计算机研究与发展
Journal of Computer Research and Development
https://crad.ict.ac.cn
62(4): 915−929, 2025

基于术语提示双路文本生成的方面情感三元组抽取

李银强[1] 蓝 天[2] 刘 瑶[1] 向飛阳[1] 孙丽纯[1] 杜知涵[1] 刘 峤[2]
[1](电子科技大学信息与软件工程学院 成都 610054)
[2](电子科技大学计算机科学与工程学院 成都 611731)
(202122090638@std.uestc.edu.cn)

Term-Prompted and Dual-Path Text Generation for Aspect Sentiment Triplet Extraction

Li Yinqiang[1], Lan Tian[2], Liu Yao[1], Xiang Feiyang[1], Sun Lichun[1], Du Zhihan[1], and Liu Qiao[2]
[1](*School of Information and Software Engineering*, *University of Electronic Science and Technology of China*, *Chengdu* 610054)
[2](*School of Computer Science and Engineering*, *University of Electronic Science and Technology of China*, *Chengdu* 611731)

Abstract Aspect sentiment triplet extraction (ASTE) is a challenging subtask within aspect-based sentiment analysis. It aims to extract triplets consisting of aspect terms, opinion terms, and sentiment polarities from texts. In the recent past, generative extraction techniques have demonstrated remarkable efficacy through the sequential concatenation of target triplets, thereby enabling the autoregressive generation of triplets. However, this concatenation method may lead to sequential dependencies among unrelated triplets, introducing error accumulation during decoding. To address this issue, we propose a term-prompted and dual-path text generation (TePDuP) method. This method first utilizes machine reading comprehension (MRC) to extract aspect and opinion term in parallel, and then uses them as prompt prefixes to guide conditional triplet generation, forming a dual-path text generation framework. Meanwhile, during the training phase, we incorporate scheduled sampling as a corrective measure to mitigate the bias stemming from MRC extraction. Furthermore, in order to enhance performance to an even greater extent, we incorporate generation probabilities to merge outcomes guided by aspect and opinion terms, thereby augmenting the resilience of the model. Experimental results on the ASTE-DATA-V2 dataset show that the proposed method is effective and significantly outperforms other baseline models, and provide case studies to demonstrate that the method solves the aforementioned problem to some extent.

Key words aspect based sentiment analysis; triplet extraction; text generation; machine reading comprehension (MRC); scheduled sampling

摘 要 方面情感三元组抽取(aspect sentiment triplet extraction, ASTE)是方面级情感分析(aspect based sentiment analysis, ABSA)中具有挑战性的子任务之一,旨在从文本中抽取方面术语、观点术语和情感极性三元组.近期基于生成式的抽取方法取得了出色的表现,这些方法通过顺序串联目标三元组来实现自回归式三元组生成.然而,这种串联方法可能导致无序三元组之间存在顺序依赖,从而在解码过程中引入错误累积.为解决这个问题,提出了基于术语提示双路文本生成(term-prompted and dual-path text generation, TePDuP)的方法.该方法首先利用机器阅读理解(machine reading comprehension, MRC)实现方面术语和观点术语的并行化抽取,然后将它们作为提示前缀来引导条件式三元组的生成,形成双路文本生成框架.同时,在训练阶段引入计划采样的方法来修正MRC抽取错误所带来的偏差.为进一步提高

收稿日期: 2023-10-31; **修回日期**: 2024-06-11
通信作者: 刘瑶(liuyao@uestc.edu.cn)

性能,引入生成概率将方面术语和观点术语引导的结果合并,以增强模型的鲁棒性.基于ASTE-DATA-V2数据集的实验结果表明,提出的方法是有效的且明显优于其他基线模型,并给出具体案例分析,证明该方法一定程度上解决了前述问题.

关键词 方面级情感分析;三元组抽取;文本生成;机器阅读理解;计划采样

中图法分类号 TP391

DOI: 10.7544/issn1000-1239.202330838 **CSTR:** 32373.14.issn1000-1239.202330838

方面级情感分析(aspect based sentiment analysis, ABSA)[1-2]是一种细粒度情感分析任务,旨在基于特定方面挖掘细粒度的观点和情感.ABSA涵盖了多个基础的任务,包括方面术语抽取(aspect term extraction, ATE)[3-5]、观点术语抽取(opinion term extraction, OTE)[6-7]和方面级情感分类(aspect level sentiment classification, ASC)[8-11].这些任务都涉及单个ABSA元素的预测,然而,近期研究进展将多个ABSA子任务合并成更复杂的任务[12-13],如方面情感三元组抽取(aspect sentiment triplet extraction, ASTE)[14].ASTE旨在从句子中抽取方面术语(aspect term)、观点术语(opinion term)和相关情感极性(sentiment polarity)的三元组,以提供更全面的情感信息,这有助于理解观点目标、情感取向以及表达这一情感的原因.与以往的单一ABSA任务相比,ASTE提供了更完整的情感信息.图1说明了一个ASTE的实例.三元组中从左往右分别是方面术语、观点术语和情感极性.其中,POS表示正向情感,NEG表示负向情感.

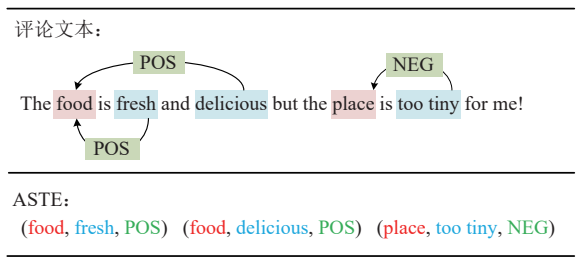
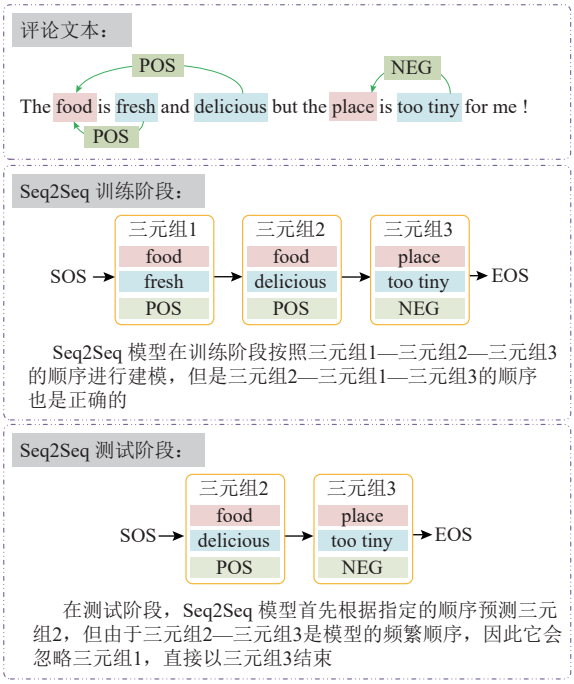


Fig. 1 An example of ASTE task

图1 ASTE任务示例

迄今为止,ASTE领域已经涌现了众多的研究工作,其中包括基于流水线的方法[14]、基于多任务学习[15]和各种标记方案的端到端的抽取方法[16-20],以及基于跨度表示[21-23]和基于机器阅读理解(machine reading comprehension, MRC)的方法[24-27].尽管这些方法在提高ASTE性能方面取得了显著进展,然而,ASTE领域仍然面临着多项挑战.

最近的生成式方法,如Seq2Seq的方法[28-32],它们将ASTE任务表述为文本到文本的生成任务,充分地利用预训练模型的知识,输出情感元组的序列.尽管在性能上取得了成功,但是仍然有一些很严重的缺点:Seq2Seq模型会对无序的三元组进行顺序建模,即元组生成方式为线性生成,当前元组依赖于之前元组的生成,会涉及到与错误累积相关联的大解码长度.上述问题都会引入与加重暴露偏差(exposure bias)[33-34],即在训练阶段,当前三元组的预测依赖于先前三元组的真实标签,而在测试或推理阶段,当前的三元组预测依赖于先前的模型预测的三元组,这可能与真实标签不同.在测试阶段,错误的预测将进一步偏离后续三元组的预测,如果解码长度较大,则与真实标签的差异将进一步加大.这种累积的差异可能会降低性能,尤其是在预测较长序列时,即多三元组预测.因此,基于上述问题模型会受到很多的学习约束,导致其做出“混乱的决策”.例如在图2中,ASTE并不是典型的生成任务,三元组之间的顺序并



注:SOS是start of sentence缩略词;EOS是end of sentence缩略词

Fig. 2 Training and prediction of Seq2Seq for different triplet orders

图2 Seq2Seq对不同三元组顺序的训练和预测

没有明确的规定，只要能准确提取，每一种顺序都可能是正确的，如顺序“三元组 1—三元组 2—三元组 3”和顺序“三元组 2—三元组 1—三元组 3”. 但是 Seq2Seq 模型在训练时会对一种顺序进行建模，而在测试时以任意顺序进行解码，这会导致模型可能预测错误.

在本文中，我们基于术语提示和双路文本生成提出了 TePDuP（term-prompted and dual-path text generation）模型，旨在改进生成式元组抽取方法. 这一模型的主要创新点在于充分利用了一个重要观察，即观点术语和方面术语与其相关的三元组和通常呈现出几乎一对一的关联特性. 因此可以将方面术语和观点术语作为生成条件引导三元组生成. TePDuP 模型利用 MRC 并行抽取方面术语和观点术语，将方面术语和观点术语视为 2 个引导方向，采用双路文本生成框架. 在训练阶段，将每个与方面术语和观点术语关联的三元组视为独立目标，使用标准的 Seq2Seq 模型进行学习，计算平均损失. 在推理阶段，通过将单个方面术语和观点术语作为条件式前缀提示，实现逐一生成三元组，从而避免了多个三元组一次性生成时带来的顺序依赖问题，有效提升了性能. 同时具有高条件概率的路径更有可能生成正确的答案，因此我们还引入了生成概率，自动选择合并正确的路径.

然而，上述方法会引入暴露偏差的问题，即训练阶段的条件式前缀提示是基于真实样本生成的，而测试和推理阶段则依赖于 MRC 抽取的结果，这可能与真实样本不一致. 因此，我们引入了计划采样（scheduled-sampling）的方法，将 MRC 抽取的样本纳入文本生成模型的训练中，以减轻流水线式推理过程中的误差累积问题，提高模型的鲁棒性.

我们的工作总结如下：

1）针对 ASTE 提出了 TePDuP 模型，该模型以 MRC 并行化抽取的方面术语和观点术语作为文本生成条件，把每个与方面术语和观点术语关联的三元组视为独立目标，使用 Seq2Seq 模型进行学习，避免了多个三元组同时生成时带来的顺序依赖问题. 同时为了提高预测性能，我们引入了生成概率合并方面术语和观点术语 2 条路径引导文本生成的结果.

2）针对文本生成在推理测试阶段中的术语结果与真实样本可能不相等的情况，我们设计了一个计划采样的方法，用于改善模型性能，增强模型的鲁棒性，将因 MRC 抽取错误所生成的样本进行修正.

3）TePDuP 在 ASTE-DATA-V2 数据集上达到了领先的性能，并给出了具体的案例分析，证明了该方法一定程度上改进了生成式元组抽取方法.

1 相关工作

近年来，ABSA 得到了十分广泛的研究，其任务都是围绕着方面目标进行展开的. 早期的 ABSA 研究主要侧重于单个元素的抽取与预测，例如 ATE、ACD（aspect category detection）[35-36]（检测文本中所提到的方面类别）、给定方面术语[37]或方面类别[38-39]预测情感极性等. 为了进行更全面的情感分析，最近的一些工作将多个情感元素组合起来进行联合检测，包括方面术语和观点术语的成对抽取（aspect-opinion pair extraction, AOPE）[40]；方面术语及其相应情感极性的预测 ASPE（aspect-sentiment pair extraction）[41-44].

近几年来，ABSA 中提出了三元组预测任务，旨在以三元组格式预测情感元素. Peng 等人[14]提出了 ASTE 任务，该任务一经提出立刻受到了大量关注. 他们首先介绍了 ASTE 任务，并提出了一个 2 阶段的方法. 第 1 阶段利用序列标记模型分别抽取带有情感的方面术语和观点术语. 在第 2 阶段，利用分类器从带有情感的方面术语和观点术语中找到有效的方面观点对，构建最终的三元组预测. 为了更好地利用多个情感元素的关系，目前已经提出了许多端到端的方法. Xu 等人[16]提出了一种位置感知标签方案，该方案通过丰富标签的表现力来解决一次性抽取三元组. Wu 等人[17]使用了一种 2 维表格填充的网格标记方案用于表示词对之间的关系，将任务转换为单词关系抽取任务. Chen 等人[18]在表格填充的网格标记方案的基础上，加入了语言特性并细化了词对表示以提高性能. 刘欣逸等人[19]在句法增强的基础上结合序列标记和网格标记，提出了一种多任务学习框架，以端到端的形式解决任务. Zhang 等人[20]为了克服多词方面术语和观点术语时会出现关系不一致和边界不敏感的情况，提出了边界驱动表填充，把每个三元组表示为 2 维表中的关系区域，并将 ASTE 任务转换为关系区域的检测和分类. 文献 [16–20] 的这些方法依赖于单词的表示与交互，在多词情况下可能表现不佳. Xu 等人[21]提出了一个跨度交互模型，明确考虑了跨度之间的交互，有效地提高了多词情况下的性能. Chen 等人[22]提出了一个跨度级双向网络，利用方面术语到观点术语和观点术语到方面术语 2 个方向的优势，采用相似跨度分离损失来指导模型区分相似跨度，以消除相互冲突的三元组结果.

Liang 等人[23]将 ASTE 任务定义为一个多类跨度分类问题, 通过抽取跨度级别的信息和约束来生成更准确的方面情感三元组.

其他建模范例, 如 MRC 和 Seq2Seq 建模也被应用到其中. Mao 等人[24]通过设计特定查询, 将 ASTE 转化为 MRC 任务, 提出了 dual-MRC 框架: 第 1 个 MRC 模型用于抽取方面术语, 第 2 个 MRC 模块随后预测相应的观点术语和情感极性. Chen 等人[25]在使用 BMRC 框架时从观点术语到方面术语和方面术语到观点术语 2 个方向进行了双向建模. 一个首先预测方面术语, 然后预测观点术语; 另一个首先预测观点术语, 然后预测方面术语. Zhai 等人[26]也在 MRC 建模基础上提出了 COM-MRC, 用于解决在多个方面术语时基于 MRC 的方法可能会由于其他方面术语的干扰而失败的情况. Liu 等人[27]在 BMRC 的基础上提出了 4 种优化策略, 以进一步加强抽取性能. Seq2Seq 建模在性能上取得了巨大的成功. Zhang 等人[28]将原始任务转化为文本生成问题, 并提出了注释样式和抽取样式, 用于预测情感三元组. 由于文献 [28] 方法没有利用标签信息, Zhang 等人[29]提出了一种释义建模方法, 将三元组转化为自然语言句子进行生成, 通过这种方式, 可以考虑标签信息的作用, 进而充分利用预训练模型的知识. Yan 等人[30]将句子作为输入, 并将各个元素的指针索引作为生成目标. Mao 等人[32]为了解决 Seq2Seq 建模中生成序列中的顺序建模问题, 以观点树的路径作为输出的目标, 大幅度提升了性能. 尽管关于 ASTE 任务的研究取得了重大的成果, 但其仍然在性能上面临着一定的挑战.

采用基于 Transformers 的预训练语言模型, 如 BERT[45]已成为解决 ABSA 问题的常见做法. 具体来说, 许多任务通过构造辅助句将任务转化为语言推理问题, 得以充分利用预训练语言模型的知识, 有效的提高性能. 例如 MRC 和 Seq2Seq 建模. MRC 旨在根据给定的上下文回答特定的问题. 最近的研究已经提出了基于上下文嵌入的 MRC 方法[46-47], 并取得了良好的效果, 尤其是基于 BERT 的 MRC 模型[45]. 目前, 已经有很多将 MRC 应用到 NLP 中的例子, 如命名实体识别[48]和实体关系抽取[49]等. 最近 MRC 也被应用到 ABSA 中, 成为一种常见的建模手段, 例如 Mao 等人[24]提出的 dual-MRC 框架和 Chen 等人[25]提出的 BMRC 框架, 在 ASPE, AOPE, ASTE 等任务中取得了良好的性能. 此外鉴于文本生成在其他 NLP 任务中所取得的成功, 有一些工作利用预训练文本生成模型[50-51]尝试以 Seq2Seq 方式解决 ABSA 问题, 例如 Yan 等人[30]和 Zhang 等人[28]把指针类别和情感元素序列作为生成模型的目标, 以更优雅的形式解决 ABSA 问题.

2 方法介绍

2.1 问题描述

设 $X=\{x_1,x_2,\cdots,x_n\}$ 是一个长度为 n 的文本, 设 $S=\{S_{1,1},S_{1,2},\cdots,S_{n,n}\}$ 是 X 中所有可能枚举跨度的集合, 任意一个跨度 $S_{i,j}$ 中 i 和 j 表示一个跨度在 X 中的起始位置和结束位置, $S_{i,j}$ 都有可能是方面术语或观点术语. 术语抽取的目的就是将 X 中所有方面术语和观点术语对应的跨度抽取出来. ASTE 的任务是抽取出文本中所有的方面层面的情感三元组 (a,o,s). a, o, s 分别对应于方面术语、观点术语和情感极性, 其中情感极性属于类别集合{POS, NEG, NEU}, 分别表示正向、负向和中性的情感.

2.2 模型架构

为了解决 ASTE 任务, 我们提出了一个基于术语提示双路文本生成的框架 TePDuP, 架构图如图 3 所示. 具体来说, 我们设计了术语抽取和文本生成 2 个模块. 首先在术语抽取模块, 使用了静态查询的方式, 根据给定的查询语句抽取所有方面术语和观点术语集. 接下来是文本生成模块, 以方面术语和观点术语构建条件式动态提示前缀, 分别引导文本生成形成一个双路文本生成框架, 旨在根据静态查询的结果提示文本生成, 生成相应的观点元组信息. 最后在推理阶段, 模型会把方面术语和观点术语形成的动态提示的生成结果合并在一起. 此外为了缓解术语抽取模块在推理阶段所产生的偏差, 我们还在术语抽取和文本生成 2 个模块之间加入了一个计划采样的机制用于修正术语抽取模块在推理阶段所产生的偏差.

2.3 查询与提示构建

我们使用基于模板的方法构建查询和提示. 具体来说, 设计了静态查询和动态提示. 静态查询不携带任何上下文信息. 动态提示需要静态查询的结果作为条件因素, 以引导文本生成模型搜索文本中有用的信息. 静态查询和动态提示用于将 ASTE 任务形式化为 MRC 任务和基于术语提示的双路文本生成任务.

1)静态方面查询 q_A. 我们设计了询问“What aspects?”从给定的文本中抽取一组方面术语 $A=\{a_i\}_{i=1}^{|A|}$.

2)静态观点查询 q_O. 我们设计了询问“What opinions?”从给定的文本中抽取一组观点术语 $O=\{o_i\}_{i=1}^{|O|}$.

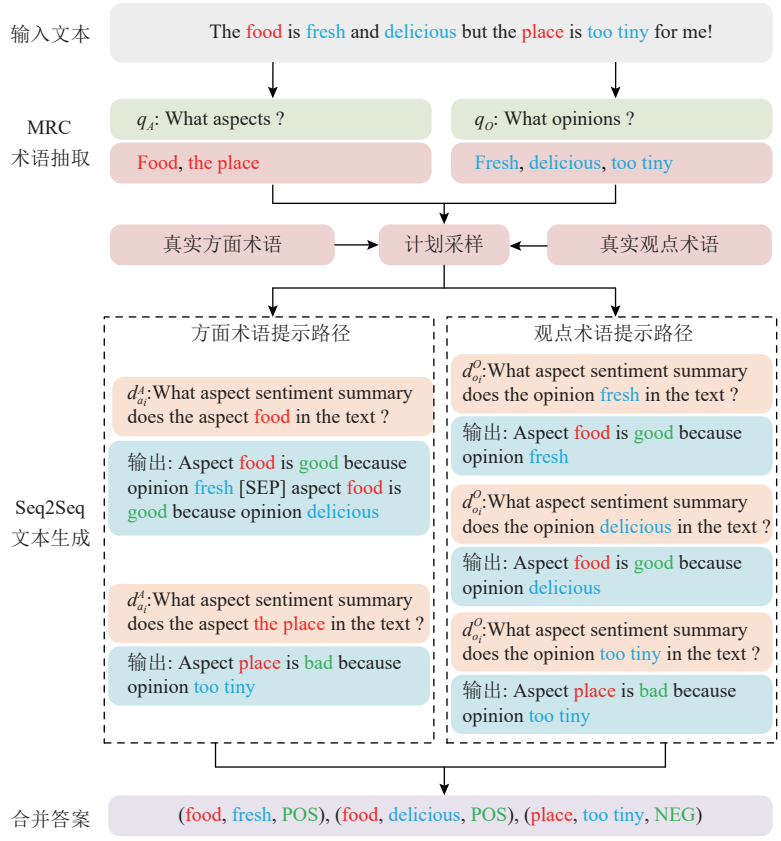


Fig. 3 Architecture of TePDuP

图 3 TePDuP 架构

3)动态方面术语提示 $d^A_{a_i}$. 设计一个基于方面术语 a_i 的动态提示："What aspect sentiment summary does the aspect a_i in the text?"，从给定的文本中生成一连串与方面术语 a_i 有关的方面情感摘要.

4)动态观点术语提示 $d^O_{o_i}$. 设计一个基于观点术语 o_i 的动态提示："What aspect sentiment summary does the opinion o_i in the text?"，从给定的文本中生成一连串与观点术语 o_i 有关的方面情感摘要.

通过上述查询和提示，文本生成优雅地学习了静态查询的结论，自然地集成了术语抽取和文本生成. 这一过程中静态查询不携带任何上下文信息，并行地输出文本中所有可能满足条件的跨度，接下来动态提示以这些跨度为生成条件，引导双路文本生成. 通过上述方式，将术语抽取和文本生成结合起来，以术语作为生成条件引导文本生成，可以极大程度避免多个三元组一次性生成时带来的顺序依赖问题.

2.4 术语抽取

在术语抽取中，我们使用的方法是 MRC 方法，并行地预测相关术语跨度的开始位置和结束位置. 在 MRC 中，有静态查询 $q_D=\{q^p_1,q^p_2,\cdots,q^p_{|q_D|}\}$，其中 D 表示查询的术语集合，即方面术语集合 A 和观点术语集合 O；还有一个长度为 n 的文本 $X=\{x_1,x_2,\cdots,x_n\}$. 我们使用带有 Transformer 结构的编码器作为 MRC 的编码器. 首先，将查询 q_D 与句子 X 拼接起来，得到输入 $I=\{[\mathrm{CLS}],q^D_1,q^D_2,\cdots,q^D_{|q_D|},[\mathrm{SEP}],x_1,x_2,\cdots,x_n\}$，[CLS] 和 [SEP] 分别是开始标记和段标记. 接下来 I 被具有 Transformer 结构的编码器编码为上下文表示序列 $H_{\mathrm{M}}=\{\boldsymbol{h}_1,\boldsymbol{h}_2,\cdots,\boldsymbol{h}_{|q_D|+2+n}\}$.

术语抽取的答案为文本中的跨度，我们使用二元分类器来预测答案跨度，具体来说，对于一个上下文表示的编码序列 H_{M}，一个分类器用于预测每一个位置是否是答案跨度的开始位置，另外一个分类器用于预测每一个位置是否是答案跨度的结束位置：

$$\hat{\boldsymbol{P}}^{\mathrm{start}}_{x_j,q_D}=softmax(\boldsymbol{h}_{j+2+|q_D|}\boldsymbol{W}_{\mathrm{start}}), \tag{1}$$

$$\hat{\boldsymbol{P}}^{\mathrm{end}}_{x_j,q_D}=softmax(\boldsymbol{h}_{j+2+|q_D|}\boldsymbol{W}_{\mathrm{end}}), \tag{2}$$

其中 $\boldsymbol{W}_{\mathrm{start}}\in\mathbb{R}^{d_H\times 2}$ 和 $\boldsymbol{W}_{\mathrm{end}}\in\mathbb{R}^{d_H\times 2}$ 都是模型的可训练参数，d_H 表示 H_{M} 中的向量的隐藏层维数. 损失函数为 $\mathcal{L}_1=-\sum_{j=1}^{n}[\boldsymbol{P}^{\mathrm{start}}_{x_j,q_D}\ln\hat{\boldsymbol{P}}^{\mathrm{start}}_{x_j,q_D}+\boldsymbol{P}^{\mathrm{end}}_{x_j,q_D}\ln\hat{\boldsymbol{P}}^{\mathrm{end}}_{x_j,q_D}]$，其中 $\boldsymbol{P}$ 表示真实的概率分布，$\hat{\boldsymbol{P}}$ 表示模型预测的概率分布.

对方面术语和观点术语使用 MRC 框架进行抽

取时, 共用同一个编码器, 且各自使用单独的分类器. 在预测跨度时, 对于每一个位置, 根据模型预测的概率分布 $\hat{\boldsymbol{P}}$, 当其作为开始或结束位置的概率大于非开始或非结束位置的概率时, 可以预测出多个可能的开始或结束位置. 匹配它们的规则十分重要, 这将影响模型的性能. 匹配规则应该考虑开始位置和结束位置的概率, 以及位置之间的关系. 我们的匹配规则具体来说是: 每一个结束位置匹配在之前未匹配的概率最大的开始位置, 如果多个位置概率相同, 则匹配最近的位置.

2.5 文本生成

鉴于文献 [29] 将文本生成(text generation)应用到 ABSA 任务上所取得的成功, 我们使用了释义建模方法, 将观点抽取任务转换为文本生成任务. 由于 ASTE 任务中有方面术语和观点术语, 因此有 2 个提示方向, 分别是方面术语提示路径和观点术语提示路径.

现在假设有一个长度为 m 的基于 a_i 的动态方面术语提示 $d^A_{a_i}=\{d^{a_i}_1,d^{a_i}_2,\cdots,d^{a_i}_m\}$, 以及一个长度为 n 的句子 $X=\{x_1,x_2,\cdots,x_n\}$. 接下来, 将动态方面术语提示 $d^A_{a_i}$ 和句子 X 组合起来得到文本生成的输入 $X_{\mathrm{G}}=\{[\mathrm{CLS}],d^{a_i}_1,d^{a_i}_2,\cdots,d^{a_i}_m,[\mathrm{SEP}],x_1,x_2,\cdots,x_n\}$, [CLS] 和 [SEP] 分别是开始标记和段标记. 同理, 假设有一个长度为 m 的基于 o_i 的动态观点术语提示 $d^O_{o_i}=\{d^{o_i}_1,d^{o_i}_2,\cdots,d^{o_i}_m\}$, 以及一个长度为 n 的文本 $X=\{x_1,x_2,\cdots,x_n\}$, 则可以得到文本生成的输入 $X_{\mathrm{G}}=\{[\mathrm{CLS}],d^{o_i}_1,d^{o_i}_2,\cdots,d^{o_i}_m,[\mathrm{SEP}],x_1,x_2,\cdots,x_n\}$.

接下来假设包含方面术语 a_i 或者观点术语 o_i 的三元组为 (a,o,s), 首先对情感 s 按照式(3)进行投影:

$$F_s(s)=\begin{cases}\text{good, if } s \text{ is POS},\\ \text{bad, if } s \text{ is NEG},\\ \text{so-so, if } s \text{ is NEU},\end{cases}\tag{3}$$

其中 $F_s(s)$ 为情感 s 的投影函数. 然后我们将三元组 (a,o,s) 按照模板 "aspect a is $F_s(s)$ because opinion o" 转化成一个方面级情感摘要, 在推理测试阶段可以根据该模板还原三元组. 如果包含方面术语 a_i 或者观点术语 o_i 的三元组存在多个, 则利用 [SEP] 把多个方面级情感摘要进行拼接, 得到文本生成的目标 Y_{G}, 令 $Y_{\mathrm{G}}=\{y_1,y_2,\cdots,y_N\}$, 其中 N 表示 Y_{G} 的长度.

对于文本生成的输入与输出, 我们使用经典的 Encoder-Decoder 模型 Transformers 进行建模. 给定一个输入 X_{G}, 编码器首先将其编码为一个上下文表示的编码序列 H_{G}:

$$H_{\mathrm{G}}=Encoder(X_{\mathrm{G}}),\tag{4}$$

其中编码序列 $H_{\mathrm{G}}=\{\boldsymbol{h}^{\mathrm{G}}_1,\boldsymbol{h}^{\mathrm{G}}_2,\cdots,\boldsymbol{h}^{\mathrm{G}}_{|H_{\mathrm{G}}|}\}$, $Encoder(\cdot)$ 表示 Transformers 的编码器. 然后, 解码器将以自回归的形式进行解码生成目标序列 Y_{G}, 并对目标序列 Y_{G} 的条件概率 $p_\theta(Y_{\mathrm{G}}|H_{\mathrm{G}})$ 进行建模, θ 表示模型的参数. 具体而言, 在解码器的第 i 步, 解码器根据编码序列 H_{G} 和先前的解码标记计算解码器的隐藏状态 $\boldsymbol{s}_i$:

$$\boldsymbol{s}_i=Decoder(H_{\mathrm{G}},y_1,y_2,\cdots,y_{i-1}),\tag{5}$$

其中 $Decoder(\cdot)$ 表示 Transformers 的解码器, $y_1,y_2,\cdots,y_{i-1}$ 表示之前的解码标记. 接下来利用隐藏状态 $\boldsymbol{s}_i$ 计算第 i 步解码标记的条件概率分布:

$$\boldsymbol{P}_\theta(y_i|H_{\mathrm{G}},y_1,y_2,\cdots,y_{i-1})=softmax(\boldsymbol{W}^{\mathrm{T}}_{\mathrm{G}}\boldsymbol{s}_i),\tag{6}$$

其中 $\boldsymbol{W}_{\mathrm{G}}$ 用于将 $\boldsymbol{s}_i$ 映射到词汇表的 logit 向量, 然后使用该向量计算整个词汇集上的概率分布. 最后从这个概率分布中得到第 i 步的解码标记 y_i 的条件概率, 记为 $p_\theta(y_i|H_{\mathrm{G}},y_1,y_2,\cdots,y_{i-1})$.

在具有预训练的 Encoder-Decoder 的模型中, 如 T5, 我们可以用预训练的参数权重进行初始化 θ, 在此基础上进一步微调输入输出目标对上的参数, 训练目标为 $\mathcal{L}_2=-\sum_{i=1}^{N}\ln p_\theta(y_i|H_{\mathrm{G}},y_1,y_2,\cdots,y_{i-1})$, 其中 N 是目标序列 Y_{G} 的长度.

2.6 训练与推理

2.6.1 计划采样

暴露偏差(exposure bias)[34] 就是指训练时的每个输入都来自于真实样本的标签, 测试时的输入却是来自上一步的输出. 在 TePDuP 中, 训练时第 2 阶段的所有提示输入都基于真实样本的标签, 而在测试时第 2 阶段的提示输入是来自第 1 阶段的输出, 因此存在暴露偏差问题. 为了解决这个问题, 我们引入了计划采样, 通过概率控制真实样本和第 1 阶段输出的比例, 以防止全部采用真实样本引起矫枉过正. 具体步骤如下:

1)文本生成的过程中设置了一个变量 R, 其初始值为 1, R 随着训练步数的增加而变小.

2)在每一步训练过程中, 我们都将生成一个范围在 [0,1] 之间的随机数 $Random$.

3)如果 $Random<R$, 文本生成训练的输入为真实术语对应的提示输入. 反之 $Random\geq R$, 文本生成训练的输入为 MRC 抽取的术语对应的提示输入.

对于 MRC 抽取的术语对应的输出, 我们采取如下的步骤进行确定:

1)假设抽取的术语为 sp, 其对应的跨度的开始位置和结束位置为 st_{p} 和 ed_{p}. 与 sp 术语类型相同的正

确的术语集合为$T=\{t_i\}_{i=1}^{|T|}$，假设第 i 个术语对应的跨度的开始位置和结束位置为st_i和ed_i.

2）术语 sp 与集合 T 中的每一个术语t_i进行匹配，定义术语 sp 和t_i之间关系为

$$r(sp,t_i)=\begin{cases}1, & \text{if } (st_{\mathrm{p}}\geqslant st_i \text{ and } ed_{\mathrm{p}}\leqslant ed_i)\\ & \text{or } (st_{\mathrm{p}}\leqslant st_i \text{ and } ed_{\mathrm{p}}\geqslant ed_i),\\ 0, & \text{其他},\end{cases}$$

其中$r(sp,t_i)=1$表示 sp 和t_i之间有关联，$r(sp,t_i)=0$表示 sp 和t_i之间没有关联.

3）如果$r(sp,t_i)=1$，并且t_i为方面术语时则对应的动态术语提示$d_{t_i}^{A}$为“What aspect sentiment summary does the aspect sp in the text?”，如果t_i为观点术语时则对应的动态术语提示$d_{t_i}^{O}$为“What aspect sentiment summary does the opinion sp in the text?”. 对应的输出则为包含t_i的三元组所对应的输出，具体如 2.5 节所描述.

这样做是因为在术语抽取中，其输出的不正确的术语与正确的术语相比，会有一些缺失或多余，有一部分不正确术语是包含了正确术语或者正确术语的关键信息的. 并且文本生成的输出包含了整个三元组，通过训练模型是能够在提示前缀中捕捉到正确信息的. 我们没有考虑 sp 和t_i部分相交的情况，这是因为需要考虑相交部分在 2 个术语中的重要性，我们也尝试考虑过这种情况，但得到了与上述的方案相近的结果，为了简单起见本文只采用上述的方法.

2.6.2 推理过程

为了合并基于方面术语提示和基于观点术语提示的答案，这里需要计算三元组的生成概率. 对于给定文本可以通过静态查询得到一组方面术语$A=\{a_i\}_{i=1}^{|A|}$和一组观点术语$O=\{o_i\}_{i=1}^{|O|}$. 在 MRC 中，术语t_i的概率等于其开始位置 l 和结束位置 r 的概率的乘积：

$$p(t_i)=\hat{p}_{x_l,q_D}^{\text{start}}\times\hat{p}_{x_r,q_D}^{\text{end}},\tag{7}$$

其中 D 表示查询的术语集合类型与t_i的术语类型相同，$\hat{p}_{x_l,q_D}^{\text{start}}$表示位置 l 为开始位置的概率，$\hat{p}_{x_r,q_D}^{\text{end}}$表示位置 r 为结束位置的概率，$\hat{p}_{x_l,q_D}^{\text{start}}$和$\hat{p}_{x_r,q_D}^{\text{end}}$都可以通过 MRC 预测过程中得到的 2 维概率分布$\hat{\boldsymbol{P}}_{x_l,q_D}^{\text{start}}$和$\hat{\boldsymbol{P}}_{x_r,q_D}^{\text{end}}$得到. 三元组的概率可以简单地认为等于其方面术语或观点术语与生成文本的生成概率的乘积.

对于一条文本，假设基于方面术语a_i提示生成的三元组集合为V_{a_i}，基于观点术语o_i提示生成的三元组集合为V_{o_i}，那么三元组 T 的生成概率为

$$p(T)=\begin{cases}\sqrt{p(a_i)p(Y_{\mathrm{G}}|a_i)}, & \text{if } T\in V_{a_i},\\ \sqrt{p(o_i)p(Y_{\mathrm{G}}|o_i)}, & \text{if } T\in V_{o_i},\end{cases}$$

其中$p(Y_{\mathrm{G}}|a_i)$和$p(Y_{\mathrm{G}}|o_i)$为文本生成模型生成目标序列Y_{G}的生成概率，具体为每一步条件概率的乘积$\prod_{i=1}^{n}p_\theta(y_i|H_{\mathrm{G}},y_1,y_2,\cdots,y_{i-1})$；另外为了在训练阶段更容易得到性能最佳的模型，我们在$p(T)$的表达式中加上根号以平滑生成概率. 同时在一个动态术语提示生成文本中可能会包含多个三元组，用生成文本的生成概率去计算三元组的生成概率并不是很严谨，但是在大部分情况下生成文本中只包含 1 个三元组. 为了简单起见这里就利用了生成文本的生成概率去计算三元组的生成概率. 设V_a为所有集合V_{a_i}的并集，V_o为所有集合V_{o_i}的并集. 此时可以合并 2 个提示路径上的答案：

$$V=V_1\cup\{T|T\in V_2,p(T)>\delta\},\tag{8}$$

其中 T 表示三元组(a,o,s)，V_1 表示V_a和V_o的交集，V_2 表示V_a和V_o的对称差，δ为超参数，$\delta\in[0,1]$. 基于上述方案，可以得到最终的三元组集合V.

2.6.3 损失函数

模型在训练过程中的损失总共有 2 个部分，即术语抽取和文本生成，因此总的损失函数为$\mathcal{L}=\lambda_1\mathcal{L}_1^A+(1-\lambda_1)\mathcal{L}_2^A+\lambda_2\mathcal{L}_1^O+(1-\lambda_2)\mathcal{L}_2^O$，其中 λ_1，$\lambda_2\in[0,1]$，$\mathcal{L}_1^A$为方面术语抽取的损失，$\mathcal{L}_1^O$为观点术语抽取的损失，$\mathcal{L}_2^A$为基于方面术语提示的文本生成的损失，$\mathcal{L}_2^O$为基于观点术语提示的文本生成的损失.

3 实验分析

3.1 实验数据

为了验证 TePDuP 的有效性，我们在 ASTE-DATA-V2[16] 数据集上进行了验证，ASTE-DATA-V2 是 ASTE 任务的基线数据集，其中包含了 14res, 14lap, 15res, 16res 这 4 个子数据集. 数据集源自 Laptop14, Rest14, Rest15, Rest16, 它们来自一个共同的竞赛 SemEval[2, 52-53]. ASTE-DATA-V2 数据集是 ASTE-DATA-V1[14] 数据集的改进版本，它完善了数据并消除一些情感冲突三元组.

3.2 评估指标

我们使用精确率 P、召回率 R 和 $F1$ 值作为评估指标来衡量性能. 当且仅当正确预测方面术语、观点术语和情感极性时，三元组预测才正确.

3.3 对比模型

进行比较的基线模型，大致可以分为基于流水线的方法[14]、基于 MRC 建模的方法[25-27]、基于跨度表示的方法[21-23]、基于生成式模型的 Seq2Seq 建模的方法[28-32] 以及基于统一标记方案的端到端的方法[16-18,20].

具体的方法介绍如下:

1)Two-Stage(2020)[14]. 一种基于流水线的方法,第 1 阶段抽取带有情感的方面术语和观点术语. 第 2 阶段从抽取的方面术语和观点术语中找到有效的方面-观点对,形成三元组预测.

2)JET(2020)[16]. 该方法设计了一种位置感知标记方案,用于丰富标签表示,将任务转化为序列标记任务以一次性地从文本中抽取所有的三元组.

3)GTS(2020)[17]. 该方法与 JET 类似都是设计了一种统一的标记方案. 该方法使用了一种网格标记法,学习词与词之间或者网格的表示,最终从网格中还原三元组.

4)Span-ASTE(2021)[21]. 一种跨度级交互模型,明确考虑各整体跨度之间的交互,该方法注重多词组合之间的交互,在多词情况下性能提升明显.

5)BMRC(2021)[25]. 该方法使用的是双向 MRC 框架,一个先预测方面术语,再预测观点术语,另一个先预测观点术语,再预测方面术语. 最后进行情感分类,得到最终的三元组.

6)EMC-GCN(2022)[18]. 该方法基于网格标记法,充分利用了语言特性,利用多通道图来编码和学习词与词之间的关系,设计并细化了词对的表示.

7)GAS(2021)[28]. 一种 Seq2Seq 建模方法,输入是句子,输出是观点元组. 该方法使用注释式和抽取式 2 种生成范式.

8)ParaPhrase(2021)[29]. 一种 Seq2Seq 建模的方法,该方法输入句子. 然后将情感元组释义建模为自然语言句子并作为生成目标. 最后从生成的句子中还原情感元组.

9)BART-ABSA(2021)[30]. 一种 Seq2Seq 建模的方法,将句子作为输入,并将指针索引作为生成目标. 将术语的开始索引和结束索引作为预测目标.

10)SEL&&SSI(2022)[31]. 一种 Seq2Seq 建模的方法,输入句子和任务信息,输出结构化观点元组,其根据是否利用外部知识被分为 SEL 和 UIE 这 2 个版本.

11)RoBMRC(2022)[27]. 在 BMRC 的基础上提出了 4 种优化策略,以进一步加强抽取性能.

12)COM-MRC(2022)[26]. 提出了一种上下文掩码 MRC,用于解决在多个方面术语时 MRC 可能会由于其他方面术语的干扰而失败的情况.

13)SBN(2022)[22]. 提出了一个跨度级双向网络指导模型区分相似跨度. 设计了一种推理策略,以消除特定于跨度模型的相互冲突的三元组结果.

14)Seq2Path(2022)[32]. 在 Seq2Seq 建模的基础上将线性生成方式更改为了树结构输出方式,以无序的方式输出情感元组.

15)BDTF(2022)[20]. 一种边界驱动表格填充的方法,将三元组表示为 2 维表中的关系区域,并将 ASTE 任务转换为关系区域的检测和分类.

16)STAGE(2023)[23]. STAGE 将 ASTE 任务定义为一个多类跨度分类问题,通过抽取跨度级别的信息和约束来生成更准确的方面情感三元组.

3.4 实验设置

我们主要使用了 T5-base[50] 模型作为 2.5 节中描述文本生成阶段的文本生成模型,该模型采用了 Transformer 的 encoder-decoder 网络体系结构. 同时使用 T5-base 的 encoder 作为 MRC 的编码器,文本生成和 MRC 的 T5-base 的 encoder 参数进行共享. 在训练过程中 T5-base 的学习率为 3E−4,模型其他部分的学习率为 1E−3,训练轮数为 20,批处理的大小设置为 8. 计划采样的方式采用了自然指数形式,即 $R = R_0 e^{-step}$, R_0 为初始值 1, $step$ 为训练步数. 超参数 δ 的取值为 0.95, λ_1, λ_2 取值分别为 0.03, 0.03. $F1$ 值在实验中至少获得了 3 次结果,并对结果进行平均.

3.5 实验结果

实验结果如表 1 所示,其中“*”标记的 ParaPhrase 方法按照相关文献和代码给的实验参数,将文本生成的释义建模变更为第 2 节所述的释义建模,进行复现得到结果, $F1$ 值与原始文献十分接近. “*”标记的 BMRC, RoBMRC, COM-MRC 方法则是将编码器从 BERT 替换为 T5-base 的 encoder 复现得到的结果. 从表 1 来看, TePDuP 远远领先于 Peng-two-stage,说明了 ASTE 任务的复杂性,不是一般的基于流水线的方法能够处理的. 与基于统一标记方案的端到端的方法,如 JET, GTS, EMC-GCN 等方法相比, TePDuP 在精确率 P、召回率 R 和 $F1$ 值上大幅度领先,其中 $F1$ 值与 EMC-GCN 相比平均领先 6.45 个百分点. 另外我们也发现基于 MRC 和基于跨度表示的方法也取得了不错的成绩,尤其是基于 BMRC 进行改进的 RoBMRC 和基于跨度表示的 SBN 取得了十分不错的成绩. 与 RoBMRC, SBN, BDTF 这 3 个强基线相比, TePDuP 在 4 个数据集上的平均 $F1$ 值上分别领先 3.53, 3.19, 3.04 个百分点. 与基于 Seq2Seq 建模方法相比, TePDuP 也是大幅度领先于这些方法,其中与强基线 UIE-base 相比, TePDuP 在 4 个数据集上的平均 $F1$ 值上领先 3.47 个百分点. 另外,我们还发现 Seq2Path 以观点树的形式生成三元组,提升了生成模型的抽取性能;但 Seq2Path 在生成路径过程中当前标记的生成依赖于

Table 1 Main Experimental Results of the Four Sub-Datasets of ASTE-DATA-V2 Dataset

表 1 ASTE-DATA-V2 数据集的 4 个子数据集上的主要实验结果 %

模型	14res			14lap			15res			16res		
	P	*R*	*F*1	*P*	*R*	*F*1	*P*	*R*	*F*1	*P*	*R*	*F*1
Peng-two-stage[18]	43.24	63.66	51.46	37.38	50.38	42.87	48.07	57.51	52.32	46.96	64.24	54.21
JET[18]	70.56	55.94	62.40	55.39	47.33	51.04	64.45	51.96	57.53	70.42	58.37	63.83
GTS[18]	68.09	69.54	68.81	59.40	51.94	55.42	59.28	57.93	58.60	68.32	66.86	67.58
EMC-GCN[18]	71.21	72.39	71.78	61.70	56.26	58.81	61.54	62.47	61.93	65.62	71.30	68.33
Span-ASTE[21]	72.89	70.89	71.85	63.44	55.84	59.38	62.18	64.45	63.27	69.45	71.17	70.26
SBN[22]	76.36	72.43	74.34	65.68	59.88	62.65	69.93	60.41	64.82	71.59	72.57	72.08
STAGE[23]	78.58	69.58	73.76	70.56	55.16	61.88	72.33	58.93	64.94	78.38	69.10	73.45
BMRC*	75.19	68.31	71.58	70.70	53.77	61.09	64.33	58.76	61.42	73.22	65.95	69.40
RoBMRC*	73.15	71.83	72.48	65.52	59.85	62.56	65.77	65.36	65.56	70.39	73.54	71.93
COM-MRC*	71.76	70.82	71.29	65.52	**63.58**	64.54	65.84	**65.98**	65.91	65.64	74.32	69.71
BART-ABSA[18]	65.52	64.99	65.25	61.41	56.19	58.69	59.14	59.38	59.26	66.60	68.68	67.62
ParaPhrase*	73.41	70.82	72.09	64.31	58.74	61.40	60.85	64.74	62.73	70.42	71.79	71.10
GAS[28]			72.16			60.78			62.10			70.10
UIE-base[31]			72.55			62.94			64.41			72.86
Seq2Path[32]			75.52			65.27			65.88			73.67
BDTF[20]	75.53	**73.24**	74.35	68.94	55.97	61.74	68.76	63.71	66.12	71.44	73.13	72.27
TePDuP（本文）	**80.79**	73.20	**76.80**	**74.79**	60.58	**66.93**	**73.35**	61.64	**66.92**	**77.53**	**74.51**	**75.99**

注：“*”标记的方法的数据来自我们复现的结果，黑体数值表示最优值.

先前标记，存在一定的误差传播问题，可能导致了其性能弱于 TePDuP.

同时我们也对 MRC 和文本生成阶段进行了实验，实验结果见表 2 和表 3. 从表 3 中可以观察到，如果第 1 阶段的结果完全正确，第 2 阶段的性能将显著优于 2 个阶段联合的结果. 然而第 1 阶段的抽取结果并不会完全正确，因此就会出现误差传播的情况，从而影响第 2 阶段的结果.

在 T5-base 的基础上，我们还引入了在 ABSA 中常用的预训练生成模型，包括 T5-small, T5-large, BART-base. 同时，我们对几个强基线算法和生成式方法的预训练模型的参数和性能进行了统计，结果如表 4 所示. 从表 4 中可以观察到，对于多个 MRC 方法而言，BMRC 在替换掉编码器后性能有明显的提升，而其他 2 种方法整体上得到了较为相近的结果. 值得注意的是，COM-MRC 方法替换掉编码器后在 14lap 数据集上提升较为明显. 然而，基于 BART-base 的模型相

Table 2 Extraction Results of ATE and OTE for the Four Sub-Datasets of ASTE-DATA-V2 Dataset

表 2 ASTE-DATA-V2 数据集的 4 个子数据集上方面术语抽取与观点术语抽取结果 %

数据集	方面术语抽取			观点术语抽取		
	P	*R*	*F*1	*P*	*R*	*F*1
14res	87.03	74.95	80.54	85.58	74.65	79.74
14lap	87.77	74.03	80.32	87.14	72.38	79.07
15res	83.94	76.49	80.04	81.17	74.64	77.76
16res	83.99	78.60	81.21	83.66	82.68	83.17

Table 3 Text Generation Results Based on Term Prompts for the Four Sub-Datasets of ASTE-DATA-V2 Dataset

表 3 ASTE-DATA-V2 数据集的 4 个子数据集上基于术语提示的文本生成结果 %

数据集	提示路径	文本生成		
		P	*R*	*F*1
14res	方面术语	83.18	82.79	82.99
	观点术语	85.10	81.79	83.41
14lap	方面术语	74.30	70.10	72.14
	观点术语	75.24	73.29	74.25
15res	方面术语	73.03	73.81	73.41
	观点术语	77.71	77.38	77.54
16res	方面术语	83.57	82.42	82.99
	观点术语	83.16	81.71	82.42

Table 4 Performance of Different Pre-Trained Models on the Four Sub-Datasets of ASTE-DATA-V2 Dataset in Terms of *F*1-score

表 4 不同预训练模型在 ASTE-DATA-V2 数据集的 4 个子数据集上的 *F*1 值表现 %

模型	预训练模型	预训练模型参数量	14res	14lap	15res	16res	平均
BMRC	BERT-base-uncased	109×10^6	67.99	57.82	60.02	65.75	62.90
	T5-base. encoder	110×10^6	71.58	61.09	61.42	69.40	65.87
RoBMRC	BERT-base-uncased	109×10^6	72.62	62.12	65.63	73.16	68.38
	T5-base. encoder	110×10^6	72.48	62.56	65.56	71.93	68.13
COM-MRC	BERT-base-uncased	109×10^6	72.01	60.17	64.53	71.57	67.07
	T5-base. encoder	110×10^6	71.29	64.54	65.91	69.71	67.86
BART-ABSA	BART-base	139×10^6	65.25	58.69	59.26	67.62	62.71
GAS	T5-base	223×10^6	72.16	60.78	62.10	70.10	66.29
ParaPhrase	T5-base	223×10^6	72.09	61.40	62.73	71.10	66.83
Seq2Path	T5-base	223×10^6	75.52	65.27	65.88	73.67	70.09
UIE	UIE-base	223×10^6	72.55	62.94	64.41	72.86	68.19
	UIE-large	750×10^6	74.52	63.88	67.15	75.07	70.16
BDTF	BERT-base-uncased	109×10^6	74.35	61.74	66.12	72.27	68.62
	DeBERTa-v3-base	184×10^6	75.48	66.71	<u>68.22</u>	75.36	71.44
TePDuP（本文）	BART-base	139×10^6	72.21	62.01	62.82	71.36	67.10
	T5-small	61×10^6	73.17	62.46	64.70	73.70	68.51
	T5-base	223×10^6	<u>76.80</u>	<u>66.93</u>	66.92	<u>75.99</u>	<u>71.66</u>
	T5-large	750×10^6	**77.16**	**67.75**	**68.25**	**76.46**	**72.40**

注：黑体数值表示最优值，划线数值表示次优值.

较于基于 T5-base 的模型表现较差. 此外，在 TePDuP 方法测试的 BART-base, T5-small, T5-base, T5-large 预训练模型中，我们发现 T5-small 取得了不错的成绩，超过了大部分的抽取式和生成式方法. 考虑到 T5-small 的参数量较小，这可能在一些设备资源有限的情况下具有用处.

3.6 消融实验

为了验证本文中所提出的创新点和观点的有效性，我们在 ASTE-DATA-V2 数据集上与基于 Seq2Seq 建模的方法进行了消融实验. 实验结果如表 5 所示. 首先可以发现计划采样对于模型的性能提升是明显的，可以看到针对单独每一个路径，加入计划采样的提示是明显的，方面术语路径加入计划采样平均 *F*1 值提升 0.80 个百分点，观点术语路径加入计划采样平均 *F*1 值提升 0.87 个百分点，2 条路径的合并结果在加入计划采样后性能 *F*1 值提升了 1.20 个百分点. 接下来，从表 5 中可以发现，没有合并 2 条路径的结果并不是很好，但是还是领先于大部分基于 Seq2Seq 建模的生成式方法，这说明了我们将术语用于提示文本生成这个思路是有效的. TePDuP 与 ParaPhrase 相比，引入了条件提示前缀与计划采样，对文本生成

Table 5 *F*1-score Ablation Experimental Results on the Four Sub-Datasets of ASTE-DATA-V2 Dataset

表 5 ASTE-DATA-V2 数据集的 4 个子数据集上的 *F*1 值消融实验结果 %

模型	14res	14lap	15res	16res	与 TePDuP 平均 *F*1 值的差值
TePDuP（本文）	76.80	66.93	66.92	75.99	
w/o S-S（本文）	75.32	66.42	65.14	74.96	–1.20
w/o OTP（本文）	74.96	64.85	65.09	72.68	–2.27
w/o OTP & S-S（本文）	74.44	64.02	64.39	71.53	–3.07
w/o ATP（本文）	74.23	64.88	63.32	73.51	–2.68
w/o ATP & S-S（本文）	73.15	64.46	62.40	72.42	–3.55
BART-ABSA	65.25	58.69	59.26	67.62	–8.96
GAS	72.16	60.78	62.10	70.10	–5.38
ParaPhrase	72.09	61.40	62.73	71.10	–4.83
SEL-base	71.27	58.69	59.60	70.24	–6.71
UIE-base	72.55	62.94	64.41	72.86	–3.47

注：w/o S-S（scheduled-sampling）表示在 TePDuP 基础上去掉计划采样优化，w/o OTP（opinion term prompt）表示没有方面术语提示路径的答案，w/o OTP & S-S 表示没有方面术语提示路径的答案并且还去掉了计划采样优化；类似地，w/o ATP（aspect term prompt）和 w/o ATP & S-S 分别表示没有方面术语提示路径的答案以及同时没有方面术语提示路径的答案和计划采样优化.

的优化是十分明显的，其中基于方面术语和观点术语提示的结果，在 4 个数据集上平均 $F1$ 值分别领先 1.76 和 1.28 个百分点. 另外与 SEL-base，UIE-base 相比，w/o ATP & S-S 的结果并没有超过 UIE-base，可能的原因有 2 方面：一方面是具有更丰富的外部知识的预训练模型可以取得更好的结果. 另一方面是观点术语抽取方法性能还不够好，表 3 中观点术语路径的平均 $F1$ 值 79.41% 高于方面术语的 77.88%，然而表 2 中观点术语的平均 $F1$ 值 79.94% 低于方面术语的 80.53%，进而可能影响模型的最终性能. 如果采用更好的术语抽取方法，TePDuP 模型是可以取得更好的结果的.

同时为了验证传统的基于 Seq2Seq 建模的生成式方法中的误差累计的问题. 我们在 ASTE-Data-V2 数据集的测试数据中选择了总共 676 条（14lap 为 144 条，14res 为 288 条，15res 为 112 条，16res 为 134 条）含有多个三元组的数据进行了测试，并对结果进行了统计与分析. 实验结果如图 4 所示. 其中，方面术语提示表示基于方面术语提示路径的答案，观点术语提示表示基于观点术语提示路径的答案，3+表示累计抽取错误的三元组数量大于等于 3. 可以看出，当错误元组数量为 1 时，传统的基于 Seq2Seq 建模的生成式方法 ParaPhrase 在对后续的三元组进行抽取时的精确率明显低于 TePDuP. 当错误元组的数量增加到 2 以及 3+时，ParaPhrase 的下降更加显著. 从整体

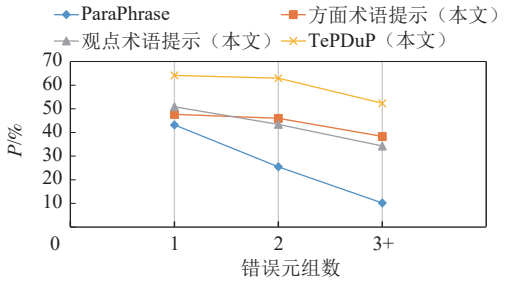


Fig. 4 The precision subsequently generated triples following incorrect triples

图 4 错误三元组之后的后续生成的三元组的精确率

趋势来看，TePDuP 对于抽取错误的累积并不敏感，即使抽取出一些错误的元组，也不会干扰其他元组的抽取. 相比之下，传统的生成式方法如 ParaPhrase 对于错误的累积非常敏感，并且随着累计抽取错误的元组数增加，后续生成的元组的精确率急剧下降. 也说明了传统的基于 Seq2Seq 建模的生成式方法，比如 ParaPhrase，其误差累积是一个客观存在的问题. 相比于传统的基于 Seq2Seq 建模的生成式方法，TePDuP 在累计抽取错误的元组数增加的情况下，对其他生成的元组的精确率影响较小. 这是因为 TePDuP 通过术语提示文本生成，不会干扰其他术语提示的元组的生成，因此对误差累积问题不敏感.

最后，我们还统计了 ParaPhrase 与 TePDuP 在不同三元组数量下的抽取结果，如图 5 所示，其中 3+表示三元组数量大于等于 3 的情况. 可以发现，TePDuP

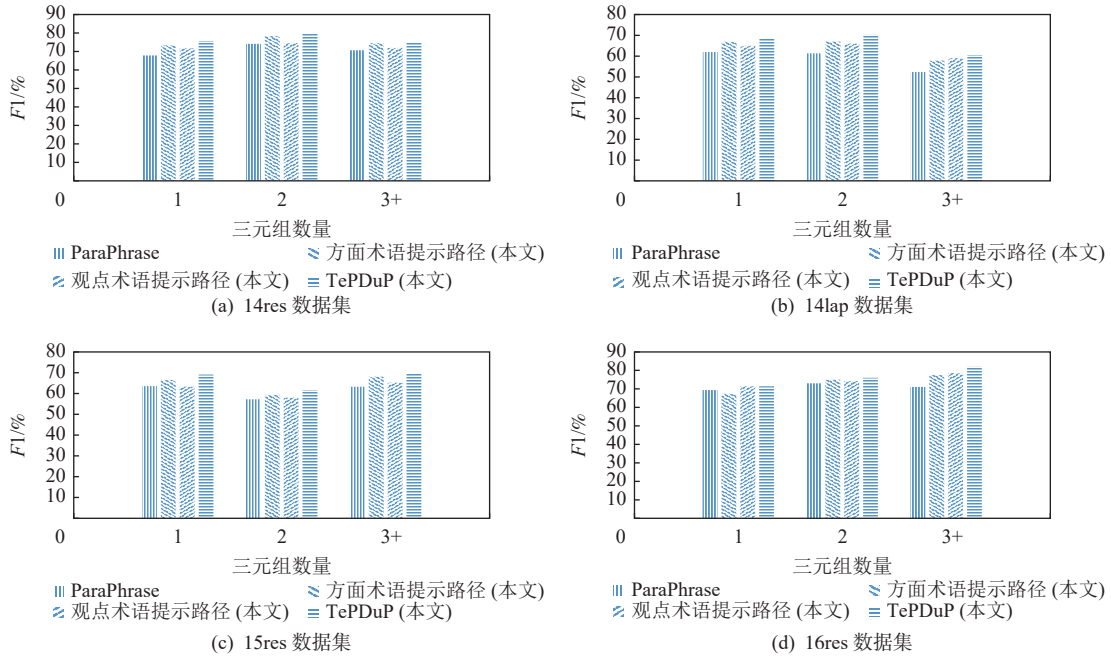


Fig. 5 Comparison of $F1$-score with different number of target triplets

图 5 不同目标三元组数量下的 $F1$ 值比较

在三元组的数量较多的情况下优于 ParaPhrase. 甚至在 14res 和 14lap 这 2 个数据集，单个三元组的抽取性能超过了 ParaPhrase. 这说明了 TePDuP 有效地缓解和避免了传统的基于 Seq2Seq 建模的生成式方法，如 ParaPhrase 以顺序串联形式生成三元组所带来的大解码长度的误差累计，并且在 TePDuP 大多数情况下都有着不错的性能表现.

3.7 样例分析

在图 6 中，我们从 ASTE-DATA-V2 的测试集中选取了多个三元组抽取的案例，用于比较 TePDuP 和 ParaPhrase. 在第 1 个样例中，ParaPhrase 抽取出了 1 个错误的三元组；方面术语提示路径少抽取了 1 个三元组，但是观点术语提示路径正确地抽取了 2 个三元组；最终通过合并得到了正确的答案. 第 2 个样例中，ParaPhrase 抽取出了 1 个错误的三元组；方面术语提示路径抽取正确，但是观点术语提示路径抽取了 1 个错误的三元组；最终通过合并，过滤掉了错误的答案，得到了正确的答案. 在第 3 个样例中，MRC 抽取了错误的方面术语，但是错误的方面术语中包含了正确的方面术语信息；在计划采样的修正与调整下，方面术语提示路径仍然能抽取出正确的答案，这证明了计划采样方法的有效性. 最后 1 个样例中三元组数量较多，ParaPhrase 只抽取了(setup, easy, POS)，(configure, intuitive, POS)这 2 个三元组，在抽取了(configure, intuitive, POS)之后，可能受到了 Seq2Seq 建模的学习约束，将(configure, intuitive, POS)作为最后 1 个三元组而结束解码. 而方面术语提示路径和观点术语提示路径的结果都是正确的. 最后 1 个样例也说明了 TePDuP 方法不是很关心三元组的顺序.

样例1：It 's so nice that the battery last so long and that this machine has the snow lion !
目标三元组：(battery, nice, POS), (battery, long, POS)
方面术语 (本文)：battery✓　　观点术语(本文)：nice✓, long✓
ParaPhrase：(battery, nice, POS) ✓, (snow lion, nice, POS) ×
ATP (本文)：(battery, long, POS) ✓
OTP (本文)：(battery, long, POS) ✓, (battery, nice, POS) ✓
TePDuP (本文)：(battery, long, POS) ✓, (battery, nice, POS) ✓

样例2：Made interneting (partof my business) very difficult to maintain .
目标三元组：(interneting, difficult, NEG)
方面术语 (本文)：interneting ✓　　观点术语(本文)：difficult ✓
ParaPhrase：(interneting, difficult, NEG) ✓, (business, difficult, NEG)×
ATP (本文)：(interneting, difficult, NEG) ✓
OTP (本文)：(interneting, difficult, NEG) ✓, (maintain, difficult, NEG) ×
TePDuP (本文)：(interneting, difficult, NEG) ✓

样例3：Both a number of the appetizer and pasta specials were amazing .
目标三元组：(pasta specials, amazing, POS), (appetizer, amazing, POS)
方面术语(本文)：appetizer and pasta specials×　　观点术语(本文)：amazing✓
ParaPhrase：(appetizer, amazing, POS) ✓,(pasta specials, amazing, POS) ✓
ATP (本文)：(appetizer, amazing, POS) ✓,(pasta specials, amazing, POS) ✓
OTP (本文)：(appetizer, amazing, POS) ✓,(pasta specials, amazing, POS) ✓
TePDuP (本文)：(appetizer, amazing, POS) ✓,(pasta specials, amazing, POS) ✓

样例4：Everything is so easy and intuitive to setup or configure .
目标三元组：(setup, easy, POS), (setup, intuitive, POS), (configure, easy, POS), (configure, intuitive, POS)
方面术语 (本文)：setup ✓, configure✓　　观点术语(本文)：easy ✓, intuitive✓
ParaPhrase：(setup, easy, POS) ✓, (configure, intuitive, POS) ✓
ATP (本文)：(setup, easy, POS) ✓, (configure, intuitive, POS) ✓, (setup, intuitive, POS) ✓, (configure, easy, POS) ✓
OTP (本文)：(setup, easy, POS)✓, (configure, intuitive, POS)✓, (setup, intuitive, POS)✓, (configure, easy, POS) ✓
TePDuP (本文)：(setup, easy, POS)✓, (configure, intuitive, POS)✓, (setup, intuitive, POS)✓, (configure, easy, POS)✓

注：×表示错误的抽取结果，✓表示正确的抽取结果. OTP 表示观点术语提示 (opinion term prompt) 路径的结果；ATP 表示方面术语提示 (aspect term prompt) 路径的结果.

Fig. 6 Case study
图 6 样例分析

4 总　　结

在本文中，我们根据观点术语、三元组和方面术语三者通常呈现出的几乎一对一的关联特性，提出了一种基于术语引导双路文本生成的 ASTE 框架——TePDuP 用于缓解 Seq2Seq 建模中存在的顺序依赖问题. TePDuP 主要分为 2 个部分：第 1 个部分利用 MRC 框架，并行地抽取文本中所有的术语；第 2 个部分在抽取的术语基础上形成动态提示前缀，引导双路文本生成. 为了缓解 MRC 抽取偏差的问题，我们设计了一个计划采样方法，对训练过程进行优化. 此外我们的推理方法，根据生成概率结合双路文本生成结果，可以有效地加强模型鲁棒性，提高抽取性能. 最后，我们在基准数据集上进行的实验证明了 TePDuP 框架的有效性. 未来，我们将致力于探索更好的生成方式，以更好地解决顺序依赖问题.

作者贡献声明：李银强提出了算法思路和实验方案；蓝天和向飛阳负责完成实验并撰写论文；孙丽纯和杜知涵提出论文修改意见；刘瑶和刘峤提出指导意见.

参　考　文　献

[1] Liu Bing. Sentiment Analysis and Opinion Mining[M]. San Rafael, CA: Morgan & Claypool Publishers, 2012

[2] Pontiki M, Galanis D, Pavlopoulos J, et al. SemEval−2014 task 4: Aspect based sentiment analysis[C]//Proc of the 8th Int Workshop on Semantic Evaluation. Stroudsburg, PA: ACL, 2014: 27−35

[3] Yin Yichun, Wei Furu, Dong Li, et al. Unsupervised word and dependency path embeddings for aspect term extraction[C]//Proc of the 25th Int Joint Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2016: 2979−2985

[4] Li Xin, Bing Lidong, Li Piji, et al. Aspect term extraction with history attention and selective transformation[C]//Proc of the 27th Int Joint Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2018: 4194−4200

[5] Ma Dehong, Li Sujian, Wu Fangzhao, et al. Exploring sequence-to-sequence learning in aspect term extraction[C]//Proc of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2019: 3538−3547

[6] Liu Pengfei, Joty S, Meng Helen. Fine-grained opinion mining with recurrent neural networks and word embeddings[C]//Proc of the 2015 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2015: 1433−1443

[7] Wu Shengqiong, Fei Hao, Ren Yafeng, et al. Learn from syntax: Improving pair-wise aspect and opinion terms extraction with rich syntactic knowledge[C]//Proc of the 30th Int Joint Conf on Artificial Intelligence. Berlin: Springer, 2021: 3957−3963

[8] Wang Yequan, Huang Minlie, Zhu Xiaoyan, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proc of the 2016 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2016: 606−615

[9] Chen Peng, Sun Zhongqian, Bing Lidong, et al. Recurrent attention network on memory for aspect sentiment analysis[C]//Proc of the 2017 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2017: 452−461

[10] Jiang Qingnan, Chen Lei, Xu Ruifeng, et al. A challenge dataset and effective models for aspect-based sentiment analysis[C]//Proc of the 2019 Conf on Empirical Methods in Natural Language Processing and the 9th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2019: 6280−6285

[11] Zhang Mi, Qian Tieyun. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]//Proc of the 2020 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2020: 3540−3549

[12] Chen Zhuang, Qian Tieyun. Relation-aware collaborative learning for unified aspect-based sentiment analysis[C]//Proc of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 3685−3694

[13] Zhao He, Huang Longtao, Zhang Rong, et al. Spanmlt: A span-based multi-task learning framework for pair-wise aspect and opinion terms extraction[C]//Proc of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 3239−3248

[14] Peng Haiyun, Xu Lu, Bing Lidong, et al. Knowing what, how and why: A near complete solution for aspect-based sentiment analysis[C]//Proc of the 34th AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2020: 8600−8607

[15] Zhang Chen, Li Qiuchi, Song Dawei, et al. A multi-task learning framework for opinion triplet extraction[C]//Proc of the Findings of the Association for Computational Linguistics: EMNLP 2020. Stroudsburg, PA: ACL, 2020: 819−828

[16] Xu Lu, Li Hao, Lu Wei, et al. Position-aware tagging for aspect sentiment triplet extraction[C]//Proc of the 2020 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2020: 2339−2349

[17] Wu Zhen, Ying Chengcan, Zhao Fei, et al. Grid tagging scheme for aspect-oriented fine-grained opinion extraction[C]//Proc of the Findings of the Association for Computational Linguistics: EMNLP 2020. Stroudsburg, PA: ACL, 2020: 2576−2585

[18] Chen Hao, Zhai Zepeng, Feng Fangxiang, et al. Enhanced multi-channel graph convolutional network for aspect sentiment triplet extraction[C]//Proc of the 60th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2022: 2974−2985

[19] Liu Xinyi, Ning Bo, Wang Ming, et al. Fine-grained sentiment triplet extraction method based on syntactic enhancement[J]. Journal of Computer Research and Development, 2023, 60(7): 1649−1660 (in Chinese)
(刘欣逸，宁博，王明，等. 基于句法增强的细粒度情感三元组抽取

方法[J]. 计算机研究与发展, 2023, 60(7): 1649−1660)

[20] Zhang Yice, Yang Yifan, Li Yihui, et al. Boundary-driven table-filling for aspect sentiment triplet extraction[C]//Proc of the 2022 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2022: 6485−6498

[21] Xu Lu, Chia Y K, Bing Lidong. Learning span-level interactions for aspect sentiment triplet extraction[C]//Proc of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2021: 4755−4766

[22] Chen Yuqi, Chen Keming, Sun Xian, et al. A span-level bidirectional network for aspect sentiment triplet extraction[C]//Proc of the 2022 Conf Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2022: 4300−4309

[23] Liang Shuo, Wei Wei, Mao Xianling, et al. STAGE: Span tagging and greedy inference scheme for aspect sentiment triplet extraction[C]// Proc of the 37th AAAI Conf Artificial Intelligence. Palo Alto, CA: AAAI, 2023: 13174−13182

[24] Mao Yue, Shen Yi, Yu Chao, et al. A joint training dual-MRC framework for aspect based sentiment analysis[C]//Proc of the 35th AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2021: 13543−13551

[25] Chen Shaowei, Wang Yu, Liu Jie, et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction[C]//Proc of the 35th AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2021: 12666−12674

[26] Zhai Zepeng, Chen Hao, Feng Fangxiang, et al. COM-MRC: A context-masked machine reading comprehension framework for aspect sentiment triplet extraction[C]//Proc of the 2022 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2022: 3230−3241

[27] Liu Shu, Li Kaiwen, Li Zuhe. A robustly optimized BMRC for aspect sentiment triplet extraction[C]//Proc of the 2022 Conf of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg, PA: ACL, 2022: 272−278

[28] Zhang Wenxuan, Li Xin, Deng Yang, et al. Towards generative aspect-based sentiment analysis[C]//Proc of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2021: 504−510

[29] Zhang Wenxuan, Deng Yang, Li Xin, et al. Aspect sentiment quad prediction as paraphrase generation[C]//Proc of the 2021 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2021: 9209−9219

[30] Yan Hang, Dai Junqi, Ji Tuo, et al. A unified generative framework for aspect-based sentiment analysis[C]//Proc of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2021: 2416−2429

[31] Lu Yaojie, Liu Qing, Dai Dai, et al. Unified structure generation for universal information extraction[C]//Proc of the 60th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2022: 5755−5772

[32] Mao Yue, Shen Yi, Yang Jingchao, et al. Seq2Path: Generating sentiment tuples as paths of a tree[C]//Proc of the Findings of the Association for Computational Linguistics: 60th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2022: 2215−2225

[33] Zhang R H, Liu Qianying, Fan A X, et al. Minimize exposure bias of Seq2Seq models in joint entity and relation extraction[C]//Proc of the Findings of the Association for Computational Linguistics: EMNLP 2020. Stroudsburg, PA: ACL, 2020: 236−246

[34] Bengio S, Vinyals O, Jaitly N, et al. Scheduled sampling for sequence prediction with recurrent neural networks[C]//Proc of the 28th Int Conf on Neural Information Processing Systems. Cambridge, MA: MIT, 2015: 1171−1179

[35] Bu Jiahao, Ren Lei, Zheng Shuang, et al. ASAP: A Chinese review dataset towards aspect category sentiment analysis and rating prediction[C]//Proc of the 2021 Conf of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg, PA: ACL, 2021: 2069−2079

[36] Zhou Xinjie, Wan Xiaojun, Xiao Jianguo. Representation learning for aspect category detection in online reviews[C]//Proc of the 29th AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2015: 417−424

[37] Huang Binxuan, Carley K M. Parameterized convolutional neural networks for aspect level sentiment classification[C]//Proc of the 2018 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2018: 1091−1096

[38] Hu Mengting, Zhao Shiwan, Zhang Li, et al. CAN: Constrained attention networks for multi-aspect sentiment analysis[C]//Proc of the 2019 Conf on Empirical Methods in Natural Language Processing and the 9th Int Joint Conf on Natural Language Processing. Stroudsburg, PA: ACL, 2019: 4601−4610

[39] Ruder S, Ghaffari P, Breslin J G. A hierarchical model of reviews for aspect-based sentiment analysis[C]//Proc of the 2016 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2016: 999−1005

[40] Chen Shaowei, Liu Jie, Wang Yu, et al. Synchronous double-channel recurrent network for aspect-opinion pair extraction[C]//Proc of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 6515−6524

[41] Cai Hongjie, Tu Yaofeng, Zhou Xiangsheng, et al. Aspect-category based sentiment analysis with hierarchical graph convolutional network[C]//Proc of the 28th Int Conf on Computational Linguistics. Stroudsburg, PA: ACL, 2020: 833−843

[42] Luo Huaishao, Li Tianrui, Liu Bing, et al. DOER: Dual cross-shared RNN for aspect term-polarity co-extraction[C]//Proc of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2019: 591−601

[43] Li Xin, Bing Lidong, Li Piji, et al. A unified model for opinion target extraction and target sentiment prediction[C]//Proc of the 33rd AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2019: 6714−6721

[44] He Ruidan, Lee Wee Sun, Ng Hwee Tou, et al. An interactive multi-task learning network for end-to-end aspect-based sentiment analysis[C]//Proc of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2019: 504−515

[45] Devlin J, Chang Mingwei, Lee K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding[C]//Proc of the 2019 Conf of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg, PA: ACL, 2019: 4171−4186

[46] Peters M E, Neumann M, Iyyer M, et al. Deep contextualized word representations[C]//Proc of the 2018 Conf of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg, PA: ACL, 2018: 2227−2237

[47] Radford A, Wu J, Child R, et al. Language models are unsupervised multitask learners[EB/OL]. 2019[2023-10-22]. https://cdn.openai.com/better-language-models/language_models_are_unsupervised_multitask_learners.pdf

[48] Li Xiaoya, Feng Jingrong, Meng Yuxian, et al. A unified MRC framework for named entity recognition[C]//Proc of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 5849−5859

[49] Li Xiaoya, Yin Fan, Sun Zijun, et al. Entity-relation extraction as multi-turn question answering[C]//Proc of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2019: 1340−1350

[50] Raffel C, Shazeer N, Roberts A, et al. Exploring the limits of transfer learning with a unified text-to-text transformer[J]. The Journal of Machine Learning Research, 2020, 21(1): 5485−5551

[51] Lewis M, Liu Yinhan, Goyal N, et al. BART: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[C]//Proc of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 7871−7880

[52] Pontiki M, Galanis D, Papageorgiou H, et al. SemEval−2016 task 5: Aspect based sentiment analysis[C]//Proc of the 10th Int Workshop on Semantic Evaluation. Stroudsburg, PA: ACL, 2016: 19−30

[53] Pontiki M, Galanis D, Papageorgiou H, et al. SemEval−2015 task 12: Aspect based sentiment analysis[C]//Proc of the 9th Int Workshop on Semantic Evaluation. Stroudsburg, PA: ACL, 2015: 486−495



Li Yinqiang, born in 1998. Master candidate. His main research interests include aspect-based sentiment analysis and machine learning.

李银强, 1998 年生. 硕士研究生. 主要研究方向为方面级情感分析、机器学习.



Lan Tian, born in 1977. PhD, professor, master supervisor. His main research interests include image processing, speech enhancement, and natural language processing.

蓝　天, 1977 年生. 博士, 研究员, 硕士生导师. 主要研究方向为图像处理、语音增强、自然语言处理.



Liu Yao, born in 1978. PhD, associate professor. Member of CCF. Her main research interests include network security, social network data mining, and machine learning.

刘　瑶, 1978 年生. 博士, 副教授, CCF 会员. 主要研究方向为网络安全、社交网络、数据挖掘、机器学习.



Xiang Feiyang, born in 1995. Master candidate. His main research interests include continual learning and machine learning.

向飛阳, 1995 年生. 硕士研究生. 主要研究方向为可持续学习、机器学习.



Sun Lichun, born in 1999. Master candidate. Her main research interests include stance detection and machine learning.

孙丽纯, 1999 年生. 硕士研究生. 主要研究方向为立场检测、机器学习.



Du Zhihan, born in 1999. Master candidate. His main research interests include sentiment analysis and machine learning.

杜知涵, 1999 年生. 硕士研究生. 主要研究方向为情感分析、机器学习.



Liu Qiao, born in 1974. PhD, professor, PhD supervisor. His main research interests include natural language processing, machine learning, and data mining.

刘　峤, 1974 年生. 博士, 教授, 博士生导师. 主要研究方向为自然语言处理、机器学习、数据挖掘.