

# 融合扩展语义和标签层次信息的文档级事件抽取

符玉娇<sup>1</sup>, 廖健<sup>1</sup>, 李旸<sup>2</sup>, 郭张峰<sup>1</sup>, 王素格<sup>1,3,\*</sup>

1.山西大学计算机与信息技术学院, 山西省 太原 030006

2.山西财经大学金融学院, 山西省 太原 030006

3.山西大学计算智能与中文信息处理教育部重点实验室, 山西省 太原 030006

wsg@sxu.edu.cn

## 摘要

文档级事件抽取是自然语言处理中的一项重要任务, 面临论元分散和多事件提及的挑战, 现有研究通常从文档的所有句子中抽取论元, 通过论元角色建模捕获实体间关系, 忽略了文档中事件-句子间的关联差异性。本文提出了一种融合扩展语义和标签层次信息的文档级事件抽取方法。首先, 利用大语言模型对文本和事件类型标签与论元角色标签进行语义扩展, 以引入更丰富的背景语义信息; 其次, 基于关联差异性的事件类型检测模块, 获取文档中与事件类型高度相关的句子, 通过约束候选实体的抽取范围, 来缓解论元分散问题; 进一步, 针对文档提及的多个事件类型, 利用有向无环图从候选实体中抽取论元, 获取所有事件要素。在ChFinAnn和DuEE-Fin两个数据集上的实验结果表明, 本文提出的方法相比基线模型可以有针对性地缓解多个事件所属论元分散的问题, 有效地提升事件抽取的性能。

**关键词:** 文档级事件抽取; 标签语义扩展; 关联差异建模; 论元抽取

## Document-Level Event Extraction with Integrating Extended Semantics and Label Hierarchy Information

Yujiao Fu<sup>1</sup>, Jian Liao<sup>1</sup>, Yang Li<sup>2</sup>, Zhangfeng Guo<sup>1</sup>, Suge Wang<sup>1,3,\*</sup>

1.School of Computer and Information Technology,

Shanxi University,Shanxi 030006

2.Shanxi University of Finance and Economics,Shanxi 030006

3.Key Laboratory Computational Intelligence and Chinese Information

Processing of Ministry of Education, Shanxi University,Shanxi 030006

wsg@sxu.edu.cn

## Abstract

Document-level event extraction is an important task in natural language processing, facing the challenges of scattered arguments and multi event mention, existing research typically extracts arguments from all sentences in a document and captures relationships between entities through argument role modeling, thereby ignoring the differences in association between events and sentences in documents. This paper proposes a document-level event extraction method that integrates extended semantic and hierarchical label information. Firstly, using large language model to semantically extend text and event type labels along with role labels to introduce richer contextual semantic information. Secondly, based on the event type detection module of correlation difference, sentences highly related to the event type in the document are obtained, and the problem of argument dispersion is alleviated by constraining the extraction range of candidate entities. Furthermore, for the multiple event types mentioned in the document, arguments are extracted from candidate entities using directed acyclic graphs to obtain all event elements. Experimental results on the ChFinAnn and DuEE-Fin datasets indicate that the proposed method effectively alleviates the problem of

scattered arguments belonging to multiple events compared to baseline models, and effectively improve the performance of event extraction.

**Keywords:** Document-level event extraction , Label semantic extension , Differences in association modeling , Argument extraction

## 1 引言

事件抽取是从文本中抽取有关特定事件的信息，即识别事件的类型和抽取事件的核心要素，包括执行动作的主体、客体、时间、地点等(Li et al., 2022)，进而将非结构化事件文本转化为结构化信息，这些信息可服务于事理图谱构建(Du et al., 2022)、基于事件的推荐系统(李治, 2022)等下游任务。针对事件相关要素分散于多个句子的问题，现有的句子级的文本事件抽取方法(Sheng et al., 2021; Lu et al., 2021)无法全面、完整地抽取出事件信息。因此，文档级事件抽取受到越来越广泛的关注，通过从长文本中抽取描述特定事件的关键信息，利用论元集合表示不同的事件(Liang et al., 2022)，可以获得更全面、细致的事件结构化信息，图1展示了一个包含3个事件的文档示例。

.....

[S3]江西国泰集团股份有限公司（以下简称“公司”）收到公司持股5%以上股东江西鑫安信和投资集团有限责任公司（以下简称“鑫安信和”）部分股份解除质押的口头通知，具体情况如下：一、本次股份解除质押的具体情况

[S4]鑫安信和于2017年9月29日将其持有的公司27,020,000股无限售流通股（占公司总股本的比例为6.91%），质押给华泰证券股份有限公司（以下简称“华泰证券”），办理股票质押式回购交易业务（详见公司2017临065号公告）

[S5]2018年9月25日鑫安信和提前购回部分本金，同时对上述流通股质押办理延期（详见公司2018临087号公告）。2019年5月27日，鑫安信和将其中11,046,000股解除质押，并办理完成了相关手续。本次解除质押股数占公司总股本的2.82%

[S6]2019年7月26日，鑫安信和将其中7,364,000股解除质押，并办理完成了相关手续，本次解除质押股数占公司总股本的1.88%。

二、持股5%以上股东股权质押情况 截至本公告披露之日，鑫安信和持有公司股份40,600,000股，占公司总股本的10.38%

[S7]已累计质押公司股份12,510,000股，占其持有公司股份总数的30.81%，占公司总股本的3.20%。特此公告

江西国泰集团股份有限公司 董事会 二〇一九年七月三十日

事件	事件类型	质押物所属公司	质押方	事件时间	质押股票/股份数量	质押物占总股比	质押物	披露时间
事件1	解除质押	江西国泰集团股份有限公司	江西鑫安信和投资集团有限责任公司	2019年5月27日	11,046,000	2.82%	股份	二〇一九年七月三十日
事件2				2019年7月26日	7,364,000	1.88%		
事件3	质押			2017年9月29日	27,020,000	NULL	无限售流通股	

图 1: 包含3个事件的文档示例，[●]为句子编号

对于文档级事件抽取，将面临以下两个挑战：

(1) 论元分散，事件论元分散于一篇文章的多个句子中。例如图1，事件类型为“解除质押”的事件1中，句子[S3]的“江西国泰集团股份有限公司”和“江西鑫安信和投资集团有限责任公司”扮演“质押物所属公司”和“质押方”的角色，句子[S5]的“11046000”和“2.82%”扮演“质押股票/股份数量”和“质押物占总股比”的角色，句子[S7]的“二零一九年七月三十日”扮演“披露时间”的角色。针对论元分散问题，需要捕捉关联性较强的上下文来抽取完整的事件信息。

(2) 多事件提及，即一篇文章包含多个事件，这些事件可能属于同一种事件类型，也可能属于不同的事件类型。例如图1，事件1和3的事件类型分别为“质押”和“解除质押”。多事件提及意味着确定文档包含的事件个数较为困难，因此需要通过事件-句子间的关联差异性约束候选实体的抽取范围。

针对论元分散问题，现有研究(Liang et al., 2022; Wan et al., 2023)主要利用注意力机制或图模型建立论元之间的关系；针对多事件提及问题，现有方法(Xu et al., 2021; Wang et al.,

©2024 中国计算语言学大会

根据《Creative Commons Attribution 4.0 International License》许可出版

\* 通讯作者 Corresponding Author.

基金项目：国家重点研发计划课题(2022QY0300-01)；国家自然科学基金项目(62106130,62376143,62076158)；山西省基础研究计划项目(202303021211021)；CCF-智谱AI大模型基金(CCF-Zhipu202310)

2023)利用跟踪机制或建立伪事件节点之间的联系,捕获事件间的依赖。在这些事件论元抽取研究中,针对同一事件类型,并未考虑句子与论元、事件类型间的关联差异性。而每篇文章中的每个句子与特定事件类型的相关性是有差异的,事件论元通常分散在与事件类型相关性较高的句子中,因此,需要建立事件论元与事件类型的关系。

本文提出了融合扩展语义与标签层次信息的文档级事件抽取模型(Document-Level Event Extraction with Integrating Extended Semantics and Label Hierarchy Information, IESLHI)。首先,利用大语言模型丰富的背景语义知识,构建增强提示,对文章和事件类型标签以及论元角色标签进行语义扩展,更好地理解并表示事件文本。在此基础上,对论元和事件类型的相关性进行建模,构建基于关联差异性的事件类型检测模块,获得文章中与每个事件类型标签相关性较高的句子,并基于该相关性对每个句子中抽取的实体给予不同程度的关注,建立候选实体。进一步,基于候选实体构建有向无环图,对文档包含的每个事件类型分别通过路径扩展进行论元抽取,以获得各事件的所有论元。通过在两个公开数据集上进行实验,实验结果验证了本文所提方法的有效性。

综上所述,本文的贡献如下:

(1)提出了一个融合扩展语义与标签层次信息的文档级事件抽取模型(IESLHI),从文档中捕获与事件类型标签关联较强的句子。在此基础上,通过在论元抽取过程中聚焦强关联的句子,以约束候选实体的抽取范围,并针对每个事件类型构建向无环图抽取论元,提升文档级事件抽取的性能。

(2)提出了一种基于大语言模型的层次化标签语义扩展与融合方法,丰富文档内容和事件类型标签与论元角色标签的语义,有效地增强了模型理解文档信息和层次信息的能力。

(3)在两个公开数据集ChFinAnn和DuEE-Fin上进行实验,与已有的文档级事件抽取方法相比,所提模型的实验性能具有一定的提升。同时与开源大语言模型进行对比,所提模型在文档级事件抽取性能上优于大语言模型。本文的实现代码在论文发表后可在GitHub上获取。

## 2 相关工作

### 2.1 给定事件类型的论元抽取

论元抽取是在给定事件类型的情况下,抽取与事件有关的实体。之前的研究(Li et al., 2021; Ma et al., 2022)通过构建特定事件类型的提示模版直接抽取论元,无需进行命名实体识别。但是,文档中的冗余信息导致抽取论元的性能较差。为了减少冗余信息,Pouran Ben Veyshe等人(2022)基于句法结构的最优传输排除不相关单词,并利用正则化对不相关单词的贡献进行约束;Xu等人(2022)引入抽象意义表示图构建句内和句间关系,并利用边界损失增强论元的边界判断。此外,为了融合丰富的语义信息,Liu等人(2023b)利用注意力机制融合触发词与上下文信息以及论元角色间的关系,进而预测跨度的角色。为了增强论元抽取过程中的可解释性,Liu等人(2023a)利用链式推理范式进行论元抽取,通过推理链的相互依赖性捕获句子间的长距离依赖;Ren等人(2023)引入基于相似性的检索增强策略给每个实例采样伪示例,提高模型的类比能力。

上述研究主要利用句间信息和实体间信息提高论元抽取的性能,忽略了事件类型和论元角色间的层次信息,本文旨在利用大语言模型对层次标签进行语义扩展,丰富事件类型标签与论元角色标签的语义。

### 2.2 文档级事件抽取

由于给定事件类型的论元抽取存在现实需求的局限性,因此,文档级事件抽取广受关注。Zheng等人(2019)基于有向无环图的路径扩展方法抽取论元,但它需要预先定义论元角色的抽取顺序。为了避免预先定义论元角色的顺序,Huang等人(2023)采用预填充策略,并行地生成事件记录的论元。Liang等人(2022)利用关系增强的注意力机制捕获实体间关系,但它未捕获句间信息,而篇章中的事件论元可能分散在多个句子中,捕捉跨句的实体信息对于文档级事件抽取非常重要。因此,许多研究利用图模型建立实体间关系以抽取论元,Zhu等人(2022)建立实体提及与伪触发词的单向边以及伪触发词间的双向边构造修剪完全图,利用伪触发词信息提升文档级事件抽取的性能。Wan等人(2023)建立token与token之间的双向边,通过训练集构造邻接矩阵,预测token之间边的关系。但是,这些方法忽略了文档中多事件间的相互依赖,Xu等人(2021)构建句子和实体提及的异质图捕获实体与句子之间的关系,同时,引入跟踪机制捕获

事件之间的相互依赖。Wang等人(2023)建立实体提及、句子与伪事件节点之间的关系，通过伪事件节点间的相互联系从全局上捕获事件信息。

上述研究旨在捕获实体与所有句子间的关系以解决论元分散问题，未考虑事件类型与句子的相关性问题，本文通过研究事件类型与句子之间的关联差异性来缓解论元分散。

### 3 文档级事件抽取模型

#### 3.1 模型概述

针对第1节引言中提出的挑战，本文提出了一个融合扩展语义与标签层次信息的文档级事件抽取模型(IESLHI)，整体框架如下图2所示，包括三个核心部分：基于大语言模型语义扩展的实体抽取与表示、基于关联差异性的事件类型检测，和基于有向无环图的候选实体的论元抽取。首先，利用大语言模型解释文章的每个句子，得到语义扩展文本。再将事件类型标签作为查询来检测文章包含的事件类型。其次，对于文章包含的每个事件类型，判断每个句子与特定事件类型的相关性。最后，基于实体的有向无环图，对每个事件类型相关性较高的句子的实体进行路径扩展，迭代地生成每个事件的论元。

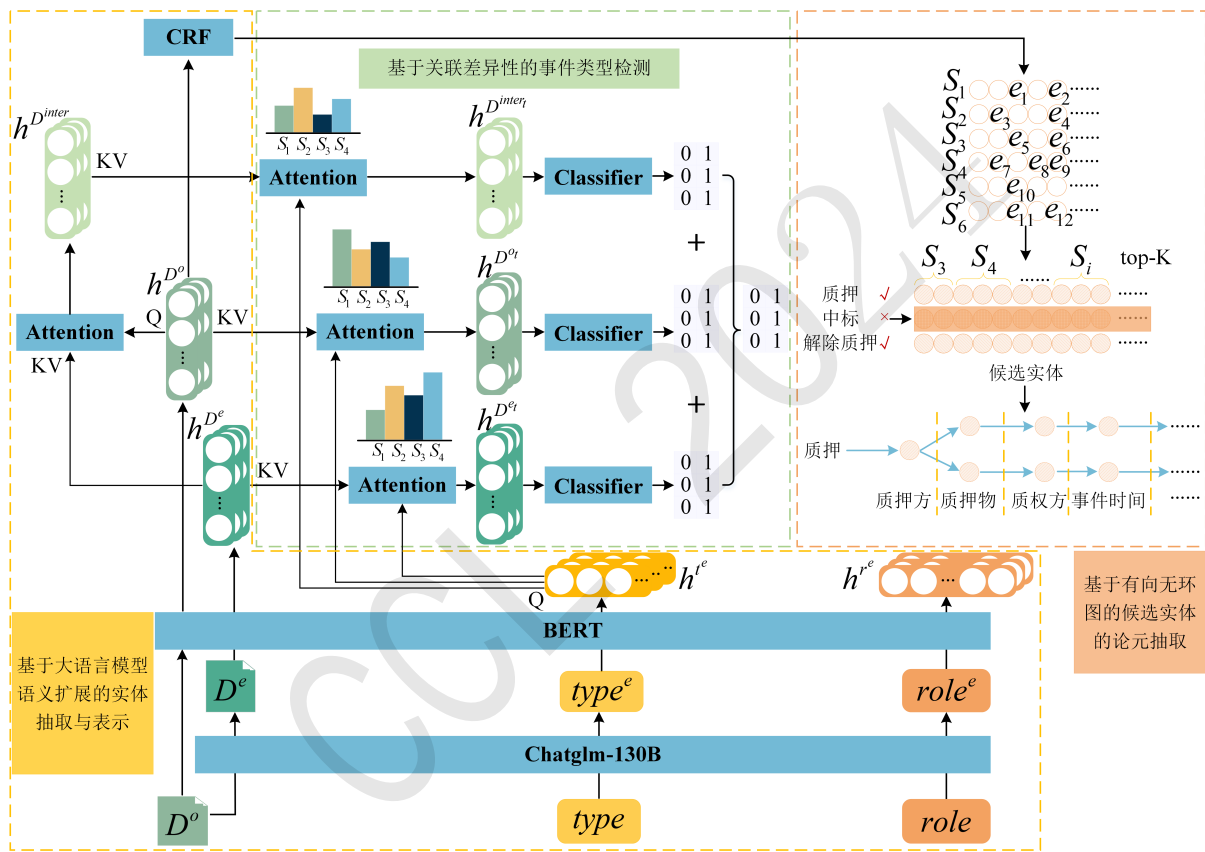


图 2: IESLHI模型框架

#### 3.2 基于大语言模型语义扩展的实体抽取与表示

##### 3.2.1 实体抽取与表示

文档 $D_i$ 由句子 $S_1, S_2, \dots, S_n$ 组成， $n$ 为文档 $D_i$ 的句子个数。其中，每个句子由 $m$ 个token组成，表示为 $S_i = [W_{i1}, W_{i2}, \dots, W_{im}]$ ， $W_{ij}$ 表示第 $i$ 个句子中的第 $j$ 个token， $W_{ij} \in R^d$ ， $d$ 为嵌入表示维度， $S_i \in R^{d \times m}$ ， $D_i \in R^{d \times m \times n}$ 。

为确定文档中的实体提及，需要对文档 $D$ 中的句子 $S_i$ 包含的命名实体进行识别。这里采用BERT模型，按句对token序列进行编码，得到包含句内上下文信息的表示 $h_{ij}^W$ 。

$$h_{ij}^W = \text{BERT}(W_{ij}), h_i \in R^{d \times m} \quad (1)$$



句中实体标签按照BIOSE(Begin, Inside, Outside, Single, End)进行序列标注。将每一句中的token表示输入到CRF层得到标签序列的预测概率 $p^{ner}$ 。

$$p^{ner} = \text{CRF}(h_i) \quad (2)$$

实体提及为文档中处于不同位置的同一实体，且实体提及通常包含多个token。因此，对每个实体提及进行max pooling操作得到相应的嵌入表示。最后，对多个实体提及进行max pooling操作得到每个实体的表示，该表示服务于后续的论元抽取任务。

命名实体识别部分的损失函数为：

$$L_{ner} = - \sum_{i=1}^n \sum_{j=1}^m \log p_{ij}^{ner} \quad (3)$$

其中， $p_{ij}^{ner}$ 表示文档D中第*i*个句子的第*j*个token对应的预测概率。

### 3.2.2 文本语义扩展

在文档中，承接上下文的句子通常省略主体信息、句子的表达存在多义性。通过对文本的语义进行拓展，可以深入理解文本的逻辑关系和含义。本文利用大语言模型的提示方法丰富和补充每个句子的语义，保持句子的主体不变性以避免生成解释过程中引起的语义偏差。本文使用glm-3-turbo分析文本中词语和短语之间的语义相关性，构造提示模版Prompt1=“请结合上下文解释以下这句话：[句子]”解释每个句子，挖掘句子之间的语义相关性，生成感知上下文的语义扩展文本 $D^e$ 。

对于得到的语义扩展文本，同样使用BERT对解释文档 $D^e$ 的token序列进行编码，得到语义扩展文本对应的token表示 $h_{ij}^e$ ，随后通过max pooling操作得到相应的句子嵌入表示 $h_i^e$ 。

$$h_{ij}^e = \text{BERT}(W_{ij}^e) \quad (4)$$

$$h_i^e = \text{MaxPooling}(h_{i1}^e, \dots, h_{im}^e), h_i^e \in R^d \quad (5)$$

其中， $h_{ij}^e$ 为解释文档 $D^e$ 中第*i*个句子的第*j*个token的表示， $h_i^e$ 为解释文档 $D^e$ 中第*i*个句子的表示，每个句子由*m*个token组成，*d*为嵌入表示维度。

### 3.2.3 标签层次信息解释

事件类型反映了一组事件的特性，但是，简短的事件类型名称具有模糊性，仅通过事件类型名称不能反映事件类型本身的丰富信息。利用大语言模型加以提示，构造提示模版Prompt2=“金融领域，怎样定义[事件类型]”解释每个事件类型标签，有助于理解文本描述的事件，得到具有丰富语义的、可以充分反映事件类型信息的事件类型解释文本，进而生成感知事件类型的解释文本表示。此外，每个事件类型定义了一系列论元角色，论元角色表示动词或其他词涉及到的实体扮演的角色，描述了实体之间的关系。但是角色名称本身表达的语义有限，利用大语言模型对角色进行详细的描述与扩展，构造提示模版Prompt3=“金融领域的[事件类型]事件中怎样定义[论元角色]”，得到有助于理解文本语义信息的论元角色解释文本，进而生成感知论元角色的解释文本表示。

与文本语义扩展类似，此处使用BERT对事件类型解释文本 $t^e$ 、论元角色解释文本 $r^e$ 进行编码，得到感知事件类型的解释文本表示 $h^{t^e}$ ，感知论元角色的解释文本表示 $h^{r^e}$ ，分别将其作为事件类型和论元角色的表示， $h^{t^e} \in R^d$ ， $h^{r^e} \in R^d$ 。

### 3.3 基于关联差异性的事件类型检测

对于文档D，通过注意力机制对各句子[CLS]表示 $S_i^C$ 进行加权，得到不同事件类型下相应的文档表示 $D^{ot}$ 。其中，注意力的查询项为事件类型 $h^{t^e}$ 。对于每一个事件类型，使用神经网络分层判断其是否在文档中被提及，并得到相应事件类型的概率 $p^{D^{ot}}$ ，具体操作如下：

$$\alpha_i = \text{softmax}\left(\frac{h^{t^e} \cdot S_i^C}{\sqrt{d_k}}\right) \quad (6)$$

$$D^{ot} = \sum_{i=1}^n \alpha_i S_i^C \quad (7)$$

$$p^{D^{ot}} = \text{softmax}(\text{FC}(D^{ot})) \quad (8)$$

同理，对于解释文档 $D^e$ ，使用注意力机制得到不同事件类型下的文档表示 $D^{et}$ 。用神经网络分类层来判断每个事件类型是否被识别，并得到相应事件类型的概率 $p^{D^{et}}$ 。

$$p^{D^{et}} = \text{softmax}(\text{FC}(D^{et})) \quad (9)$$

进一步，为将原始文档与语义扩展文本进行交互，得到融合上下文解释信息的文本表示，本模型将原始文档表示 $[S_1, S_2, \dots, S_n]$ 与语义扩展文本 $[S_1^e, S_2^e, \dots, S_n^e]$ 送入Transformer，得到其交互表示 $[S_1^{inter}, S_2^{inter}, \dots, S_n^{inter}]$ 。

$$S_i^{inter} = \text{Transformer}(Q, K, V) = \text{Transformer}(S_i^e, S_i, S_i) \quad (10)$$

通过注意力得到相应的文档表示 $D^{inter}$ ，并完成事件类型检测，得到相应事件类型的概率 $p^{D^{inter}}$ 。

$$p^{D^{inter}_t} = \text{softmax}(\text{FC}(D^{inter}_t)) \quad (11)$$

将三种方式得到的概率求和，并进行归一化操作得到最终的相应事件类型的概率 $p^{D^t}$ 。

$$p^{D^t} = \text{softmax}(p^{D^{ot}} + p^{D^{et}} + p^{D^{inter}_t}) \quad (12)$$

事件类型检测的损失函数为：

$$L_{dect} = - \sum_{t=1}^z (\log p^{D^t} + \log p^{D^{ot}} + \log p^{D^{et}} + \log p^{D^{inter}_t}) \quad (13)$$

其中， $z$ 表示事件类型的个数。

### 3.4 基于有向无环图的候选实体的论元抽取

由于事件论元抽取是为文档所包含事件的每个论元角色填充相应的实体，本文受(Zheng et al., 2019)的启发，使用基于实体的有向无环图生成每个事件的论元。预先定义每种事件类型的论元角色顺序，每个事件记录的长度等于预先定义的论元角色的数量，每个论元节点用实体或空节点填充。当文档 $D$ 包含特定的事件类型时，按照论元角色顺序预测每个角色的实体。对于每个论元角色，可以存在0个、一个或几个满足条件的实体，因此每个论元角色展开的分支数量是不确定的。每一条完整路径表示预测出当前事件类型的一个事件。

针对事件类型与句子间的关联差异性，通过判断特定事件类型下相关性较高的句子，有助于检索和查找与该事件类型相关的事件记录，这些句子往往也包含了事件相关的时间、地点和主要参与者。因此，找出这些句子可以提高抽取论元的准确率。事件类型检测模块，模型分析了文档中各句子的重要性，据此，可以选出top-k个相关性较高的句子，候选句子中提及的实体作为候选实体。

有向无环图的路径扩展子任务为多个二分类问题的集合，即预测所有候选实体的扩展或不扩展。为了能够感知当前路径状态、历史上下文和当前论元角色，将上下文记忆向量 $m$ 和实体向量 $e^b$ 拼接起来，使用Transformer对其进行编码，促进上下文感知推理。从Transformer的输出中抽取相应的实体向量表示 $e^r$ ，并在 $e^r$ 上堆叠一个线性分类器来进行路径扩展分类。

$$e^r = \text{Transformer}(e^b, [m; e^b]) \quad (14)$$

$$p_{vr}^a = \text{softmax}(\text{FC}(e^r)) \quad (15)$$

其中， $p_{vr}^a$ 表示对于论元角色 $v$ ，各候选实体 $r$ 的预测概率。

每扩展一个节点，记忆向量更新一次，更新方式如下：

$$m' = [m; e^b] \quad (16)$$

论元抽取的损失函数为：

$$L_{ext} = - \sum_{v=1}^V \sum_{r=1}^Q \log p_{vr}^a \quad (17)$$

其中， $V$ 表示事件类型对应的论元角色个数， $Q$ 表示候选实体的个数。

### 3.5 基于多任务学习的联合优化

利用多任务学习的方式，联合3.2节获取实体提及、3.3节判断事件类型和3.4节抽取事件论元三者的损失，得到最终损失 $L$ ：

$$L = \lambda_1 L_{ner} + \lambda_2 L_{dect} + \lambda_3 L_{ext} \quad (18)$$

其中， $\lambda_1, \lambda_2, \lambda_3$ 是超参数。

## 4 实验和分析

### 4.1 数据集

本文在两个公开的中文数据集ChFinAnn(Zheng et al., 2019)和DuEE-Fin<sup>0</sup>上进行了实验，ChFinAnn包含5个事件类型，24种不同的论元角色。DuEE-Fin包含13个事件类型，61种不同的论元角色。两个数据集的详情及划分如表1所示。

	ChFinAnn	DuEE-Fin
训练集	25632	6011
验证集	3204	1004
测试集	3204	1171
单事件	71%	67%
多事件	29%	33%

表 1: ChFinAnn和DuEE-Fin数据集详情

### 4.2 评价指标和参数设置

文档级事件抽取的最终目标是为每个事件的事件论元角色分配正确的实体，因此，在论元级别计算预测事件与真实事件标签的微平均的精确率P、召回率R和F1。本文设置最大句子数量和最大句子长度为64和128。为保证实验对比的公平性，本文选择了与对比模型MMR等模型相同的基座BERT-Base Chinese<sup>1</sup>(Devlin et al., 2019)，Transformer的隐藏层和前馈层的维度分别是768和1024。训练过程中，设置 $\lambda_1 = 0.05, \lambda_2 = \lambda_3 = 0.95$ ，学习率为 $5e^{-5}$ ，梯度累积步数为8，使用Adam优化器，并在NVIDIA A100 GPU(40G)上训练，选择验证集上分数最高的轮次用于测试集的评估。

### 4.3 对比基线模型

本文选择了以下代表性的模型和大语言模型进行对比：

- DCFEE(Yang et al., 2018)：该模型从文档的中心句抽取论元，针对单事件和多事件抽取任务提出了两个变体DCFEE-O和DCFEE-M。
- Doc2EDAG(Zheng et al., 2019)：该模型利用基于实体的有向无环图实现文档级多事件抽取，Greedy-Doc是一个利用贪婪策略填充事件表的基础模型。
- GIT(Xu et al., 2021)：该模型利用异质图建模句子和实体提及之间的关系，并提出了一种跟踪机制捕获事件间的依赖。
- DE-PPN(Yang et al., 2021)：该模型利用Transformer编码句子和实体，用多粒度解码器并行地抽取所有事件。
- PTPCG(Zhu et al., 2022)：该模型是一个轻量级模型，构造了伪触发词的修剪完全图用于非自回归解码。
- ReDEE\*(Liang et al., 2022)：为保证本文与对比实验的公平性，将ReDEE模型的参数gradient\_accumulation\_steps和train\_batch\_size分别设置为4和4，记作ReDEE\*模型。
- MMR(Yang et al., 2022)：该模型将文档级事件抽取任务视为机器阅读理解任务，把论元抽取转化为从文档中识别论元，并基于MRC捕获角色与文档上下文的依赖关系。
- TFECI(Chen et al., 2023)：该模型提出了一种选择伪触发词的策略，利用实体共指和实体的缩写信息提高抽取性能。

<sup>0</sup><https://aistudio.baidu.com/datasetdetail/186939>

<sup>1</sup><https://github.com/google-research/bert>

• Zou(Zou et al., 2023): 该研究提出了一种捕捉实体信息与文档信息的编码方法, 并在解码过程中预测出每种事件类型的事件个数。

• ChatGLM-6B<sup>2</sup>:清华大学发布的具有60亿参数的生成式大语言模型, 采用P-Tuning的微调方式。

• Qwen-1.8B<sup>3</sup>:阿里云研发的具有18亿参数规模的大语言模型, 本文对其进行全参数微调。

## 4.4 实验

### 4.4.1 实验结果和分析

为了评估所提模型的整体性能, 将本文方法与第4.3节介绍的对比基线模型在ChFinAnn数据集上进行对比实验, 实验结果见表2。

Model	F1 for each event type						overall	
	EF	ER	EU	EO	EP	P	R	F1
DCFEE-O	46.7	80.0	47.5	46.7	56.1	67.7	54.4	60.3
DCFEE-M	42.7	73.3	45.8	44.6	53.8	58.1	55.2	56.6
Greedy-Doc	57.7	79.4	51.2	50.0	54.2	80.4	49.1	61.0
Doc2EDAG	71.0	88.4	69.8	73.5	74.8	80.3	75.0	77.5
GIT	73.4	90.8	<u>74.3</u>	<u>76.3</u>	77.7	82.3	<b>78.4</b>	<u>80.3</u>
DE-PPN	<u>73.5</u>	87.4	<b>74.4</b>	75.8	<b>78.4</b>	83.7	<u>76.4</u>	79.9
PTPCG	—	—	—	—	—	<b>88.2</b>	69.1	79.4
ReDEE*	63.4	88.6	61.4	69.6	74.0	84.0	69.6	76.1
MMR	71.3	88.7	72.4	<b>76.9</b>	78.0	83.8	76.3	79.9
TFECI	<b>74.1</b>	<u>91.6</u>	70.9	71.4	76.7	83.3	76.0	79.5
Zou	72.4	90.4	72.6	73.3	74.8	81.6	75.1	78.2
ChatGLM-6B	—	—	—	—	—	34.2	30.8	32.4
Qwen-1.8B	—	—	—	—	—	46.8	46.7	46.7
IESLHI(ours)	70.8	<b>92.9</b>	72.5	74.0	<u>78.1</u>	<u>86.3</u>	<u>75.9</u>	<b>80.7</b>

\*: 本文用(Liang et al., 2022)公开的代码复现的实验结果(下同)。P、R、F1分别表示Precision(%)、Recall(%)、F1-score(%) (下同)。股权冻结(EF)、股权回购(ER)、股权减持(EU)、股权增持(EO)、股权质押(EP)。

表 2: 模型在ChFinAnn数据集上的实验结果

由表2可知:

(1) 本模型在F1指标上的整体表现均优于对比基线, 相比最优的对比模型, 本模型取得了0.4%的提升。特别地, 相比Doc2EDAG模型, 本模型进一步度量了句子与事件类型的关联差异性, 其能够约束候选实体的抽取范围, 进而缓解论元分散, 并取得了3.2%的提升。

(2) 在事件类型ER和EP中, 本模型取得了最优或次优的表现, 表明通过度量句子与事件类型的关联差异性, 可以抽取出文档中与事件类型关联性较强的句子, 从而有效地约束候选实体的识别范围。

(3) 对于事件类型EF、EU和EO, 本文方法不及GIT、DE-PPN和MMR, 可能原因是存在事件类型如股权增持(EO)等事件类型的大部分文档包含40多个句子, 论元在文档中较为分散、且跨度较大。而本文未建立句子之间的关系, 导致模型在这些事件类型上的抽取性能不理想。

为了进一步验证模型的性能, 将本文方法与第4.3节介绍的对比基线模型在DuEE-Fin数据集上进行对比实验, 实验结果见表3。

由表3可知:

(1) 本模型相比最优的基线模型在F1指标上提高了0.3%, 其在大多数事件类型上取得了最优或次优的结果, 表明通过捕获事件类型与关联性较强的句中实体的关系有助于提高事件抽取性能, 验证了所提模型的有效性。

(2) 对于一些事件类型, 本文方法次于GIT和ReDEE, 可能原因是本模型没有对句间关系建模, 而解除质押(RP)、亏损(Lo)等事件类型的文档长度较长, 无法较好地捕获句间依赖关系。

<sup>2</sup><https://github.com/THUDM/ChatGLM-6B>

<sup>3</sup><https://github.com/QwenLM/Qwen>



Model	F1 for each event type														overall	
	WB	Lo	CA	EB	CF	GP	EU	EO	ER	Vi	RP	PI	EC	P	R	F1
DCFEE-O	54.0	65.4	44.0	27.3	58.2	42.0	48.8	53.9	76.7	32.9	63.3	58.3	40.6	59.8	55.5	57.6
DCFEE-M	49.2	68.0	40.4	28.4	51.2	35.1	42.3	45.9	74.0	51.0	55.8	56.4	37.4	50.2	55.5	52.7
Greedy-Doc	53.7	71.8	49.5	41.1	61.3	42.1	49.7	57.4	74.4	29.2	60.8	50.5	39.4	66.0	50.6	57.3
Doc2EDAG	60.0	<b>78.3</b>	50.6	40.1	63.2	51.5	50.7	52.9	83.7	51.2	64.8	61.7	51.2	73.7	59.8	66.0
GIT	58.8	<u>77.6</u>	<u>56.6</u>	44.7	68.5	<b>55.1</b>	58.8	<b>71.2</b>	<u>86.4</u>	45.0	66.4	<u>71.3</u>	<b>53.8</b>	<u>75.4</u>	61.4	67.7
DE-PPN	50.7	62.7	41.3	21.4	36.3	23.0	32.9	31.3	67.8	25.8	42.1	36.3	23.4	69.0	33.5	45.1
PTPCG	—	—	—	—	—	—	—	—	—	—	—	—	—	71.0	<u>61.7</u>	66.0
ReDEE *	<u>65.9</u>	75.9	56.1	<b>48.7</b>	<u>69.4</u>	51.0	<u>64.1</u>	56.4	<b>87.5</b>	<u>51.6</u>	<b>71.5</b>	70.3	52.5	<b>79.8</b>	<u>60.9</u>	<u>69.1</u>
ChatGLM-6B	—	—	—	—	—	—	—	—	—	—	—	—	—	38.7	36.6	37.6
Qwen-1.8B	—	—	—	—	—	—	—	—	—	—	—	—	—	41.5	38.9	40.1
IESLHI(ours)	<b>68.4</b>	76.7	<b>56.8</b>	<u>47.7</u>	<b>71.9</b>	<u>53.1</u>	<b>65.2</b>	<u>65.0</u>	81.6	<b>56.6</b>	<u>71.0</u>	<b>75.8</b>	<u>52.8</u>	71.0	<b>67.8</b>	<b>69.4</b>

公司上市(GP)、股东减持(EU)、股东增持(EO)、企业收购(CA)、企业融资(CF)、股份回购(ER)、高管变动(EC)、解除质押(RP)、企业破产(EB)、亏损(Lo)、被约谈(Vi)、中标(WB)、质押(PI)。

表 3: 模型在DuEE-Fin数据集上的实验结果

(3) 各模型在DuEE-Fin数据集上的整体表现较差，主要原因是ChFinAnn的训练集数据量是DuEE-Fin的5倍，而DuEE-Fin的事件类型是ChFinAnn的2.6倍。

另外，综合表2和表3可以观察到：本文方法与大语言模型的性能对比，ChatGLM和Qwen的微调结果在特定领域的文档级事件抽取任务上表现不佳。在ChatGLM和Qwen微调过程中，构造了提示Prompt4=“[文档]，请判断文档包含的事件类型并抽取相应的论元：[[事件类型1，论元角色1：论元1，论元角色2：论元2],[事件类型2，论元角色3：论元3，论元角色4：论元4]]”，尽管已经在训练数据上对所对比的大模型进行了训练和微调，但是它们处理语义理解和推理等复杂任务的能力依然有限，进一步表明为复杂任务设计相应的模型是有必要的。本文方法既利用了大语言模型丰富的背景语义信息，建立了语义扩展的实体抽取与表示模块，并通过获取文本的扩展语义，对事件进行了有效的表示。在此基础上，又建立了基于关联差异性的事件类型检测模块，用于捕获长文本中与事件类型关联性较高的句子，以约束候选论元的抽取范围。而大模型无法捕获长文本中与事件类型高度相关的句子，进而无法约束候选论元的抽取范围，容易导致多个事件-论元间对应关系出现混乱的问题。

#### 4.4.2 单事件和多事件抽取分析

为了评估所提模型在单事件和多事件上的表现，本文将ChFinAnn数据集中涉及单个事件和多个事件的数据分别进行分析，结果如表4所示。

Model	EF		ER		EU		EO		EP	
	S.	M.	S.	M.	S.	M.	S.	M.	S.	M.
DCFEE-O	55.7	38.1	83.0	55.5	52.3	41.4	49.2	43.6	62.4	52.2
DCFEE-M	45.3	40.5	76.1	50.6	48.3	43.1	45.7	43.3	58.1	51.2
Greedy-Doc	74.0	40.7	82.2	50.0	61.5	35.6	63.4	29.4	78.6	36.5
Doc2EDAG	79.7	63.3	90.4	70.7	74.7	63.3	76.1	70.2	84.3	69.3
GIT	<u>81.9</u>	<b>65.9</b>	<u>93.0</u>	71.7	<b>82.0</b>	64.1	<b>80.9</b>	<u>70.6</u>	85.0	<b>73.5</b>
DE-PPN	<b>82.1</b>	<u>63.5</u>	89.1	70.5	79.7	<b>66.7</b>	80.6	69.6	<u>88.0</u>	73.2
ReDEE *	77.9	49.1	90.8	67.9	71.6	46.7	74.8	62.8	83.6	68.2
MMR	81.2	61.8	89.8	70.1	77.9	<u>65.4</u>	80.8	<b>71.7</b>	86.2	72.6
Zou	81.2	64.8	92.6	<u>73.6</u>	78.4	<u>65.4</u>	80.3	65.5	<b>89.6</b>	66.2
IESLHI(ours)	81.5	60.6	<b>93.6</b>	<b>75.8</b>	<u>80.3</u>	62.2	<u>79.5</u>	67.3	86.4	<u>73.3</u>

S.表示单事件，M.表示多事件。

表 4: 模型在ChFinAnn数据集上的单事件和多事件比较

由表4可知：

(1) 在大多数事件类型的单事件中，本模型取得了最优或次优的表现。各模型单事件的F1整体都高于多事件的F1，体现出多事件抽取任务是有一定难度的。

(2) 事件类型ER、EP的多事件中，本模型表现较好，表明所提模型通过判断不同事件类型的相关句子，并分别对每个事件类型进行路径扩展以抽取论元的策略可以提高多事件抽取的性能。

(3) 本模型在事件类型EF、EU、EO的多事件中表现并不理想，可能原因是多个事件间存在事件类型重叠的情况，对解码路径造成一定的干扰，导致出现漏判或错判的情况。

### 4.4.3 消融实验

为了证明所提模型每个模块的有效性，设计了三种变体模型进行消融实验。1) 移除事件类型标签和论元角色标签的解释(-标签解释); 2) 移除判断事件类型与句子的关联差异性(-关联差异性); 3) 移除文档的语义扩展(-语义扩展)。

	ChFinAnn			DuEE-Fin		
	P	R	F1	P	R	F1
IESLHI	<b>86.3</b>	<b>75.9</b>	<b>80.7</b>	<b>71.0</b>	<b>67.8</b>	<b>69.4</b>
-标签解释	88.7	70.5	78.6	67.3	68.3	67.8
-关联差异性	86.5	72.9	79.1	65.7	70.8	68.2
-语义扩展	87.5	72.7	79.4	69.4	68.1	68.7

表 5: IESLHI在ChFinAnn和DuEE-Fin数据集的消融实验

表5显示了移除任一模块，模型的性能都有所下降，说明每个模块对所提模型都有积极作用。可以观察到：

(1) 移除标签解释在ChFinAnn和DuEE-Fin上F1分别下降了2.1%和1.6%，表明利用大模型生成的标签解释可以在解码图中发挥较大作用，帮助模型判断每一论元角色时正确识别相应的实体。

(2) 移除关联差异性模块在ChFinAnn和DuEE-Fin上F1分别下降了1.6%和1.2%，表明度量与事件类型相关的句子的权重对模型性能提升也有较大的贡献，且该组件可以有效约束候选实体的产生范围，避免过多实体导致的信息冗余。

(3) 移除语义扩展模块在ChFinAnn和DuEE-Fin上F1分别下降了1.3%和0.7%，显示出文档的语义扩展也可以对模型做出比较稳定的贡献，该语义扩展组件可以丰富句子的语义，为命名体识别任务提供帮助。

为了进一步分析各个模块对模型性能的影响，本文选取了一个多事件论元抽取的例子，如图3所示。根据图中IESLHI列的抽取结果，所提模型可以正确地抽取事件类型为“股权质押”的两个事件包含的所有论元，通过大语言模型对文本的解释和扩展，可以丰富文本信息，有助于正确地识别论元。

[S1]证券代码：300286证券简称：安科瑞……[S2]安科瑞电气股份有限公司关于……[S3]安科瑞电气股份有限公司接到……周中先生……吴建明先生的通知，周中先生将……1600000股质押给南京证券股份有限公司……质押期限自2018年9月25日起……吴建明……1600000股质押给南京证券股份有限公司……质押期限自2018年9月20日起……为止[S6]截至本公告日，周中先生持有本公司股份39197988股，占公司总股本的18.07%，其中本次质押的股份总数为1600000股，占周中……累计质押的股份总数为4675000股，占周中……[S8]截至本公告日，吴建明先生持有本公司股份16679436股，占公司总股本的7.69%，其中本次质押的股份总数为1600000股，占吴建明……累计质押的股份总数为4795000股，占吴建明……[S13]……

事件类型	股权质押	股权质押	股权质押	股权质押	股权质押
质押方	周中	周中	周中	周中	周中
质押股份	1600000股	1600000股	1600000股	1600000股	1600000股
质权方	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司
总持有股份	39197988股	39197988股	NULL	39197988股	39197988股
总持有比例	18.07%	18.07%	18.07%	18.07%	18.07%
总质押股份	4675000股	4675000股	4675000股	NULL	4675000股
开始时间	2018年9月25日	2018年9月25日	2018年9月20日	2018年9月20日	NULL
结束时间	NULL	NULL	NULL	NULL	2018年9月25日
解除时间	NULL	NULL	NULL	NULL	NULL
	真实标签	IESLHI	标签解释	-关联差异性	-语义扩展

事件类型	股权质押	股权质押	股权质押	股权质押	股权质押
质押方	吴建明	吴建明	吴建明	吴建明	吴建明
质押股份	1600000股	1600000股	1600000股	1600000股	1600000股
质权方	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司	南京证券股份有限公司
总持有股份	16679436股	16679436股	16679436股	39197988股	16679436股
总持有比例	7.69%	7.69%	7.69%	7.69%	7.69%
总质押股份	4795000股	4795000股	4795000股	4795000股	NULL
开始时间	2018年9月20日	2018年9月20日	NULL	2018年9月25日	NULL
结束时间	NULL	NULL	NULL	NULL	NULL
解除时间	NULL	NULL	NULL	NULL	NULL
	真实标签	IESLHI	标签解释	-关联差异性	-语义扩展

图 3: 多事件文档示例，橙色标注表示实体，绿色框线标注表示论元

对于移除标签解释或语义扩展模块后，存在对文档的理解偏差，导致论元抽取的缺失或误判，如将事件1中的开始时间“2018年9月25日”预测为“2018年9月20日”。而移除关联差异性模块

后，实体较多引入的冗余信息，导致论元抽取错误，如将事件2中的总持有股份“16679436股”预测为“39197988股”。

#### 4.4.4 关联差异性影响分析

为了评估关联差异性对模型性能的影响，本文选择与事件类型相关的句子个数 $K$ 分别为3、6、8、10时在ChFinAnn数据集进行实验，实验结果见表6。

	P	R	F1
$K = 3$	89.2	51.2	65.1
$K = 6$	88.1	73.7	80.2
$K = 8$	86.3	75.9	80.7
$K = 10$	85.8	74.7	79.9

表 6: 不同 $K$ 值时IESLHI在ChFinAnn数据集上的比较

根据研究(Xu et al., 2021)，该数据集的每个文档平均由20个句子，912个token组成，一个事件记录大约涉及6个句子。由表6可以观察到：选择与事件类型关联性较强的句子个数 $K$ 为8时，几乎可以包含文档中完整的事件记录所在的句子，避免了候选实体的缺失以及过多命名实体带来的信息冗余，因此，模型整体表现优异，P、R、F1值的表现较为稳定。

## 5 结论

本文针对文档级事件抽取任务中的论元分散和多事件提及问题，提出了融合扩展语义与标签层次信息的文档级事件抽取模型。该模型基于大语言模型对文档信息和标签信息进行语义扩展，利用关联差异性的判断选出了文档中与事件类型相关性较高的句子，针对每个事件类型，基于有向无环图从候选实体中抽取论元。在ChFinAnn和DuEE-Fin数据集上的实验表明，相比基线对比模型，所提模型在F1指标上分别提升了0.4%和0.3%，验证了通过关联差异性的判断可以选取与事件类型相关性较高的句子中的实体作为候选实体，有效地缓解论元分散；对每个事件类型分别进行路径扩展可以提升多事件提及的性能。下一步，我们将考虑基于异质图融入实体与句子的关系以捕获句子之间的长距离依赖关系，并进一步整合这些信息。

## 参考文献

- Fumin Chen, Xu Wang, Xiaohui Liu, and Dezhong Peng. 2023. A trigger-free method enhanced by coreference information for document-level event extraction. In *Proceeding of the 2023 International Joint Conference on Neural Networks*, pages 1–8.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 4171–4186.
- Li Du, Xiao Ding, Yue Zhang, Ting Liu, and Bing Qin. 2022. A graph enhanced BERT model for event prediction. In *Findings of the Association for Computational Linguistics: ACL 2022*, pages 2628–2638.
- Guanhua Huang, Runxin Xu, Ying Zeng, Jiaze Chen, Zhouwang Yang, and Weinan E. 2023. An iteratively parallel generation method with the pre-filling strategy for document-level event extraction. In *Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing*, pages 10834–10852.
- Sha Li, Heng Ji, and Jiawei Han. 2021. Document-level event argument extraction by conditional generation. In *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 894–908.
- Qian Li, Jianxin Li, Jiawei Sheng, Shiyao Cui, Jia Wu, Yiming Hei, Hao Peng, Shu Guo, Lihong Wang, Amin Beheshti, and Philip S. Yu. 2022. A survey on deep learning event extraction: Approaches and applications. *IEEE Transactions on Neural Networks and Learning Systems*, 35(5):1–21.

- Yuan Liang, Zhuoxuan Jiang, Di Yin, and Bo Ren. 2022. RAAT: Relation-augmented attention transformer for relation modeling in document-level event extraction. In *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 4985–4997.
- Jian Liu, Chen Liang, Jinan Xu, Haoyan Liu, and Zhe Zhao. 2023a. Document-level event argument extraction with a chain reasoning paradigm. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, pages 9570–9583.
- Wanlong Liu, Shaohuan Cheng, Dingyi Zeng, and Qu Hong. 2023b. Enhancing document-level event argument extraction with contextual clues and role relevance. In *Findings of the Association for Computational Linguistics: ACL 2023*, pages 12908–12922.
- Yaojie Lu, Hongyu Lin, Jin Xu, Xianpei Han, Jialong Tang, Annan Li, Le Sun, Meng Liao, and Shaoyi Chen. 2021. Text2Event: Controllable sequence-to-structure generation for end-to-end event extraction. In *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*, pages 2795–2806.
- Yubo Ma, Zehao Wang, Yixin Cao, Mukai Li, Meiqi Chen, Kun Wang, and Jing Shao. 2022. Prompt for extraction? PAIE: Prompting argument interaction for event argument extraction. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*, pages 6759–6774.
- Amir Pouran Ben Veyseh, Minh Van Nguyen, Franck Dernoncourt, Bonan Min, and Thien Nguyen. 2022. Document-level event argument extraction via optimal transport. In *Findings of the Association for Computational Linguistics: ACL 2022*, pages 1648–1658.
- Yubing Ren, Yanan Cao, Ping Guo, Fang Fang, Wei Ma, and Zheng Lin. 2023. Retrieve-and-sample: Document-level event argument extraction via hybrid retrieval augmentation. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, pages 293–306.
- Jiawei Sheng, Shu Guo, Bowen Yu, Qian Li, Yiming Hei, Lihong Wang, Tingwen Liu, and Hongbo Xu. 2021. CasEE: A joint learning framework with cascade decoding for overlapping event extraction. In *Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021*, pages 164–174.
- Qizhi Wan, Changxuan Wan, Keli Xiao, Dexi Liu, Chenliang Li, Bolong Zheng, Xiping Liu, and Rong Hu. 2023. Joint document-level event extraction via token-token bidirectional event completed graph. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, pages 10481–10492.
- Xinyu Wang, Lin Gui, and Yulan He. 2023. Document-level multi-event extraction with event proxy nodes and hausdorff distance minimization. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, pages 10118–10133.
- Runxin Xu, Tianyu Liu, Lei Li, and Baobao Chang. 2021. Document-level event extraction via heterogeneous graph-based interaction model with a tracker. In *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*, pages 3533–3546.
- Runxin Xu, Peiyi Wang, Tianyu Liu, Shuang Zeng, Baobao Chang, and Zhifang Sui. 2022. A two-stream AMR-enhanced model for document-level event argument extraction. In *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 5025–5036.
- Hang Yang, Yubo Chen, Kang Liu, Yang Xiao, and Jun Zhao. 2018. DCFEE: A document-level Chinese financial event extraction system based on automatically labeled training data. In *Proceedings of ACL 2018, System Demonstrations*, pages 50–55.
- Hang Yang, Dianbo Sui, Yubo Chen, Kang Liu, Jun Zhao, and Taifeng Wang. 2021. Document-level event extraction via parallel prediction networks. In *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*, pages 6298–6308.
- Hang Yang, Yubo Chen, Kang Liu, Jun Zhao, Zuyu Zhao, and Weijian Sun. 2022. Multi-turn and multi-granularity reader for document-level event extraction. *Association for Computing Machinery*, 22(2):1–16.



- Shun Zheng, Wei Cao, Wei Xu, and Jiang Bian. 2019. Doc2EDAG: An end-to-end document-level framework for Chinese financial event extraction. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, pages 337–346.
- Tong Zhu, Xiaoye Qu, Wenliang Chen, Zhefeng Wang, Baoxing Huai, Nicholas Yuan, and Min Zhang. 2022. Efficient document-level event extraction via pseudo-trigger-aware pruned complete graph. In *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence, IJCAI-22*, pages 4552–4558.
- Jinan Zou, Yanxi Liu, Yuankai Qi, Haiyao Cao, Lingqiao Liu, and Javen Qinfeng Shi. 2023. A generative approach for comprehensive financial event extraction at the document level. In *Proceedings of the Fourth ACM International Conference on AI in Finance*, page 323–330.
- 李治. 2022. 基于实时事件侦测的兴趣点推荐系统研究. *数据分析与知识发现*, page 114.