

基于桥实体增强的联合事件关系抽取

张俊驰, 刘浩源, 冼彦宁, 朱 珣

(江汉大学 人工智能学院, 湖北 武汉 430056)

摘要: 事件关系抽取(ERE)是自然语言处理(NLP)中的重要任务,旨在从文本中识别事件对之间的语义关系,广泛应用于事件推理、知识图谱构建和信息抽取等领域。然而,现有方法主要依赖事件触发词进行关系建模,难以准确捕捉隐式事件关系和复杂的跨句语境信息。并且,对事件论元(如桥实体)的潜在价值尚未充分挖掘,限制了对事件关系的全面建模能力。鉴于此,提出一种基于桥实体增强的联合事件关系抽取方法。该方法通过NLP工具提取事件触发词的句内和跨句实体作为桥实体,结合交叉注意力和双重门控机制对事件触发词和桥实体进行联合建模。交叉注意力模块捕捉触发词与桥实体间的全局交互信息,双重门控机制动态事件触发词与交叉注意力输出之间的交互信息融合,以及调节两个事件表示的融合。在MAVEN-ERE数据集上的实验结果表明,该方法在因果、时间、子事件和共指4种关系上优于基线模型,验证了所提方法的有效性。

关键词: 事件关系抽取;桥实体;交叉注意力机制;桥实体抽取算法;自然语言处理

DOI: 10.11907/rjdk.251063

扫描二维码阅读全文:



中图分类号: TP391.1

文献标识码: A

文章编号: 1672-7800(2026)003-0069-09

Joint Event Relation Extraction Based on Bridging Entities Enhancement

ZHANG Junchi, LIU Haoyuan, XIAN Yanning, ZHU Xun

(Artificial Intelligence Academy, Jiangnan University, Wuhan 430056, China)

Abstract: Event Relation Extraction (ERE) is a critical task in the field of Natural Language Processing (NLP), aiming to identify semantic relationships between event pairs from text, with broad applications in event reasoning, knowledge graph construction, and information extraction. However, existing methods predominantly rely on event triggers for relation modeling, struggling to accurately capture implicit event relations and complex cross-sentence contextual information. Moreover, the potential value of event arguments, such as bridging entities, has not been fully explored, limiting comprehensive modeling of event relations. To address these challenges, this paper proposes a bridging entity-enhanced joint event relation extraction method. This approach leverages NLP tools to extract intra-sentence and cross-sentence entities of event triggers as bridging entities, jointly modeling them with cross-attention and dual gating mechanisms. The cross-attention module captures global interaction information between triggers and bridging entities, while the dual gating mechanisms dynamically fuse the interaction information between event triggers and cross-attention outputs, as well as adjust the fusion of two event representations. The method was evaluated on the MAVEN-ERE dataset through experiments and comparisons, demonstrating superior performance over baseline models on causal, temporal, subevent, and coreference relations, thus validating its effectiveness.

Key Words: event relation extraction; bridging entities; cross-attention mechanism; bridging entities extraction algorithm; natural language processing

0 引言

事件关系抽取(Event Relation Extraction, ERE)是自然

语言处理(Natural Language Processing, NLP)领域的重要任务之一,旨在从文本中识别事件之间的语义关系。事件关系抽取在事件推理、知识图谱构建和信息抽取等领域具有重要应用价值^[1]。然而,现有研究在事件关系抽取任务中

收稿日期: 2025-03-10

基金项目: 国家自然科学基金青年科学基金项目(62106179)

作者简介: 张俊驰(1990-),男,博士,江汉大学人工智能学院讲师、硕士生导师,研究方向为机器学习、自然语言处理;刘浩源(1999-),男,江汉大学人工智能学院硕士研究生,研究方向为自然语言处理;冼彦宁(1999-),男,江汉大学人工智能学院硕士研究生,研究方向为自然语言处理;朱珣(1976-),女,博士,江汉大学人工智能学院副教授、硕士生导师,研究方向为自然语言处理、大数据挖掘与分析。本文通讯作者: 朱珣。

仍面临诸多挑战:一方面,事件之间的语义关系往往隐式存在,依赖于复杂的上下文语义和跨句语境;另一方面,现有方法通常仅依赖事件触发词本身(Event Triggers)进行关系推断,而忽略了上下文中其余信息(例如与事件关联的论元、实体等)的丰富语义,这在一定程度上限制了模型对事件关系的全面理解和建模能力。

近年来的研究表明,事件论元(Arguments,即参与事件的实体或短语)在事件关系建模中具有积极作用。Wen等^[2]通过引入事件论元进行事件时间关系抽取。此外,桥实体(Bridging Entities)作为连接目标实体对的中介信息,被证实能够有效捕捉它们之间的隐式关联。例如Bhushan等^[3]通过桥实体连接两个原本不相连的实体,从而改善知识库(Knowledge Base, KB)推理任务的表现。通过这些中介实体能够补充目标实体本身无法提供的上下文信息。然而,如何有效地将桥实体与事件触发词结合起来进行事件关系建模,仍然是一个值得深入研究的问题。

为了解决上述问题,本文提出了一种基于桥实体增强的联合事件关系抽取方法。具体而言,本文利用NLP工具的依存关系解析和共指解析技术,自动抽取事件触发词的句内实体和跨句实体作为桥实体,以捕捉隐式的事件关联。桥实体被引入到事件关系建模中,以补充触发词的语义并增强事件对之间的语义联系。在此基础上,本文设计了一种结合交叉注意力和双重门控机制的联合建模框架:交叉注意力模块用于捕捉事件触发词与桥实体间的全局交互信息,双重门控机制则动态控制桥实体信息对事件和事件关系间的贡献。实验结果表明,在MAVEN-ERE数据集的基础上与基线模型对比,验证本文方法和模型的有效性。

1 相关工作

1.1 常见事件关系抽取方法

事件关系抽取的目标是识别事件对之间的语义关系,例如因果关系(Causal)、时间关系(Temporal)、子事件关系(Subevent)和共指关系(Coreference)。该任务在事件推理、知识图谱构建和信息抽取中具有广泛应用。然而,随着文本复杂度和关系类型的增加,事件关系抽取面临隐式关系捕捉和上下文信息融合的挑战。

事件关系抽取的早期研究主要依赖于规则和统计机器学习方法。Allen^[4]提出区间代数法,将时间视为区间,通过定义时序关系规则(如Before、After)实现关系推理。Khoo等^[5]则利用句法模板和因果标志词(如“因为”“导致”)识别因果关系。这些规则方法简单直观,但在处理多样化文本时缺乏泛化能力。随着TimeBank等语料库的出现,统计学习方法逐渐兴起。例如,Girju^[6]通过提取命名实体、动词和句法树特征,构建分类器识别因果关系;Laokulrat等^[7]结合短语结构树和语义角色标注提升时序关

系分类。然而,这些方法高度依赖人工特征设计,且在跨句或隐式关系场景中表现不佳。

近年来,深度学习技术的引入显著推动了事件关系抽取的发展。神经网络方法通常以事件触发词(如“形成”“摧毁”)为核心表征,通过自动特征提取提升性能。例如:Chen等^[8]采用卷积神经网络(CNN)捕捉触发词的局部语义特征;Dmitriy等^[9]利用循环神经网络(RNN)建模事件序列的时序依赖;Rujun等^[10]通过深度结构化网络融合句法信息以增强触发词表示。然而,这些方法多聚焦于触发词本身,忽视了事件论元(如参与者、时间)及上下文实体提供的丰富语义,导致在隐式关系和长距离依赖场景中建模能力受限。

1.2 桥实体及其在关系抽取中的作用

桥实体是指连接目标实体对的中介实体,在捕捉隐式关联方面具有重要作用。近年来,桥实体被广泛应用于实体关系抽取任务。例如,Wang等^[11]通过引入桥实体,以连接不同的文档或句子,帮助模型更好地理解分散在多个文档中的复杂关系。Junyoung等^[12]深入探讨了桥实体的不同类型及其选择策略对模型效果的具体影响,通过实验表明了桥实体可以显著增强模型捕捉远距离实体间关系的能力。本文将此概念扩展至事件关系抽取任务,通过引入桥实体的概念,丰富事件触发词的语义上下文以推断关系。

1.3 多事件关系任务

主流数据集多集中于单一或两个事件关系类型。例如,MATRES^[13]、RED^[14]数据集包含有限的事件关系标签,仅关注因果关系或时间顺序关系,ESC^[15]包含因果和时序关系。多事件关系任务近年来逐渐受到关注,在文献[16]和文献[17]的工作中,它们同时关注两个关系任务,通过联合建模探索多事件关系之间的交互作用,展示了多任务学习的潜力。MAVEN-ERE^[18]是少有的同时覆盖多种事件关系的数据集,该数据及包含时间、因果、子事件和共指4种事件关系,该数据集的推出为多事件关系抽取任务提供了统一的实验基础。

1.4 大语言模型

近年来,大语言模型(Large Language Models, LLMs)的快速发展,如GPT、LLaMA在通用性方面表现突出,同时在自然语言处理任务上也有显著进步,其基于Transformer架构赋予了模型强大的文本理解与生成能力。Xu等^[19]指出,LLMs在信息抽取(Information Extraction, IE)任务中展现出潜力,尤其是在生成式范式下,通过自回归预测捕捉文本语义模式,支持零样本和少样本学习。

尽管LLMs在各任务上展现出潜力,但大语言模型在处理长距离依赖和复杂隐含关系时可能面临挑战。例如,在特定的事件关系抽取任务中,虽然大语言模型具备丰富的语言知识,但由于其训练目标和数据分布与事件关系抽取任务不完全匹配,在经过预训练模型针对事件关系抽取

任务进行微调后,往往能在任务相关指标上取得更优表现。大语言模型缺乏对事件关系抽取任务中特定语义关系和上下文特征的针对性学习,导致在处理复杂的事件关系时,难以准确捕捉和分析。相比之下,预训练模型微调能够聚焦任务数据,学习到任务关键特征,从而在事件关系抽取任务中展现出更好的性能。

2 基于桥实体的事件关系抽取任务建模

2.1 事件关系抽取任务定义

本文聚焦于文档级别的事件关系抽取任务,即给定一篇文档 D 中包含 N 条句子 $D = [s_1, s_2, \dots, s_n]$,而每条句子是由 m 个单词Tokens构成的序列 $S = [w_1, w_2, \dots, w_m]$ 。在给定文档 D 中,含有已经被标注出来的 x 个事件触发词和 y 个表示时间的词(TIMEX,只用于时间关系预测),记作 $E = [e_1, e_2, \dots, e_x]$ 和 $Q = [q_1, q_2, \dots, q_y]$ 。这些事件触发词或表示时间的词都由文档中的若干词所表示,用于后续事件对的预测。事件关系抽取旨在识别一对事件之间的语义关系,本文重点关注4种最广泛研究的事件关系:时间关系、因果关系、子事件关系和共指关系。不同的关系任务下都含有其对应的几种子类别。

2.1.1 时间关系

该任务旨在判断两个事件在时间上的先后顺序和重叠情况。时间关系标签如下:

$$TempRel(e_h, e_t) = \begin{cases} \text{BEFORE} & \text{如果 } e_h \text{ 发生在 } e_t \text{ 之前} \\ \text{OVERLAP} & \text{如果 } e_h \text{ 与 } e_t \text{ 重叠} \\ \text{CONTAINS} & \text{如果 } e_h \text{ 包含 } e_t \\ \text{SIMULTANEOUS} & \text{如果 } e_h \text{ 与 } e_t \text{ 同时发生} \\ \text{ENDS - ON} & \text{如果 } e_h \text{ 在 } e_t \text{ 结束时发生} \\ \text{BEGINS - ON} & \text{如果 } e_h \text{ 在 } e_t \text{ 开始时发生} \end{cases}$$

2.1.2 因果关系

该任务旨在判断一组事件对之间的因果关系,CAUSE定义为“给定头部事件,尾部事件是不可避免的”,PRE-CONDITION定义为“如果头部事件未发生,尾部事件不会发生”。因果关系标签如下:

$$CausalRel(e_h, e_t) = \begin{cases} \text{PRECONDITION} & \text{如果 } e_t \text{ 发生需要 } e_h \text{ 为前提条件} \\ \text{CAUSE} & \text{如果 } e_h \text{ 是 } e_t \text{ 发生的直接原因} \end{cases}$$

2.1.3 子事件关系

该关系任务需要识别事件 e_1 是否是事件 e_2 的子事件,例如“开幕式”可以是“会议”的子事件。子事件关系标签如下:

$$SubeventRel(e_h, e_t) = \begin{cases} \text{SUBEVENT} & \text{如果 } e_t \text{ 是 } e_h \text{ 的子事件} \\ \text{NONE} & \text{如果 } e_h \text{ 和 } e_t \text{ 之间无关} \end{cases}$$

2.1.4 共指关系

在事件共指关系任务中,事件提及是指文本中描述某个事件的短语或句子,目的是识别文本中提及的相同事件

的多个表达。共指关系标签如下:

$$CorefRel(e_h, e_t) = \begin{cases} \text{COREF} & \text{如果 } e_t \text{ 和 } e_h \text{ 共指同一事件} \\ \text{NONE} & \text{如果 } e_h \text{ 和 } e_t \text{ 之间无关} \end{cases}$$

2.2 桥实体定义

目前,引入上下文信息的常规方法是引入目标事件周围的文本片段^[20]、结合位置信息与常识知识^[21],或者引入文档级别的图表示方法扩大可被分析的文本范围^[22],而这些片段可能着包含大量噪声和无关的上下文信息,从而对事件本身表述带来较大偏差和影响并导致模型预测性能下降。

为了探究如何有效利用文档中的上下文信息,本文通过引入一种启发式算法,用于抽取与事件相关联的实体。桥实体作为连接目标事件间的纽带,有助于捕捉它们之间潜在的联系,以构建文本路径间的语义链条,填补事件对之间的语义鸿沟。本文基于与目标事件的句子位置是否相同,将桥实体定义为两类。

2.2.1 句内实体

句类实体直接来源于事件本身,指那些通过依存关系直接从句子中抽取得到的与事件触发词紧密相连的论元。它们通常是触发词的主语、宾语、修饰语或补语等,在句法结构上与事件触发词有直接关联。句内实体的识别依赖于句子的依存关系树,确保选取的实体在局部句子层面上与触发词具备明确的语法关系,能够为事件的语义构建提供直接的上下文支撑。

2.2.2 跨句实体

跨句实体是基于句内实体而扩展的,指那些与事件触发词在语义上相关联,但分布于文档中不同句子或段落内的实体。这些实体的识别通过共指解析和文本共现方法实现。首先,共指解析能够识别同一实体在不同句子中的指代,从而建立起跨句的语义关联链条。然而,共指解析在长距离依赖或复杂句法结构下可能存在不足,因而进一步引入共现方法,将限定在触发词前后一定句子窗口内的语义共现文本作为候选补充。

3 本文方法

本文方法框架如图1所示。

3.1 启发式桥实体抽取方法

自然语言处理中,事件抽取和关系识别任务所涉及的数据量通常较大,依靠人工标注成本高昂,且难以保证一致性。为了实现自动化处理并保证抽取结果的一致性,本文采用NLP工具结合启发式方法以实现桥实体的自动抽取。

Stanford CoreNLP提供了丰富的自然语言处理功能,包括分词、词性标注、依存句法分析等,能够对句子的语法结构进行详细解析^[23]。该工具可以在较短时间内批量处理文档,并且该工具的解析模型能够在所有文档上保持一致




Fig. 1 Method framework

图1 方法框架

的输出标准,从而确保论元提取的结果稳定可靠。

3.1.1 句内实体抽取

通过文档已经标注给出的目标事件(事件触发词),利用NLP工具的句法分析以获取目标事件在句子中的词性信息(POS),例如动词(如VB、VBD)或名词(如NN、NNS),并根据目标事件的词性决定该事件需要关注哪些类别的论元作为句内桥实体。例如,若触发词为动词类,则在论元提取中关注主语、宾语等;若触发词为名词类,则关注修饰词或同位语等。基于此种关系,本文提供了对照表(见表1),以决定事件触发词需要关注的论元类型。

Table 1 Speech-argument type comparison

表1 词性—论元类型对照

事件触发词词性	论元依存类型	说明
动词(verb)	nsubj, dobj, iobj, xcomp, ccomp, advmod	主语、直接宾语、间接宾语、补语、状语
名词(noun)	amod, nmod, poss, compound, nsubj, dobj	修饰语、名词修饰、所有格、复合词、主语、宾语
形容词(adj)	amod	修饰语
副词(adv)	advmod	状语
介词(preposition)	prep, pobj	介词、宾语
助词(part)	prt	小品词
不定式标记(to)	mark	标记
代词(pronoun)	nsubj, dobj	主语、宾语
冠词(det)	det	限定词
其他	pass	忽略

为了确定事件触发词的相关论元,需通过依存关系分析,对事件触发词所在的句子结构进行解析。依存关系分析能够揭示句子中词汇之间的语法关联,尤其是目标触发词与其直接相关联的其他词语。通过依存关系解析得到的依存关系树,可以直观地获取目标触发词所依赖的节点,并根据表1得到需要关注的论元节点,确保所选论元在语法上具有直接关联性。这些词语与触发词一起构成了该事件的基本语义框架。将这些直接相连的节点视为句内桥实体,不仅可以为后续事件间关系提供丰富的上下文,还能保证所选论元在语法结构上与触发词的相关性最强,最大程度地减少噪声。句内实体抽取算法步骤如下:

Step1:数据预处理。从标注数据中获取事件触发词所在句子的索引、跨度信息和分词句子。

Step2:依存句法解析。利用StanfordCoreNLP的依存

解析功能,对该句子进行解析,获取句子的依存句法树和相应的“tokens”信息。遍历解析结果中的“tokens”列表,找到指定事件触发词及其对应的索引、词语和词性。

Step3:事件触发词对应的关注类型。根据事件触发词的词性,确定目标触发词在表1中的关注类型。

Step4:抽取实体。遍历句子的依存解析结果,寻找与目标触发词相连的满足条件的依存关系节点,并获取该节点在分词句子中的跨度信息。

Step5:返回结果。输出包含每个句内实体的句子索引、文本和对应跨度信息的句内实体列表。

3.1.2 跨句实体抽取

为了进一步扩展论元的上下文关联性,引入共指解析和文本共现的方法,以识别跨句的相关实体。

共指解析可以揭示文档中不同句子间指代相同实体的论元链条,从而能够在目标事件句子外找到相关联的跨句实体。这些实体即便出现在不同句子中,也可能通过指代关系为事件提供语义支撑。

具体实现中,可利用共指解析模块,对整个文档进行共指链分析。对于每一个通过依存关系识别出的句内实体,检查其是否出现在共指链中。如果句内实体所在共指链存在指代,则将这些指代实体纳入为潜在的跨句桥实体。跨句实体抽取算法步骤如下:

Step1:共指解析。对整个文档进行共指消解,生成一个共指链集合。每个共指链表示一组在文档中指代同一实体的提及。

Step2:筛选相关共指链。从解析结果中获取“corefs”键对应的值得到共指链集合,遍历所有共指链,检查每条链中是否包含了之前在触发词句子中抽取出的句内实体。只有当一个共指链中的某个提及与句内实体属于同一实体簇时,才认为该共指链与当前事件相关。

Step3:抽取跨句实体。对于筛选出的共指链,将其中除触发词所在句子外的其他提及抽取出来(包括该提及在文档中的句子索引以及跨度信息),输出为当前触发词的跨句实体列表。

虽然共指解析有效地扩展了跨句论元的范围,但它在面对复杂句法结构或模糊指代时,可能会漏掉部分潜在的桥实体。因此,为了弥补共指解析的不足,引入文本共现方法,作为共指解析的补充机制。共现启发式方法基于语

义邻近性,限定在目标事件句子前后的一定窗口内(例如触发词所在句子的前后几句)提取潜在的桥实体。通过局部窗口,选取上下文中的共现文本,以补充共指解析可能遗漏的潜在关联。为了确保这些共现文本具有语义上的高度相关性,进一步计算候选共现文本与目标事件之间的余弦相似度,只有当候选共现文本与触发词的相似度超过阈值 θ 时,才将其视为共现跨句实体,从而有效避免噪声信息的干扰。

3.2 联合事件关系抽取模型

为了整合抽取的桥实体并有效利用桥实体为事件对的关系预测提供额外信息,本文提出了基于桥实体增强的交叉注意力门控聚合网络,具体流程如图2示。首先,将输入文档经过抽取方法得到桥实体;其次,通过编码器编码得到嵌入表示后构建事件对,作为后续交叉注意力的输入;接着,经过交叉注意力门控聚合模块得到事件对的表示;最后,通过各子关系任务的分类器得到预测结果。

3.2.1 编码器

采用共享编码器,以统一的语义表示为后续提




Fig. 2 Cross-attention gated aggregation module

图2 交叉注意力门控聚合模块

$$I = \text{Mean}([i_1, i_2, \dots, i_n]) \quad (5)$$

$$C = \text{Mean}([c_1, c_2, \dots, c_n]) \quad (6)$$

3.2.2 事件对构建

对于每个事件,将其事件触发词表示 E 、句内实体的整体表示 I 和跨句实体整体表示 C 按顺序拼接为一个联合序列 S ,如式(7)所示。

$$S = [E; I; C] \quad (7)$$

在事件关系建模中,为了准确捕捉事件间的语义交互,需要构建事件对作为模型输入。遵循与MAVEN-ERE基线相同的预处理:对于不同类型的事件关系任务,事件对的生成策略有所不同,以确保充分覆盖所有可能的语义关系,同时避免冗余或违背任务假设的关系对。

时间关系、因果关系和子事件关系均为对称任务,因此每个事件对都可被视为无方向的。为确保完整性,生成所有可能的事件对组合,包括两事件对的正反顺序,如式(8)所示。

$$\text{EventPairs} = (S_i, S_j) | i \neq j, \forall i, j \in [1, m] \quad (8)$$

供基础。共享编码器选择了预训练的RoBERTa模型,其因在广泛的文本语料上经过训练,而具备强大的语言理解能力,适合捕捉句子中的细微语义关系^[24]。具体而言,给定输入文档中的文本序列 $S = [w_1, w_2, \dots, w_m]$,经过共享的RoBERTa编码器,得到每个位置的嵌入表示,如式(1)所示。

$$H = [h_1, h_2, \dots, h_n] = \text{RoBERTa}(S) \quad (1)$$

其中, $H \in R^{n \times d}$ 表示RoBERTa输出的嵌入表示, d 是隐藏层维度。通过事件触发词和桥实体的跨度信息(offset),从 H 中获取事件触发词 T 、句内实体集以及跨句实体集的嵌入表示。相关公式如式(2)一式(4)所示。

$$E = \text{Mean}(H[\text{start}_{\text{trigger}}:\text{end}_{\text{trigger}}]) \quad (2)$$

$$i = h_{\text{intra}} = \text{Mean}(H[\text{start}_{\text{intra}}:\text{end}_{\text{intra}}]) \quad (3)$$

$$c = h_{\text{cross}} = \text{Mean}(H[\text{start}_{\text{cross}}:\text{end}_{\text{cross}}]) \quad (4)$$

将句内实体集和跨句实体集作均值计算,将其作为该事件触发词的句内实体表示 I 和跨句实体表示 C ,如式(5)、式(6)所示。

$$O_h = \text{CrossAtt}_{h \rightarrow t} = \text{softmax}\left(\frac{E_h \cdot S_t^T}{\sqrt{d}}\right) \cdot S_t \quad (9)$$

(2) 尾事件对头事件的交叉注意力。在尾事件对头事件的交叉注意力中, 查询矩阵 $Q_t = E_t$, 键值矩阵 $K_h, V_h = S_h$, 尾事件对头事件的交互表示为如式(10)所示。

$$O_t = \text{CrossAtt}_{t \rightarrow h} = \text{softmax}\left(\frac{E_t \cdot S_h^T}{\sqrt{d}}\right) \cdot S_h \quad (10)$$

3.2.4 门控聚合机制

受 Qian 等^[26]的启发, 为了更有效地建模事件对的语义关系, 在交叉注意力输出的基础上采用了双门控机制, 以进一步增强事件表示并实现事件对的聚合。事件的交叉注意力输出表达了事件间的交互信息, 为了保留触发词表示 E 的核心特征, 同时有效利用交叉注意力输出 O , 设计了第一个门控机制用于生成动态权重信号 G_1 , 如式(11)所示。

$$G_1 = \sigma([E; O] \cdot W_1 + b_1) \quad (11)$$

其中, σ 为 Sigmoid 激活函数, $W \in R^{2d \times d}$ 和 $b \in R^d$ 是可学习的权重矩阵和偏置项。通过门控信号 G_1 , 对 E 和 O 进行加权融合得到增强后的事件表示 F , 如式(12)所示。

$$F = E + G_1 \odot O \quad (12)$$

此机制通过自适应权重信号, 有效融合了原始触发词信息与交互特征, 使增强后的表示既保留了原始语义, 又包含了对另一个事件的关键联系。

得到事件的增强表示后, 头事件和尾事件的互补信息需进一步融合, 以建模事件对的整体特征。为此, 设计了第二个门控机制并进行聚合。具体地, 将头事件和尾事件的增强表示拼接, 然后通过门控网络生成聚合信号 G_2 如式(13)所示。

$$G_2 = \sigma(W_2 \cdot [F_h; F_t] + b_2) \quad (13)$$

通过聚合信号动态调整头尾事件的权重, 生成事件对的最终表示 P_h 和 P_t , 如式(14)、式(15)所示。

$$P_h = G_2 \odot F_h \quad (14)$$

$$P_t = (1 - G_2) \odot F_t \quad (15)$$

3.2.5 分类器

为准确预测不同关系任务的关系类型, 使用独立的多层感知机 (Multilayer Perceptron, MLP) 作为分类器, 并将头尾事件的拼接向量作为输入。分类器包含输入层、中间层和输出层 3 层全连接网络, 通过 Leaky ReLU 激活函数逐步提取和整合特征信息, 输出层将特征映射到目标关系类别的维度。

$$\hat{R} = \text{MLP}([P_h; P_t]) \quad (16)$$

3.2.6 损失函数

采用交叉熵 (Cross-Entropy) 作为损失函数, 用于衡量预测分布 $\hat{R}$ 与真实分布 R 的差异:

$$\mathcal{L}_r = - \sum_{i=1}^{c_r} R_i^{(r)} \log(\hat{R}_i^{(r)}) \quad (17)$$

其中, $r \in \{\text{time}, \text{causal}, \text{subevent}, \text{coref}\}$, c_r 表示第 r 个

任务的标签数量。同时, 为了优化 4 个任务的分类器, 将每个任务的交叉熵损失加权求和作为总损失, 如式(18)所示。

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{time}} + \mathcal{L}_{\text{causal}} + \mathcal{L}_{\text{subevent}} + \mathcal{L}_{\text{coref}} \quad (18)$$

4 实验与结果分析

4.1 数据集

将本文方法在 MAVEN-ERE 数据集上进行了实验, 该数据集为共指、因果、时间和子事件事件关系提供了统一的注释。MAVIEN-ERE 是目前最大的 ERE 数据集, 共有 4 480 个文档、112 276 个事件提及、103 193 个事件共指链、1 216 217 个时间、57 992 个因果关系和 15 841 个子事件关系。

4.2 实验设置与训练细节

实验基于以下软硬件环境和参数配置进行, 软件环境采用深度学习框架 PyTorch 2.1.2, 运行于 Python 3.10, GPU 上采用两张 NVIDIA RTX 3080 (显存 20 GB)。选用 Stanford CoreNLP v4.5.6 英文版本用于文档的依存解析与共指解析, 共现实体的句子窗口设为 2 (触发词所在句子前后 2 句), 余弦相似度的阈值 θ 设置为 0.8。模型编码器采用 HuggingFace 提供的 RoBERTa-base 版本, RoBERTa-base 学习率设为 $1e-5$, 其余模块学习率为 $1e-4$, 训练数据批次大小为 8, 优化器选用 AdamW。为避免错过最佳模型权重, 设置每训练 50 步进行一次验证, 并保留各子任务最高得分的权重参数, 以确保模型在多任务事件关系抽取中达到较优性能。

4.3 基线模型

为评估本文模型的性能和有效性, 选取了一系列具有代表性的基线模型进行对比分析。其中, RoBERTa-split 和 RoBERTa-joint 分别为 Wang 在 Maven-ere 中两个基线模型。

RoBERTa-split: 简单典型的管道方法, 各任务使用独立的预训练模型 RoBERTa 对上下文进行编码, 并通过独立的前馈神经网络单独预测所有子任务的事件对分数。

RoBERTa-joint: 一种单阶段多任务方法, 由 RoBERTa-split 改进而来, 即使用一个共享的 RoBERTa 编码器和独立的分类器, 然后通过加权求和所有子任务损失以实现联合学习。

OneEE^[27]: 这是一种用于事件抽取的模型, 特别针对重叠和嵌套事件抽取任务进行设计。它通过创新的标签方案和架构, 旨在解决传统方法在处理复杂事件结构时面临的问题, 如多阶段方法中的错误传播问题。采用相同的预处理方法, 将 OneEE 模型适配到 Maven-ere 数据集上, 以开展 ERE 任务。

GraphERE^[28]: 该方法提出基于图增强事件嵌入的联合事件关系抽取框架, 在 MAVEN-ERE 数据集上对其进行

实验,利用 AMR 图和 OpenIE 构建静态事件图增强事件嵌入,并通过 Node Transformer 和任务特定动态图抽取 4 种事件关系。

4.4 模型预测结果比较与分析

对上述模型进行了对比,评估指标涵盖了精确率(Precision, P)、召回率(Recall, R)、F1 分数以及针对共指关系的 MUC、B3、CEAF_e 和 BLANC 等指标。总体结果如表 2 所

示。相较于 RoBERTa-split 和 OneEE,本文方法在 4 种事件关系任务上均有提升;RoBERTa-split 采用独立训练,忽略了各事件关系间的依赖;OneEE 作为事件抽取框架,在 Temporal (R=62.4) 和 Causal (R=33.5) 上展现出较高召回率,表明其对事件对的覆盖能力较强。然而,其较低的精确率(Temporal P=49.4 和 Causal P=31.5)导致 F1 分数受限,可能原因是未针对事件关系任务对语义增强进行优化。

Table 2 Prediction results and evaluation indicators of each model

表 2 各模型预测结果与评价指标 (%)													
模型/关系任务	Temporal			Causal			Subevent			Coreference			
评价指标	P	R	F1	P	R	F1	P	R	F1	MUC	B ³	CEAF _e	BLANC
RoBERTa-split	57.8	53.9	55.8	35.0	27.2	30.6	29.6	24.6	26.7	81.4	98.1	97.7	89.8
RoBERTa-joint	55.4	56.6	56.0	33.8	29.5	31.5	29.8	25.6	27.5	82.1	98.2	97.9	90.2
OneEE	49.4	62.4	55.1	31.5	33.5	32.4	25.8	27.1	26.4	77.1	97.4	97.3	85.9
GraphERE-split	57.1	50.0	53.3	33.0	28.2	30.4	26.1	20.8	22.1	79.6	-	-	-
GraphERE-joint	55.1	54.4	54.7	29.0	33.4	31.1	31.2	24.2	27.3	80.1	-	-	-
Ours	54.6	59.9	57.1	37.5	32.3	34.7	32.9	29.8	31.3	82.3	98.1	97.9	90.0

与 RoBERTa-joint 相比,RoBERTa-joint 仅依赖触发词嵌入作为事件表示,缺乏额外语义支持,在时间关系、因果关系、子事件关系和共指任务上分别提升 1.1、3.2、3.8、0.2 个百分点;GraphERE 依赖于预定义图结构,受限于 AMR 和 OpenIE 的提取精度。而本文方法通过依存解析和共指解析自动抽取桥实体,结合交叉注意力和门控机制,能够更好地捕捉隐式关联,尤其在 Causal 和 Subevent 任务中表现出色,证明了本文方法在事件关系任务中的优越性和有效性。

4.5 消融实验

为了验证引入桥实体和模型设计的有效性,在开发集

上进行了消融实验,结果如表 3 所示。首先对模型的输入部分进行修改,不引入桥实体,仅使用触发词的方式验证引入桥实体的有效性。具体而言,在构建事件对时仅使用触发词本身,不与桥实体进行拼接操作,由结果可以看出,去掉桥实体后各任务性能均有所下降。其次,分别去除两个门控机制,同样可以看到在各子任务中出现了不同程度的性能损失,且在去除了第一个门控机制时(原始触发词信息与交互特征)影响较大,这说明在没有该门控机制下,交叉注意力输出的交互特征给事件触发词引入了过量的噪声,而该门控有效地调整了交互特征的贡献度。

Table 3 Ablation experiment results

表 3 消融实验结果 (%)													
模型/关系任务	Temporal			Causal			Subevent			Coreference			
评价指标	P	R	F1	P	R	F1	P	R	F1	MUC	B ³	CEAF _e	BLANC
Ours	54.6	59.9	57.1	37.5	32.3	34.7	32.9	29.8	31.3	82.3	98.1	97.9	90.0
w/o entity	51.7	56.5	54.0	33.6	30.6	32.0	25.5	24.7	26.3	80.5	97.8	97.5	88.2
w/o gate_1	49.6	58.8	53.8	37.1	23.9	29.0	28.7	20.9	24.1	79.7	97.9	97.6	88.1
w/o gate_2	50.5	59.6	54.6	32.2	31.9	32.1	29.8	25.6	27.5	80.7	97.9	97.6	88.8


4.6 数据集规模分析

为分析本文模型对数据量的需求,本文开展了数据规模实验,结果如图 3 所示。可以看出,在较少数据场景(40%数据规模以下)下表现略逊于基线。这可能是因为交叉注意力和门控机制的引入,使得模型复杂度增加,在少量数据集的条件下较难充分训练其参数。当数据规模超过 45% 时,本文方法表现逐渐向好,并超过基线,在 100% 数据规模时持续领先。此外,当数据规模超过 45%~60% 时,本文方法在各关系中的增长速度快于基线。这表明,随着数据量的增加,本文方法能够更好地发挥潜力,展示出较强的扩展能力,这一趋势在 Causal 关系上较为明显。

4.7 桥实体路径案例分析


通过进一步的案例分析,研究桥实体在推理任务中是

如何构建事件间的推理链条以提升关系抽取效果。以图 3、表 4 文档中的事件“formed”“weakened”和“dissipated”为例,Cyclone 为一整个灾难事件的代表,其他触发词各自表述事件的发生动作。本文方法通过引入桥实体,从局部扩展到更广的视野,触发词“formed”的句内实体“it”“weakened”和“dissipated”的句内实体“cyclone”明确了动作的主体,并且“storm”作为“it”和“cyclone”的跨句共指实体,指向同一主体。从时间顺序上明确了主体事件的发展过程,即风暴从形成到减弱和消失的过程,使得模型能够在句内和跨句信息的协同作用下构建事件间的推理链条。因此,模型可以正确推断出触发词之间发生的时间关系。由于动作发生为同一个主体,故模型也能推理出与 Cyclone 之间是子事件关系。但同时,基线模型仅依靠事件触发词的信息进行推理面临信息不足的问题,尤其在需要跨句推理或




(a) The variation of temporal task performance with the scale of data

(a) 时间关系任务性能随数据规模变化




(b) The variation of causal task performance with the scale of data

(b) 因果关系任务性能随数据规模变化



(c) The variation of subevent task performance with the scale of data

(c) 子事件关系任务性能随数据规模变化




(d) The variation of coreference task performance with the scale of data

(d) 共指关系任务性能随数据规模变化

Fig. 3 The variation of performance of different relation tasks with the scale of data

图3 不同关系任务的性能随数据规模变化

**Fig. 4 Bridge entity case study****图4 桥实体案例分析****Table 4 Case document****表4 案例文档**

案例文档句子	中文翻译
The 1996 Andhra Pradesh cyclone (also known as Cyclone 07B) was a small but powerful storm that left heavy damage in the Indian state of Andhra Pradesh	1996 年的安得拉邦气旋(也被称为气旋 07B)是一个小但强大的风暴,给安得拉邦造成了严重破坏
It formed on November 4 in the eastern Bay of Bengal	它于 11 月 4 日在孟加拉湾东部形成
Soon after landfall, the cyclone weakened and dissipated by November 7	登陆后不久,气旋减弱并于 11 月 7 日消散
The storm destroyed crops and killed millions of cattle and chicken	风暴摧毁了农作物并导致数百万头牛和鸡死亡

复杂关系判断时,触发词的局限性更加显著,因此基线模型难以直接推断它们的时间、因果等关系。

5 结语

本文研究聚焦于事件关系抽取任务,为突破传统方法局限,提出桥实体抽取方法,并引入桥实体作为事件的辅助信息,从而为两个事件在关系预测中构建推理链。通过整合句内实体与跨句实体信息,并结合交叉注意力机制与双门控机制,模型能够有效捕捉事件间的语义关联与结构依赖。实验结果表明,本文方法在核心关系类型(共指关系、时间关系、因果关系及子事件关系)的抽取任务上均取得了性能提升。

尽管取得了一定进展,但仍存在一些不足:当前模型在构建桥实体表示时主要依赖平均操作,还未深入考虑不同实体的语义重要性与上下文贡献度。未来工作中,可引入更细粒度的权重分配机制,进一步提高实体表示的区分能力。

在最近研究中,Wang 等^[29]在 MAVEN 数据集的基础上标注了更细粒度的论元信息,发布了高质量的 MAVEN-ARG 数据集,未来研究可结合该数据集作进一步探索。

联合事件关系抽取作为信息抽取领域的重要任务,不

仅在理论研究中具有重要价值,还在实际应用(如舆情监控、社交网络分析与情报挖掘)中展现出广阔的前景。通过结合最新的深度学习技术与事件关系建模方法,有望进一步提升模型性能。例如,Chen等^[30]针对大语言模型在事件关系逻辑预测中的不足,提出了3种优化方法,有效提升了大模型的推理能力,为事件关系抽取任务提供了技术支持与新的启发。

参考文献:

- [1] MA F L, ZHANG Z L, YAN Y. Subject knowledge graph: connotation, technique architecture, application and development trend [J]. *Software Guide*, 2024, 23(3): 212–220.
马富龙, 张泽琳, 闫燕. 学科知识图谱: 内涵、技术架构、应用与发展趋势 [J]. *软件导刊*, 2024, 23(3): 212–220.
- [2] WEN H Y, QU Y R, JI H, et al. Event time extraction and propagation via graph attention networks [C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2021: 62–73.
- [3] BHUSHAN K, PRADEEP B, PARTHA P T. Knowledge base inference using bridging entities [C]//Lisbon: 2015 Conference on Empirical Methods in Natural Language Processing, 2015.
- [4] ALLEN J F. Maintaining knowledge about temporal intervals [J]. *Communications of the ACM*, 1983, 26(11): 832–843.
- [5] KHOO C S G, KORNFILT J, ODDY R N, et al. Automatic extraction of cause-effect information from newspaper text without knowledge-based inferencing [J]. *Literary and Linguistic Computing*, 1998, 13(4): 177–186.
- [6] GIRJU R. Automatic detection of causal relations for question answering [C]//Sapporo: ACL 2003 Workshop on Multilingual Summarization and Question Answering, 2003.
- [7] LAOKULRAT N, MIWA M, TSURUOKA Y, et al. UTime: temporal relation classification using deep syntactic features [C]//Proceedings of the Seventh International Workshop on Semantic Evaluation (SemEval 2013), 2013: 88–92.
- [8] CHEN L, TIMOTHY M, DMITRIY D, et al. Representations of time expressions for temporal relation extraction with convolutional neural networks [C]//Proceedings of the 16th BioNLP Workshop, 2017: 322–327.
- [9] DMITRIY D, TIMOTHY M, CHEN L, et al. Neural temporal relation extraction [C]//Valencia: 15th Conference of the European Chapter of the Association for Computational Linguistics, 2017.
- [10] RUJUN H, HUNG H, MU Y, et al. Deep structured neural network for event temporal relation extraction [C]//Hong Kong: 23rd Conference on Computational Natural Language Learning, 2019.
- [11] WANG F, LI F, FEI H, et al. Entity-centered cross-document relation extraction [C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing, 2022: 9871–9881.
- [12] JUNYOUNG S, JINSUNG K, JUNGWOO L, et al. Explore the way: exploring reasoning path by bridging entities for effective cross-document relation extraction [C]//Singapore: Findings of the Association for Computational Linguistics, 2023.
- [13] QIANG N, HAO W, DAN R. A multi-axis annotation scheme for event temporal relations [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 1318–1328.
- [14] TIM O, KRISTIN W, MARTHA P. Richer event description: integrating event coreference with temporal, causal and bridging annotation [C]//Proceedings of the 2nd Workshop on Computing News Storylines, 2016: 47–56.
- [15] TOMMASO C, PIEK V. The event storyline corpus: a new benchmark for causal and temporal relation extraction [C]//Proceedings of the Events and Stories in the News Workshop, 2017: 77–86.
- [16] QIANG N, FENG Z L, WU H, et al. Joint reasoning for temporal and causal relations [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 2278–2288.
- [17] WANG H, CHEN M, ZHANG H, et al. Joint constrained learning for event-event relation extraction [C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2020: 696–706.
- [18] WANG X Z, CHEN Y L, DING N, et al. MAVEN-ERE: a unified large-scale dataset for event coreference, temporal, causal, and subevent relation extraction [C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing, 2022: 926–941.
- [19] XU D, CHEN W, PENG W, et al. Large language models for generative information extraction: a survey [J]. *Frontiers of Computer Science*, 2024, 18(6): 186357.
- [20] SHANG S P, PU R L, LI Y, et al. Based on the center of events and sentences perception of cause and effect recognition model [J]. *Journal of Shanxi University (Natural Science Edition)*, 2025, 48(1): 20–28.
尚舒鹏, 普瑞丽, 李旻, 等. 基于中心事件和句子感知的事件因果识别模型 [J]. *山西大学学报 (自然科学版)*, 2025, 48(1): 20–28.
- [21] QIANG N, SANJAY S, DAN R. An improved neural baseline for temporal relation extraction [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: 6203–6209.
- [22] CHRIS Q, HOIFUNG P. Distant supervision for relation extraction beyond the sentence boundary [C]//Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, 2017: 1171–1182.
- [23] CHRISTOPHER M, MIHAI S, JOHN B, et al. The stanford corenlp natural language processing toolkit [C]//Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations, 2014: 55–60.
- [24] LIU Y, OTTM, GOYAL N, et al. Roberta: a robustly optimized bert pre-training approach [DB/OL]. <https://arxiv.org/pdf/1907.11692>.
- [25] LU L, KONG F. Interactive information enhanced relation extraction from dialogue [J]. *Journal of Chinese Information Processing*, 2021, 35(8): 82–88, 97.
陆亮, 孔芳. 面向对话的融入交互信息的实体关系抽取 [J]. *中文信息学报*, 2021, 35(8): 82–88, 97.
- [26] QIAN L, SHU G, CHENG J, et al. Dual-gated fusion with prefix-tuning for multi-modal relation extraction [C]//Toronto: Findings of the Association for Computational Linguistics, 2023.
- [27] CAO H, LI J, SU F, et al. OneEE: a one-stage framework for fast overlapping and nested event extraction [C]//Proceedings of the 29th International Conference on Computational Linguistics, 2022: 1953–1964.
- [28] LI H, DI G. GraphERE: jointly multiple event-event relation extraction via graph-enhanced event embeddings [DB/OL]. <https://arxiv.org/abs/2403.12523>.
- [29] WANG X, PENG H, GUAN Y, et al. MAVEN-ARG: completing the puzzle of all-in-one event understanding dataset with event argument annotation [C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics, 2024: 4072–4091.
- [30] CHEN M, MA Y, SONG K, et al. Improving large language models in event relation logical prediction [C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics, 2024: 9451–9478.