

ETC-DRE:基于实体类型约束的对话级关系抽取

龙奕锟,李卫疆

(昆明理工大学 信息工程与自动化学院,昆明 650500)
(昆明理工大学 云南省人工智能重点实验室,昆明 650500)
E-mail:2829667887@qq.com

摘要:目前针对对话级关系抽取的大多数方法都集中在通过序列或图方法增强实体对的上下文表示,但却忽略了长尾问题.关系相关性是缓解长尾问题的一种有效方法,该方法可以将头部关系的丰富信息传递给尾部关系,从而缓解尾部关系训练数据不足的情况.本文针对长尾问题和非对称互逆问题构造了一个实体类型约束图,该约束图为每个关系制定了所有对应的主/客体类型,并且约束图中明确指示了一个实体在关系三元组中属于主体还是客体,不同的关系由共同的实体类型连接,进而反映关系的相关性.通过利用图卷积网络将信息从数据丰富的头部关系传递给信息稀缺的尾部关系,从而同时缓解尾部关系训练不足和非对称互逆关系的问题.本文模型在 DialogRE 数据集上进行了实验,其中 F1 和 F1c 分数分别达到了 64.1% 和 60.3%,验证了其有效性.

关键词:对话关系抽取;关系相关性;实体类型约束;异构图

中图分类号: TP391

文献标识码: A

文章编号: 1000-1220(2026)02-0370-08

ETC-DRE: Dialogue-level Relation Extraction Based on Entity Type Constraints

LONG Yikun, LI Weijiang

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)
(Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Most current methods for dialogue-level relation extraction focus on enhancing the contextual representations of entity pairs through sequence or graph-based approaches, while overlooking the long-tail problem. Relation relevance is an effective way to alleviate the long-tail problem, as it can propagate rich information from head relations to tail relations, thereby mitigating the issue of insufficient training data for tail relations. This paper addresses both the long-tail problem and the asymmetric inverse problem by constructing an entity-type constraint graph. The constraint graph defines all possible subject/object types for each relation and explicitly indicates whether an entity in a relation tuple is a subject or an object. Different relations are connected by shared entity types, which reflects the relevance between relations. By using graph convolutional networks to propagate information from data-rich head relations to data-scarce tail relations, the proposed model mitigates both the insufficient training data for tail relations and the asymmetric inverse relation issue. Experiments on the DialogRE dataset show that the model achieves F1 and F1c scores of 64.1% and 60.3%, respectively, demonstrating its effectiveness.

Keywords: dialogue relation extraction; relation correlations; entity type constraints; heterogeneous graph

0 引言

关系抽取旨在从非结构化的文本中识别两个或多个实体之间的关系,该任务是知识图谱构建^[1]、智能问答^[2]、对话系统^[3]等领域中不可或缺的基础任务.具体而言,关系抽取能够从大量的文本数据中提取出实体及其之间的关系,从而为各种应用提供结构化的信息支持.例如,在知识图谱的构建中,关系抽取用于识别实体之间的关联并构造图谱结构;在智能问答系统中,能够帮助系统理解用户问题的语境并作出有效回答;在对话系统中,关系抽取能够识别对话中的语义关系,从而提升对话的准确性和流畅度.

近年来,随着自然语言处理技术的不断发展,关系抽取的

研究领域也日益丰富.对话级关系抽取作为关系抽取领域中新兴的方向,旨在从多个对话中的上下文信息中推断出两个实体之间的关系.与传统的句子级^[4]和文档级关系^[5]抽取相比,对话级关系抽取具有更大的挑战性.首先,对话级文本的风格通常较为随意,其中包含了大量的冗余信息、人称代词,导致文本信息的密度较低.其次,多个对话中的上下文信息往往不连贯,涉及到多个话题和观点的切换,实体之间的关系可能跨越多个轮次.

除上述问题之外,对话级关系抽取中的数据还存在长尾分布,即小部分关系(头部关系)占据了大部分数据,而大多数关系(长尾关系)只占据了小部分数据.由于长尾关系在训练过程中缺乏足够的训练实例,导致模型对这些关系的学习

和预测能力大大降低,从而影响模型性能和泛化能力.如图 1 所示,在 DialogRE 数据集中,关系类型 `per:alter_names` 占整个数据集的 34%,而关系类型 `per:roommate` 只占整个数据集的 3.3%.




图 1 关系类型长尾分布图

Fig. 1 Long-tail distribution of relationship types diagram

对于长尾分类任务,一般采用重新采样或重新加权来解决.与长尾分类不同,长尾关系抽取的关系标签并不是相互独立的,而是彼此之间存在联系.例如,某个人是另一个人的“父母”,那么他们之间必然存在“孩子”这种关系.因此,针对长尾关系抽取可以通过建模依赖路径来挖掘关系之间的存在的潜在关系.在该依赖路径中,关系之间不再相互独立,可以通过该路径将数据丰富的头部关系的信息传递给数据稀少的长尾关系从而帮助长尾关系进行训练.

在对话级关系抽取中还存在非对称互逆问题.具体来说,在对话文本当中,部分关系类型之间为互逆关系,其中互逆关系可以分为对称互逆关系和非对称互逆关系.对称互逆关系:如 `per:friends`,若主题 A 是客体 B 的朋友,从逻辑上而言客体 B 也应该是主体 A 的朋友,且两个实体类型都属于 PER.非对称互逆关系:如 `per:place_of_residence` 和 `gpe:residents_of_place` 这二者互逆关系之间存在非对称现象,当主体 A 和客体 B 之间的关系为居住地时,主体 A 的实体类型显然为 PER,客体 B 的实体类型为 GPE.相反,当 B 作为主体,A 作为客体,二者之间的关系为居民.由此可知,模型对非对称互逆关系的分类一定程度上取决于主客体的实体类型,如图 2 所示,Bert 模型在推断 S3 和 New York 的关系时错误地将关系分类为 `residents_of_place`.由于 Bert 模型是通过自注意力机制来学习输入序列的分词表示,无法区分输入序列中的主体和客体,当主体和客体交换时,模型在非对称互逆关系中的性能明显低于在对称互逆关系中的性能.

| | | | |
|---|----------|---------|--|
| S1: So what's your name? | | | |
| S2: Chandler. | | | |
| S1: Chandler?What an unusual name!You must've had terribly fascinating parents. | | | |
| S2: Oh,they're a hoot. | | | |
| S1: And who is your friend? | | | |
| S3: I'm-I'm Monica. | | | |
| S1: Monica!Where are you from? | | | |
| S3: New York. | | | |
| Subject | Object | Trigger | Relation type |
| S3 | New York | from | <code>residents_of_place</code> × <code>place_of_residence</code> ✓ |

图 2 非对称互逆问题示例

Fig. 2 Non-symmetric inverse relationship example

综上所述,针对长尾问题和非对称互逆关系问题,本文贡

献如下:

1) 本文提出了一种类型约束图方法,该方法利用实体类型来捕获关系相关性.基于该方法,本文提出了 ETC-DRE 模型,该模型可以同时缓解长尾问题和非对称互逆问题.

2) 本文构建的类型约束图为每个关系制定了所有可能的主/客体类型并且类型约束图中的类型信息和约束信息可以为模型提供额外信息,其中实体类型信息为实体对之间的关系增加了语义约束;约束信息根据主/客体的实体类型将关系限制在一定范围内.该约束可以为模型提供先验信息,一定程度上缓解噪声问题.除此之外,类型约束图可以明确区分一个实体属于主体还是客体,通过这种方式可以一定程度上缓解非对称互逆问题.

3) 本文采用图卷积网络作为图编码器,从约束图中提取交互信息.图卷积网络的领域融合机制可以将信息从头部关系传播到尾部关系,使模型可以更好地学习长尾关系的表示.

4) 本文在公开数据集上与其他模型的性能进行了对比,并通过 Hit@K 实验验证了本文模型在处理长尾关系方面的有效性.

1 相关工作

1.1 对话级关系抽取

对话级关系抽取是关系抽取领域下的子任务,该任务针对日常生活中的对话场景下的实体对关系识别.与句子级关系抽取相比,对话级关系抽取中的实体关系等大量信息隐藏在发言者之间的对话中,并且一个对话中可能存在多个发言者,导致谈话的主题会随时发生变化,模型需要充分理解上下文信息并且具有跨句推理能力才能准确地判断实体之间的关系.目前,对话级关系抽取的相关研究可以分为基于序列和基于图的方法.

基于序列的关系抽取:基于序列方法通常采用 LSTM^[6] 对实体和文档进行编码,从而实现关系抽取. Xue^[7] 等人使用多个 [CLS] 标记来捕捉对话中不同实体对之间的可能关系,并通过关系精炼门进一步改进语义表示. Son^[8] 等人设计了一个具有实体感知的提示标记策略和关系线索检测任务,前者构建一个带有提示模板的输入,在实体前插入提示标记,后者利用模型判断每个标记是否属于主语、宾语或触发词,模型不需要引入额外的网络层即可缓解对话中低信息密度的问题. Albalak^[9] 等人提出了一个 D-REX 模型,模型将关系抽取建模为关系重排序问题,并在推理过程中加入解释作为中间步骤.为了提高解释抽取的质量,模型结合策略梯度方法和半监督信号(如触发词)进行训练.模型在提升对话关系抽取性能的同时也提供了可解释的推理过程. Chen^[10] 等人提出了一种知识感知提示的微调方法.通过将语义知识和结构化先验知识注入到提示构建过程中,并引入协同优化方法来增强它们的表示.该方法不仅提升了模型性能,同时也降低了对领域专业知识的依赖. Zhao^[11] 等人设计了说话人预测和触发词预测两种策略.前者通过随机屏蔽说话人标记,利用上下文信息推测说话人的身份,帮助模型更好地理解对话中说话人的角色.后者用于检测支持当前关系成立的上下文,有助于模型识别实体对之间的关系.最后将全局对话表示和局部实体对表

示进行结合,从而进一步优化关系抽取的性能. An^[12]等人设计了一个自适应触发器融合机制.为了充分利用触发信息,模型将触发信息与上下文信息和实体对信息进行融合,并且利用标签感知语义知识提高触发词提取的性能.该方法减少了由于触发词提取错误对关系分类造成的影响. An^[13]等人提出了一种知识增强调优方法,该方法将触发词知识和标签语义知识注入到模型中.为了充分利用知识,模型将对话关系抽取任务转换为掩码语言建模任务.通过这种方式,使模型对触发词和标签语义的理解能力得到了提升,并且可以更有效地利用预训练语言模型的知识. Qiu^[14]等人提出了一个 SocAoG 模型,该模型将社会关系网络建模为一个具有个人属性的与或图,以确保关系的一致性.同时又提出了一种增量解析策略: α - β - γ 策略,该策略对传入的句子进行动态推理,以推断对话中的不同实体对之间存在的社会关系. Lin^[15]等人提出了一个 TREND 模型,该模型通过在包含触发词的数据集中训练触发词查找能力,再将该能力转移到不同的数据集和关系上,从而提高对话关系抽取的性能.

基于图的关系抽取:与基于序列的方法相比,基于图的方法在捕捉长距离依赖和实体之间的复杂关联方面更有优势. Chen^[16]等人提出了一种基于图注意力网络的方法,该方法构建了一个包含发言者、实体、实体类型和话语节点的异构图.该异构图先对发言者、实体、实体类型、话语和单词进行建模,再利用图注意力网络对图中的相关节点进行上下文传播,从而有效地捕获上下文信息. Xue^[17]等人利用高斯图生成器初始化潜在图的边,捕捉不同标记之间的非对称关系.为了从图中筛选出最具指示性的词汇,模型采用动态时间规整池化方法,以自适应的方式优化图结构,保留最相关的节点,从而提高关系抽取的效果. Lee^[18]等人提出了 TUCORE-GCN 模型,该模型通过应用 BERT 和 SA-BERT 的发言人嵌入来编码输入序列,从而捕捉对话中人物之间的关系.为了更好地提取每个对话轮次的表示,模型采用了带周围轮次掩码的 Masked Multi-Head Self-Attention 方法,从而捕捉对话轮次的上下文信息.除此之外,模型构建了一个异构对话图,其中包含对话节点、轮次节点、主体节点、客体节点.这些节点通过不同类型的边相连,从而捕捉对话中的关系信息. Fei^[19]等人提出了一种对话级关系抽取框架,为了充分利用对话结构中的信息,分别引入了混合依赖图(D2G)和论据推理图(ARG).混合依赖图将对话文本建模为层次化的依赖图,集成了句法结构和话语结构信息,该结构能够更好地捕捉对话语义,并有效提取关系推理所需的关键线索.基于混合依赖图中的论元提及,构建了双向的论据推理图来推断论元之间的关系.该模型有效地捕捉了对话中的语法和话语结构信息,解决了长期依赖和关系推理问题,提高模型性能. Bai^[20]等人将抽象意义表示(AMR)引入了模型,模型提出了两种方法来结合对话级 AMR:一种是将 AMR 与对应句子的词汇进行对齐,并通过 Transformer 对其进行编码;另一种是分别对 AMR 和句子进行编码,并通过特征融合或双重注意力机制将它们进行结合.通过引入 AMR 有助于模型更好地理解长对话,并提高对话生成的连贯性.并且 AMR 增强了模型的鲁棒性,提高了神经网络模型的可解释性.

上述方法都是集中在如何获得更好的实体对和上下文表

示,但都忽略了长尾问题和非对称互逆关系问题.

1.2 关系相关性

关系相关性即关系之间存在共现现象,最初由 Jin^[21]等人提出.在长尾关系中,分析关系之间的相关性可以揭示数据集中关系的重要联系,模型可以采用关系相关性方法利用头部关系的丰富信息来帮助训练尾部关系. Han^[22]等人利用编码器联合学习文档的上下文表示和关系嵌入,又基于关系嵌入从粗粒度和细粒度两个角度捕捉关系之间的相关性,最后利用带有关系相关性的关系嵌入指导关系分类. Huang^[23]等人针对关系之间存在的相关性构建了一个关系图,并创建了一个关系相关矩阵指导关系信息的传播,最后利用图注意力网络聚合关系嵌入.上述方法虽然提升了模型性能,但往往会引入新的噪声.受 Han^[22]等人的启发,本文构建了一个实体类型约束图,该约束图将关系所对应的实体类型限制在一定范围内,不同的关系由共同的实体类型相连,从而捕获关系相关性.

2 方法

2.1 问题定义

给定一个包含 N 个话语的对话 $D = \{u_1, u_2, \dots, u_N\}$ 和实体对 $A = \{(x_1, y_1), (x_2, y_2), \dots\}$. 每个话语中包含若干个单词 $u_i = \{w_{i,1}, \dots, w_{i,r}\} (i = 1, 2, \dots, N)$. 其中 u_i 表示一段话中的第 i 个话语, (x_i, y_i) 是对话中提到的实体, x_i 代表主体, y_i 代表客体. 目标是识别主客体 (x_i, y_i) 之间的关系.

2.2 模型结构

如图 3 所示,本文介绍的模型主要包括基础模型和类型约束图两个部分.基础模型首先对整个对话信息进行编码,再基于编码后的信息构建一个包含发言者、实体、类型和话语节点的异构图,进而采用 5 个图注意力层来聚合相邻节点之间的信息,最后得到所有实体的新表示.类型约束图限制了每个关系类型可能对应的主/客体实体类型,并通过图卷积网络以提取节点的交互特征,之后将实体类型和关系表示连接起来得到约束表示.最后,这些约束表示将为每对实体补充额外的特征,从而能够更准确地抽取和识别对话中的实体关系.

通过上述方式,模型可以有效地捕获上下文信息,充分利用不同实体对之间的关系.在此基础上,通过类型约束图得到的约束表示可以进一步补充额外信息,以便引导分类器利用关系相关性作出更精细的分类.

2.3 基础模型

2.3.1 编码器

由于预训练模型 BERT 在对语义建模方面非常强大,并且 BERT 模型已经在很多领域上取得了成功.因此,本文采用 BERT 模型对上下文进行编码.在基础的编码序列中,本文还在每个话语后单独加入了说话人标记,通过这种方式,模型可以更好地利用说话人信息.除此之外,为了在后续异构图的构建中获得更多信息,本文采用 spaCy 对话语进行了标记化,同时获得每个标记的词性和命名实体类型,并将每个标记的词性和命名实体类型添加到上下文表示中.为了获得包含单词和说话人的上下文表示,本文在输入序列中将话语和说话人进行拼接,输入到 BERT 编码器中:

$$X = \{ [CLS], (w_{i,1}, w_{i,2}, \dots, w_{i,r}), [SEP], \text{Speaker} \} \quad (1)$$

$$\text{BERT}(X) = \{ H_{[CLS]}, H_{i,1}^w, H_{i,2}^w, \dots, H_{i,r}^w, H_{[SEP]}, H_i^s \}_{i=1}^N \quad (2)$$

其中 $w_{i,r}$ 代表第 i 个话语中的第 r 个单词, Speaker 代表当前话语的说话者, $[CLS]$ 代表分类标记, $[SEP]$ 代表分隔标记,

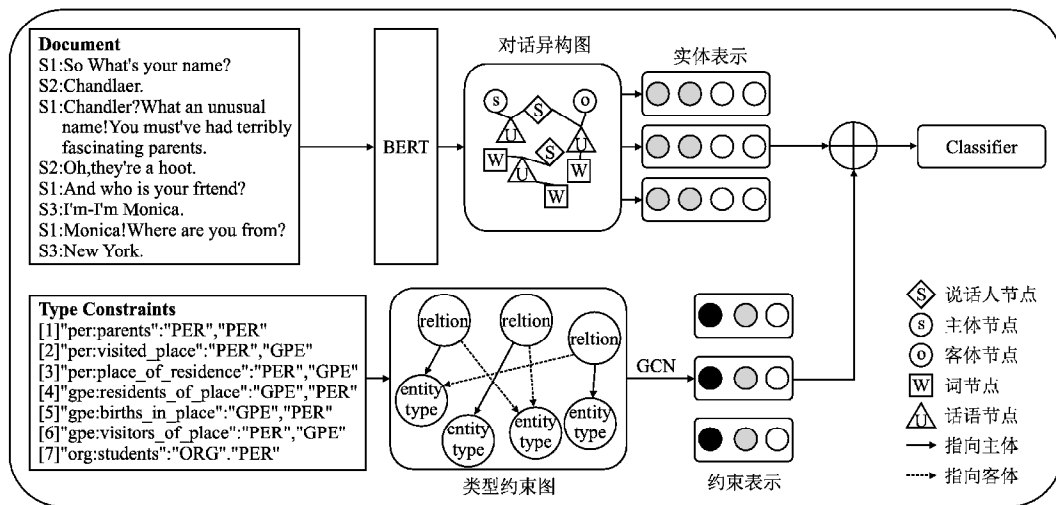


图3 模型结构

Fig. 3 Model structure

$H_{[CLS]}$ 是上下文表示, $H_{i,r}^w$ 是第 i 个话语中的第 r 个单词的表示, H_i^s 是第 i 个话语的说话者的表示。

2.3.2 对话异构图

为了捕捉节点之间的复杂交互,本文构造了一个对话异构图。异构图具有5种不同类型的节点:单词节点、话语节点、发言者节点、实体节点和类型节点。

单词节点表示对话中的每个单词,本文将每个词节点与包含该单词的话语相连,同时与该单词可能所对应的类型节点相连。由于BERT模型产生的词向量不仅考虑了单词本身的语义信息,同时也结合了单词与上下文之间的关系。因此本文采用BERT来初始化词节点,即将BERT产生的词向量作为词节点的初始状态。

话语节点表示对话中的完整语句,话语节点与构成该语句的词节点、发言者节点和论元节点相连。这样的连接使模型在完整语句和其组成部分之间建立联系,从而能够更好地理解和处理对话中的信息。本文利用BERT生成的话语嵌入来初始化话语节点的状态。

发言者节点表示每个话语的唯一发言者,每个发言者节点与相应的话语进行连接。本文采用BERT生成的相应嵌入来初始化发言者节点。

实体节点即模型最终需要对其判断关系的节点,本文采用BERT生成的相应嵌入来初始化实体节点。

类型节点表示每个单词的类型信息。除了节点包含了类型信息之外,在最终分类阶段,通过类型约束图获得的关系嵌入可以与该类型信息进行整合,从而提高模型的推理能力。本文采用BERT生成的相应嵌入来初始化类型节点。

本文将这些节点通过无向边进行连接,话语节点分别与单词节点、实体节点和发言者节点连接,类型节点分别与单词节点和实体节点连接。其中,话语-单词边本文采用词性标记来初始化该边的特征。通过这种方式,该边可以捕捉到全局语义特征和局部的句法特征。具体来说:话语节点包含了对话整体的语义信息,而词性标注可以提供词语的句法信息,话语节

点与单词节点之间的边在传播的过程中可以将这些信息传递给词节点。通过利用这些知识,模型可以更好地去理解词语。为了增强节点之间的信息交流,本文设计了一个无路径:

$$V_u \rightarrow V_b \rightarrow V_i \rightarrow V_b \rightarrow V_u \rightarrow V_b \quad (3)$$

其中 V_u 表示话语节点, V_b 包含词节点、发言者节点和实体节点, V_i 表示类型节点。具体来说:本文先利用 V_u 来对 V_b 进行更新,接下来利用更新后的 V_b 来对 V_i 进行消息传播,之后经过多次这样的更新迭代,得到最终的 V_b 。

通过上述传播方式,最终更新后的节点表示融合了来自其他节点的信息,能够更好地捕捉到更为复杂的上下文关系。

2.4 类型约束图

本文通过对训练集的统计来构造类型约束图,具体来说:本文统计了训练集中的36种关系类型和每个关系类型可能对应的实体类型,从而进行约束图的构造,其中特殊关系类型“unanswerable”不包括在内。注意:约束图中的每个关系类型所对应的实体类型分为主体和客体。例如,关系类型“per:place_of_residence”的主客体实体类型可能分别是“PER”和“GPE”,而不可能是“GPE”和“PER”。

类型约束图中节点和边的定义如下:

节点:图中一共包含两种节点,分别是关系类型节点和实体类型节点。每个关系类型节点通过边与两个实体类型节点相连接。通过这种方式,不同的关系类型节点与共同的主客体实体类型节点相连接可以揭示关系之间的相关性。

边:为了区分主体和客体,图中一共包含两种边,这两种边分别指向主体和客体。

2.4.1 图编码器

首先将约束图 G 转换为邻接矩阵,以便接下来采用图编码器来提取实体类型和关系的表示。

给定一个约束图 $G = \{T, R, C\}$, 其中 T, R, C 分别表示实体类型、关系和约束的集合。定义节点集合 $V = T \cup R$, 每个约束的定义为 $C = (c_{e_1}, r, c_{e_2})$ 。为了区分主体和客体,本文将 (c_{e_1}, r) 和 (r, c_{e_2}) 添加到边集 E 中。邻接矩阵 $\hat{A} \in \mathbb{R}^{n \times n}$ ($n =$

|V|)定义如下:

$$\hat{A}_{ij} = \begin{cases} 1 & \text{if } (v_i, v_j) \in E \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

为了将原始约束图转换为嵌入矩阵,本文将每个节点 $v_i \in V$ 初始化为一个 d 维的嵌入向量 v_i , 通过将所有节点的初始嵌入向量进行组合,得到一个嵌入矩阵:

$$V^{(0)} = \{v_1^{(0)}, v_2^{(0)}, \dots, v_n^{(0)}\} \quad (5)$$

其中 n 代表节点总数,嵌入矩阵包含了所有节点的初始嵌入,大小为 $n \times d$.

本文采用两层的图卷积网络对图结构进行编码. 通过利用图卷积网络的领域整合机制,可以将图中节点与其邻居节点的信息进行结合,从而有效地促进信息在图中的传播. 为了防止节点在更新过程中丢失自身特征,本文在边集 E 中添加了自环,即 $\hat{A}_{ii} = 1$.

本文将邻接矩阵 \hat{A} 和嵌入矩阵 $V^{(0)}$ 作为输入,其中邻接矩阵表示节点之间的连接关系,嵌入矩阵表示节点的初始特征. 对嵌入矩阵 $V^{(k-1)}$ 进行处理后得到节点更新后的特征:

$$H_{node} = W^{(k)} v_i^{(k-1)} + b^{(k)} \quad (6)$$

其中 $v_i^{(k-1)}$ 是节点 v_i 在第 $k-1$ 层的特征表示, $W^{(k)}$ 是第 k 层的权重矩阵, $b^{(k)}$ 是偏置向量. 之后,利用邻接矩阵 \hat{A} 对邻居节点的嵌入进行加权求和,得到邻接矩阵中聚合后的邻居特征:

$$H_{neighbors} = \sum_{j=1}^n \hat{A}_{ij} v_j^{(k-1)} \quad (7)$$

其中 \hat{A}_{ij} 表示邻接矩阵中节点 v_i 与节点 v_j 之间的连接关系, $v_j^{(k-1)}$ 表示邻居节点 v_j 在第 $k-1$ 层的特征表示.

在第 k 层,节点 v_i 更新后的表示如下:

$$v_i^{(k)} = \rho(W^{(k)} v_i^{(k-1)} + b^{(k)} + \sum_{j=1}^n \hat{A}_{ij} v_j^{(k-1)}) \quad (8)$$

其中 $v_i^{(k)}$ 表示节点在第 k 层的最终特征表示, $\rho(\cdot)$ 表示激活函数.

为了构造后续的约束表示,本文将得到的输出 $V^{(2)} \in \mathbb{R}^{n \times d_n}$ 分为关系表示 $R \in \mathbb{R}^{n_r \times d_n}$ 和类型表示 $T \in \mathbb{R}^{n_t \times d_n}$.

2.4.2 约束表示构造

假设关系 r_i 对应的头实体和尾实体分别为 e_1 和 e_2 ,需要在类型表示 T 中查找 e_1 和 e_2 的类型表示 $t_{r_i}^1$ 和 $t_{r_i}^2$. 注意:某些关系可能由多个头尾实体组成,例如,关系 `per: alternate_names` 的尾实体可以是 `PER` 或者 `STRING`,针对该情况本文对头实体或尾实体取平均值. 将关系表示 r_i 与头尾实体类型表示 $t_{r_i}^1$ 和 $t_{r_i}^2$ 连接起来得到约束表示:

$$c_i = [r_i; t_{r_i}^1; t_{r_i}^2] \in \mathbb{R}^{3d_h} \quad 1 \leq i \leq n, \quad (9)$$

2.5 分类器

本文将实体对节点 e_s 和 e_o 、词节点 w_s 和 w_o 和约束表示 c_i 进行拼接得到:

$$e'_s = [\max pool(e_s); \max pool(w_s)] \\ e'_o = [\max pool(e_o); \max pool(w_o)] \quad (10)$$

$$e'_{(s,o)} = [e'_s; e'_o; c_i] \quad (11)$$

经过拼接之后,本文将对 e' 进行线性变换:

$$z = W_e e' + b_e \quad (12)$$

最后将其输入到激活函数中获得预测结果:

$$P(r|e_{(s,o)}) = \sigma(z) \quad (13)$$

其中 $P(r|e_{(s,o)})$ 表示实体对属于关系 r_i 的概率, W_e 和 b_e 分别表示线性变换的权重和偏执向量, $\max pool$ 表示最大池化操作, σ 表示激活函数.

3 实验与分析

3.1 数据集与评价指标

DialogRE 是第一个基于对话关系抽取的数据集,旨在预测对话中实体对之间存在的关系. 该数据集对《老友记》对话中存在的 36 种关系类型进行了标注,在 1788 段对话中获得了 10168 个三元组. 对于每个三元组,该数据集标注了能够表明两个论元存在关系的最小连续文本片段,即触发词. 如果存在多个触发词,只为每个三元组保留其中一个. 数据集详细信息如表 1 所示.

表 1 数据集数据统计
Table 1 Dataset data statistics

| 类别 | 训练集 | 验证集 | 测试集 |
|---------|-------|-------|-------|
| 对话文本数量 | 1073 | 358 | 357 |
| 实体对数量 | 5963 | 1928 | 1858 |
| 平均对话轮次 | 13.1 | 13.1 | 12.4 |
| 平均发言者数量 | 3.3 | 3.2 | 3.3 |
| 平均对话长度 | 229.5 | 224.1 | 214.2 |

本文遵循 DialogRE 的评估指标 F1、F1c. 其中, F1 是标准的评估指标, F1c 专门用于评估模型在对话场景中的表现.

F1 分数是精确率和召回率的调和平均数. F1c 分数是对话级精确率和召回率的调和平均数.

$$F1 = \frac{2 \times P \times R}{P + R} \quad (14)$$

其中, P 表示精确率, R 表示召回率.

$$F1c = \frac{2 \times CP \times CR}{CP + CR} \quad (15)$$

其中 CP 表示对话级精确率, CR 表示对话级召回率.

为了进一步验证模型在处理长尾关系方面的有效性,本文采用 Hit@K 评估标准在 DialogRE 数据集上对模型进行实验验证.

$$Hit@K = \frac{N_{hit}}{N_{total}} \quad (16)$$

其中 N_{hit} 表示在前 K 个预测中包含正确答案的样本数量, N_{total} 表示样本的总数量.

3.2 实验参数设置

本文实验采用 Pytorch 1.10.0 框架,为了优化模型性能,采用 Adam 作为优化器. 此外,本文将训练周期设置为 20 次,批处理大小设置为 16,学习率设置为 4×10^{-4} ,丢弃率设置为 0.2. 图注意力网络的隐藏层维度设置为 512,注意力头数为 10.

3.3 实验结果分析

本文模型与以下几个基线模型进行了对比:

CNN^[24]: 编码器以 GloVe 词向量、提及嵌入和类型嵌入作为特征. 模型为相同论元的提及分配相同的提及嵌入,并根据两个论元的命名实体类型获取类型嵌入.

CGCN^[25]: 模型使用图卷积网络对输入的句子依存树

结构进行编码,从而高效地聚合长距离的词语信息,并提出了一种基于最短路径的剪枝策略,有效地解决了依存结构中的长距离依赖和信息冗余问题。

BERT^[26]:采用BERT作为预训练模型,将给定的对话d与BERT中的分类标记[CLS]和分隔符标记[SEP]连接起来作为构成输入序列。

DHGAT^[16]:将一个包含发言者、实体、实体类型、话语节点的异构图馈送到图注意力网络,使得相关节点之间进行上下文传播,从而有效地捕捉对话的上下文信息。

TDGCN^[27]:为了解决关系重叠存在歧义的问题,在模型中引入了一个动态机制,并针对模型推理能力不足的问题设计了触发器节点,有效地提高了关系分类的性能。

TLAG^[12]:该模型通过自适应触发融合机制和标签感知知识引导模块来充分挖掘触发信息和使用标签感知知识引导来提升关系抽取性能。

TREND^[15]:该模型具有可泛化的触发词查找能力,能够将学到的触发词查找能力转移到不同的数据集和多种关系上,从而提高对话关系抽取的性能。

SimpleRE^[7]:模型通过设计多个CLS标记来捕捉对话中多个关系之间的相互关系,并通过细化门改善关系分类的性能。

TUCORE-BERT^[18]:模型采用了带周围轮次掩码多头自注意力方法,从而捕捉对话轮次的上下文信息,帮助模型有效地全面理解对话信息。

表2 模型性能对比

Tabel 2 Model performance comparison

| Model | Dev | | Test | |
|-------------|-------------|-------------|-------------|-------------|
| | F1 | F1c | F1 | F1c |
| CNN | 46.1 | 43.7 | 48.0 | 45.0 |
| CGCN | 59.2 | — | 58.1 | — |
| BERT | 60.6 | 55.4 | 58.5 | 53.2 |
| DHGAT | 56.3 | 51.4 | 55.2 | 50.2 |
| TDGCN | 61.4 | 56.4 | 60.1 | 55.7 |
| TOD-BERT | 64.5 | — | 63.7 | — |
| SimpleRE | 63.9 | 58.3 | 62.8 | 58.9 |
| TREND | 64.2 | 58.4 | 63.1 | 58.8 |
| TUCORE-BERT | 64.6 | 58.2 | 63.4 | 59.6 |
| TLAG | 65.0 | 58.9 | 63.8 | 59.8 |
| Ours | 65.2 | 59.6 | 64.1 | 60.3 |

实验结果如表2所示。模型在测试集中的F1和F1c中的分数分别达到了64.1%和60.3%。与TDGCN模型相比,本文模型在验证集中的F1和F1c分数分别提高了3.8%和3.2%,在测试集中的F1和F1c分数分别提高了4%和4.6%。与TOD-BERT模型相比,本文模型在验证集中的F1分数提高了0.7%,在测试集中的F1分数提高了0.4%。结果表明,本文提出的模型通过利用关系相关性对关系进行定量分析,有效地捕捉了关系之间的相互依赖关系,并且本文构建的约束图可以明确指示主客体实体类型,一定程度上缓解了非对称互逆问题,从而改进了模型的性能。

为了进一步验证本文模型在解决长尾问题上的有效性,本文在DialogRE数据集上采用Hit@K评价标准来评估模型在长尾关系上的性能,其中Hit@K指的是在前K个预测中,模型正确预测的关系的比例。本文在训练集中统计了出现频

率少于100/200个训练实例的关系,然后将其关系ID映射到测试集中,最后在这些长尾关系中采用Hit@K评价标准对少于100和200的训练实例进行测试。实验结果如表3所示。

表3 长尾性能对比

Tabel 3 Long-tail performance comparison

| 训练实例 | <100 | | | <200 | | |
|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| | Hits@5 | Hits@10 | Hits@15 | Hits@5 | Hits@10 | Hits@15 |
| TUCORE GCN | 18.1 | 42.6 | 62.5 | 18.2 | 50.5 | 68.2 |
| SimpleRE | 12.5 | 27.4 | 59.8 | 21.4 | 35.7 | 63.9 |
| DHGAT | 17.1 | 40.2 | 62.9 | 20.1 | 51.5 | 66.8 |
| TDGCN | 17.4 | 39.7 | 63.7 | 18.9 | 49.3 | 67.7 |
| Ours | 37.1 | 63.8 | 79.2 | 59.4 | 77.8 | 82.5 |

实验结果表明,其他模型在长尾关系方面性能较差,而本文提出的模型通过构造约束图对实体类型和关系类型进行显式建模,将信息从数据丰富的关系传递到数据稀缺的关系从而有效地提升了模型在处理长尾关系上的性能。

4 消融实验

为了验证本文构建的实体类型约束图在模型中的作用,本文进一步探索约束图和约束图中的类型信息和约束信息的作用。为了评估类型信息的影响,本文将实体表示与其对应的类型表示进行拼接。为了评估约束信息的影响,本文在训练中删除了违反约束的实例,并在测试中将其预测为unanswerable。本文对出现频率少于100和200的训练实例采用Hit@K评价标准进行测试,同时也对数据集中的所有关系类型进行测试。实验结果如表4所示。

表4 消融实验

Tabel 4 Ablation experiment

| 模型 | All | | <100 | | <200 | |
|---------|-------|--------|-------|--------|-------|--------|
| | Hit@5 | Hit@10 | Hit@5 | Hit@10 | Hit@5 | Hit@10 |
| ETC-DRE | 55.5 | 69.4 | 37.1 | 63.8 | 59.4 | 77.8 |
| -约束图 | 41.4 | 51.3 | 17.1 | 40.2 | 20.1 | 51.5 |
| -类型信息 | 50.3 | 61.8 | 29.4 | 51.1 | 38.2 | 64.7 |
| -约束信息 | 43.2 | 54.7 | 20.7 | 48.4 | 29.2 | 60.2 |

实验结果表明,实体类型和关系约束的额外信息在长尾关系抽取方面带来了显著的提升。在删除约束图之后模型性能显著下降,这是由于模型无法捕捉关系之间的依赖性,缺少了约束条件,导致模型性能下降。在删除约束图中的类型信息后,模型无法聚焦于相关关系,导致处理长尾关系的能力下降。

实验结果表明,实体类型和关系约束的额外信息在长尾关系抽取方面带来了显著的提升。在删除约束图之后模型性能显著下降,这是由于模型无法捕捉关系之间的依赖性,缺少了约束条件,导致模型性能下降。在删除约束图中的类型信息后,模型无法聚焦于相关关系,导致处理长尾关系的能力下降。例如,如果一个实体为“地点”,模型可能会优先考虑“出生地”之类的关系,而这同时也加强了模型抗噪声的能力。在删除约束图中的约束信息后,模型在长尾关系方面的性能明显下降。这是由于约束信息可以帮助模型理解不同关系之间的相互关联,模型可以将已知关系的丰富信息传递给未知的尾部关系,从而帮助模型更好地学习尾部关系。并且约束信

息可以在训练过程排除违反约束的样本,从而减少噪声对模型的影响。

5 结论与展望

本文提出了一种基于实体类型约束的对话级关系抽取模型,与之前的研究方法不同,该模型通过构造一个类型约束图建立依赖路径来发掘关系之间潜在的联系。具体来说,约束图对所有关系类型所属的实体对类型进行了限制,不同的关系可能拥有共同的实体类型。通过这种方式可以在不同关系之间建立联系,再利用 GCN 网络的邻域融合机制将头部关系的丰富信息传递给尾部关系从而缓解尾部关系训练不足的情况。除此之外,由于约束图可以明确指示实体在关系三元组中作为主体还是客体,该方法对于解决对话级关系抽取中的非对称互逆问题具有重要意义。具体来说,在对话级关系抽取中,某些关系类型可能存在互逆性,即同一对实体在关系三元组中将主/客体位置变换会导致关系类型发生改变。

虽然本文通过构建约束图一定程度上缓解了长尾问题和非对称互逆问题,但在对话级关系抽取中,模型的跨句逻辑推理能力也同样重要。以 DialogRE 数据集为例,对话中存在大量人称代词并且信息密度较低,95.6%的关系三元组需要结合多个句子的上下文信息进行推理才能正确地关系进行分类。

在未来的工作中,本文提出的类型约束图方法将进一步应用于逻辑推理问题方面。本文将利用类型约束图的思想深入挖掘关系之间存在的潜在联系,特别是探索不同句子之间的依赖关系。这将帮助模型提升在处理长对话、跨句推理任务中的表现,使模型在对话级关系抽取中的推理能力得到提高。

6 示例学习

本文展示了模型在实验中的示例来进一步验证本模型中约束条件信息的有效性,如图 4 所示。

| 对话 | 实体类型 | 约束条件 | 分数 |
|---|------------|----------------|-------|
| <p>.....</p> <p>"S2: Maybe uh, Vunda could give me her number and I can ask her to dinner sometime."</p> <p>"S1: Okay, she would love that! Y'know, 'cause you know all the clean places to eat."</p> <p>.....</p> | (PER, PER) | 满足 | 0.954 |
| <p>.....</p> <p>"S2: So uh, what's your name?"</p> <p>"S1: It's Jake."</p> <p>"S2: Joey. Hey Jake, do you like the Knicks?"</p> <p>"S4: Yeah, big fan."</p> <p>"S2: Me too! There's a game on Tuesday do you wanna go?"</p> <p>.....</p> | (PER, ORG) | 不满足 | 0.009 |
| 关系类型: per:positive_impression | | 约束条件:(PER,PER) | |

注:图中加粗字体为待识别主客体,两段对话中的主客体属于同一关系类型。

图 4 示例学习

Fig. 4 Learning by examples

图 4 中两段对话中的待识别主客体都属于同一关系类型,即第 1 段对话中的主客体 S1、S2 和第 2 段对话中的主客体“Knicks”、S4 均属于关系类型 per:positive_impression。从图中可以看到,满足约束条件的第 1 段对话中的预测分数为

0.954,而第 2 段对话由于不满足约束条件被分配了较低的分。由此可以验证,本文的约束信息可以有效地从噪声数据中识别出正确结果,证明了约束信息的有效性。

References:

- [1] Ji S, Pan S, Cambria E, et al. A survey on knowledge graphs: representation, acquisition, and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(2): 494-514.
- [2] Budler L C, Gosak L, Stiglic G. Review of artificial intelligence-based question-answering systems in healthcare [J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2023, 13(2): e1487.
- [3] Ni J, Young T, Pandealea V, et al. Recent advances in deep learning based dialogue systems: a systematic survey [J]. Artificial Intelligence Review, 2023, 56(4): 3055-3155.
- [4] Sui D, Zeng X, Chen Y, et al. Joint entity and relation extraction with set prediction networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 35(9): 12784-12795.
- [5] Zheng Y, Guo Y, Luo Z, et al. A survey on document-level relation extraction: methods and applications [C] // 3rd International Conference on Internet, Education and Information Technology, 2023: 1061-1071.
- [6] Zhou P, Shi W, Tian J, et al. Attention-based bidirectional long short-term memory networks for relation classification [C] // Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), 2016: 207-212.
- [7] Xue F, Sun A, Zhang H, et al. An embarrassingly simple model for dialogue relation extraction [C] // International Conference on Acoustics, Speech and Signal Processing, 2022: 6707-6711.
- [8] Son J, Kim J, Li J, et al. GRASP: guiding model with relational semantics using prompt for dialogue relation extraction [C] // Proceedings of the 29th International Conference on Computational Linguistics, 2022: 412-423.
- [9] Albalak A, Embar V, Tuan Y L, et al. D-REX: dialogue relation extraction with explanations [J]. arXiv preprint arXiv: 2109.05126, 2021.
- [10] Chen X, Zhang N, Xie X, et al. Knowprompt: knowledge-aware prompt-tuning with synergistic optimization for relation extraction [C] // Proceedings of the ACM Web Conference, 2022: 2778-2788.
- [11] Zhao T, Yan Z, Cao Y, et al. Enhancing dialogue-based relation extraction by speaker and trigger words prediction [C] // Findings of the Association for Computational Linguistics, 2021: 4580-4585.
- [12] An H, Chen D, Xu W, et al. TLAG: an informative trigger and label-aware knowledge guided model for dialogue-based relation extraction [C] // 6th International Conference on Computer Supported Cooperative Work in Design, 2023: 59-64.
- [13] An H, Zhu Z, Cheng X, et al. Knowledge-enhanced prompt tuning for dialogue-based relation extraction with trigger and label semantic [C] // Proceedings of the Joint International Conference on Computational Linguistics, 2024: 9822-9831.
- [14] Qiu L, Liang Y, Zhao Y, et al. Socaog: incremental graph parsing for social relation inference in dialogues [J]. arXiv preprint arXiv: 2106.01006, 2021.
- [15] Lin P W, Su S Y, Chen Y N. TREND: trigger-enhanced relation-extraction network for dialogues [J]. arXiv preprint arXiv: 2108.

- 13811, 2021.
- [16] Chen H, Hong P, Han W, et al. Dialogue relation extraction with document-level heterogeneous graph attention networks[J]. *Cognitive Computation*, 2023, 15(10110):1-10.
- [17] Xue F, Sun A, Zhang H, et al. Gdpnet: refining latent multi-view graph for relation extraction[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021:14194-14202.
- [18] Lee B, Choi Y S. Graph based network with contextualized representations of turns in dialogue[J]. *arXiv preprint arXiv:2109.04008*, 2021.
- [19] 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.
- [20] Bai X, Chen Y, Song L, et al. Semantic representation for dialogue modeling[J]. *arXiv preprint arXiv:2105.10188*, 2021.
- [21] Jin Z, Yang Y, Qiu X, et al. Relation of the relations: a new paradigm of the relation extraction problem[J]. *arXiv preprint arXiv:2006.03719*, 2020.
- [22] Han R, Peng T, Wang B, et al. Document-level relation extraction with relation correlations[J/OL]. *Neural Networks*, 2024, 171:14-24, <http://arxiv.org/abs/2310.13000>.
- [23] Huang Y, Lin Z. Document-level relation extraction with relation correlation enhancement[C]//International Conference on Neural Information Processing, 2023:427-440.
- [24] Yu D, Sun K, Cardie C, et al. Dialogue-based relation extraction[J]. *arXiv preprint arXiv:2004.08056*, 2020.
- [25] Zhang Y, Qi P, Manning C D. Graph convolution over pruned dependency trees improves relation extraction[J]. *arXiv preprint arXiv:1809.10185*, 2018.
- [26] Devlin J. Bert: pre-training of deep bidirectional transformers for language understanding[J]. *arXiv preprint arXiv:1810.04805*, 2018.
- [27] ZI Y C, LI W J. TDGCN: research on conversation relationship extraction of two stage dynamic graph convolutional networks enhanced by triggers[J]. *Journal of Chinese Computer Systems*, 2025, 46(1):90-96.

附中文参考文献:

- [27] 自彦丞, 李卫疆. TDGCN: 触发器增强的两阶段动态图卷积网络的对话关系抽取研究[J]. *小型微型计算机系统*, 2025, 46(1):90-96.