

基于事件动作方向的隐式因果关系抽取方法

缪峰¹ 王萍² 李太勇²

1 西南政法大学人工智能法学院 重庆 401120

2 西南财经大学经济信息工程学院 成都 611130

摘要 抽取事件之间的因果关系能够应用于自动问答、知识提取、常识推理等方面。隐式因果关系由于缺乏明显的词汇特征和中文复杂的句法结构,使得其抽取极为困难,已成为当前研究的难点。相比而言,显示因果关系的抽取比较容易、准确率高,且因果关系事件之间的逻辑关系稳定。为此,文中提出了一种原创的方法,首先通过对抽取的显示因果事件对进行事件动作的归一化处理形成事件方向,然后对事件主体进行泛化处理,最终形成标准的匹配因果事件对集合。利用此集合根据事件相似度从语句中抽取隐式因果事件对。为了识别更多的隐式因果关系,文中同时提出了一种因果连接词发现算法。在网易财经、腾讯财经和新浪财经上爬取的实验数据验证,对事件动作进行归一化处理形成事件方向相比传统方法抽取准确率提高了1.02%。

关键词: 因果关系;因果连接词;事件抽取;事件动作;句法结构分析

中图法分类号 TP391.1

Implicit Causality Extraction Method Based on Event Action Direction

MIU Feng¹, WANG Ping² and LI Tai-yong²

1 School of Artificial Intelligence and Law, Southwest University of Political Science & Law, Chongqing 401120, China

2 School of Economic Information Engineering, Southwestern University of Finance and Economics, Chengdu 611130, China

Abstract Extracting the causality between events can be applied to automatic question answering, knowledge extraction, common sense reasoning and so on. Due to the lack of obvious lexical features and the complex syntactic structure of Chinese, it is very difficult to extract implicit causality, which has become the bottleneck of the current research. In contrast, it is easy to extract explicit causality with high accuracy, and the logical causal relationship between events is stable. Therefore, an original method is proposed in this paper. Firstly, the extracted explicit causal event pairs are normalized to form the event direction, and then the event subject is generalized to form a standard set of matched causal event pairs. This set is used to extract implicit causal event pairs according to event similarity. In order to identify more implicit causality, a new causal connectives discovery algorithm is proposed. The experimental data crawling on NetEase Finance, Tencent Finance and Sina Finance show that the extraction precision is improved by 1.02% compared with the traditional method.

Keywords Causality, Causal connectives, Event extraction, Event action, Syntactic structure analysis

1 引言

俗话说,太阳底下无新鲜事,过去发生的事件在未来仍然可能出现,因此对历史事件的分析有助于我们对未来发生相似事件时可能产生的影响做出合理的预测。如2016年英国脱欧后英镑暴跌,导致英国的旅游成本和诸多奢侈品的价格大幅降低,引发大量热衷奢侈品消费的人群去英国抢购。类似的事件还有2018年土耳其汇率大幅下跌使得其国内的奢侈品被代购和游客抢购一空,同时当地的旅游业增长30%。事件因果关系作为一种重要的语义关系,反映了前后两个事件之间由因及果的强相关性关系,识别并抽取事件之间的因果关系具有重要意义,能够应用于自动问答、知识提取、常识推理等方面。

按照是否包含因果连接词,可以将因果关系分为显示因果关系和隐式因果关系。显示因果关系由于含有明显的因果连接词,其识别抽取比较容易,并能够取得较高的准确率。而隐式因果关系由于缺乏明显的词汇特征和中文复杂的句法结构,使得其抽取尤为困难。另一方面,相较于复杂多变的句法结构而言,具有因果关系的事件之间的逻辑语义关系较稳定。受此启发,本文提出了一种利用抽取的显示因果关系来识别抽取隐式因果关系的方法,该方法的难点在于事件的匹配上。文中通过对事件动作进行归一化处理形成事件方向,从而提高匹配的准确率,进而提高抽取的隐式因果关系的准确率。以“需求下降”和“需求疲弱”两个事件为例,由于下降属于动词,疲弱属于形容词,现有基于同义词词典和基于相似度计算的方法都无法准确判断两个事件的相同语义关系,而利用

到稿日期:2021-11-24 返修日期:2021-12-17

基金项目:教育部人文社会科学研究一般项目(19YJAZH047)

This work was supported by the Humanities and Social Science Project from the Ministry of Education of China(19YJAZH047).

通信作者:缪峰(miufeng@swupl.edu.cn)

本文提出的方法则能够将两个词都划分到同类事件方向中。

以一个简单的例子来说明本文方法的流程和目的。首先可以从句子“春节临近,老百姓对肉类的需求增加,自然导致猪肉价格上涨”中,根据因果连接词“导致”提取出显示因果关系事件对(老百姓对肉类的需求增加,猪肉价格上涨),如果直接根据该事件对来识别隐式因果关系没有任何意义,因此需要通过句法分析对原因事件和结果事件中的主体进行泛化,从而获取得到(需求增加,价格上涨)事件;然后利用本文提出的方法对事件动作进行归一化处理得到事件方向,得到(需求[向上],价格[向上])。利用此规范化后的匹配事件对,则可以从句子“目前,新能源车、风能、工业电机等需求旺盛,稀土四季度价格仍有望维持强势”中抽取(新能源车需求旺盛,稀土价格强势)、(风能需求旺盛,稀土价格强势)、(工业电机需求旺盛,稀土价格强势)3个隐式因果关系,这类因果关系对于投资者而言具有一定的参考价值。

文中提出的方法侧重于抽取的准确性,因为抽取错误的因果关系可能会遭受重大损失。现有研究中侧重于准确率指标并非本文独创,还有 Oh 等^[1]和 Hashimoto 等^[2]。

本文第2节介绍了近期的研究现状;第3节详细介绍了本文提出的隐式因果关系抽取方法;第4节为实验部分。

2 研究现状

在现有的因果关系研究中,按照使用的方法可以分为3类:

(1)根据因果连接词,如英文中的“cause, if, ..., then, because”,中文中的“导致、因为...所以”等,结合句法和语义分析构建模板规则的方法进行识别。

Yang^[3]构建了一个中文因果连接词词库,并为每类因果连接词设计了对应的句法模式,实验结果表明,部分句法模式取得了较高的准确率(0.98),部分句法模式的准确率结果较差(0.45)。Doan 等^[4]提出了一种基于词汇-句法结构的模式规则方法,从 Twitter 中抽取健康相关的显示因果关系,最高取得了 92.27% 的准确率。An 等^[5]提出了一个基于模板规则的方法,用于从文献中判断两个实体之间的因果关系。Cui 等^[6]引入约束网络原理来优化因果关联规则的挖掘过程,从而更容易导出原因变量集合。Drury 等^[7]基于规则匹配的方法,利用因果关系从新闻文本中找出影响甘蔗的相关因素。Lee 等^[8]基于因果连接词,从医学文献中提取前后疾病之间的因果关系。Izumi 等^[9]利用4种句法模式,从财务报表语句中抽取因果关系。

基于规则的方法通常能够取得较高的准确率,但识别的范围,即召回率不高,且大多只能识别显示因果关系而忽略了隐式因果关系。

(2)基于机器学习的方法。其将因果关系的识别考虑为二分类或三分类问题,利用训练的分类器模型进行识别。

Mirza 等^[10]提出一个从英文文本中抽取时序关系和因果关系的 CATENA 系统,其中因果关系的抽取是利用规则匹配和机器学习相结合的混合方法。实验结果表明,基于规则的方法取得了较高的准确率(0.917),结合机器学习方法后,准确率下降(0.737),但召回率有所提升。Yang 等^[11]以结合的关系词特征为输入,利用 Transformer 模型来识别因果关系复句,取得了较好的结果。Yu 等^[12]训练了6种不同的

分类模型,从 Twitter 中抽取与药物相关的因果关系,实验结果显示,SVM 方法取得了最高的准确率。Ding 等^[13]基于最大熵模型分别构建了一个句子级别和文档级别的分类器模型。首先利用句子级的分类器进行判定,如果结果大于阈值,则标记为因果关系;如果结果小于阈值,再利用文档级的分类器进行识别。Kruengkrai 等^[14]提出一个结合背景知识库(4-billion-page web archive),利用 MCNNs (Multi-column Convolutional Neural Networks) 模型来识别因果关系。Huang 等^[15]将原因在前、结果在后的时序关系考虑进因果关系的抽取中,提出一个因果关系和时序关系抽取的联合模型。Tian 等^[16]将因果关系抽取考虑为一个三分类问题,提出一种基于 Bi-LSTM 的维吾尔语事件因果关系抽取方法。Kilicoglu^[17]构建了23种特征,利用 SVM 分类器识别抽取医学文本中的跨句隐式因果关系,取得了 59.7% 的准确率。Ayyanar 等^[18]利用句法分析树和语法标签作为特征,使用通过训练的 CNN 模型来识别同句中两个名词之间的因果关系。Hashimoto^[19]基于 Wikipedia 的结构特点,提出了一个弱监督的方法来抽取实体间的因果关系。

基于机器学习的方法可同时识别显示和隐式因果关系,虽然提高了召回率,但准确率有所下降。另外,复杂的特征构建、缺乏大量的标注训练样本都给其带来了困难。

(3)基于序列标注的方法。其将因果关系的识别转化为序列标注问题,单纯的序列标注方法忽略了上下文信息,因此通常需要结合其他方法来提高准确率。

Zhong 等^[20]提出一种基于双层序列标注模型的维吾尔语突发事件的因果关系抽取方法。单纯的利用序列标注模型,忽略了事件上下文信息、实体及属性之间的长距离依赖问题,后续的学者提出了一系列改进模型^[21-22];Xu 等^[23]针对模型中使用句法依存树方法存在的单向依赖关系问题,提出一种将句法依存树转换为句法依存图的方法,并基于句法依存图构建了 BiLSTM+CRF+S-GAT 相结合的序列标注方法来抽取因果关系。

3 隐式因果关系抽取方法

3.1 隐式因果关系抽取流程

本文提出的隐式因果关系识别抽取方法是基于句子级的方法。首先将新闻文本进行分词、词性标注等预处理操作;然后利用构建的因果连接词从语句集中提取显示因果事件对;最后通过句法结构分析和事件方向词表对显示因果事件对进行主体泛化和事件动作归一化处理。利用规范化后的显示因果事件对集合,基于相似度方法识别抽取隐式因果关系,同时更新因果连接词库和事件方向词表。利用更新后的因果连接词库和事件方向词表,重复整个过程直至无新的隐式因果关系为止。

本文提出的方法主要完成了以下3个方面的工作:1)基于模板规则的方法通常能够取得较高的准确率,但现有研究更多的是对显示因果关系的抽取,针对隐式因果关系的研究较少。本文基于显示因果关系抽取较容易和因果关系事件之间逻辑语义关系稳定的特点,提出一种利用显示因果关系来识别抽取隐式因果关系的方法。2)通过构建事件方向词表和所提算法对事件动作进行归一化处理,形成事件方向,从而

提高事件的匹配准确率,进而提高隐式因果关系抽取的准确率。3)提出了一种因果连接词发现算法,用于识别更多的隐式因果关系。

3.2 事件动作归一化处理

通过因果连接词及其句法结构,从语句中抽取显示因果事件对后,将原因和结果事件中的词去除停用词,只保留动词和形容词作为事件的候选动作词。利用本文构建的初始事件方向词表对事件中的动作进行归一化处理,形成事件方向,在匹配原因和结果事件过程中,利用算法1判断事件动作词方向,并将新词加入方向词表中。表1列出了本文构建的初始事件方向词。

表1 初始事件动作方向词

Table 1 Initial event direction thesaurus

事件方向	所属归约的词汇
向上	增加、提高、大增、大涨、上升、上涨、提升、升温、发家致富、改善、回升、抬升、较强、扩大、提质、稳中有升、由降转涨、反弹、回暖
向下	减少、减弱、偏弱、下降、下跌、下滑、大跌、跌落、降低、减低、暴跌、回落、骤降、下挫、狂跌、滑降、稳中有降、由涨转降、下行、下调、受挫、减缓、放缓、承压

算法1 事件动作方向词发现算法

输入:两个因果关系事件对A和B,事件对表示为: $[(O_{(C,A)}, P_{(C,A)}), (O_{(E,A)}, P_{(E,A)})]$ 。其中 $O_{(C,A)}, O_{(E,A)}$ 表示事件对A的原因和结果事件中的主体; $P_{(C,A)}, P_{(E,A)}$ 表示事件对A的原因和结果事件中的动作,由归一化后的方向词、其他动词或形容词构成

输出:新事件动作方向词

1. if $P_{(C,A)} \in WD$ and $P_{(E,A)} \in WD$
2. if $P_{(C,B)} \in WD$ and $O_{(C,A)} = O_{(C,B)}$ and $O_{(E,A)} = O_{(E,B)}$
3. if only one word w_i in $P_{(E,B)} \notin P_{(E,A)}$ and $P_{(E,B)} \notin WD$
4. if $Direction(P_{(C,A)}) = Direction(P_{(C,B)})$
5. Tag(w_i)
6. $Direction(w_i) = Direction(P_{(E,A)})$
7. if $P_{(E,B)} \in WD$ and $O_{(C,A)} = O_{(C,B)}$ and $O_{(E,A)} = O_{(E,B)}$
8. if only one word w_j in $P_{(C,B)} \notin P_{(C,A)}$ and $P_{(C,B)} \notin WD$
9. if $Direction(P_{(E,A)}) = Direction(P_{(E,B)})$
10. Tag(w_j)
11. $Direction(w_j) = Direction(P_{(C,A)})$
12. if $P_{(C,A)} \in WD$ and $P_{(E,A)} \notin WD$
13. if $P_{(E,B)} = P_{(E,A)}$ and $O_{(C,A)} = O_{(C,B)}$ and $O_{(E,A)} = O_{(E,B)}$
14. if only one word w_s in $P_{(C,B)} \notin P_{(C,A)}$ and $P_{(C,B)} \notin WD$
15. Tag(w_s)
16. $Direction(w_s) = Direction(P_{(C,A)})$
17. if $P_{(E,A)} \in WD$ and $P_{(C,A)} \notin WD$
18. if $P_{(C,B)} = P_{(C,A)}$ and $O_{(C,A)} = O_{(C,B)}$ and $O_{(E,A)} = O_{(E,B)}$
19. if only one word w_t in $P_{(E,B)} \notin P_{(E,A)}$ and $P_{(E,B)} \notin WD$
20. Tag(w_t)
21. $Direction(w_t) = Direction(P_{(E,A)})$

3.3 事件主体泛化

考虑语句“过年期间,肉类需求增加导致羊肉价格上涨”,可以从中抽取显示因果关系对(肉类需求增加,羊肉价格上涨),本文选取名词按照句中顺序作为事件的主体,若事件中无名词,则以具有主谓关系SBV结构的动词作为事件主体,以动词形式表示的事件主体不进行动作归一化和泛化处理。因此原因事件的主体词为(肉类、需求),结果事件的主体词为

(羊肉、价格)。如果以此形式直接匹配候选隐式因果句,其能够匹配的范围较小。因此本文结合句法分析(如图1所示),对名词形式的定中关系进行规整,只保留核心名词作为事件的主体,经过处理后,上述因果关系对可以泛化为(需求[向上],价格[向上])。




图1 原因和结果事件的句法结构

Fig. 1 Syntactic structure of cause and effect events

3.4 隐式因果关系判断方法

首先通过对因果事件进行主体泛化和事件动作方向归一化后,形成了规范化的匹配因果事件对集合,然后将文本中与匹配因果事件对集合原因事件和结果事件相似度超过阈值的语句标记为候选隐式因果句,最后利用句法结构相似性结合子句所在位置识别和抽取隐式因果关系事件对。

其中候选隐式因果句的选取是针对当前待判定语句 j ,通过对其与所有抽取的因果事件对集合进行分析,选取满足条件且相似度最大值超过阈值的显示因果事件对作为隐式因果关系抽取判断对象,具体过程如下:

(1)语句 j 中包含原因和结果事件主体的词汇,若满足,则继续步骤(2),否则,选取下一个因果事件对继续与语句 j 进行对比。

(2)通过式(1)分别计算语句 j 中所有子句与原因和结果事件的相似度,将相似度超过阈值且相似度最大的子句作为原因或结果所在子句。

$$SIMCE_{i,c,j,n} = \frac{Count_{i,c,j,n}}{Count_{i,c}} \quad (1)$$

其中, $Count_{i,c,j,n}$ 代表在第 i 个因果事件对中的原因事件 c 与第 j 条语句的第 n 个子句中相同词的个数, $Count_{i,c}$ 代表第 i 个因果事件对中的原因事件 c 中词的总个数, $SIMCE_{i,c,j,n}$ 代表第 i 个因果事件对中的原因事件 c 与第 j 条语句中的第 n 个子句的相似度。同理, $SIMCE_{i,e,j,n}$ 表示第 n 个子句与结果事件的相似度。

(3)通过步骤(2)确定显示因果事件对中的原因和结果事件在语句中的位置,然后通过式(2)计算语句与因果事件对的整体相似度。

$$SIM_{i,j} = \frac{Count_{i,c}}{(Count_{i,c} + Count_{i,e})} \times SIMCE_{i,c,j} + \frac{Count_{i,e}}{(Count_{i,c} + Count_{i,e})} \times SIMCE_{i,e,j} \quad (2)$$

其中, $SIMCE_{i,c,j}$ 代表在第 i 个因果事件对中的原因事件 c 与第 j 条语句的所有子句的最大相似度, $SIM_{i,j}$ 代表第 i 个显示因果事件对与第 j 条语句最终的相似度。

(4)通过将第 j 条语句与所有因果事件对进行相似度计算,选取相似度最大的因果事件对作为匹配事件对,如果最大的整体相似度超过阈值,则将该语句 j 标记为候选隐式因果句。

(5)将语句 j 中剩余子句去掉停用词后,通过2-POS模式进行标注,然后将子句分别与原因子句和结果子句计算相似

度,同时再结合子句与原因子句、结果子句的距离,抽取隐式因果关系事件对。

(6)无任何新的隐式因果关系时截止。

3.5 因果连接词发现方法

当隐式因果关系事件对被抽取出来后,通过算法 2 判断原因事件和结果事件之间是否存在新的因果关系连接词。如果能够找出新的因果连接词,则可以提取出更多的匹配因果事件对,从而提高方法的召回率。

算法 2 因果连接词发现算法

输入:因果事件对 A 和隐式因果关系语句 B

输出:新的因果连接词及其句法识别规则

1. if $SIMCE_{(A,C,m,B)}$ = 最大值
2. $Locate(Event_{(A,C)}) = m$
3. if $SIMCE_{(A,E,n,B)}$ = 最大值
4. $Locate(Event_{(A,E)}) = n$
5. add NotStopwords(noun words in clause m) in O_1
6. add NotStopwords(noun words in clause n) in O_2
7. add NotStopwords(verb or adjective in clause m) in P_1
8. if w_i in P_1 exist no relation to any w_j in the O_1
9. delete w_i from P_1
10. add NotStopwords(verb or adjective in clause n) in P_2
11. if w_i in P_2 exist no relation to any w_j in the O_2
12. delete w_i from P_2
13. if $(m < n)$
14. $Csite = \max(Wlocate(w_i \text{ in } O_1), Wlocate(w_j \text{ in } P_1))$
15. $Esite = \min(Wlocate(w_i \text{ in } O_2), Wlocate(w_j \text{ in } P_2))$
16. else
17. $Csite = \min(Wlocate(w_i \text{ in } O_1), Wlocate(w_j \text{ in } P_1))$
18. $Esite = \max(Wlocate(w_i \text{ in } O_2), Wlocate(w_j \text{ in } P_2))$
19. for every verb w_i between $(Csite, Esite)$
20. if $SBV(w_i, w_j \text{ in } (O_1, P_1))$ and $SBV(w_i, w_2 \text{ in } (O_2, P_2))$
21. add w_i in Causal WD
22. add all relation with (O_1, P_1)
23. add all relation with (O_2, P_2)

4 实验

本文从网易财经、腾讯财经和新浪财经中爬取并整理了共 1 000 份新闻文本,以句子为单位构建语句集作为实验数据。由 3 位标注人员对语句中的因果关系进行标注,标记的形式为一个 6 元组 $(jid, wid, jnid, ctype, cause, effect, num)$ 。其中, jid 为该语句在语句集中的编号, wid 为所属新闻 ID, $jnid$ 为语句在新闻文本中的编号, $ctype$ 标记为显示因果或隐式因果关系, $cause$ 为原因语句, $effect$ 为结果语句, num 为该语句中包含的因果事件对个数。标注人员在判断标注因果关系时,应遵守以下几个标准:

(1)由于本文方法是从语句中识别抽取隐式因果关系的,因此对于跨句、跨段或跨篇章的因果关系统一标注为非因果关系。

(2)在句子中,根据因果连接词能够准确定位到原因和结果部分,标记为显示因果关系;反之则标记为隐式因果关系。如语句“受基建和房地产销售回暖的影响,委托贷款和信托贷款负增长的势头在持续减缓”判断为显示因果关系。

(3)一个语句中如果包含多个原因或多个结果,则标记

数量为该语句中实际的原因和结果事件对数量。如语句“目前,新能源车、风能、工业电机等需求旺盛,稀土四季度价格仍有望维持强势”,标记的隐式因果关系数为 3 个。

(4)部分学者认为因果关系是一种逻辑语义关系,而研究因果链的学者则认为其是一种概率关系。因果关系的判断标准目前还存在争议,特别是隐式因果关系的判断受背景知识的影响较大。因此,如果标注人员对某个因果关系存在争议,则从实验语句集中删除包含该因果关系的语句。

根据上述标准,最终获得的实验数据如表 2 所列。

表 2 实验数据中标记的因果关系

Table 2 Causality information in experimental data

文章篇数	语句数	显示因果关系数量	隐式因果关系数量
1 000	26 090	1 553	7 201

抽取出错误的因果关系可能会导致重大损失,因此本文更关注所提方法能否抽取准确的隐式因果关系。基于此,本文选取准确率 P 作为实验的评价指标,其形式化描述如下:

$$P = \frac{\text{识别正确的隐式因果关系个数}}{\text{识别的隐式因果关系总数}}$$

本文采取与文献[4,24]相同的实验策略,即通过与基准方法进行对比来验证所提方法的有效性。本文所做的工作主要包含 3 个方面(如 3.1 节所述)。其中第 1)、第 3)点的有效性体现在最终的准确率上;对于第 2)点,本文认为构建事件方向词表有助于提高事件匹配的准确率,进而提高隐式因果关系识别的准确率,因此将传统方法,即只基于同义词词典的方法作为基准方法。

本文使用 MSSQL2012 存储实验数据,利用 python 编写实验程序,文本的处理选择哈工大的 ltp 工具,基准方法中的同义词词典使用《同义词词林-扩展版》。表 3 和图 2 给出了本文方法与基准方法在不同的候选隐式因果句相似度阈值 β 和句子结构相似度阈值 θ 下的准确率对比结果。

表 3 基准方法与本文方法的准确率实验结果

Table 3 Precision of benchmark method and our method

(β, θ) 取值	P 值(基准方法)	P 值(本文方法)
(0.5, 0.55)	0.4188	0.3895
(0.55, 0.6)	0.8398	0.8289
(0.6, 0.65)	0.8621	0.8581
(0.65, 0.7)	0.8640	0.8646
(0.7, 0.75)	0.9059	0.9161
(0.75, 0.8)	0.9051	0.9104
(0.8, 0.85)	0.9008	0.9071
(0.85, 0.9)	0.8988	0.9001
(0.9, 0.95)	0.8943	0.8996

从表 3 的实验结果可以看出,在两个阈值设定为较高值时,本文方法的准确率均高于基准方法。而在阈值设定较低的情况下,本文方法取得的准确率低于基准方法,主要原因在于,当阈值选取较低时,会抽取出错误的隐式因果关系,从而导致错误的事件动作方向词被添加到词表中,错误的词表进一步导致抽取更多的错误隐式因果关系,从而产生级联错误。当阈值取值较高时,相比传统方法,归一化处理形成事件方向能够更好地规整因果关系事件对,提高事件匹配的准确性,而隐式因果关系准确性也会相应地提高。

本文方法属于模板规则的方法,在现有的研究中基于

模板规则的方法更多的是用于显示因果关系的抽取,而应用于隐式因果关系的研究较少。本文方法虽然取得了较高的准确率,但识别的数量,即召回率较低,主要原因在于,识别的隐式因果关系数量受抽取的显示因果关系数量影响较大。但随着本文方法处理新闻文本数量的增加,能够提取的显示因果事件对数量也会不断增加,因此当处理的新闻文本数量达到一定规模以后,本文方法的召回率也会随之提高。

参 考 文 献

- [1] OH J H, TORISAWA K, HASHIMOTO C, et al. Why-Question Answering Using Intra-and Inter-Sentential Causal Relations [C]//Proceedings of the 51st ACL. Sofia, Bulgaria; Association for Computational Linguistics, 2013:1733-1743.
- [2] HASHIMOTO C, TORISAWA K, KLOETZER J, et al. Toward future scenario generation: Extracting event causality exploiting semantic relation, context, and association features [C]// Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2014:987-997.
- [3] YANG P F. Research and Construction of causal knowledge base [D]. Changchun: Jilin University, 2016.
- [4] DOAN S, YANG E W, TILAK S S, et al. Extracting health-related causality from twitter messages using natural language processing [J]. BMC Medical Informatics and Decision Making, 2019, 19(3): 71-77.
- [5] AN N, XIAO Y, YUAN J, et al. Extracting causal relations from the literature with word vector mapping [J]. Computers in Biology and Medicine, 2019, 115: 103524.
- [6] CUI Y, LIU C H. Research on Causal Association Rule Mining Based on Constraint Network [J]. Computer Science, 2016, 43(11A): 466-468.
- [7] DRURY B, ROCHA C, MOURA M F, et al. The Extraction from News Stories a Causal Topic Centred Bayesian Graph for Sugarcane [C]// Proceedings of the 20th International Database Engineering & Applications Symposium. 2016:364-369.
- [8] LEE D, SHIN H. Disease causality extraction based on lexical semantics and document-clause frequency from biomedical literature [J]. BMC Medical Informatics and Decision Making, 2017, 17(1): 1-9.
- [9] IZUMI K, SAKAJI H. Economic causal-chain search using text mining technology [C]// Proceedings of the First Workshop on Financial Technology and Natural Language Processing. 2019: 61-65.
- [10] MIRZA P, TONELLI S. Catena: Causal and temporal relation extraction from natural language texts [C]// Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics; Technical Papers. 2016: 64-75.
- [11] YANG J C, CAO Y, HU Q, et al. Relation Classification of Chinese Causal Compound Sentences Based on Transformer Model and Relational Word Feature [J]. Computer Science, 2021, 48(6A): 295-298.
- [12] YU F, MOH M, MOH T S. Towards extracting drug-effect relation from Twitter: a supervised learning approach [C]// 2016 IEEE 2nd International Conference on Big Data Security on Cloud (BigDataSecurity), IEEE International Conference on High Performance and Smart Computing (HPSC), and IEEE International Conference on Intelligent Data and Security (IDS). IEEE, 2016: 339-344.
- [13] DING W, ZHOU F, MIAO J P, et al. Temporal Relation Recognition Method for News Events Based on Cross Event Theory [J]. Computer Engineering, 2017, 6: 189-194.
- [14] KRUENCKRAI C, TORISAWA K, HASHIMOTO C, et al. Improving event causality recognition with multiple background knowledge sources using multi-column convolutional neural networks [C]// Thirty-First AAAI Conference on Artificial Intelligence. 2017.
- [15] HUANG Y L, LI P F, ZHU Q M. Joint Model of Events' Causal and Temporal Relations Identification [J]. Computer Science, 2018, 45(6): 204-207.
- [16] TIAN S W, ZHOU X F, YU L, et al. Causal Relation Extraction of Uyghur Events Based on Bidirectional Long Short-term Memory Model [J]. Journal of Electronics and Information Technology, 2018, 40(1): 200-208.
- [17] KILICOGU H. Inferring implicit causal relationships in biomedical literature [C]// Proceedings of the 15th Workshop on Biomedical Natural Language Processing. 2016: 46-55.
- [18] AYYANAR R, KOOMULLIL G, RAMASANGU H. Causal Relation Classification using Convolutional Neural Networks and Grammar Tags [C]// 2019 IEEE 16th India Council International Conference (INDICON). IEEE, 2019: 1-3.
- [19] HASHIMOTO C. Weakly Supervised Multilingual Causality Extraction from Wikipedia [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: 2979-2990.
- [20] ZHONG J, YU L, TIAN S W, et al. Causal Relation Extraction of Uyghur Emergency Events Based on Cascaded Model [J]. Acta Automatica Sinica, 2014, 40(4): 771-779.
- [21] MA J H, HAO Y J, ZHANG Y M. Causal Relation Label Based on Cascading Skip-chain Conditional Random Fields [J]. Journal of Zhengzhou University (Natural Science Edition), 2016, 48(4): 54-59.
- [22] ZHOU W. The Construction and Application of Knowledge Graph Incorporating Causal Events [D]. Shanghai: East China Normal University, 2019.
- [23] XU J H, ZUO W L, LIANG S L, et al. Causal Relation Extraction Based on Graph Attention Networks [J]. Journal of Computer Research and Development, 2020, 57(1): 159-174.
- [24] MU W J. Judgment of News Oriented Argument Causation [D]. Harbin: Harbin Institute of Technology, 2018.



MIU Feng, born in 1982, Ph.D, lecturer. His main research interests include NLP and financial intelligence.