它们聚合了更多信息。(1).对于文字知识，本文使用多语言Bert(Devlin et al., 2019)来获得文字嵌入。(2).对于视觉知识，本文采用ResNet50(He et al., 2016)学习图像嵌入。(3).在这项工作中，本文认为属性信息也可以为判断两个实体是否相同提供重要线索。根据之前的工作(Sun et al., 2017)，本文直接使用属性三元组作为支撑知识。




Figure 1: 本文的LDEA 框架。左边是基于DRM 的结构学习模块，右边是带有对抗训练的知识监督降噪模块。

形式上，给定文本向量表示 L ，视觉特征表示 V 和属性特征表示 A ，计算实体对 (e_1, e_2) 之间的相似度得分，然后利用该相似度得分来预测潜在的对齐实体对。为了计算总体相似度，本文首先计算实体对之间的特定特征相似度得分，即 $Sim_A(e_1, e_2)$ ， $Sim_L(e_1, e_2)$ 和 $Sim_V(e_1, e_2)$ ，最后来获得实体对 (e_1, e_2) 的融合相似度：

$$Sim_{fused}(e_1, e_2) = \beta_1 Sim_L(e_1, e_2) + \beta_2 Sim_V(e_1, e_2) + \beta_3 Sim_A(e_1, e_2) \quad (1)$$

其中， β_1 ， β_2 和 β_3 分别代表文本，视觉和属性信息的相似度权重。

4.2 图编码器

本文采用对偶关系匹配编码器(Dual Relational Matching Encoder, DRM)有效地关注它们的邻居，从而进一步地计算每个实体在KG中的隐表示。输入是两个矩阵： $H_e \in \mathcal{Z}^{|E| \times d}$ 表示实体嵌入， $H_r \in \mathcal{Z}^{|R| \times d}$ 表示关系嵌入。实体 e_i 在第 ℓ 层的输出嵌入由以下公式获得：

$$h_{e_i}^{\ell+1} = \tanh \left(\sum_{e_j \in \mathcal{N}_{e_i}} \sum_{r_k \in \mathcal{R}_{ij}} \alpha_{ijk}^{\ell} (h_{e_j}^{\ell} - 2h_{r_k}^T h_{e_j}^{\ell} h_{r_k}) \right) \quad (2)$$

其中，对于 α_{ijk}^{ℓ} ，本文指定权重：

$$\alpha_{ijk}^{\ell} = \frac{\exp(v^T h_{r_k})}{\sum_{e'_j \in \mathcal{N}_{e_i}} \sum_{r_{k'} \in \mathcal{R}_{ij'}} \exp(v^T h_{r_{k'}})} \quad (3)$$

其中， v^T 是一个注意力向量。然后，本文通过堆叠更多层来创建全局感知的图表示。所以，实体 e_i 的最终嵌入是：

$$h_{e_i}^{combined} = [h_{e_i}^0 \| h_{e_i}^1 \| \dots \| h_{e_i}^{\ell}] \quad (4)$$

其中, \parallel 代表级联操作。

为了降低计算成本, 本文采用一个代理匹配注意力层来捕获跨图对齐信息, 专注于计算所有实体和有限锚点之间的相似度, 而不需要计算所有节点到节点的交互。这种交互方式可以将计算复杂度从 $\mathcal{O}(|E_1||E_2|)$ 大大降低到 $\mathcal{O}(|E_1| + |E_2|)$ 。该代理匹配注意力层的输入是两个矩阵: $\mathbf{H}^{combined} \in \mathcal{Z}^{|E| \times \ell \times d}$ 表示通过简化关系注意层获得的实体嵌入, $\mathbf{Q} \in \mathcal{Z}^{n \times \ell \times d}$ 表示具有随机初始化的代理向量, 其中 n 表示代理向量的数量。

$$\beta_{ij} = \frac{\exp(\cos(\mathbf{h}_{e_i}^{combined}, \mathbf{q}_j))}{\sum_{k \in \mathcal{S}_p} \exp(\cos(\mathbf{h}_{e_i}, \mathbf{q}_k))} \quad (5)$$

其中, β_{ij} 是每个实体与所有代理向量之间的相似度, \mathcal{S}_p 表示代理向量的集合。然后, 实体 e_i 的交叉图嵌入可以计算为:

$$\mathbf{h}_{e_i}^p = \sum_{j \in \mathcal{S}_p} \beta_{ij} (\mathbf{h}_{e_i}^{combined} - \mathbf{q}_j) \quad (6)$$

最后, 本文采用门控机制将 $\mathbf{h}_{e_i}^p$ 和 $\mathbf{h}_{e_i}^{combined}$ 结合起来, 控制单图和多图之间的信息流:

$$\eta_{e_i} = \text{sigmoid}(\mathbf{M}\mathbf{h}_{e_i}^p + \mathbf{b}) \quad (7)$$

$$\mathbf{h}_{e_i}^{final} = \eta_{e_i} \cdot \mathbf{h}_{e_i}^p + (1 - \eta_{e_i}) \cdot \mathbf{h}_{e_i}^{combined} \quad (8)$$

其中, \mathbf{M} 和 \mathbf{b} 是门权重矩阵和门偏置向量。因此, 上述编码器可将知识图谱 \mathcal{G}_1 和 \mathcal{G}_2 的实体映射到相同的嵌入空间中, 得到实体的最终嵌入表征:

$$\mathbf{H}_{e_1}^{final}, \mathbf{H}_{e_2}^{final} = f_{\text{DRM}}(\mathcal{G}_1, \mathcal{G}_2) \quad (9)$$

附带证据降噪对齐。 值得注意的是, 本文采用带有对齐概率的边际损失函数用作降噪对齐优化目标, 即:

$$\mathcal{L}_{EA} = \sum_{(e_i, e_j) \in \mathcal{LS}} \sum_{(e'_i, e'_j) \in \mathcal{LS}'} AS(e_i, e_j) [\text{sim}(e_i, e_j) - \text{sim}(e'_i, e'_j) + \lambda]_+ \quad (10)$$

4.3 降噪训练

本文在对抗性训练的启发下 (Goodfellow et al., 2014), 通过生成对抗网络来建模降噪过程。包含2个模块: 噪声生成器和噪声鉴别器, 相互迭代优化。

噪声生成器。 更具体地说, 利用上述编码器 f_{DRM} 中学习到的 (e_x, e_y) 的嵌入来生成噪声对 (e'_x, e'_y) , 使它们在潜在分布上尽可能地接近真实分布, 以便在 $D(\cdot; \theta)$ 固定的情况下, 使 (e'_x, e'_y) 被识别为噪声的可能性最小。因此, 本文定义生成噪声实体对 (e'_x, e'_y) 的概率如下:

$$G((e'_x, e'_y) | (e_x, e_y); \theta) = \frac{\exp(f_\theta(e'_x, e'_y))}{\sum \exp(f_\theta(e_x^*, e_y^*))} \quad (11)$$

$$(e_x^*, e_y^*) \in \mathcal{N}(e_x, e_y) \subset \mathcal{LS}'_{(e_x, e_y)} \quad (12)$$

由于生成器生成的实体对 (e_x, e_y) 是离散的, 本文使用基于策略梯度的强化学习算法对优化器对其进行优化。对于实体对 (e_x, e_y) , 其梯度 \mathcal{L}_G 可以推导出如下公式:

$$\begin{aligned}
 & \nabla_{\theta} \mathcal{L}_G(e_x, e_y) \\
 &= \nabla_{\theta} \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] \\
 &= \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\nabla_{\theta} \log G(\cdot | (e_x, e_y); \theta) \log(1 - D((e'_x, e'_y); \phi))] \\
 &\simeq \frac{1}{\eta} \sum_{\eta} \nabla_{\theta} \log G(\cdot | (e_x, e_y); \theta) \log(1 - D((e'_x, e'_y); \phi))
 \end{aligned} \tag{13}$$

其中，最后一个近似相等意味着从当前生成器中采样 η 个负实体对 (e'_x, e'_y) 来使用采样近似。更具体地说， (e_x, e_y) 可以看作是状态， $G(\cdot | (e_x, e_y); \theta)$ 是策略， (e'_x, e'_y) 是动作， $\log(1 - D((e'_x, e'_y); \phi))$ 是奖励。因此，生成器（代理）可以通过根据当前状态和策略执行操作来与判别器（环境）交互，然后通过最大化来自环境的奖励作为执行操作的响应来更新自身。此外，本文在奖励函数中引入了一个广泛使用的基线函数 $\mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))]$ 来减少方差，并更新奖励如下：

$$\mathcal{R}_G = \log(1 - D((e'_x, e'_y); \phi)) - \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] \tag{14}$$

因此，噪声生成器使用如下优化目标函数：

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \sum_{(e_i, e_j) \in \mathcal{L}S^T} \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] \tag{15}$$

其中，本文假设 $\mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] = \mathcal{L}_G(e_x, e_y)$ 是一对样本 (e_x, e_y) 的损失函数。

噪声鉴别器。 本文将噪声鉴别器定义为二元分类器，其目标函数是在 $G(\cdot | (e_x, e_y); \theta)$ 固定的情况下最大化正确区分正样本与生成负样本的对数似然，定义如下：

$$\phi^* = \underset{\phi}{\operatorname{argmax}} \sum_{(e_i, e_j) \in \mathcal{L}S^T} \mathbb{E}_{(e_x, e_y) \sim \mathcal{L}S^T} [\log D((e_x, e_y); \phi)] + \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] \tag{16}$$

$$D((e_x, e_y); \phi) = \sigma(f_{\phi}(e_x, e_y)) = \frac{\exp(f_{\phi}(e_x, e_y))}{\exp(f_{\phi}(e_x, e_y)) + 1} \tag{17}$$

其中， $f_{\phi}(x, y)$ 是以ReLU为激活函数的两层神经网络，其输入为 $\|x - y\|_1$ ； $\sigma(x)$ 是Sigmoid函数。因为 f_{ϕ} 对 ϕ 是可微的，所以可以通过随机梯度下降来更新目标函数。

值得注意的是，本文将公式 10 中提到的对齐分数定义如下：

$$AS(e_x, e_y) = \begin{cases} 1, & \sigma(f_{\phi}(e_x, e_y)) \geq \delta \\ 0.5, & \sigma(f_{\phi}(e_x, e_y)) < \delta \in \text{Simfused}(e_x, e_y) > \tau \\ 0, & \sigma(f_{\phi}(e_x, e_y)) < \delta \notin \text{Simfused}(e_x, e_y) > \tau \end{cases} \tag{18}$$

其中， $\sigma(f_{\phi}(e_x, e_y))$ 是判别器的输出， δ 和 τ 是阈值，用来区分真假实体对。本文将 $AS(e_x, e_y)$ 设置为 $\{0, 0.5, 1\}$ ，分别表示某一对实体不能对齐，不确定和能对齐。此外，集合 $\mathcal{L}S^T$ 可以根据 $\mathcal{L}S^U$ 中实体对的对齐分数的变化进行扩充，即在每一轮对抗训练后，从集合 $\mathcal{L}S^U$ 中选择 $AS = 1$ 的实体对加入 $\mathcal{L}S^T$ 集合。

降噪损失。 最后本文将整体的降噪损失函数定义如下：

$$\mathcal{L}_{NR} = \max_{\phi} \min_{\theta} \sum_{(e_i, e_j) \in \mathcal{L}S^T} \mathbb{E}_{(e_x, e_y) \sim \mathcal{L}S^T} [\log D((e_x, e_y); \phi)] + \mathbb{E}_{(e'_x, e'_y) \sim G(\cdot | (e_x, e_y); \theta)} [\log(1 - D((e'_x, e'_y); \phi))] \tag{19}$$

Algorithm 1 Refined De-noising for Labeled Entity Alignment(LDEA)**Input:**

知识图谱 \mathcal{G}_1 和 \mathcal{G}_2 ，标记种子集合 $\mathcal{L}S^U$ ，可信种子集合 $\mathcal{L}S^T$ 。

Output:

\mathcal{G}_1 和 \mathcal{G}_2 的实体嵌入 H_{e_1} 、 H_{e_2}

- 1: 初始化嵌入 H_{e_1} 、 H_{e_2} ；生成器 G 、鉴别器 D 和编码器 f_{DRM} 的参数；
- 2: 初始化 $\mathcal{L}S^U$ 和 $\mathcal{L}S^T$ 的信任分数；
- 3: 训练文字和视觉模块，得到对应实体的嵌入 e_1 、 e_2 ；
- 4: **while** 不收敛 **do**
- 5: //基于标记种子集合 $\mathcal{L}S^U$ 和可信种子集合 $\mathcal{L}S^T$ 训练噪声感知的拓扑模型；
- 6: **for** $m=0$; $m < m_{EN}$ **do**
- 7: 从 $\mathcal{L}S^T$ 中采样一批实体对，根据公式10更新 \mathcal{L}_{EA}
- 8: **end for**
- 9: 从 $\mathcal{L}S^T$ 中采样一批实体对，为每个 (e_1, e_2) 生成噪声实体对 $(e'_1, e'_2) \sim G(\cdot | (e_1, e_2))$ ；
- 10: **for** $m = 0$; $m < m_D$ **do**
- 11: 根据公式16更新 ϕ
- 12: **end for**
- 13: **for** $m = 0$; $m < m_G$ **do**
- 14: 根据公式15更新 θ
- 15: **end for**
- 16: //标签精化；
- 17: **for each** $e_1 \in \mathcal{L}S^U$ **do**
- 18: $e_1 \leftarrow \text{NearestNeighbor}(e_1, E_2)$
- 19: **if** $\text{NearestNeighbor}(e_2, E_1) = e_2$ and $\text{Sim}_{\text{fused}}(e_1, e_2) > \tau$ **then**
- 20: $AS(e_1, e_2) = 1$ ；
- 21: **end if**
- 22: **end for**
- 23: 更新 $\mathcal{L}S^U$ 中实体对的信任分数，将 $AS = 1$ 的 $\mathcal{L}S^U$ 中的实体对添加到 $\mathcal{L}S^T$ 中；
- 24: **end while**

5 实验

本文使用Keras框架，实验是在配备GeForce GTX 1080Ti GPU和128 GB内存的工作站上进行的。本文采用了两个评估指标：Hits@k和MRR，较高的Hits@k和MRR分数表示更好的对齐性能。

5.1 数据集

本文在实验中使用了五个数据集。(1) DBP15K：该数据集由DBpedia构建的三个跨语言子集组成。每个子集包含15,000个用于训练和测试的预对齐锚种子。它们都包含实体图像和摘要。(2) DW100K：该数据集包含实体属性，每个数据集包含两个单语子集，每个子集包含100,000个预对齐的锚种子。本文随机拆分30%的标记节点对进行训练，其余70%用于测试。由于上述数据集中给定的标记节点对都是干净的，因此本文需要生成一些噪声数据来替换部分干净数据，以模拟标注噪声。根据最近的工作(Pei et al., 2020)，本文随机破坏40%的训练集作为噪声样本，并将其余60%作为正确样本。然后本文随机选择50%的正确样本作为可信的正标签 $\mathcal{L}S^T$ ，并将剩下50%的正确样本与噪声样本混合作为不可信的标签 $\mathcal{L}S^U$ 。本文的研究就是使用含噪声的训练集 $\mathcal{L}S^U$ 去训练本文的抗噪模型，使其能够从不可信的标签 $\mathcal{L}S^U$ 中尽可能检测出噪声。表1描述了数据集的统计信息。

5.2 实验设置

超参数。在这项工作中，本文最佳配置为：嵌入维度 d 设定为200，间隔参数 γ 为3.0，GCN层数 ℓ 为2，用于生成器和判别器的MLP网络有两层，分别有100和30个隐藏单元。本文设定 m_{EN} 为1500， m_D 和 m_G 都为500，负采样的数量 η 设定为10。此外，本文将信任分数设定为

Table 1: 数据集统计信息

Datasets	DBP15K _{ZH-EN}		DBP15K _{JA-EN}		DBP15K _{FR-EN}		DWY100K _w		DWY100K _y	
	ZH	EN	JA	EN	FR	EN	DBP	Wikidata	DBP	YAGO3
Entities	19388	19572	19814	19780	19661	19993	100000	100000	100000	100000
Relations	1701	1323	1299	1153	903	1208	330	220	302	31
Triples	70414	95142	77214	93484	105998	115722	463294	448774	428952	502563
Images covered	15912	14125	12739	13741	14174	13858	-	-	-	-
Abstracts covered	14840	14954	14946	14946	14923	14926	-	-	-	-
Attributes covered	248035	343218	248991	320616	273825	351094	341770	779402	383757	98028
Anchors	15000		15000		15000		100000		100000	
$\mathcal{L}S^T + \mathcal{L}S^U$	1350+3150		1350+3150		1350+3150		30000+70000		30000+70000	

Table 2: 跨语言数据集和单语言数据集的主要结果 (40%噪声)

Models	DBP15K _{ZH-EN}			DBP15K _{JA-EN}			DBP15K _{FR-EN}			DWY100K _w			DWY100K _y		
	Hits@1	Hits@5	MRR	Hits@1	Hits@5	MRR	Hits@1	Hits@5	MRR	Hits@1	Hits@5	MRR	Hits@1	Hits@5	MRR
MTransE	.169	.362	.216	.148	.345	.198	.143	.338	.192	.154	.325	.203	.137	.318	.186
IPTransE	.185	.394	.258	.174	.386	.242	.181	.402	.269	.193	.414	.296	.158	.346	.223
GCN-Align	.223	.424	.316	.223	.439	.321	.231	.462	.337	.331	.487	.392	.376	.525	.448
AlignEA	.263	.457	.342	.254	.451	.338	.278	.471	.357	.331	.487	.392	.376	.525	.448
MuGNN	.274	.471	.361	.279	.481	.368	.284	.485	.372	.348	.503	.417	.401	.554	.475
AliNet	.286	.468	.365	.295	.470	.379	.298	.486	.384	.372	.514	.437	.420	.563	.490
REA-KE	.235	.437	.319	.236	.451	.334	.229	.456	.332	.312	.468	.379	.352	.513	.432
REA	.289	.486	.380	.293	.498	.388	.304	.539	.403	.368	.547	.444	.426	.577	.494
CPUGA-KE	.228	.426	.316	.230	.446	.323	.228	.457	.334	.298	.462	.375	.356	.509	.427
CPUGA	<u>.306</u>	<u>.506</u>	<u>.397</u>	<u>.312</u>	<u>.521</u>	<u>.406</u>	<u>.321</u>	<u>.556</u>	<u>.424</u>	<u>.390</u>	<u>.568</u>	<u>.467</u>	<u>.449</u>	<u>.603</u>	<u>.524</u>
LDEA	.568	.790	.668	.542	.772	.645	.583	.823	.689	.507	.724	.607	.712	.873	.784
Improv.	85.6%	56.1%	68.3%	23.5%	73.7%	48.2%	81.6%	48.0%	62.5%	30.0%	27.5%	30.0%	58.6%	44.8%	49.6%

”Improv.”表示与SOTA相比增加的百分比。

离散概率形式 $\{0, 0.5, 1\}$ ，阈值 δ 为0.01，相似度阈值 τ 为区间 $[0.5, 0.95]$ ，以便在实体对齐的性能和噪声的影响之间取得更好的平衡。本文使用Adam优化器对公式 16和公式 15中的损失函数进行优化，学习率为0.01，并应用SGD对公式 10中的损失函数进行优化。每个评估重复5次后报告平均结果。其余基线，本文遵循原始论文中的设置来实现最佳性能。

对比模型。为了验证本文提出的方法的有效性，本文将LDEA与几种基于嵌入的方法进行了比较：如MTransE(Chen et al., 2016)、IPTransE(Zhu et al., 2017)、AlignEA(Sun et al., 2018)、GCN-Align(Wang et al., 2018)、MuGCN(Cao et al., 2019)、AliNet(Sun et al., 2020)、REA-KE(Pei et al., 2020)和CPUGA-KE(Pei et al., 2022)，值得注意的是，这些方法都没有噪声检测模块。另外，本文还将提出的方法与带有降噪模块的方法进行了比较：如REA(Pei et al., 2020)和CPUGA(Pei et al., 2022)。

5.3 主要结果

在表 2 中，列出了所有被评估模型的对齐结果。本文的框架在所有数据集上始终保持最佳性能。在跨语言数据集 (DBP15K) 上，LDEA 在Hits@1和MRR方面均优于其他方法约23%-85%。在单语言数据集 (DW100K) 上，与之前的SOTA 相比，性能提升了27%-49% 以上。尽管一些基于嵌入的方法，如GCN-Align、MuGNN和AliNet，使用了先进的图编码技术，但它们仍然会受到给定的标记噪声的影响。由于这些方法没有任何抗噪机制，噪声标签对模型的影响比较大。此外本文的方法在和含降噪模块的方法REA、CPUGA相比也显示出了优越性。实验结果表明，本文的LDEA框架设计在多个真实世界数据集的对齐精度和噪声辨别能力始终优于其他基线方法。

5.4 错误检测定量分析

本文在DBP15K_{JA-EN}上测试了 $\mathcal{L}S^U$ 的10% - 60%不同强度的噪声。如图 2 所示，所有方法的性能都随着噪声比例的增加而下降。值得注意的是，本文的LDEA曲线的斜率比较平坦，这意味着LDEA模型对于任何比例的噪声数据都具有一定的鲁棒性，应该标签细化模块作用导致了上述结果。实验结果表明，与其他基线相比，LDEA具有很大优势，可以有效地减轻噪声的影响。

本文先后改变 $\mathcal{L}S$ 中可信实体的比率来评估不同比率 $\mathcal{L}S^T$ 在LDEA上的效果。图 3 表明，


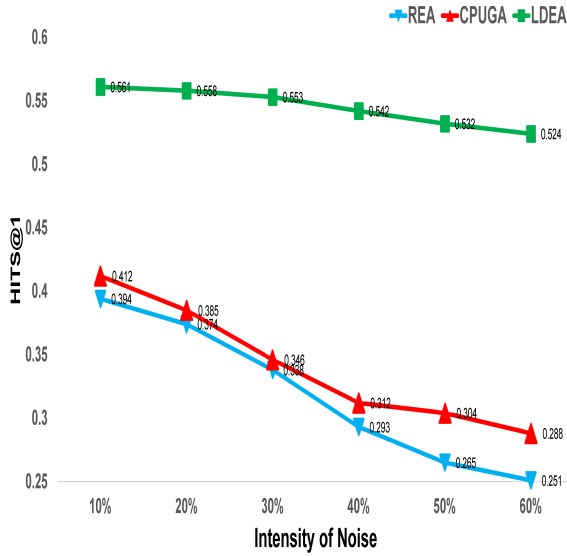


Figure 2: 不同强度噪声在DBP15K_{JA-EN}上的结果 Figure 3: 不同比例正样本在DW100K上的结果

随着 LS^T 在 LS 中的百分比增加，DW100K的性能有所提高。特别是，模型将40%的 LS 作为可信实体对实现了最佳性能。原因是较大的 LS^T 可以提供更多关于真实实体对的信息，以帮助噪声检测模块将真实实体对与 LS^U 区分开来。相比之下，噪声检测模块却会与较小比例的 LS^T (10%) 形成欠拟合，并导致错误地将一些真实样本识别为噪声。

表 3报告了在20%和40%两种不同强度的噪声中，本文模型的错误检测结果。使用了含标签精化模块的融合判别器，针对 LS^U 中的实体对进行二元分类，用来区分真实实体对和噪声实体对。高准确率表明大部分的噪声被正确地检测出来。表中的召回率意味着本文的判别器能够在不同的数据集上将 LS^U 中83%-88%的真实实体对判别为阳性。总的来说，这些结果表明，本文的噪声检测模块表现稳健，对涉及标注噪声的实体对齐任务很有帮助。值得注意的是，由于LDEA使用了标签细化模块，原本在对抗性训练中动摇的标签被辅助知识监督后修正，这大大改善了模型的噪声检测性能。

5.5 消融实验

本小节通过消融实验来检验所提出的模块的有用性。我们在DBP15K_{JA-EN}上使用了三种变体：(1) LDEA-w/o-CNS使用随机负采样判别器+标签精化模块，为每个可信的正样本对随机生成负样本对；(2) LDEA-w/o-SNS使用距离最近的负样本进行负采样+标签精化模块。(3) LDEA-w/o-LR，使用随机负采样，不包括标签降噪模块。从表 4，可以看到，本文提出的降噪模块和标签精化模块都是有效的。此外，LDEA-w/o-LR的表现不如LDEA，因为在没有标签精化模块的情况下，一些标签被误判为不可信任的样本。此外，LDEA-w/o-SNS比LDEA-w/o-CNS取得了更好的性能，因为当噪声实体更接近真实数据（干净的标签）时，模型可以工作得更好，而LDEA-w/o-CNS使用简单随机负采样不能为判别器选择利于模型学习的高效负样

Table 3: 错误检测性能

Noise	20%			40%		
	Pre.	Rec.	F1	Pre.	Rec.	F1
DBP15K _{ZH-EN}	0.946	0.852	0.899	0.962	0.856	0.909
DBP15K _{JA-EN}	0.931	0.836	0.884	0.963	0.843	0.903
DBP15K _{FR-EN}	0.943	0.835	0.889	0.956	0.868	0.912
DWY100K _W	0.953	0.861	0.907	0.948	0.880	0.914
DWY100K _Y	0.941	0.859	0.900	0.937	0.887	0.912

Table 4: 消融实验

Methods	DBP15K _{JA-EN}		
	Hits@1	Hits@5	MRR
LDEA	.542	.772	.645
-w/o-CNS.	.526	.737	.613
-w/o-SNS.	.539	.744	.615
-w/o-LR.	.540	.751	.627

5.6 标签精化效果分析

为了验证标签精化的效果，本文使用假阳性率 R_{FP} 和假阴性率 R_{FN} (公式 20)来衡量引导过程中迭代样本的质量。从图 4可以看出，随着epoch的增长，LDEA，CPUGA和REA的假阳性




Figure 4: 标签精化效果影响分析




Figure 5: τ 的不同取值(x轴)对EA结果的影响

率 R_{FP} 和假阴性率 R_{FN} 都在下降，说明三个模型的降噪模块都在发挥作用。然而值得注意的是，两条蓝色曲线始终在最下方，说明本文的LDEA模型整体效果明显好于CPUGA和REA，可能的原因是标签精化模块在降噪对抗训练之后把误判的标签进行了纠正，进一步剔除了负样本，对于整个降噪EA起到了附带的监督作用。

此外，本文还在DBP15K上验证 τ 的不同取值对EA结果的影响。从图5中可以看出，随着 τ 的取值越来越大，对于相似实体对的标签验证越来越严格，从而导致结果稍微提升。本文认为如果 τ 拥有较低的阈值会给整体的除噪框架带来更多新的不相似实体对(错误的伪标签)从而影响模型的效率，比如部分折线下沉的拐点。总之，从整体上看， τ 的不同取值确实会给模型带来一定的影响，但是HITS@1影响效果甚微，尤其在DBP15K_{JA-EN}数据集上表现一般。最后，本文根据各个数据的多次实践，一般 τ 的取值大概在0.8至0.9左右。

$$R_{FP} = \frac{|\mathcal{L}S_{iter}^+ - \mathcal{L}S_{test}|}{|\mathcal{L}S_{iter}^+|}, R_{FN} = \frac{|\mathcal{L}S_{iter}^- \cap \mathcal{L}S_{test}|}{|\mathcal{L}S_{iter}^-|} \quad (20)$$

6 结论

为了应对EA中标记噪声的挑战，本文提出了一个改进的EA降噪框架，以纠正标记和引导过程中的种子错误。特别是，考虑到以前基于邻域的嵌入方法的弱点，本文应用了一种新的对偶关系匹配编码器来加速KG的结构学习。然后，通过对抗强化学习来执行具有知识弱监督降噪模块。对于误差累积的问题，本文进一步使用对齐细化模块来改进本文的模型。最后，本文在抗噪声的环境下实现了对齐实体的任务。在多个数据集上的实验结果证明了本文降噪框架的优越性。对于未来的工作，本文将尝试在更加复杂的场景下，比如在稀疏和不完备的KG中实现EA抗噪任务。

参考文献

- Antoine Bordes, Nicolas Usunier, Alberto Garcia-Duran, Jason Weston, and Oksana Yakhnenko. 2013. Translating embeddings for modeling multi-relational data. In *NIPS 2013*.
- Yixin Cao, Zhiyuan Liu, Chengjiang Li, Zhiyuan Liu, Juanzi Li, and Tat-Seng Chua. 2019. Multi-channel graph neural network for entity alignment. In *Proc. of ACL*.
- Muhao Chen, Yingtao Tian, Mohan Yang, and Carlo Zaniolo. 2016. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment.

- Muhao Chen, Yingtao Tian, Kai-Wei Chang, Steven Skiena, and Carlo Zaniolo. 2018. Co-training embeddings of knowledge graphs and entity descriptions for cross-lingual entity alignment. In *Proc. of IJCAI*.
- Xuelu Chen, Muhao Chen, Weijia Shi, Yizhou Sun, and Carlo Zaniolo. 2019. Embedding uncertain knowledge graphs. In *Proc. of AAAI*.
- Enyan Dai, Charu Aggarwal, and Suhang Wang. 2021. Nrgnn: Learning a label noise resistant graph neural network on sparsely and noisily labeled graphs. In *Proc. of KDD*.
- Enyan Dai, Wei Jin, Hui Liu, and Suhang Wang. 2022. Towards robust graph neural networks for noisy graphs with sparse labels. In *Proc. of WSDM*.
- Charalampos Davalas, Dimitrios Michail, and Iraklis Varlamis. 2019. Graph matching on social networks without any side information. In *2019 IEEE International Conference on Big Data (IEEE BigData), Los Angeles, CA, USA, December 9-12, 2019*.
- Tim Dettmers, Pasquale Minervini, Pontus Stenetorp, and Sebastian Riedel. 2018. Convolutional 2d knowledge graph embeddings. In *Proc. of AAAI*.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. Bert: Pre-training of deep bidirectional transformers for language understanding. In *ACL 2019*.
- Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. 2014. Generative adversarial nets. In *NIPS*.
- Lingbing Guo, Zequn Sun, and Wei Hu. 2019. Learning to exploit long-term relational dependencies in knowledge graphs. In *ICML 2019*.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. 2016. Deep residual learning for image recognition. In *CVPR 2016*.
- Mark Heimann, Xiyuan Chen, Fatemeh Vahedian, and Danai Koutra. 2021. Refining network alignment to improve matched neighborhood consistency. In *Proc. of SDM*.
- Jiacheng Huang, Yao Zhao, Wei Hu, Zhen Ning, Qijin Chen, Xiaoxia Qiu, Chengfu Huo, and Weijun Ren. 2022. Trustworthy knowledge graph completion based on multi-sourced noisy data. In *Proceedings of the ACM Web Conference 2022*.
- Thanh Trung Huynh, Van Vinh Tong, Thanh Tam Nguyen, Hongzhi Yin, Matthias Weidlich, and Nguyen Quoc Viet Hung. 2020. Adaptive network alignment with unsupervised and multi-order convolutional networks. In *Proc. of ICDE*.
- Shengbin Jia, Yang Xiang, Xiaojun Chen, Kun Wang, and Shijia E. 2019. Triple trustworthiness measurement for knowledge graph. In *Proc. of WWW*.
- Seyed Mehran Kazemi and David Poole. 2018. Simple embedding for link prediction in knowledge graphs. In *NIPS*.
- Thomas N Kipf and Max Welling. 2016. Semi-supervised classification with graph convolutional networks.
- Jia Li and Dandan Song. 2022. Uncertainty-aware pseudo label refinery for entity alignment. In *Proceedings of the ACM Web Conference 2022*.
- Huiying Li, Yuanyuan Li, Feifei Xu, and Xinyu Zhong. 2015. Probabilistic error detecting in numerical linked data. In *Database and Expert Systems Applications - 26th International Conference, DEXA 2015, Valencia, Spain, September 1-4, 2015, Proceedings, Part I*.
- Fangyu Liu, Muhao Chen, Dan Roth, and Nigel Collier. 2021. Visual pivoting for (unsupervised) entity alignment. In *Proc. of AAAI*.
- Xin Mao, Wenting Wang, Huimin Xu, Man Lan, and Yuanbin Wu. 2020. Mraea: an efficient and robust entity alignment approach for cross-lingual knowledge graph. In *WSDM 2020*.
- Xin Mao, Wenting Wang, Yuanbin Wu, and Man Lan. 2021. Boosting the speed of entity alignment 10 \times : Dual attention matching network with normalized hard sample mining. In *WWW 2021*.

- Mojtaba Nayyeri, Sahar Vahdati, Emanuel Sallinger, Mirza Mohtashim Alam, Hamed Shariat Yazdi, and Jens Lehmann. 2021. Pattern-aware and noise-resilient embedding models. In *Proc. of ECIR*.
- Shichao Pei, Lu Yu, Guoxian Yu, and Xiangliang Zhang. 2020. REA: robust cross-lingual entity alignment between knowledge graphs. In *Proc. of KDD*.
- Shichao Pei, Lu Yu, Guoxian Yu, and Xiangliang Zhang. 2022. Graph alignment with noisy supervision. In *Proceedings of the ACM Web Conference 2022*.
- Jay Pujara, Eriq Augustine, and Lise Getoor. 2017. Sparsity and noise: Where knowledge graph embeddings fall short. In *EMNLP*.
- Zequn Sun, Wei Hu, and Chengkai Li. 2017. Cross-lingual entity alignment via joint attribute-preserving embedding. In *ISWC 2017*.
- Zequn Sun, Wei Hu, Qingheng Zhang, and Yuzhong Qu. 2018. Bootstrapping entity alignment with knowledge graph embedding. In *Proc. of IJCAI*.
- Zequn Sun, Jiacheng Huang, Wei Hu, Muhao Chen, Lingbing Guo, and Yuzhong Qu. 2019a. Transedge: Translating relation-contextualized embeddings for knowledge graphs. In *ISWC 2019*.
- Zhiqing Sun, Zhi-Hong Deng, Jian-Yun Nie, and Jian Tang. 2019b. Rotate: Knowledge graph embedding by relational rotation in complex space. In *Proc. of ICLR*.
- Zequn Sun, Chengming Wang, Wei Hu, Muhao Chen, Jian Dai, Wei Zhang, and Yuzhong Qu. 2020. Knowledge graph alignment network with gated multi-hop neighborhood aggregation. In *Proc. of AAAI*.
- Bayu Distiawan Trisedya, Jianzhong Qi, and Rui Zhang. 2019. Entity alignment between knowledge graphs using attribute embeddings. In *Proc. of AAAI*.
- Zhen Wang, Jianwen Zhang, Jianlin Feng, and Zheng Chen. 2014. Knowledge graph embedding by translating on hyperplanes. In *Proc. of AAAI*.
- Zhichun Wang, Qingsong Lv, Xiaohan Lan, and Yu Zhang. 2018. Cross-lingual knowledge graph alignment via graph convolutional networks. In *EMNLP 2018*.
- Yaqing Wang, Fenglong Ma, and Jing Gao. 2020. Efficient knowledge graph validation via cross-graph representation learning. In *Proc. of CIKM*.
- Song Wang, Xiao Huang, Chen Chen, Liang Wu, and Jundong Li. 2021. REFORM: error-aware few-shot knowledge graph completion. In *Proc. of CIKM*.
- Yuting Wu, Xiao Liu, Yansong Feng, Zheng Wang, Rui Yan, and Dongyan Zhao. 2019. Relation-aware entity alignment for heterogeneous knowledge graphs. In *Proc. of IJCAI*.
- Yuting Wu, Xiao Liu, Yansong Feng, Zheng Wang, and Dongyan Zhao. 2020. Neighborhood matching network for entity alignment. In *ACL 2020*.
- Yuejia Xiang, Ziheng Zhang, Jiaoyan Chen, Xi Chen, Zhenxi Lin, and Yefeng Zheng. 2021. Ontoea: Ontology-guided entity alignment via joint knowledge graph embedding.
- Kexuan Xin, Zequn Sun, Wen Hua, Wei Hu, and Xiaofang Zhou. 2022. Informed multi-context entity alignment. In *Proc. of WSDM*.
- Kun Xu, Liwei Wang, Mo Yu, Yansong Feng, Yan Song, Zhiguo Wang, and Dong Yu. 2019. Cross-lingual knowledge graph alignment via graph matching neural network. In *Proc. of ACL*.
- Chengjin Xu, Fenglong Su, and Jens Lehmann. 2021. Time-aware graph neural networks for entity alignment between temporal knowledge graphs. In *EMNLP 2021*.
- Hsiu-Wei Yang, Yanyan Zou, Peng Shi, Wei Lu, Jimmy Lin, and Xu Sun. 2019. Aligning cross-lingual entities with multi-aspect information. In *EMNLP 2019*.
- Liren Yu, Jiaming Xu, and Xiaojun Lin. 2021. Graph matching with partially-correct seeds. *J. Mach. Learn. Res.*

- Weixin Zeng, Xiang Zhao, Wei Wang, Jiuyang Tang, and Zhen Tan. 2020. Degree-aware alignment for entities in tail. In *Proc. of SIGIR*.
- Wentao Zhang, Yexin Wang, Zhenbang You, Meng Cao, Ping Huang, Jiulong Shan, Zhi Yang, and Bin Cui. 2022. Information gain propagation: a new way to graph active learning with soft labels.
- Xiang Zhao, Weixin Zeng, Jiuyang Tang, Wei Wang, and Fabian Suchanek. 2020. An experimental study of state-of-the-art entity alignment approaches. *IEEE Transactions on Knowledge and Data Engineering*.
- Fan Zhou, Ce Li, Zijing Wen, Ting Zhong, Goce Trajcevski, and Ashfaq A. Khokhar. 2021. Uncertainty-aware network alignment. *Int. J. Intell. Syst.*
- Hao Zhu, Ruobing Xie, Zhiyuan Liu, and Maosong Sun. 2017. Iterative entity alignment via joint knowledge embeddings. In *Proc. of IJCAI*.
- Yao Zhu, Hongzhi Liu, Zhonghai Wu, and Yingpeng Du. 2021. Relation-aware neighborhood matching model for entity alignment. In *Proc. of AAAI*.