

基于路径推理图的文档级关系抽取模型研究

刘军平,何玉茹,彭涛,胡新荣,朱强

(武汉纺织大学计算机与人工智能学院,湖北武汉430200)

摘要: 关系抽取(RE)最近已经从句子级转移到文档级,这需要聚合文档信息,并使用实体和提及加以推理。现有研究忽略了围绕目标实体对的局部上下文信息,且只关注实体级的推理路径,没有考虑文档中跨多个句子的长距离实体之间的复杂交互。为此,提出了一种新的具有信息聚合和长距离跨句推理的文档级关系抽取模型。首先,构造了一个文档图,对文档中的全局信息进行建模;其次,加入了一个新的节点,以聚合目标实体对的局部上下文信息;再次,将目标实体对之间的各种路径集成到一个更简单的推理图结构中以推理长距离跨句实体对的关系,并进行关系推理。在DocRED、CDR和GDA 3个公共数据集上的实验结果表明,路径推理模型在F1上均优于对比模型,验证了该模型的有效性。

关键词: 文档级关系抽取;路径推理;长距离依赖;文档图;路径推理图

DOI: 10.11907/rjdk.241851

扫描二维码阅读全文:



中图分类号:TP391

文献标识码:A

文章编号:1672-7800(2026)001-0026-06

Research on Document-Level Relation Extraction Model Based on Path Reasoning Graph

LIU Junping, HE Yuru, PENG Tao, HU Xinrong, ZHU Qiang

(School of Computer Science and Artificial Intelligence, Wuhan Textile University, Wuhan 430200, China)

Abstract: Relation extraction (RE) has recently shifted from the sentence level to the document level, which requires aggregating document information and using entities and mentions for reasoning. Existing research ignores local contextual information around the target entity pairs. In addition, existing work focuses only on entity-level inference paths without considering the complex interactions between long-distance entities across multiple sentences in a document. To this end, a new document-level relation extraction model with information aggregation and long-distance cross-sentence reasoning is proposed. A document-level graph is first constructed to model the global information in a document, and a new node is added to aggregate the local contextual information of target entity pairs. In addition, various paths between target entity pairs are integrated into a simple inference graph structure for long-distance cross-sentence entity pairs and perform relation inference. The experimental results on the three public datasets of DocRED, CDR and GDA show that the path reasoning model outperforms the comparison models on F1, verifying the validity of the model.

Key Words: document-level relation extraction; path reasoning; long-distance dependence; document-level graph; path reasoning graph

0 引言

关系抽取(Relation Extraction, RE)是自然语言处理中的最基本任务之一,旨在从纯文本中识别实体之间的语义关

系^[1]。大多数关系抽取研究都假设实体对在句子内或文档中^[2]。早期工作集中于句子级关系提取,它检测单个句子中实体对之间的关系^[3]。然而,各种有价值的关系事实,通过多重提及加以表达,如临床事实,它们在现实世界的语义场景中跨越了句子^[4-5]。鉴于此,研究人员开始探

收稿日期:2024-11-13

基金项目:教育部人文社会科学研究一般项目(23YJAZH082);湖北省自然科学基金计划项目(2024AFB736);湖北省教育科学规划重点课题(2022GA046)

作者简介:刘军平(1980-),男,博士,武汉纺织大学计算机与人工智能学院副教授,研究方向为自然语言处理;何玉茹(2001-),女,武汉纺织大学计算机与人工智能学院硕士研究生,研究方向为关系抽取;彭涛(1981-),男,博士,武汉纺织大学计算机与人工智能学院教授,研究方向为计算机视觉、虚拟仿真;胡新荣(1973-),女,博士,武汉纺织大学计算机与人工智能学院教授,研究方向为3D计算机图形学、计算机视觉;朱强(1984-),男,博士,武汉纺织大学计算机与人工智能学院讲师,研究方向为自然语言处理、生物信息学。本文通讯作者:朱强。

索文档级别的 RE^[6],它需要一种理解多个句子的方法,通过从整个文档中聚合相关的上下文信息以推理实体之间的关系。

已有研究仅基于堆栈神经网络聚合了具有上下文信息的实体表示,这些方法可捕获上下文信息,但也忽略了提及和实体之间的交互,故难以有效地解决实体之间的长距离问题^[6-7]。除基于图的模型外,一些基于路径的模型试图提取目标实体对之间的路径,并保留足够的信息以预测关系^[8]。这些方法明确地考虑了上述推理技能,可以缓解长距离实体交互建模的问题,但它们单独处理每个路径,并不是所有的实体对都可以通过一条路径连接。

为了解决上述限制,本文提出了基于文档图和路径推理图的文档级关系抽取,并为整个文档构建两个不同类型的图,即文档图、路径推理图。其中,文档图包含实体节点、提及节点和句子节点。由于文档级关系抽取需要一定的推理技能,故设计了一个简单但非常有效的启发式策略以显式构建生成推理路径,以充分利用不同的推理路径信息。本文基于之前生成的路径,在目标实体周围生成推理图,最后在路径推理图上应用 R-GCN^[9]。通过这种方式,模型可以关注最关键的实体、提及和句子,并对各种推理路径执行联合推理。

1 相关工作

文档级关系抽取的研究由来已久,文档级图为实体对提供了更多的特性,而实体之间的相关性可以通过使用 GNN 的图形学习加以捕获^[10]。例如,Dai 等^[11]利用 GNN 聚合文本图节点的邻域信息进行文本分类。随后,Tang 等^[12]构建了一个具有异构节点的文档级图,并提出了一个面向边缘的模型以获得全局表示。Liu 等^[13]学习了一种全局表示并通过文档级图获取实体,并使用仅包含实体的图,用于推理相关信息的节点。Li 等^[14]对句子与实体对之间的交互作用进行了表征,以提高句子间的推理能力。Zhou 等^[15]引入实体对的上下文作为实体节点之间的边,以建模多个实体之间的语义交互。Zhang 等^[16]构造了一个双层异构图以编码文档的固有结构,并推理了实体的多跳关系。Wang 等^[17]通过文档级图学习实体的全局表示,并根据实体的上下文学习局部表示。Nan 等^[18]将文档级图定义为一个潜在变量,通过优化文档级图的结构以提高 RE 模型的性能。Zeng 等^[19]提出一种基于双图的图聚合和推理网络(Graph Aggregation-and-Inference Network, GAIN)。与 GAIN 不同,本文研究的路径推理图是一个异构图,使用 R-GCNs 使实体节点之间的交互以发现长距离跨句子实体对的潜在关系。Wang 等^[20]运用修辞结构理论构建了一个文档级图,并利用证据进行推理。Shi 等^[21]将输入文档构造为异构图,并利用图变换网络生成语义路径。Ma 等^[22]提出证据增强的文档级关系抽取模型,使用

一个简单且内存高效的证据提取模型,针对目标实体对进行证据句子抽取,从而增强特征信息捕获效率。Dong 等^[23]提出一种基于关系距离和文档级对比预训练的关系抽取模型,引入关系距离的概念以实现文档级对比预训练,并从文档级数据集中存在的复数指标中找到最可能的关系指标对进行对比学习。

此外,还有一些研究尝试直接使用预先训练过的模型,而不是引入图结构。Tang 等^[12]采用一种分层推理方法以聚合不同粒度的推理信息。Zhou 等^[24]提出自适应阈值化和局部上下文池化以解决多标签和多实体问题。这些模型都是利用 Transformer 的多头注意力而不是 GNN 以聚合信息。

然而,这些研究主要集中在局部实体表示上,它忽略了分布在不同句子中实体之间的交互作用^[25]。为了挖掘长距离跨句子实体对的潜在关系,本文在目标实体周围引入了一个新的节点,并将提及图中的信息作为推理路径的特征,对实体之间的关系进行推理。

2 本文模型

给定一个文档 $D = \{s_i\}_{i=1}^n$,它由 n 个句子组成,包含 m 个实体 $E = \{e_i\}_{i=1}^m$ 。而文档级关系抽取任务是预测每个实体对之间的关系 r ,其中 $r \in R(e_h, e_t)$, R 是一个预先建立的关系集, e_h 和 e_t 分别指头实体和尾实体。其中,每个实体 $e_i = \{m_j\}_{j=1}^P$ 都可以通过句子中的 P 提及加以表示。当关系可以被它们的任何一对提及加以表示时, r 就存在于实体 e_h 和 e_t 之间。文档级关系抽取路径推理模型架构如图 1 所示。




Fig. 1 The framework of path reasoning model for document-level relation extraction

图 1 文档级关系抽取路径推理模型架构

2.1 文档编码模块

文档编码模块的任务是将文档 $D = \{w_i\}_{i=1}^{|d|}$ 编码为一个对应的向量序列,并将单词嵌入和实体类型嵌入连接起来作为词表示,如式(1)所示。

$$x_i = [E_w(w_i); E_t(t_i)] \quad (1)$$

其中,“;”代表拼接操作, w_i 和 t_i 分别是单词和实体类

型, $E_w(\cdot)$ 和 $E_t(\cdot)$ 分别表示词嵌入编码器和实体类型嵌入编码器。将其编码成一个序列 $\{o_i\}_{i=1}^{|\mathcal{D}|}$, 如式(2)所示。

$$[o_1, o_2, \dots, o_n] = \text{Encoder}([x_1, x_2, \dots, x_n]) \quad (2)$$

其中, $o_i \in R^{D_h}$ 是 BERT 最后一层输出的隐藏状态序列, x_i 是 e_i 的单词嵌入和实体类型嵌入的连接。

2.2 文档图构建

文档图包含 3 种类型不同的节点:

(1) 提及节点。它代表文档 D 中的提及, 提及节点 m_i 的表示是通过平均组成提及的单词的表示加以实现, 如式(3)所示。

$$h_{m_i} = \text{Avg}\left(\left\{o_j\right\}_{w_j \in m_i}\right) \quad (3)$$

(2) 实体节点。它代表文档 D 中的实体, 实体节点 e_i 的表示是通过平均组成实体的提及的表示加以实现, 如式(4)所示。

$$h_{e_i} = \text{Avg}\left(\left\{h_{m_j}\right\}_{m_j \in e_i}\right) \quad (4)$$

(3) 句子节点。它代表文档 D 中的句子, 句子节点 s_i 的表示是通过平均所包含单词的表示加以实现, 如式(5)所示。

$$h_{s_i} = \text{Avg}\left(\left\{o_j\right\}_{w_j \in s_i}\right) \quad (5)$$

文档图包含 4 类不同类型的边: ①提及—提及边: 当两个提及引用同一实体时, 添加一个提及边以建模提及之间的共引用交互; ②提及—实体边: 当提及与实体相关联时, 将提及节点连接到实体节点, 以便对提及的共同引用建模; ③实体—句子边: 当提及在句子中时, 提及与其所在句子构成一条句子到提及的边; ④句子—句子边: 如果两个句子包含同一个实体, 则连接两个句子节点, 并只在文档中对句子相邻的两个句子节点之间添加边, 以保持顺序信息。

2.3 实体路径推理模块

2.3.1 推理路径构建

本文方法旨在通过关注相关实体、提及和句子以预测关系。为此, 文中假设两个目标实体之间的路径, 包含图中所有节点的一个子集, 并且提供了足够的信息以确定这些关系。关于现有路径构建方法, 引入推理路径, 它们连接了两个目标实体, 并明确地建模了实体路径。推理路径类型如图 2 所示。

在实体推理路径图中, 包含了 3 种类型的边:

(1) 句内推理边。两个实体之间的关系同时出现在同一句子中, 句子内推理路径建模了模式识别和常识推理两种类型的推理, 这两种推理路径它们通常在句子内执行推理。

(2) 句间推理边。对于同一个句子中没有提及的两个实体, 使用句间推理路径以建模它们之间的关系, 可以将其视为向句子内推理路径添加额外的桥梁, 根据桥梁类型




Fig. 2 Reasoning path types

图 2 推理路径类型

的不同, 引入逻辑推理路径和共引用推理路径。

(3) 直接推理边。由于存在提及对之间无实体桥梁的情况, 同时受文献[8]的启发, 本文额外设计一种直接推理路径以满足提及对不符合句内推理路径和句间推理路径的情况。假设实体 A 和 B 分别存在不同的集合, 实体 A 和实体 B 分别存在 i 个提及和 j 个提及, 则至多存在 $i \times j$ 条直接推理路径。对于每组实体对存在多条路径的情况, 每种推理路径至多保存 3 条。

2.3.2 路径推理图构建

在文档级关系抽取中, 一个实体对之间可能存在多个关系, 对应于多个推理路径。此外, 确定一个单一的隐式关系也可能需要多条推理路径。已有研究倾向于使用每条路径以独立地预测关系, 然后汇总结果^[8]。相比之下, 本文在图 G 中的实体对周围提取一个封闭的推理图 g 以整合不同的路径。具体而言, 推理图 g 是由路径上至少出现一次的节点和在 G 中这些节点之间的所有边组成。对于不出现在同一句子中但可以通过桥实体或桥句子相关联的两个目标实体, 在它们之间生成两条没有重复的句子间推理路径 (逻辑推理路径和共引用推理路径), 然后使用这些路径提取推理图。

2.3.3 推理图编码

本文在推理图中加入了一个新的节点 Q , 然后将 Q 加入到推理图中的目标实体节点中, 再利用 L 层的 R-GCN 在推理图中的每个层中分别对不同类型的边进行消息的传递 (L 在文中被设置为 2), 让新加入的节点能够聚合来自目标实体节点的信息, 同时整合来自推理图中所有实体和提及节点的信息。给定第 l 层的节点 r , r 的近邻的聚合被定义为如式(6)所示。

$$h_r^{(l+1)} = \sigma \left(W_0^{(l)} h_r^{(l)} + \sum_{t \in \gamma} \sum_{u \in N_t} \frac{1}{|N_t^l|} W_t^{(l)} h_u^{(l)} \right) \quad (6)$$

其中, $\sigma(\cdot)$ 是一个激活函数, $|N_t^l|$ 表示与边 t 相连的节点 r 的邻居集合, $W_0^{(l)}$ 和 $W_t^{(l)} \in R^{D_h \times D_h}$ 是可训练参数。

2.4 关系分类模块

文档级关系抽取是一个多标签分类任务,为了计算实体对之间关系的概率(e_m, e_n),本文使用了来自全局文档编码器、实体路径推理模块的信息。并且,连接了以下表示形式:①初始目标实体节点嵌入 $h_c = E_c([h_{e_m}; h_{e_n}])$ 的线性组合,提供目标实体对的全局实体感知信息;②新加入的节点嵌入 h_Q^l ,提供目标实体对的局部实体感知信息;③所有遍历句子节点嵌入的最大池化 $h_g^l = \text{Avg}(\{h_{s_i}^l\}_{s_i \in g})$;④实

$$L = - \sum_{m \neq n} \sum_{r_i \in R} I(r_i = 1) \log(P(r_i | e_m, e_n)) + I(r_i = 0) \log(1 - P(r_i | e_m, e_n)) \quad (8)$$

其中, $I(\cdot)$ 表示指示函数。

3 实验与结果分析

3.1 数据集设置

本文分别在 DocRED、CDR 和 GDA 3 个公共数据集上对路径推理模型进行评估。

(1)DocRED。大型文档级关系抽取数据集(DocRED)是一个由维基百科构建的大规模人工注释数据集,它包含 96 种不同的关系类型、132 275 个实体、56 354 个关系事实和 5 000 多份文档。这些文档中有 3 053 篇用于训练,1 000 篇用于验证,1 000 篇用于测试。在 DocRED 上提取关系的模型需要具有很强的句间关系推理能力。

(2)CDR。化学—疾病关系(CDR)数据集是一个人工注释的数据集,CDR 包含了 1 500 篇关于化学和疾病的 PubMed 摘要,以及 3 116 个相关事实。

(3)GDA。与 CDR 一样,基因—疾病关联数据集(GDA)也是一个识别基因和疾病概念相互作用的二元关系分类任务,但其规模要大得多,是通过使用 MEDLINE 摘要的远距离监督而构建。它包括 29 192 个文件作为训练集,1 000 个文件作为测试集。

本文使用 BERT 实现词的嵌入与编码,将批处理大小设置为 4,并将嵌入维数设置为 768。对于 CDR、GDA 数据集,选择 BioBERT 模型,它在生物医学语料库上重新训练了 BERT 包下的模型^[26]。并在已有工作基础上,利用 F1、lgnF1 对路径推理模型进行了验证。特别地,lgnF1 意味着 F1 分数忽视了训练与验证/测试集之间的关系事实。

3.2 实验结果分析

3.2.1 整体性能

在 DocRED 数据集上的结果如表 1 所示,路径推理模型在开发集和测试集上都取得了更好的性能。在测试集上比基于图的模型 GLRE 高出 0.72%F1 和 0.57%lgnF1。GLRE 在提取长距离实体之间的关系方面,当实体距离 ≥ 3 时,效果比较显著。路径推理模型在提取长距离实体之间的关系方面,当实体距离 ≥ 64 时,更显著,能够对更长距离的实体对关系进行预测。

此外,在测试集上相比基于序列的模型 HIN,其 F1 和

体嵌入的相对距离 $E_s(s_{mn}), s_{mn}$ 表示从文档中第一次提及 e_m 到 e_n 的相对距离的嵌入, $E_s(\cdot)$ 是相对距离嵌入层。通过 $FFNN(\cdot)$ 传递连接的表示如式(7)所示。

$$P(r | e_m, e_n) = FFNN([h_c; h_Q^l; h_g^l; E_s(s_{mn})]) \quad (7)$$

本文使用二元交叉熵损失对模型加以训练,在训练过程中采用交叉损失熵函数以优化目标。损失函数如式(8)所示。

Table 1 Results on DocRED, CDR and GDA datasets

表 1 在 DocRED、CDR 和 GDA 数据集上的结果 (%)

类型	模型	DocRED				CDR		GDA
		验证集		测试集		F1	F1	
		F1	lgnF1	F1	lgnF1			
基于序列的模型	CNN ^[6]	43.45	41.58	42.26	40.33	-	-	
	LSTM ^[6]	50.68	48.44	50.07	47.71	-	-	
	BiLSTM+Glove ^[6]	50.94	48.87	51.06	48.78	64.9	80.6	
	HIN+Glove ^[12]	52.95	51.06	53.30	51.15	-	-	
	EOG ^[6]	52.15	45.94	51.82	49.48	63.6	81.5	
基于图的模型	GEDA ^[14]	56.16	54.52	55.74	53.71	-	-	
	GCGCN ^[15]	57.35	55.43	56.67	54.53	-	-	
	LSR+Glove ^[18]	55.17	48.52	54.18	52.15	64.8	82.2	
	GAIN+Glove ^[19]	55.29	53.05	55.08	52.66	-	-	
	SIRE+Glove ^[27]	55.91	54.10	55.96	54.04	70.8	84.7	
基于路径的模型	GLRE ^[24]	-	-	57.40	55.40	-	-	
	DRN+Glove ^[28]	56.49	54.61	56.33	54.35	-	-	
	Path+BiLSTM ^[8]	-	56.54	56.23	-	-	-	
	POR+Glove ^[29]	54.42	56.04	53.42	55.47	-	-	
	GCP+Glove ^[30]	55.61	53.94	55.88	52.95	-	-	
基于图和路径的模型	本文模型	58.39	57.01	58.12	55.97	71.2	84.9	

lgnF1 分别高出 4.82% 和 4.82%。而对于基于路径的模型,路径推理模型也取得了显著得性能。结果表明,路径推理模型结合了基于路径的模型和基于图的模型的优势,通过设计良好的推理路径和推理图结构以学习更具表现力的特征。同时,模型在句内和句间设置上也优于所有基线模型,这表明路径推理提高了句间关系实例的性能,句内关系实例性能也得到了提升。

从表 1 实验结果可以看出,路径推理模型在 CDR 和 GDA 数据集上的 F1 分别达到了 71.2%、84.9%,优于对比模型。特别是与上述最先进的方法 SIRE-Glove 相比,路径推理模型在 CDR 和 GDA 数据上的 F1 分别提高了 0.4、0.2。这表明,该方法在生物医学领域的文档级关系提取中也有效。

3.2.2 消融实验

为了进一步探索路径推理模块的合理性,本文分别在 3 个数据集上进行了消融实验以验证该模块的有效性。从表 2 实验结果可以看出,所有组件都有助于提升模型性能。当去掉新加入的节点时,模型在 3 个数据集上的性能都有所下降。结果表明,新加入的节点对于聚合目标实体对之间的局部上下文信息具有重要意义。在评估推理边

的有效性实验中,当所有推理边被删除时,模型在 DocRED 上的 F1 和 lgnF1 分数分别下降了 0.22% 和 0.13%,在 CDR、GDA 上的 F1 分数也有所下降。这一现象验证了推理路径的有效性。而当分别单独删除各推理模块时,F1 分数也出现了不同程度的下降。这验证了不同的推理边对推理实体关系都有一定效果,并验证了所有模块协同工作可以更加有效地处理 RE 任务。

Table 2 Ablation experiment results

表 2 消融实验结果 (%)

模型	DocRED		CDR	GDA
	F1	lgnF1	F1	F1
本文模型	58.39	57.01	71.2	84.9
本文模型 w/o 新的节点	58.25	56.82	69.5	83.2
本文模型 w/o 所有推理路径	58.17	56.88	69.1	83.5
本文模型 w/o 句内推理路径	58.21	56.78	70.6	84.1
本文模型 w/o 句间推理路径	57.87	56.84	70.2	83.9
本文模型 w/o 直接推理路径	57.65	56.61	70.3	84.0

3.3 对比实验

3.3.1 句内句间关系提取

本文进一步分析了模型在 DocRED、CDR 和 GDA 数据集上的句内和句间关系抽取表现,实验结果如表 3 所示。可以发现,路径推理模型在 DocRED、CDR、GDA 数据集上的句内 F1 和句间 F1 均优于对比模型,在 DocRED 上分别为 63.47%、49.47,在 CDR 上分别为 70.7、51.3,在 GDA 上分别为 84.9、53.6。结果表明,路径推理模型不仅能考虑句内关系,而且能很好地处理长距离句间关系。

Table 3 Intra- and inter-sentence results of the model on the three datasets

表 3 模型在 3 个数据集上的句内和句间结果 (%)

模型	DocRED		CDR		GDA	
	intra F1	inter F1	intra F1	inter F1	intra F1	inter F1
BiLSTM ^[7]	57.05	43.49	-	-	-	-
LSR ^[18]	60.83	48.35	66.2	50.3	83.1	49.6
GAIN ^[19]	61.67	48.77	-	-	-	-
GEDA ^[14]	61.85	49.46	-	-	-	-
EOG ^[6]	-	-	68.2	50.9	79.1	49.3
SIRE ^[28]	62.94	48.97	-	-	-	-
本文模型	63.47	49.47	70.7	51.3	84.9	53.6

3.3.2 实体距离分析

本文对模型长距离实体交互进行探究,以分析模型捕捉实体对之间关系的能力。同时,设置了不同的实体距离以验证模型性能,并在图 3 中列出了 F1 分数。更需注意的是,随着实体距离的增加,F1 分数逐渐下降,体现出长距离关系交互仍然是一个具有挑战力的问题。还可以看出,拥有构建的推理图模型性能比未加入推理图的模型要好。此外,加入的推理图结构能够使得模型更加关注与实体对相关的实体数量。

3.3.3 实体提及数量分析

本文对目标实体对的平均提及数进行分析,以进一步分析模型聚合信息的能力。从图 4 可以看出,当实体的平




Fig. 3 Performance analysis among different entity distances

图 3 不同实体距离之间的性能分析

均提及数很小时,模型效果不佳,表明当只有单个提及,它本身的信息很少,这使得关系难以预测。但是当实体的平均提及数很大时,并不是所有提及所携带的信息都是目标实体所需,且较多的提及数可能会带来不相关提及的噪声。然而,路径推理模型更加关注目标实体对相关的提及,因而当平均提及数不断增加时,路径推理模型能够保持相对较高的性能。




Fig. 4 Performance analysis among different mention average

图 4 提及平均数之间的性能分析

4 结语

本文提出了一种基于文档图和启发式的实体路径推理方法,它结合了基于图模型和基于路径模型的优势,能够更加有效地处理文档级关系抽取任务。采用提及对类型构建图结构,加入一个新的节点,根据相应的推理路径在目标实体对周围构建了一个路径推理图,并通过在推理图上构建显式推理路径以更好地利用不同的推理路径。同时,通过显式推理路径考虑所有潜在的推理技能,进一步划分推理类型。实验结果表明,在公共数据集 DocRED、CDR 和 GDA 上,路径推理模型性能得到了有效提升。

参考文献:

- [1] ZHOU W Y, LIU L L, ZHANG Z Y. Multi-level attention-based bidirectional long short-term memory networks for relation extract [J]. Software

- Guide, 2019, 18(7): 10–14.
- 周文辉, 刘亮亮, 张再跃. 融合多层注意力机制与双向 LSTM 的语义关系抽取[J]. 软件导刊, 2019, 18(7): 10–14.
- [2] WANG X, WANG D, JI F. A span-based model for joint entity and relation extraction with relational graphs[C]//2020 IEEE International Conference on Parallel & Distributed Processing with Applications, Big Data & Cloud Computing, Sustainable Computing & Communications, Social Computing & Networking (ISPA/BDCloud/SocialCom/SustainCom), 2020: 513–520.
 - [3] FEI H, LI J, WU S, et al. Global inference with explicit syntactic and discourse structures for dialogue-level relation extraction[C]//International Joint Conference on Artificial Intelligence, 2022: 4107–4113.
 - [4] SUN Q, ZHANG K, LYU L, et al. Joint extraction of entities and overlapping relations by improved graph convolutional networks[J]. Applied Intelligence, 2022, 52(5): 5212–5224.
 - [5] XU T, LI S, XU X, et al. Quantitative study of meridian topology model based on acupoint-symptom relationship[J]. Chinese Acupuncture & Moxibustion, 2017, 37(11): 1229–1232.
 - [6] CHRISTOPOULOU F, MIWA M, ANANIADOU S. Connecting the dots: document-level neural relation extraction with edge-oriented graphs[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 2019: 4925–4936.
 - [7] YAO Y, YE D, LI P, et al. DocRED: a large-scale document-level relation extraction dataset[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 764–777.
 - [8] HUANG Q Z, ZHU S Q, FENG Y S, et al. Three sentences are all you need: local path enhanced document relation extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 998–1004.
 - [9] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]//Proceedings of the European Semantic Web Conference, 2018: 593–607.
 - [10] JI G L, LIU K, HE S Z, et al. Distant supervision for relation extraction with sentence-level attention and entity descriptions[C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017: 3060–3066.
 - [11] DAI Y, SHOU L, GONG M, et al. Graph fusion network for text classification[J]. Knowledge-based Systems, 2022, 236: 107659.
 - [12] TANG H, CAO Y, ZHANG Z, et al. Hin: hierarchical inference network for document-level relation extraction[C]//Proceedings of the 24th Pacific-Asia Conference on Advances in Knowledge Discovery and Data Mining, 2020: 197–209.
 - [13] LIU H, KANG Z, ZHANG L, et al. Document-level relation extraction with cross-sentence reasoning graph[C]//Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining, 2023: 316–328.
 - [14] LI B, YE W, SHENG Z, et al. Graph enhanced dual attention network for document-level relation extraction[C]//Proceedings of the 28th International Conference on Computational Linguistics, 2020: 1551–1560.
 - [15] ZHOU H, XU Y, YAO W, et al. Global context-enhanced graph convolutional networks for document-level relation extraction[C]//Proceedings of the 28th International Conference on Computational Linguistics, 2020: 5259–5270.
 - [16] ZHANG Z, YU B, SHU X, et al. Document-level relation extraction with dual-tier heterogeneous graph[C]//Proceedings of the 28th International Conference on Computational Linguistics, 2020: 1630–1641.
 - [17] WANG D, HU W, CAO E, et al. Global-to-local neural networks for document-level relation extraction[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020: 3711–3721.
 - [18] NAN G, GUO Z, SEKULIĆ I, et al. Reasoning with latent structure refinement for document-level relation extraction[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 1546–1557.
 - [19] ZENG S, XU R, CHANG B, et al. Double graph based reasoning for document-level relation extraction[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020: 1630–1640.
 - [20] WANG H, QIN K, LU G, et al. Document-level relation extraction using evidence reasoning on RST-GRAPH[J]. Knowledge-Based Systems, 2021, 228: 107274.
 - [21] SHI Y, XIAO Y, QUAN P, et al. Document-level relation extraction via graph transformer networks and temporal convolutional networks[J]. Pattern Recognition Letters, 2021, 149: 150–156.
 - [22] MA Y, WANG A, OKAZAKI N. DREEM: guiding attention with evidence for improving document-level relation extraction[C]//Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics, 2023: 1971–1983.
 - [23] DONG Y, XU X. Relational distance and document-level contrastive pre-training based relation extraction model[J]. Pattern Recognition Letters, 2023, 167: 132–140.
 - [24] ZHOU W, HUANG K, MA T, et al. Document-level relation extraction with adaptive thresholding and localized context pooling[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 14612–14620.
 - [25] WANG D, HU W, CAO E, et al. Global-to-local neural networks for document-level relation extraction[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020: 3711–3721.
 - [26] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding[C]//Proceedings of Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT), 2019: 4171–4186.
 - [27] ZENG S, WU Y T, CHANG B B. Sire: separate intra- and inter-sentential reasoning for document-level relation extraction[C]//Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021, 2021: 524–534.
 - [28] XU W, CHEN K H, ZHAO T J. Discriminative reasoning for document-level relation extraction[C]//Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021, 2021: 1653–1663.
 - [29] XU W, CHEN K H, ZHAO T J. Document-level relation extraction with path reasoning[J]. ACM Transactions on Asian and Low-Resource Language Information Processing, 2023, 22(4): 1–14.
 - [30] JIA W, MA R, YAN L, et al. Document-level relation extraction with global and path dependencies[J]. Knowledge-Based Systems, 2024, 289: 111545.

(责任编辑: 孙 娟)