

基于框架语义映射和类型感知的篇章事件抽取*

卢江¹, 李茹^{1,2,*†}, 苏雪峰^{1,3}, 闫智超¹, 陈加兴¹

¹山西大学 计算机与信息技术学院, 山西 太原 030006

²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 太原 030006

³山西工程科技职业大学 现代物流学院, 山西 晋中 030609

{lujiangsxu, suexf, 15735104675, 18536201921}@163.com

{liru}@sxu.edu.cn

摘要

篇章事件抽取是从给定的文本中识别其事件类型和事件论元。目前篇章事件普遍存在数据稀疏和多值论元耦合的问题。基于此, 本文将汉语框架网 (CFN) 与中文篇章事件建立映射, 同时引入滑窗机制和触发词释义改善了事件检测的数据稀疏问题; 使用基于类型感知标签的多事件分离策略缓解了论元耦合问题。为了提升模型的鲁棒性, 进一步引入对抗训练。本文提出的方法在DuEE-Fin和CCKS2021数据集上实验结果显著优于现有方法。

关键词: 汉语框架网; 框架语义映射; 类型感知; 事件抽取

Document-Level Event Extraction Based on Frame Semantic Mapping and Type Awareness

Jiang Lu¹, Ru Li^{1,2,*†}, Xuefeng Su^{1,3}, Zhichao Yan¹, Jiaxing Chen¹

¹School of Computer and Information Technology, Shanxi University, Taiyuan, Shanxi 030006, China

²Key Laboratory of Computational Intelligence and Chinese Information Processing of Ministry of Education, Shanxi University, Taiyuan, Shanxi 030006, China

³School of Modern Logistics, Shanxi Vocational University of Engineering Science and Technology, Jinzhong, Shanxi 030609, China

{lujiangsxu, suexf, 15735104675, 18536201921}@163.com

{liru}@sxu.edu.cn

Abstract

Document-Level event extraction is the identification of its event type and event arguments from a given text. At present, the problems of sparse data and multi-event argument coupling are most in Document-Level events. Based on this, We map Chinese FrameNet with Chinese text events, and the sliding window mechanism and trigger word Paraphrase are introduced to improve the data sparseness problem of event detection. The use of a multi-event separation strategy based on type-aware labels alleviates the problem of meta-coupling. In order to improve the robustness of the model, adversarial training is further introduced. The experimental results of our approach on the DuEE-Fin and CCKS2021 datasets are significantly better than the existing methods.

Keywords: Chinese FrameNet, Frame Semantic Mapping, Type Awareness, Event Extraction

1 引言

©2022 中国计算语言学大会

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

***基金项目:**山西省重点研发计划项目(NO.202102020101008);国家自然科学基金重点项目(NO.61936012) This work was supported by the Key Research and Development Project of Shanxi Pcovince (NO.202102020101008) and Key Natural Science Foundation of China (NO.61936012)

† 通讯作者Corresponding Author

事件抽取旨在从非结构化的文本中抽取结构化的事件信息，包含事件检测 (Li et al., 2020; Liao et al., 2021; Lin et al., 2019; Cao et al., 2021)和论元识别 (Aly et al., 2019; Chalkidis et al., 2019; Chang et al., 2020)两部分。根据事件抽取的粒度不同，可分为：句子级事件抽取 (Sentence-level Event Extraction, SEE) 和篇章级事件抽取 (Document-level Event Extraction, DEE)。DEE任务难点主要在于文本的复杂和事件结构的复杂。文本的复杂体现在输入文本为篇章，这使得输入文本受限的模型需要在考虑篇章全局信息的情况下进行数据分割；事件结构复杂性体现在篇章中包含多事件，不同事件之间互有重叠，较单一事件抽取难度更大。

篇章事件抽取是从给定的篇章中完成对事件类型的识别以及论元实体的抽取。如图1所示，该篇章由多个句子组成，包含“质押”和“解除质押”两个事件，根据预先定义的事件类型和论元角色，完成事件论元表中的触发词以及论元实体的抽取。



图 1: 篇章事件抽取示例

分析主流的篇章事件抽取数据集发现，DEE任务面临的挑战主要体现在两个方面：1) 篇章数据稀疏。现有数据集人工标注难度较大，导致篇章中各事件类型呈现长尾分布2) 篇章包含多事件。同一论元分布在不同事件中，存在多值论元耦合现象，也即论元重叠。因此本文探索引入汉语框架网 (Chinese FrameNet, CFN) (Li et al., 2013)与事件建立一定的映射关系以改善数据稀疏问题；融合事件类型标签和篇章全局信息以缓解篇章多值论元耦合问题。

CFN是由山西大学以Fillmore的框架语义学为理论基础、同时参照FrameNet开发的汉语框架语义知识库。CFN包括框架库、词元库和例句库。现有1313个框架，21123个词元，94353条例句，这些句子是CCL (Center for Chinese Linguistics PKU) 和BCC (BLCU Corpus Center) 的真实语料 (Zhao et al., 2016)。

针对DEE中数据稀疏的问题。以往大多通过引入字典例句或百度百科等语料的方式进行简单的数据扩充，并没有针对性地考虑数据本身包含的事件和论元信息，而CFN中的例句来自真实语料，符合现实语义场景。CFN中定义的框架与中文事件抽取中的事件具有天然相似的结构：1) 事件由事件触发词和一组论元组成。类似地，CFN中的框架由激活该框架的词元和一组框架元素构成。它们分别扮演着类似事件中的触发词和论元这一角色。2) 中文篇章事

件通常包含多个触发词对应的多个事件，CFN中的“事件”也包含多个词元对应多个框架。此外，CFN中许多框架表达了某些具体类型的事件，表1中CFN框架与事件存在对应关系，分别为：[（‘出售’->‘质押’），（‘盈亏’->‘亏损’），（‘倒闭’->‘破产’）]，同时CFN中的例句与篇章子句也有着相似的描述，表1中的相关事件句即为框架语义映射下的CFN例句。这促使我们探索是否存在CFN中的框架到事件的某种映射，以及是否可以通过使用CFN来改进事件检测。因此，本文在事件检测阶段根据事件和CFN相似的结构这一特点，建立两级框架语义映射[一级：‘框架’->‘事件’；二级：‘词元’->‘触发词’]，同时通过对既有知识CFN框架-词元的引入，将CFN中与事件映射后的例句作为外部数据以此增强事件检测任务的性能。

框架-词元	事件-触发词	CFN中相关例句
出售-出让	质押-质押	作为交换条件，一是史玉柱出让80%的股份； 二是收购方出资5000~6000万元
盈亏-赔	亏损-损失	会计师事务所即使被处罚，也不过承担有限责任， 只要将公司注册时的资本赔完就行了
倒闭-关闭	企业破产-倒闭	企业亏损或不能维持下去而关闭，全体职工利益都要受到影响

表 1: CFN与中文事件的映射

针对DEE论元识别阶段多值论元耦合的问题，目前大多数模型采用联合抽取方法以便于更好地捕获事件检测和论元之间的交互，但却无法针对性的解决篇章中论元耦合现象。本文兼顾事件类型与论元的交互，在论元识别阶段把事件类型作为类别标签与篇章文本拼接共同作为输入特征，从而将篇章多事件转化为多个单事件，同时整合篇章全局信息增强模型建模表示。

本文的贡献主要有以下几点：1)将CFN与中文篇章事件抽取任务相结合，探索框架和事件之间的联系。2)在事件检测阶段，通过引入CFN这一外部知识，构造CFN框架与事件的两级映射，将映射后的CFN相关事件句作为外部数据改善数据稀疏问题。3)在论元识别阶段，通过融合事件类型标签以及整合全局上下文信息，将篇章多事件转化为多个单事件，在一定程度上缓解了多值论元耦合问题。

2 相关工作

现阶段根据抽取方式的不同，DEE任务分为管道式抽取（Pipeline extraction）（Chen et al., 2015）和联合（Joint extraction）抽取（Cui et al., 2020）。Pipeline抽取将触发词作为事件的核心，（Yang et al., 2019; Liu et al., 2016）把事件检测和论元识别视作独立的多阶段分类任务。（Chen et al., 2015）提出基于深度学习的事件抽取模型DMCNN，该模型使用两个动态多池卷积神经网络进行触发词分类和论元分类。（Liu et al., 2016）针对英文事件抽取数据稀疏问题，第一次将FrameNet应用于事件检测任务取得了明显效果。以上方法通过引入预训练模型，在一定程度上丰富了文本语义，但针对中文篇章事件抽取任务，并未考虑引入外部知识，将事件检测和论元识别任务孤立地完成，缺少信息间的交互。联合抽取使用深度学习和联合学习进行特征交互。（Yang et al., 2018）针对篇章事件数据人工标注复杂度高、难度大的问题，提出了一个事件自动抽取框架DCFEE。（Zheng et al., 2019）针对篇章事件抽取中论元分散问题提出了Doc2EDAG模型，将篇章级的事件表填充任务转化为基于实体的有向无环图的路径扩展任务。（Xu et al., 2021）分别基于篇章级和多粒度的解码，提出了Git模型。大多数联合抽取采用图构建（Yao et al., 2019）的方式捕获事件类型与论元之间的交互，避免了错误传播，但是针对篇章事件中多值论元耦合的问题并不能有效的解决。

事实上，事件检测和论元识别两阶段的上下文表示本质上捕获了不同的信息，然而联合抽取方式共享两者的模型结构和参数，会影响事件抽取整体性能。通过将CFN外部数据用于事件检测任务，可针对性的提升其实验效果，事件检测性能的提升也有助于论元识别的准确率，因此本文采用Pipeline抽取，相比于大多数Pipeline模型，更加注重事件类型与论元的交互。在事件检测阶段，引入框架语义映射，将CFN相关事件句作为外部数据在一定程度上改善了事件稀疏问题；在论元识别阶段，提出了基于类型感知的多事件分离策略，在一定程度上缓解了多值论元耦合问题。

3 篇章事件抽取模型

3.1 任务定义

篇章事件抽取任务可形式化地描述为：从给定的篇章中识别事件（事件检测任务）和事件中的论元（论元识别任务）。本文采用滑动窗口的方法将长篇章分割为多个片段，每个片段 $s = \{c_1, c_2, c_3, \dots, c_i\}$ (c_i 表示片段中第*i*个字符) 包含多个事件 e ($e \in E$, E 表示事件类型总数)，每个事件由一个触发词 t 和一组论元 $\{a_1, a_2, \dots, a_j\}$ 组成， a_j 表示该事件中的第*j*个论元。

3.2 模型结构

针对篇章事件中存在的数据稀疏和多值论元耦合问题。本文从事件检测和论元识别两个方面解决事件抽取上述难点，模型如图2所示，主要包含以下4个模块。1) 文本输入：事件检测阶段，将CFN映射后的事件句、触发词汉语释义信息以及滑窗切分的文本共同作为输入；论元识别阶段，将滑窗切分的文本作为输入。2) 事件检测：对CFN事件句、片段文本、触发词释义进行编码，并根据事件中触发词对事件类型识别。3) 论元识别：对输入的片段文本进行编码，并根据已知的事件类型对相应事件中的论元进行识别。4) 文本输出：事件检测阶段输出事件类型，论元识别阶段输出各事件论元，将事件类型与论元进行组合形成完整的事件。

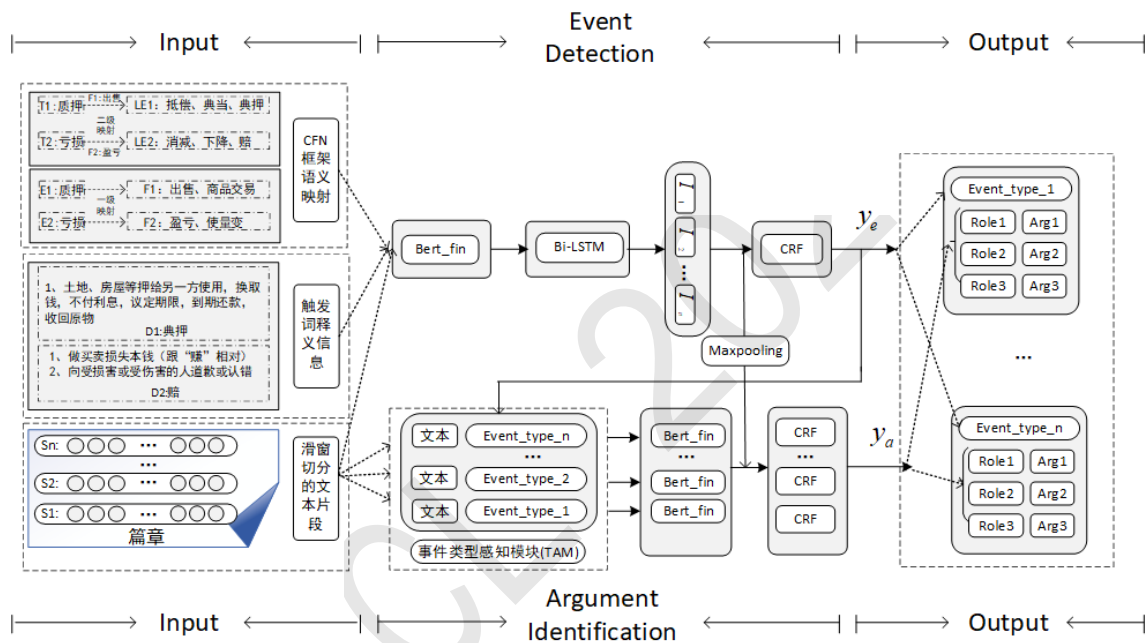


图 2: 篇章事件抽取模型总体图

3.3 事件检测

3.3.1 CFN与中文事件的映射

由于CFN中框架与事件结构高度相似，同时CFN中框架与词元有着天然的关联关系，因此本文在引入CFN这一外部知识时需遵循以下两点原则：

- 1) 框架中的词元与中文事件中的触发词匹配一致时，倾向于表达相同类型的事件。
- 2) 隶属于同一框架下的句子倾向于表达相同类型的事件。

基于以上两点原则，本文制定了框架与事件的两级映射，具体映射形式如下：

- 1) 框架与事件的一级映射。如图3，CFN中的“出售”框架与“质押”事件表达的意义相近。
- 2) 框架中的词元与事件触发词的二级映射。如图3，“出售”框架中的‘典押、典当、抵偿’词元对应于“质押”事件中的‘质押、出质、延期’触发词。

基于以上规则，CFN中的框架与事件形成二级映射，而后通过树查询的方式进行（框架-词元）与（事件-触发词）的相似度计算，取相似度前10的词元作为与触发词匹配的目标词元，并将中该词元下的事件句作为外部数据用以缓解数据稀疏问题，提升事件检测任务的性能。

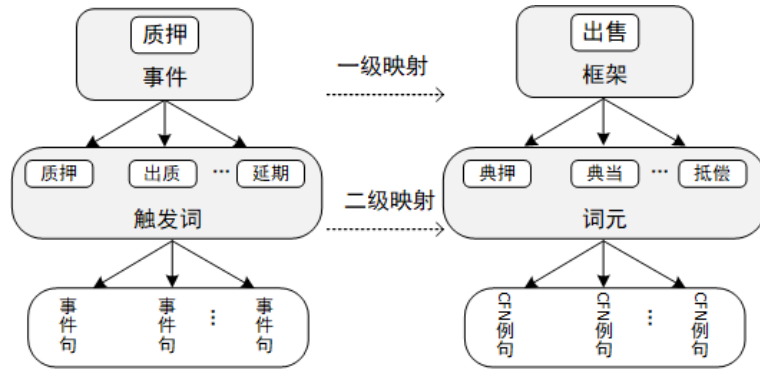


图 3: CFN框架在事件下的两级映射

3.3.2 序列建模层

为了充分感知上下文信息，本文采用滑窗机制将文本按字符分成多片段，每个片段 $s = \{c_1, c_2, c_3, \dots, c_i\}$ 作为事件检测任务的一次输入。同时为了增强触发词对事件类型的语义理解，将其汉语释义信息 $t = \{t_1, t_2, \dots, t_j\}$ (t_j 表示触发词释义的第 j 个字符) 拼接到触发词之后，共同作为文本的输入。编码层采用BERT对文本编码，如公式1、2所示。

$$input = [CLS] + s + [SEP] + t + [SEP] \quad (1)$$

$$s' = BertEncoder(input) \quad (2)$$

其中， $s' = \{c_1, c_2, \dots, c_{len}\}$ ， $s' \in R^{len \times d}$ ， len 表示文本片段与释义信息的总长度， d 为隐层维度。为了进一步增强篇章中的长实体信息的表示，在预训练模型之后加入 bi_lstm 进一步增强其语义表示，将前向 \vec{h} 和后向 \overleftarrow{h} 隐层向量拼接作为下一层的输入 I ，如公式3、4所示。

$$h = bi_lstm(s') \quad (3)$$

$$I = concat([\vec{h}, \overleftarrow{h}]) \quad (4)$$

在解码阶段，使用CRF输出其最优得分序列，对于已知的输入序列 $s' = (c_1, c_2, \dots, c_n)$ 对应的输出标签结果为 $y_e = (y_1, y_2, \dots, y_n)$ ，定义当前序列得分如公式5所示，其中， I_{i, y_i} 表示第 i 个位置 $soft \max$ 输出的概率。每个位置得分由隐层输出向量 I 和CRF转移矩阵 A 共同组成，最后利用 $soft \max$ 计算归一化后的概率，采用最大对数似然函数优化目标函数，如公式6、7所示。

$$score(x, y_e) = \sum_{i=1}^n I_{i, y_i} + \sum_{i=1}^{n+1} A_{y_{i-1}, y_i} \quad (5)$$

$$P(y_e|x) = \frac{\exp(score(x, y_e))}{\sum_{y'_e} \exp(score(x, y'_e))} \quad (6)$$

$$\log P(y_e|x) = score(x, y_e) - \ln(\sum_{y'_e} \exp(score(x, y'_e))) \quad (7)$$

3.4 论元识别

3.4.1 多值论元耦合

论元识别难点在于多事件混淆，从而导致不同事件之间论元耦合。如图4所示，篇章中包含三个事件，分别是：事件1：‘高管变动’；事件2：‘回购’；事件3：‘高管变动’。事件1和事件3触发词‘离职’相同，但是论元不尽相同，事件2中的论元“宁波美诺华药业股份”同时属于事件1和事件3的论元。因此由于篇章多事件，导致同一论元出现在不同事件中。




图 4: 多值论元耦合

3.4.2 多类型感知层

针对多值论元耦合这一难点，本阶段设置了一个类型感知模块，其核心在于将事件检测阶段感知的每个事件类别标签 $e = \{e_1, e_2, \dots, e_j\}$ (e_j 表示当前事件类型的第 j 个字符) 分别与原始文本片段 $s = \{c_1, c_2, c_3, \dots, c_i\}$ 拼接共同作为模型输入，依据不同的类型标签对文本中多事件进行分离，从而将多事件论元识别转化为多个单事件论元识别，编码层输入如公式8、9所示：

$$input = [CLS] + s + [SEP] + e + [SEP] \quad (8)$$

$$s' = BertEncoder(input) \quad (9)$$

其中， $s' = \{c_1, c_2, \dots, c_{len}\}$, $s' \in R^{len \times d}$, len 表示文本片段与类型标签的总长度， d 为隐层维度。为了进一步增强事件检测与论元识别的交互，将事件检测中篇章全局信息经过 $max\ pooling$ 得到表示 \hat{I} ，之后与文本片段的编码 s' 进行融合，进一步增强文本信息表示。如公式10、11所示， I_n 表示滑窗切分后的第 n 个片段的编码， s'' 表示融合篇章全局信息的隐层表示。

$$\hat{I} = \max\ pooling\{I_1, I_2, \dots, I_n\} \quad (10)$$

$$s'' = \hat{I} \oplus s' \quad (11)$$

3.4.3 多标签解码层

本阶段将类型标签分离后的单事件经过各自的CRF解码层，由原先对多事件论元角色分类任务转化为多个单事件论元角色分类任务。CRF解码与事件检测阶段一致，如公式12、13所示， $y_{a_i}^*$ 表示第 i 个事件经过CRF解码之后的标签序列， y_a^* 表示所有事件论元标签序列的集合。

$$y_{a_i}^* = CRF(s'') \quad (12)$$

$$y_a^* = \{y_{a_1}^*, y_{a_2}^*, \dots, y_{a_n}^*\} \quad (13)$$

为解决正负样本不均衡现象，采用 $Focalloss$ 损失函数，如公式14所示， P 表示当前序列得分经过 $softmax$ 后的归一化概率值， α 为正负样本比例平衡因子， γ 为样本难度平衡因子。

$$L_{fl} = \begin{cases} -\alpha(1-p)^\gamma \log p, p^* = 1 \\ -(1-\alpha)p^\gamma \log(1-p), p^* = 0 \end{cases} \quad (14)$$

3.5 文本输出

由于本文将事件检测预测的事件类型作为类别标签融入论元识别文本输入中，因此本阶段只需将事件检测预测全部事件类型与论元识别预测的所有论元标签进行拼接。公式如下所示， y_e^* 表示事件检测模型的预测标签， y_e 表示事件检测模型的真实标签。 y_a^* 表示论元识别模型的预测标签， y_a 表示论元识别模型的真实标签。

$$y_e^* = \arg \max_{y_e} f(y_e | d, t) \quad (15)$$

$$y_a^* = \arg \max_{y_a} f(y_a | d, e, r) \quad (16)$$

$$y^* = y_e^* \oplus y_a^* \quad (17)$$

3.6 对抗训练

为增强模型的鲁棒性，在论元识别训练阶段加入对抗训练 (Aleksander et al., 2018) (adversarial training) 对编码层的Embedding参数矩阵混合一些微小扰动，让模型自适应这种改变，公式如下， D 代表训练数据， x 表示数据输入序列， y 表示样本的预测标签， θ 表示模型参数， Δx 表示在训练样本中增加的扰动， $L(x, y; \theta)$ 表示样本的loss， $\nabla_x L(x, y; \theta)$ 表示loss对 x 的梯度， ζ 表示常量， Ω 是扰动空间。 $L(x + \Delta x, y; \theta)$ 表示在训练数据 x 上增加扰动 Δx ，内层公式在于寻找损失函数最大的扰动，外层公式是最优化求解的最小化公式。

$$\min_{\theta} E_{(x,y) \sim D} [\max_{\Delta x \in \Omega} L(x + \Delta x, y; \theta)] \quad (18)$$

$$\Delta x = \zeta \text{sign}(\nabla_x L(x, y; \theta)) \quad (19)$$

4 实验

4.1 数据集

4.1.1 数据集介绍

本文使用DuEE-fin以及CCKS2021篇章事件抽取数据集进行实验。1) DuEE-fin数据集 (Liu et al., 2020)。百度最新发布的首个包含触发词信息的金融篇章事件抽取数据集，包含13种事件类型和92种论元角色，共1.17万个篇章；2) CCKS2021篇章事件抽取数据集。包含13种论元角色的5000个篇章。DuEE-fin和CCKS-2021训练集、验证集、测试集统计如表2所示。

数据集	训练集	验证集	测试集
DuEE-fin	7047	1174	60000
CCKS-2021	4000	500	500

表 2: 数据集分布

4.1.2 数据稀疏分析

DuEE-fin数据集未公开测试集真实标签。因此本文对训练集和测试集中8221篇金融篇章进行分析，从图5、图6中可以看出，Duce-Fin数据集存在数据稀疏问题，13种不同的事件类型文本呈现长尾分布，以训练集为例，‘股份回购’事件占比13.8%，‘被约谈’事件仅占比1.8%，因此各事件类型分布稀疏且极不均匀。




图 5: DuEE-fin训练集各事件类型分布




图 6: DuEE-fin验证集各事件类型分布

4.2 参数设置及评价指标

本文使用金融领域预训练模型FinBERT。由于文本篇幅较长，采用滑窗机制分片段输入。为了综合考虑模型的训练效率，滑窗大小为400，步长为200，与 (Liu et al., 2021) 实验保持一致，实验参数如下，epoch为50，learning_rate为5e-5，使用实验的环境为32G显存的Tesla V100，采用Adam优化器对模型进行优化。实验采用准确率(Accuracy)、召回率(Recall)、F1值评价指标衡量模型性能。

4.3 实验结果

4.3.1 事件检测对比实验

为了验证本文提出方法的有效性，在DuEE-fin公开数据集上将本文的方法与以下五种方法进行了对比。模型具体如下：（1）BERT (Devlin et al., 2019)；（2）BERT-wwm (Y.Cui et al., 2018)；（3）Ernie (Yu et al., 2019)；（4）FinBERT (Liu et al., 2020)；（5）BERT-BiLSTM-CRF：主流事件抽取模型。由于官方未给出测试集的真实标签，只允许在线提交事件抽取最终结果，因此本文事件检测在1174条验证集篇章上进行实验。

Model	Dev
BERT	90.15
BERT-wwm	90.19
Ernie(baseline)	89.94
FinBERT	90.42
BERT-BiLSTM-CRF	91.32
Ours	93.83

表 3: 事件检测在DuEE-fin上实验结果

事件类型	触发词/CFN词元/CFN例句	Ernie(baseline)	Ours	Δ
公司上市	15/14/383	87.50	93.43	+5.93
股东减持	7/18/183	90.35	91.86	+1.15
股东增持	6/12/229	86.42	88.50	+2.08
企业收购	16/35/675	91.26	94.83	+3.57
企业融资	18/2/25	87.15	88.95	+1.80
股份回购	6/4/38	94.62	96.24	+1.62
质押	6/4/58	93.04	94.66	+1.62
解除质押	15/4/58	89.42	89.52	+0.10
企业破产	3/25/269	84.60	89.46	+4.86
亏损	11/13/165	93.21	94.32	+1.11
被约谈	3/48/950	83.65	93.85	+10.20
中标	5/2/8	91.84	93.25	+1.41
高管变动	74/29/1003	89.52	96.20	+6.68
overall	185/206/3986	89.94	93.83	+3.89

表 4: DuEE-fin上各事件类型实验结果

从表3中可以看出，在验证集上较基线提高了3.89%，较当前主流模型提高了2.51%，从表4中可以看出，13种事件类型的触发词共计185个，经过CFN与DuEE-fin事件映射后引入CFN词元206个，词元下的CFN例句3986条，证明了事件与框架存在较强的相关性；各事件类型识别效果均有一定的提升，其中“被约谈”事件提升了10.2%，证明了通过框架语义映射引入CFN这一外部知识对事件检测任务性能提升有积极作用。

4.3.2 论元识别对比实验

为了验证本文提出方法的有效性，在DuEE-fin公开数据集上将本文的方法与以下8种方法进行了对比。模型具体如下：（1）BERT (Devlin et al., 2019)；（2）Ernie (Yu et al., 2019)；（3）BERT-BiLSTM-CRF，主流事件抽取模型；（4）DCFEE (Yang et al., 2018)，一种篇章级中文金融事件抽取模型；（5）Doc2EDAG (Zheng et al., 2019)，一种端到端的基于有向无环图的预训练模型；（6）Greedy-Dec，Doc2EDAG模型提出的基线；（7）GIT (Xu et al., 2021)，一种基于transformer结构的篇章级和多粒度的事件抽取模型；（8）PTPCG (Tong et al., 2021)，采用非自回归解码算法进行图剪枝的快速轻量级模型。由于未给出测试集的真实

标签，因此本文通过在线提交预测文件得到测试集上的实验结果。在论元识别阶段，本文的模型与以下9种模型进行对比，分别对应3种Pipeline抽取模型和6种当前最新的联合抽取模型。

	Model	Dev	Online Test
pipeline抽取	BERT	55.64	44.93
	Erine(baseline)	55.13	45.60
	BERT-BiLSTM-CRF	65.46	54.20
联合抽取	DCFEE-O	44.52	41.33
	DCFEE-M	37.63	36.12
	Greedy-Dec	47.35	40.71
	Doc2EDAG	66.10	58.13
	Git	67.71	55.62
	PTPCG	66.42	60.15
	Ours	69.82	64.50

表 5: 论元识别在DuEE-fin上实验结果

从表5的数据中可以看出，在Ducee-fin验证集和在线测试集上实验效果与其他Pipeline模型相比F1值分别提升了4.36%和10.3%，与当前最新的联合模型相比F1值分别提升了2.11%和4.35%，验证了本文实验方法的有效性。证明了基于事件检测的类型感知策略和融合篇章全局信息对解决多值论元耦合有明显效果。

4.4 消融实验

为了验证不同模块的有效性，本文分别对CFN框架映射模块、类型感知模块（Type Aware Module）以及对抗训练（FGM）消融去掉，来检测模型性能的变化，具体结果如表6所示。

Model	Online Test	Model	CCKS-2021 Test
Ours	64.50	BERT	60.58
-CFN	62.35	ERNIE	60.63
-TAM	63.26	Doc2EDAG	68.35
-FGM	63.72	Git	68.74
-ALL	60.33	Ours	70.25

表 6: 消融实验的结果

表 7: 模型在CCKS-2021数据集实验结果

表6的数据可以看出：

(1) CFN框架映射模块、类型感知模块以及对抗训练对事件抽取任务均有明显效果提升。其中，CFN框架映射模块消融去掉后，模型性能下降较大，我们认为：1) CFN有助于提升事件检测子任务性能；2) 事件检测性能的提升有助于增强后续论元识别子任务的准确率。这充分说明了CFN框架语义映射对模型效果有积极作用。

(2) 相比于模型-CFN，模型-TAM性能下降较大，但也取得有效的提升，这说明类型感知的多事件分离方法对于解决篇章多值论元耦合也有一定的效果。

(3) 模型-FGM性能有所下降，这说明对抗训练之后，增强了模型的鲁棒性。

4.5 模型泛化能力实验

为了验证本文方法的泛化性，选取了CCKS-2021面向金融领域篇章要素抽取评测数据集进行实验。由于CCKS评测任务主办方未公开测试集，本文只能在训练集与验证集上进行测试。本文将原始验证集按照1:1的比例进行随机等比例切分，形成新的验证集与测试集，数据划分比例见表2所示，并选取了目前主流的事件抽取模型进行对比实验，实验结果如表7所示，可以看出：本文方法相比于基线提升了9.62%。这充分说明了本文提出的模型在篇章事件抽取任务中有较好的泛化能力。

4.6 案例分析

为了验证本文方法的有效性，进一步对论元识别模型的预测数据进行了分析，具体细节如图7所示。文本中包含同一事件类型“高管变动”的两个事件。左侧是本文模型的预测结果。

右侧是ERNIE基线预测结果。可以看到“高管变动”这一事件类型对应‘杜秋龙’和‘陈体引’两个事件，这两个事件类型下的‘任职公司’、‘变动类型’论元角色分别对应‘卧龙地产集团股份有限公司’和‘辞职’两个论元发生了论元耦合。本文模型通过类型感知标签将两个事件分别进行论元识别，避免了两个事件之间相同论元重叠的问题。而基线模型由于没有对多事件进行区分，因此将两个事件预测为一个事件，这大大降低其论元识别的准确率。因此本文模型经过类型感知的事件分离方法可以较好的区分同一论元在不同事件中的耦合问题。

篇章

[S1]卧龙地产集团股份有限公司（以下简称“公司”）近期收到公司董事杜秋龙先生、监事陈体引先生提交的书面辞职报告

[S2]杜秋龙先生因个人原因，申请辞去公司董事、董事会提名委员会委员及副总经理的职务；陈体引先生因年龄原因，申请辞去公司监事会主席的职务

事件类型	变动类型	高管姓名	高管职位	高管职位	任职公司
高管变动	辞职	杜秋龙	公司董事	董事会提名委员会及副总经理	卧龙地产集团股份有限公司
事件类型	变动类型	高管姓名	高管职位	高管职位	任职公司
高管变动	辞职	陈体引	监事	公司监事会主席	卧龙地产集团股份有限公司

本文模型预测事件结果

事件类型	变动类型	高管姓名	高管姓名	高管职位	高管职位	任职公司
高管变动	辞职	杜秋龙	陈体引	公司董事 会主席	董事会提名 委员会及副 总经理	卧龙地 产集团 股份 有限 公司

ERNIE 模型预测事件结果

图 7: 不同事件之间论元耦合案例分析对比

5 结论

本文围绕篇章事件数据稀疏和事件多值论元耦合的问题展开研究。提出了基于框架语义映射和类型感知的篇章事件抽取模型。该模型在事件检测阶段，通过引入CFN框架语义并制定了三类映射约束，建立了框架与事件的两级映射，将CFN相关事件句作为外部数据，改善了数据稀疏问题。在论元识别阶段，通过设计类型感知模块将多事件分离成单事件进行论元识别，缓解了多值论元耦合问题，为了增强事件检测与论元抽取的交互，将事件检测的全局向量信息与论元识别隐层向量融合，进一步丰富了模型的语义表示。在提升篇章多事件抽取性能的同时，对大量实验结果分析发现，不同的窗口大小和步长对实验也有一些影响，后续可以对滑动窗口参数做进一步分析，此外篇章中仍存在很多跨句论元分散的问题，如何设计跨句论元抽取框架是后续的研究重点。

参考文献

- Li, Zhihui and Chang, Xiaojun and Yao, Lina and Pan, Shirui and Zongyuan, Ge and Zhang, Huaxiang. 2020. *Grounding Visual Concepts for Zero-Shot Event Detection and Event Captioning*. Association for Computing Machinery, pages:297–305.
- Liao, Jinzhi and Zhao, Xiang and Li, Xinyi and Zhang, Lingling and Tang, Jiuyang. 2021. *Learning Discriminative Neural Representations for Event Detection*. Association for Computing Machinery, pages:644–653.
- Lin, Hongyu and Lu, Yaojie and Han, Xianpei and Sun, Le 2019. *Cost-sensitive Regularization for Label Confusion-aware Event Detection*. Association for Computational Linguistics, pages:5278–5283.

- Cao, Yuwei and Peng, Hao and Wu, Jia and Dou, Yingdong and Li, Jianxin and Yu, Philip S. 2021. *Knowledge-Preserving Incremental Social Event Detection via Heterogeneous GNNs*. Association for Computing Machinery, pages:3383–3395.
- Aly, Rami and Remus, Steffen and Biemann, Chris. 2019. *Hierarchical Multi-label Classification of Text with Capsule Networks*. Association for Computational Linguistics, pages:323–330.
- Chalkidis, Ilias and Fergadiotis, Emmanouil and Malakasiotis, Prodromos and Androutsopoulos, Ion 2019. *Large-Scale Multi-Label Text Classification on EU Legislation*. Association for Computational Linguistics, pages:6314–6322.
- Chang, Wei-Cheng and Yu, Hsiang-Fu and Zhong, Kai and Yang, Yiming and Dhillon, Inderjit S. 2020. *Taming Pretrained Transformers for Extreme Multi-Label Text Classification*. Association for Computing Machinery, pages:3163–3171
- 李茹, 王智强, 李双红, 梁吉业, Collin Baker. 2013. 基于框架语义分析的汉语句子相似度计算. 计算机研究与发展, pages:1728–1736.
- 赵红燕, 李茹, 张晟, 张力文. 2016. 基于DNN的汉语框架识别研究. 中文信息学报, 30(6):75-83.
- Chen, Yubo and Xu, Liheng and Liu, Kang and Zeng, Daojian and Zhao, Jun. 2015. *Event Extraction via Dynamic Multi-Pooling Convolutional Neural Networks*. Association for Computational Linguistics, pages:167–176.
- Cui, Shiyao and Yu, Bowen and Liu, Tingwen and Zhang, Zhenyu and Wang, Xuebin and Shi, Jinqiao. 2020. *Edge-Enhanced Graph Convolution Networks for Event Detection with Syntactic Relation*. Association for Computational Linguistics: EMNLP 2020, pages:2329–2339.
- Yang, Sen and Feng, Dawei and Qiao, Linbo and Kan, Zhigang and Li, Dongsheng. 2019. *Exploring Pre-trained Language Models for Event Extraction and Generation*. Association for Computational Linguistics, pages:5284–5294.
- Devlin, Jacob and Chang, Ming-Wei and Lee, Kenton and Toutanova, Kristina 2019. *Pre-training of Deep Bidirectional Transformers for Language Understanding*. Association for Computational Linguistics, pages:4171–4186.
- Liu, Shulin and Chen, Yubo and He, Shizhu and Liu, Kang and Zhao, Jun 2016. *Leveraging FrameNet to Improve Automatic Event Detection*. Association for Computational Linguistics”, pages:2134–2143.
- Yao, Liang and Mao, Chengsheng and Luo, Yuan. 2019. *Graph Convolutional Networks for Text Classification*. AAAI Press, numpages:8.
- Yang, Hang and Chen, Yubo and Liu, Kang and Xiao, Yang and Zhao, Jun. 2018. *A Document-level Chinese Financial Event Extraction System based on Automatically Labeled Training Data*. Association for Computational Linguistics, pages:50–55.
- Zheng, Shun and Cao, Wei and Xu, Wei and Bian, Jiang. 2019. *Doc2EDAG: An End-to-End Document-level Framework for Chinese Financial Event Extraction*. Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), pages:337–346.
- Xu, Runxin and Liu, Tianyu and Li, Lei and Chang, Baobao. 2021. *Document-level Event Extraction via Heterogeneous Graph-based Interaction Model with a Tracker*. Association for Computational Linguistics, pages:3533–3546.
- Aleksander Madry and Aleksandar Makelov and Ludwig Schmidt and Dimitris Tsipras and Adrian Vladu. 2018. *Towards Deep Learning Models Resistant to Adversarial Attacks*. ArXiv, volume:abs/1706.06083.
- Liu, Z. and Huang, D. and Huang, K. and Li, Z. and Zhao, J. 2020. *FinBERT: A Pre-trained Financial Language Representation Model for Financial Text Mining*. International Joint Conference on Artificial Intelligence,
- Li, and X, et al. 2021. *DuEE-fin: a document-level event extraction dataset in the financial domain released by Baidu*. Retrieved from <https://aistudio.baidu.com/aistudio/competition/detail/46>,

- Y. Cui, W. Che, T. Liu, B. Qin and Z. Yang. 2018. *Pre-Training With Whole Word Masking for Chinese BERT*. IEEE/ACM Transactions on Audio, Speech, and Language Processing, vol. 29, pages:3504-3514
- Yu Sun and Shuohuan Wang and Yukun Li and Shikun Feng and Xuyi Chen and Han Zhang and Xin Tian and Danxiang Zhu and Hao Tian and Hua Wu. 2019. *ERNIE: Enhanced Representation through Knowledge Integration*. ArXiv, volume:abs/1904.09223
- Tong Zhu, Xiaoye Qu, Wenliang Chen, Zhefeng Wang, Baoxing Huai, Nicholas Jing Yuan, Min Zhang. 2021. *Efficient Document-level Event Extraction via Pseudo-Trigger-aware Pruned Complete Graph*. <https://arxiv.org/pdf/2112.06013.pdf>.
- Liu, Yaduo and Zhang, Longhui and Yin, Shujuan and Zhao, Xiaofeng and Ren, Feiliang. 2021. *An Effective System for Multi-Format Information Extraction*. Natural Language Processing and Chinese Computing: 10th CCF International Conference, NLPCC 2021, Qingdao, China, October 13–17, 2021, Proceedings, Part II pages = 460–471.