

BART 驱动的跨领域方面词与情感词联合抽取方法

郝雯娜^{1,2}, 刘 韧³, 李晓戈^{1,2}

¹(西安邮电大学 计算机学院, 西安 710061)

²(陕西省网络数据分析与智能处理重点实验室(西安邮电大学), 西安 710061)

³(山东财经大学 公共管理学院, 济南 250014)

E-mail: xiaoxia0319@stu.xupt.edu.cn

摘要: 跨领域方面级情感分析面临目标领域标注数据不足以及不同领域间文本特征差异带来的领域适应问题。为此, 本文提出一种基于 BART 的跨领域数据增强框架, 利用大语言模型结合源领域的语义信息, 为目标领域生成高质量的标注数据, 以解决数据短缺问题。首先, 采用 BERT-BiLSTM-CRF 架构结合 Transformer 编码器, 为目标领域的未标注数据分配伪标签。其次, 提取不同领域标注数据和伪标注数据的特定领域特征, 并对其掩码处理, 构建与领域无关的数据。随后, 利用预训练 BART 模型生成既连贯又准确的目标领域数据, 同时通过引入熵最小化过滤器提升生成数据的质量与一致性。在三个公开数据集上的实验结果表明, 所提框架在性能上显著优于多种基准方法和其他数据增强技术。

关键词: 跨领域方面级情感分析; 数据增强; 无监督域适应; BART

中图分类号: TP391

文献标识码: A

文章编号: 1000-1220(2026)02-0318-08

BART-enhanced Cross-domain Aspect and Opinion Extraction

HAO Wenna^{1,2}, LIU Ren³, LI Xiaoge^{1,2}

¹(School of Computer Science, Xi'an University of Posts and Telecommunications, Xi'an 710061, China)

²(Key Laboratory of Network Data Analysis and Intelligent Processing in Shaanxi Province (Xi'an University of Posts and Telecommunications), Xi'an 710061, China)

³(School of Public Administration and Policy, Shandong University of Finance and Economics, Jinan 250014, China)

Abstract: Cross-domain aspect-based sentiment analysis faces challenges due to the scarcity of labeled data in the target domain and domain adaptation issues arising from differences in text characteristics across domains. To address these challenges, this paper proposes a BART-based cross-domain data augmentation framework, leveraging large language model combined with semantic information from the source domain to generate high-quality labeled data for the target domain, thereby alleviating the data shortage problem. First, a BERT-BiLSTM-CRF architecture combined with a Transformer encoder is used to assign pseudo-labels to unlabeled data in the target domain. Second, domain-specific features are extracted from both labeled and pseudo-labeled data and masked to construct domain-independent data. Subsequently, the pretrained BART model is employed to generate coherent and accurate target domain data, with an entropy minimization filter introduced to enhance the quality and consistency of the generated data. Experimental results on three public datasets demonstrate that the proposed framework significantly outperforms various baseline methods and other data augmentation techniques.

Keywords: cross-domain aspect-based sentiment analysis; data augmentation; unsupervised domain adaptation; BART

0 引言

方面级情感分析旨在从文本中提取方面词并预测情感极性。方面词和情感词联合抽取是方面级情感分析中的核心任务之一, 其目标是从评论文本中同时识别出方面词和情感词。例如, 在评论语句“这家餐厅的沙拉总是做得很好, 但是服务很差”中, “沙拉”和“服务”是方面词, 而“好”和“差”则是相应的情感词。近年来, 大多数研究将方面级情感分析视为监督序列标注问题, 借助预训练语言模型 (Pre-trained Language Models, PLM) 中蕴含的丰富语义信息, 以提高数据标注的准确性, 并在多个基准数据集上展现了良好的性能^[1-4]。

然而, 现有的监督学习方法依赖大量标注数据进行训练,

许多领域的标注语料库规模有限, 且相比粗粒度情感分析任务, 细粒度标注数据的获取成本更高。同时, 随着互联网技术的快速发展, 许多新兴领域不断涌现, 获取大规模且高质量的标注数据变得更加困难, 甚至在某些情况下几乎不可能。这些因素限制了监督学习模型的泛化能力。此外, 领域间的差异进一步影响了模型在目标领域的表现, 导致模型无法达到理想效果。例如, “这地方真是太冷了”在酒店领域可能是对空调温度过低或房间舒适度不足的消极评价, 而在旅游领域, 如果指的是避暑胜地或滑雪场, 则可能是中性描述, 甚至隐含积极的推荐意味。这种语义差异使得将某个领域训练的情感分析模型直接应用到其他领域时, 往往效果不佳。因此, 现有的方面级情感分析方法难以适应不同领域的需求, 跨领域方面级

情感分析应运而生。

跨领域方面级情感分析面临的两大挑战是:目标领域缺乏细粒度标注数据,以及不同领域间显著的文本特征差异带来的领域适应问题。为解决这些问题,先前的研究提出了无监督域适应(Unsupervised Domain Adaptation, UDA)方法^[5-8],该方法通过将标注数据丰富的源领域知识迁移至标注数据匮乏的目标领域,有效缓解了目标领域细粒度标注数据不足的问题,并解决了跨领域表述差异带来的领域适应问题。然而,在跨领域情感分析任务的训练过程中,许多模型未能充分利用目标领域的未标注数据,而这些数据对吸收目标领域知识至关重要。

与此同时,随着以 ChatGPT 为代表的大语言模型(Large Language Model, LLM)的兴起,情感分析领域迎来了新的发展机遇。尽管大语言模型在少样本学习场景中表现出色,但在像方面级情感分析这类需要深入理解和处理复杂情感信息的任务中,仍存在一定的局限性。近期的研究中,研究者利用生成式大语言模型,提出了跨领域数据增强方法^[9-11],基于源领域的标注数据直接生成大量目标领域的标注数据。然而,这些方法生成的数据通常缺乏流畅性和连贯性,且与真实数据的分布存在较大差异,数据质量仍有待提升。此外,现有方法中为目标领域数据标注伪标签的基础模型准确性较低,这在一定程度上影响了生成数据的质量以及模型的最终效果。

针对上述问题,本文提出一种基于 BART 模型的跨领域数据增强框架(BART-based Cross-Domain Data Augmentation, BART-CDDA),利用大语言模型结合源领域语义信息,为目标领域生成高质量标注数据,以缓解数据短缺问题。框架分为 4 个阶段:首先,伪样本标注阶段利用 BERT-BiLSTM-CRF 模型结合 Transformer 编码器,为目标领域未标注数据分配伪标签;其次,在特定领域特征掩码阶段,提取不同领域标注数据和伪标注数据的特定领域特征,并对其掩码处理,构建与领域无关的数据;随后,通过目标领域数据重构阶段利用 BART 的生成能力,生成既连贯又准确的目标领域数据;最后,在生成数据过滤阶段引入熵最小化过滤器,提升生成数据质量与一致性。本文在 3 个公开数据集上进行的一系列实验证明了所提框架的有效性。本文的具体贡献有以下 3 个方面:

1) 本文提出一种基于 BART 模型的跨领域数据增强框架,通过无监督领域适应解决目标领域标注数据不足的问题,利用大语言模型 BART 为目标领域生成相关的高质量数据。

2) 本文在 BERT-BiLSTM-CRF 架构中引入 Transformer 编码器,以更好地捕捉文本中的语义特征,从而显著提高目标领域数据标注伪标签的准确性。同时,采用熵最小化过滤器进一步优化生成数据的质量。

3) 本文提出的方法在 3 个公开数据集上进行的实验表明,与现有方法相比,本文提出的框架在性能上取得了一定程度的提升,大量实验结果验证了其在方面词与情感词联合抽取任务中的有效性。

1 相关研究

1.1 方面词和情感词联合抽取

在方面级情感分析领域,方面词和情感词联合抽取是至

关重要的一环,其核心目标是从评论文本中准确提取方面词和表达用户观点的情感词。为实现这一目标,以往的研究大致可分为以下几类:1) 基于语言依赖规则的方法^[12-14]:利用方面词与情感词之间,或与其他附加术语之间的语言依赖关系,实现方面词抽取任务。然而,这些规则通常更倾向于优先处理高频出现的方面词和情感词,忽视了低频但同样重要的方面词和情感词,从而导致其适用性和泛化能力受限;2) 监督序列学习算法^[15]:例如隐马尔可夫模型(Hidden Markov Model, HMM)和条件随机场(Conditional Random Field, CRF)等监督序列学习算法也被广泛应用于方面词和情感词联合抽取任务。尽管如此,这些监督模型的训练严重依赖标注数据。相比于粗粒度情感分析任务,细粒度标注数据的获取成本更高;3) 主题建模技术:多粒度隐含狄利克雷分布(Multi-Grain Latent Dirichlet Allocation, MG-LDA)^[16]等主题建模方法也被应用于方面级情感分析。但这类方法在捕捉细粒度方面词时往往表现不佳,难以有效应对复杂多样的评论文本;4) 预训练语言模型^[9,17]:诸如 BERT^[18]等预训练语言模型已成功应用于方面级情感分析任务。近期的研究则探索了生成式大语言模型,如 BART^[19]、T5^[20]和 GPT-3^[21],在方面级情感分析中的强大能力。

尽管有监督方法在过去取得了显著成就^[4,22,23],但在各个领域普遍存在的标注数据短缺问题,仍然严重制约了这些方法的泛化能力和最佳效果的发挥。

1.2 无监督域适应

在情感分析领域,现有的领域适应技术主要聚焦于粗粒度的情感分类任务。这些技术主要可分为以下几类:1) 基于 pivot 词方法:Blitzer 等人^[24]、Yu 和 Jiang^[25]以及 Ziser 和 Reichart^[26-28]等研究者提出通过捕捉源领域和目标领域共享的情感词信息,拉近源领域和目标领域之间的距离,从而提升模型的领域适应性;2) 对抗训练方法:Alam 等人^[29]和 Du 等人^[30]利用对抗训练,调整源领域与目标领域数据分布的不一致性,从而增强模型的领域泛化能力;3) 领域不变特征提取方法:Fang 等人^[31]、Giorgi 等人^[32]以及 Li 等人^[33]专注于学习领域间不变的特征表示,以改善模型在不同领域间的适应性。

尽管如此,对于细粒度的领域适应任务,现有研究仍较为有限,特别是在减少对标注数据依赖方面。典型的方法包括:1) 基于规则的方法^[34,35]:依赖严格编制的句法规则和情感字典实现方面词和情感词的抽取任务,其有效性受限于句法规则的特殊性和鲁棒性,难以应对复杂多变的语言场景;2) 基于领域不变的特征表示学习方法^[5,8,36,37]:通过学习领域通用的特征表示,将源领域的知识迁移到目标领域。这类方法利用领域不变的特征,促使源领域和目标领域共享知识,虽然取得了一定成效,但未能充分利用目标领域潜在的监督信号,影响了其适应效果;3) 基于数据增强的方法:近期研究提出的一种新型领域适应方法,通过直接生成目标领域的标注数据来解决领域适应问题。例如, Yu 等人^[38]基于掩码语言模型(Masked Language Model, MLM),通过学习源领域标注数据来生成目标领域标注数据。Deng 等人^[39]基于 T5 模型提出了一个统一的双向生成框架,用于处理多种跨领域方面级情感分析任务。

1.3 数据增强

数据增强技术是增加机器学习模型训练数据量的常用策略,通过各种方式扩充和修改现有数据,以提高机器学习模型的训练效果和性能.常见的数据增强方法包括词替换^[40],即从词库中选取同义词或在词向量空间中找到语义相似的词,替换原句中的特定词汇,以生成多样化的训练样本;反向翻译^[41],即将原始句子翻译成其他语言后,再重新翻译回源语言,通过多轮语言转换生成新的训练数据,其效果很大程度上依赖于翻译模型的质量和准确性.

与文本分类等粗粒度任务不同,细粒度的方面级情感分析任务需要更为精细的数据增强.简单的词序调整或词汇增删往往无法满足这一需求.因此,针对细粒度任务,数据增强方法可分为以下3种类型^[42].第1类方法通过引入额外约束来优化粗粒度的数据增强策略,生成适合细粒度任务的伪样本.例如,Dai等人^[43]提出了一种词级扰动方法,采用标签单词替换、同义词替换、提及替换和段内乱序等技术,生成用于序列标注的细粒度伪样本.Chen等人^[44]则通过引入依赖路径和词性标签的约束条件,优化生成过程,从而提高了伪样本的质量;第2类方法通过模型为未标注数据添加伪标签,进而扩充数据集.Wang等人^[45]结合课程学习和自监督学习方法,为大量未标注数据生成伪标签,并将其作为额外的训练样本,以增强数据的多样性;第3类方法则借助预训练语言模型生成符合语义和标注要求的细粒度样本.例如,Wang等人^[46]利

用生成模型根据给定的方面和情感标签生成新的句子,以增加数据的多样性;Li等人^[47]则提出了一种基于生成模型的跨领域数据增强框架,促进无监督域适应方法的发展.这3类方法为细粒度任务提供了不同的增强策略,能够有效提升训练数据的多样性和质量,从而改善细粒度情感分析的性能.

综上所述,尽管现有的领域适应和数据增强方法在一定程度上缓解了标注数据短缺的问题,但在处理细粒度的方面级情感分析任务时,仍存在诸多挑战.本研究提出的基于BART的跨领域数据增强框架(BART-CDDA),结合无监督域适应和生成模型的优势,有效提升了方面词和情感词联合抽取任务的准确性和鲁棒性.

2 本文方法

2.1 本文模型架构

图1所示为本文提出的生成框架(BART-CDDA)的整体架构.该框架通过4个阶段有效缓解目标领域标注数据稀缺的问题.首先,在伪样本标注阶段,采用BERT-BiLSTM-CRF架构结合Transformer编码器的分类器,在源领域标注数据上进行训练,并为目标领域未标注实例分配伪标签.与传统架构相比,Transformer编码器的引入能够更好地捕捉文本中的深层语义特征和长距离依赖特征,从而显著提高目标领域数据伪标注的准确性,为后续生成任务提供高质量的伪标注样本.

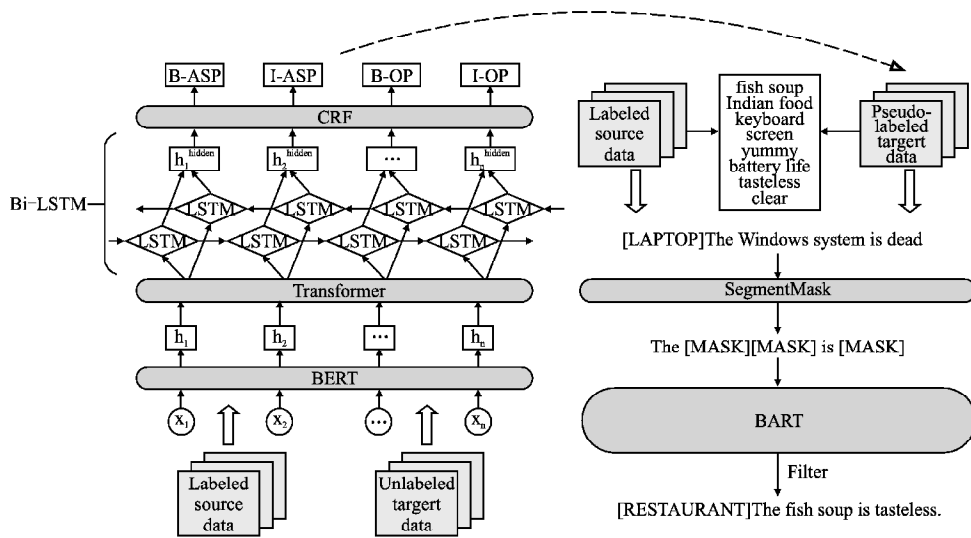


图1 BART-CDDA 模型图

Fig. 1 BART-CDDA model diagram

其次,在特定领域特征掩码阶段,利用频率比方法识别领域特定特征并进行掩码处理,以保留跨领域上下文的通用性,确保生成数据的适用性和一致性.目标领域数据重构阶段,基于预训练生成模型BART,整合目标领域的特定领域特征,对原始文本进行重构.该阶段能够有效生成贴合目标领域语义需求的新数据,增强目标领域数据的多样性与质量.最后,生成数据过滤阶段通过引入熵最小化过滤器对生成数据进行筛选,剔除低质量样本,优化生成数据的连贯性与有效性.这一阶段进一步提升模型对目标领域的适应能力与性能表现.上述4个阶段紧密协同,有效提升了目标领域生成数据的质量,促进

解决数据稀缺问题.

2.2 问题定义

本研究重点关注方面词和情感词联合抽取任务,将该任务定义为序列标注问题.给定一个包含 n 个单词的句子 $S = \{w_1, w_2, \dots, w_n\}$,其token序列表示为 $X = \{x_1, x_2, \dots, x_n\}$.任务目标是预测标注序列 $Y = \{y_1, y_2, \dots, y_n\}$,其中 $y_i \in \{B-ASP, I-ASP, B-OP, I-OP, O\}$.源领域包含足够的标注数据 $D_s = \{(x_i^s, y_i^s)\}_{i=1}^{N_s}$,而目标领域只包含未标注数据 $D_u = \{(x_i^u)\}_{i=1}^{N_u}$.最终任务是预测目标领域测试集 $D_T = \{(x_i^t)\}_{i=1}^{N_t}$ 的数据标注.

2.3 伪样本标注

在伪样本标注阶段, 目标是为目标领域中每个未标注实例生成伪标注. 然而, 当源领域和目标领域的数据分布存在显著差异时, 为目标领域生成高质量的伪标注成为一项挑战. 因此, 需要更为强大的上下文建模和特征提取技术, 以提升伪标注的准确性和鲁棒性. 具体而言, 给定源领域标注数据 D_S 和目标域无标注数据 D_U , 首先在 D_S 上训练分类器. 使用预训练 BERT 模型提取句子的隐藏表示 $H_{BERT} \in \mathbb{R}^{n \times d}$, 其中 d 代表隐藏状态的维度.

$$H_{BERT} = \text{BERT}(X) \quad (1)$$

接下来, 使用 Transformer 编码器进一步捕捉全局信息, 并优化从 BERT 获得的句子表征. 每个 Transformer 编码器层包含自注意机制和前馈网络子层, 有助于进一步完善句子表征 $H_{Trans} \in \mathbb{R}^{n \times d}$.

$$H_{Trans} = \text{TransformerEncoder}(H_{BERT}) \quad (2)$$

为了准确识别领域特定的方面词和情感词, 将 Transformer 编码器的输出 H_{Trans} 输入至双向长短期记忆网络 (Bidirectional Long Short-Term Memory, Bi-LSTM), 以捕捉序列中的长距离依赖关系. Bi-LSTM 对输入序列进行双向处理, 得到输出 $H_{BiLSTM} \in \mathbb{R}^{n \times 2h}$, 其中 $2h$ 是前向和后向 LSTM 输出的综合维度.

$$H_{BiLSTM} = \text{BiLSTM}(H_{Trans}) \quad (3)$$

最后, 将特征向量序列 H_{BiLSTM} 输入 CRF 层, 以预测最终的标签序列 $P(Y|H_{BiLSTM})$. 优化目标是最小化每个源领域实例的正确标签序列的负对数概率.

$$L_{crf} = - \sum_{i=1}^n \log P(y_i | h_{BiLSTM_i}) \quad (4)$$

上述分类器在 D_S 上训练完成后, 为 D_U 中未标注数据生成伪标注, 构造伪标注数据集 $D_{PT} = \{(x_i^u, y_i^u)\}_{i=1}^{N_u}$. 伪标注基于未标注数据的特征生成, 并通过最大化条件概率确定.

2.4 特定领域特征掩码

特定领域特征掩码阶段旨在提取并掩码每个领域的特定领域特征, 以生成与领域无关的评论句子. 针对不同领域内容与观点表达方式的差异, 采用 Li 等人^[48] 提出的频率比方法, 将在某一领域出现频率较高的文本片段识别为特定领域特征. 具体而言, 首先将句子分割成不同长度的单词序列, 计算 n -gram 段 w 在数据集 D_m 中的相对频率.

$$s(w, D_m) = \frac{\text{count}(w, D_m) + \lambda}{\sum_{m' \in M, m' \neq m} \text{count}(w, D_{m'}) + \lambda} \quad (5)$$

其中, $\text{count}(w, D_m)$ 表示 n -gram 段 w 在数据集 D_m 中的出现次数, $m \in M, M = \{S, PT\}$, λ 为平滑参数. 接着, 设定阈值 δ , 选择符合条件的 n -gram 段构成特定领域特征集 M .

$$s(w, D_m) \geq \delta \quad (6)$$

使用前向最大匹配算法从数据集 M 中识别并掩码片段, 每个匹配的词语将被替换为特殊标记 [mask]. 若某个涉及特定领域方面或情感的短语中任一词被掩码, 则整个短语都会被掩码.

2.5 目标领域数据重构

目标领域数据重构阶段将目标领域特定特征重新整合至上述每个与领域无关的评论句子中, 从而提高模型的整体性能. 根据上述步骤, 对每个实例 $(X, Y) \in D_S \cup D_{PT}$ 生成相应的掩码

对 (\bar{X}, Y) , 其中 $\bar{X} = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n\}$ 为掩码后的评论句子, 标签序列为 $Y = \{y_1, y_2, \dots, y_n\}$. 受 Li 等人研究^[47] 的影响, 采用改进的 BART 框架重建原始文本及其标签序列. 对于每个实例, 在每个时间步长 t 分别计算 token 序列与标注序列的负对数似然损失.

$$L_x = - \sum_{i=1}^{n+1} \log P(x_i | x_{<i}, y_{<i}, H) \quad (7)$$

$$L_y = - \sum_{i=1}^{n+1} \log P(y_i | y_{<i}, x_{<i}, H) \quad (8)$$

其中 $H \in \mathbb{R}^{n \times d}$, d' 表示隐藏维度. 最终的总训练损失为这两部分之和.

$$L = L_x + L_y \quad (9)$$

为了生成更多实例, 进一步提高生成句子的多样性, 对每个实例 $(X, Y) \in D_S$ 使用不同随机种子重复 3 次掩码过程, 获得 3 个不同的掩码对 (\bar{X}, Y) . 若某实例不包含任何方面词或情感词, 以 60% 的概率进行随机掩码. 最终, 每个源域标注句子可生成 3 个不同句子.

2.6 生成数据过滤

完成上述步骤后, 获得生成句子集 X_G . 为提高生成句子质量, 通过熵最小化方法对其进行过滤.

$$H(x_i) = - E_{x_i} [\log P(x_i)] = - P(x_i) \log P(x_i) \quad (10)$$

$$P(x_i) = \text{Softmax}(hW + b) \quad (11)$$

$$h = F(x_i) \quad (12)$$

其中, $x_i \in X_G$ 表示每个生成句子, h 表示隐藏层, $W \in \mathbb{R}^{d \times 3}$ 表示模型权重, b 表示各层偏置, F 表示分类模型. 具有高不确定性 (高熵) 的生成句子被过滤, 最终生成目标域数据集 $D_G = \{(x_i^g, y_i^g)\}_{i=1}^{N_g}$ 用于训练 BERTE-CRF 模型^[49] 并在目标领域的测试数据集上评估其有效性.

3 实验结果与分析

3.1 数据集

为评估提出框架的有效性, 在 3 个代表不同领域的方面级情感分析基准数据集上进行实验: 餐厅 (R)、笔记本电脑 (L) 和设备 (D), 详见表 1. 餐厅 (R) 和笔记本电脑 (L) 数据集包括来自 2014 年^[50] 和 2015 年^[51] SemEval ABSA 挑战赛

表 1 数据集

Table 1 Data set

Dataset	Domain	Sentence	Train	Test
R	Restaurant	5841	4381	1460
L	Laptop	3845	2884	961
D	Device	3836	2877	959

的评论. 设备 (D) 数据集包含消费电子类别中 5 种数码产品的数据^[52]. 与以往的研究一致, 实验以 3:1 的比例将每个领域的数据集划分为训练集和测试集, 采用 3 种不同的随机种子分别进行 3 次实验以确保结果的稳定性.

3.2 实验环境配置

在伪标注阶段, 采用在 Yelp 和亚马逊电子产品数据集上进行微调的 BERT_{base} 模型. Transformer 编码器配置为 6 个编码块和 8 个注意力头. 在特定域特征掩码阶段, 设置 n -gram 片段 w 长度为 $n \in [1, 4]$, 并将公式 (6) 中的相对频率阈

值 δ 设为 10. 在目标领域重构阶段, 预训练的序列到序列模型 BART 在数据集 $D_S \cup D_{PT}$ 上进行了 3 次微调, 批量大小为 8. 针对下游任务, 使用 Adam 优化器对 BERT_{base} 和 CRF 进行优化, 学习率分别设为 $3e-5$ 和 0.02. 最后, 通过计算 Micro-F1 得分评估本文方法在跨领域方面级情感分析任务中的效果.

3.3 测试集实验对比

为了验证所提方法在跨领域方面级情感分析任务中的有效性, 本文与多个领域适应方法进行跨领域方面词和情感词联合抽取任务的比较. 以下是所比较的方法及其特点:

Hier-Joint^[35]: 基于循环神经网络 (Recurrent Neural Network, RNN), 结合人工规则生成的辅助标签, 捕捉方面和情感实体之间的共同句法模式.

ARNN-GRU^[53]: 基于依存树和门控递归单元 (Gated Recurrent Unit, GRU) 构建递归神经网络, 并引入自动编码器作为辅助任务以减轻标签噪声的影响.

TRNN-GRU^[53]: 在 ARNN-GRU 的基础上加入条件域对抗网络, 以处理词法特征与句法依赖关系.

BERT_E + CRF^[49]: 结合 BERT_{base} 基本模型和 CRF 层的序列标注方法.

SA-EXAL^[36]: 将 BERT 架构与语法感知注意力机制相结合的一种领域适应方法, 提升领域适应性能.

CDRG-Merge^[38]: 通过掩码语言模型生成目标领域标注数据, 并应用数据增强策略实现领域适应.

GCDDA^[47]: 利用 BART 生成目标领域标注数据, 实现跨领域的增强方法.

BGCA^[39]: 基于 T5 的双向生成框架, 综合解决跨领域的方面级情感分析任务.

BRCNN^[54]: 利用不同领域之间的句法和语义信息作为枢轴信息, 弥合源领域与目标领域之间的差距, 解决跨领域方面词抽取任务.

CBiLSTM^[55]: 以语义信息作为枢轴, 融合全局与局部语义信息实现跨领域方面词抽取的方法.

表 2 汇总了所有方法的实验结果. 本文提出的框架在大多数跨领域数据集上均实现了最佳性能. 例如, 在方面词提取和情感词提取任务中, 与基准方法 BERT_E + CRF 相比, 性能分别提升了 6.62% 和 1.25%. 相较于基于数据增强的 GCDDA 方法, 本文框架在这两项任务上的性能分别提高了 1.72% 和 0.89%. 这一提高主要归功于本文框架所采用的基分类器能够充分捕捉源领域的语义特征, 强化上下文与当前信息之间的潜在语义关联, 并利用目标领域的监督信号学习特定语境, 结合熵过滤器得到更高质量的目标领域生成数据, 从而确保了用于下游任务的训练数据具有更高的可靠性和有效性.

此外, 与仅利用生成模型 T5 预测伪标签的 BGCA_{text-to-label} 方法相比, 本文方法在方面词提取和情感词提取任务上的性能分别提高了 8.42% 和 7.79%; 与使用句法或语义信息降低源领域和目标领域差异性的 BRCNN 及 CBiLSTM 方法相比, 本文方法在方面词提取任务上的性能分别提高了 5.35% 和 5.24%. 这些结果进一步凸显了本文跨领域数据增强策略的优势.

表 2 各模型实验对比结果

Table 2 Comparison results with each model

Model	R→L		R→D		L→R		L→D		D→R		D→L		AVE	
	AS	OP	AS	OP	AS	OP	AS	OP	AS	OP	AS	OP	AS	OP
Hier-Joint	33.66	-	33.20	-	48.10	-	31.25	-	47.97	-	34.74	-	38.15	-
ARNN-GRU	40.43	65.85	35.10	60.17	52.91	72.51	40.42	61.15	48.36	73.75	51.14	71.18	44.73	67.44
TRNN-GRU	40.15	65.63	37.33	60.32	53.78	73.40	41.19	60.20	51.17	74.37	51.66	68.79	45.88	67.12
BERT _E + CRF	52.77	75.94	43.65	66.36	50.08	82.39	45.47	60.29	64.21	81.79	58.75	76.15	52.49	73.82
SA-EXAL	47.59	75.79	40.50	63.33	54.67	80.05	42.19	60.19	54.54	71.57	47.72	63.98	47.87	69.15
CDRG-Merge	58.23	76.08	37.96	62.19	72.88	82.34	40.62	59.04	66.79	82.23	54.26	76.42	55.12	73.05
GCDDA	66.56	77.63	44.80	64.86	62.22	82.67	45.11	60.72	68.23	82.44	57.44	76.75	57.39	74.18
BGCA _{text-to-label}	53.06	65.47	43.00	63.18	50.49	74.51	44.66	56.11	56.27	72.54	56.68	71.85	50.69	67.28
BGCA _{label-to-text}	58.44	72.32	40.21	65.27	66.68	81.39	46.53	58.89	65.11	79.02	57.36	73.32	55.72	71.70
BRCNN	52.20	-	43.77	-	65.26	-	45.28	-	61.05	-	54.98	-	53.76	-
CBiLSTM	52.82	-	43.65	-	65.10	-	45.26	-	60.97	-	55.39	-	53.87	-
Ours (BART-CDDA)	66.92	78.38	45.19	67.60	67.67	84.52	47.13	61.21	69.25	81.75	58.52	76.96	59.11	75.07

注: 除 BGCA 模型外的实验结果均来自原文.

以上实验对比结果充分验证了本文方法在跨领域方面级情感分析任务中的整体有效性.

3.4 消融实验分析

为全面评估本文方法中各关键组件的作用, 表 3 展示了消融实验结果.

首先, 移除伪样本标注阶段的 Transformer 编码器后, 6 组跨领域数据的平均性能下降了 0.83 个百分点. 这表明 Transformer 编码器能够有效捕捉语义信息与建模长距离依赖特征, 对于目标领域伪标注数据生成的准确性至关重要. 其次, 去除特定领域特征掩码和目标领域重构阶段时, 平均 F1

分数下降了 2.75 个百分点, 这验证了生成大量高质量目标领域标注数据对模型性能的显著贡献. 进一步分析发现, 用 BiLSTM 模型替换预训练生成模型 BART 后, 模型性能出现明显下降. 这是因为 BART 模型具有丰富的语言知识和强大的生成能力, 在生成任务中比 BiLSTM 更能生成语义连贯的高质量数据. 此外, 省略生成数据过滤步骤导致平均 F1 分数下降了 1.64 个百分点, 这一结果凸显了数据筛选策略的重要性, 其中熵过滤器通过剔除低质量样本, 有效提升了生成数据的准确性与一致性, 从而增强了模型的泛化能力. 最后, 在目标领域数据重构阶段去除源领域标注数据后, 平均 F1 分数降

低 0.7 个百分点, 这表明源领域数据在帮助模型捕捉领域无关的上下文与标注信息方面起到了重要支撑作用。

表 3 消融分析
Table 3 Ablation study

Methods	F1	
	AS	OP
Ours(BART-CDDA)	59.11	75.07
w/o Transformer	58.28	74.39
w/o DSFM & TDR	56.36	73.86
BART = > Bi-LSTM	58.25	74.53
w/o data filter	57.47	74.17
w/o source data	58.41	74.56

综上所述, 本文提出的框架通过充分结合源领域和目标领域特征, 利用多阶段的生成与过滤策略, 有效提升了跨领域方面级情感分析任务的性能。

3.5 生成数据质量评估

本小节通过一系列实验全面评估生成数据的质量, 与另一种跨领域数据增强方法(GCDDA)的对比结果汇总于表 4, 总结了 6 组跨领域数据的平均表现。

表 4 评估分析
Table 4 Evaluation results

Model	BLEU	Perplexity	MMD
Source	100.00	26.54	0.2821
GCDDA	90.32	28.61	0.1754
Ours	89.55	28.05	0.1487

BLEU 值。BLEU 值用于衡量生成句子与源数据的相似性。如表 4 中第 2 列所示, 与其他方法相比, 本文方法的 BLEU 值显著更低, 表明所生成句子的形式更加多样化, 能够有效增加数据的丰富性。

困惑度(Perplexity)。为进一步评估生成数据的语义一致性, 本文引入预训练语言模型 GPT-2 计算生成句子的困惑度指标。结果如表 4 中第 3 列所示, 本文方法生成数据的困惑度显著低于其他方法, 说明其在语义一致性上具有更优表现。此外, 图 2 对比了本文框架与 GCDDA 在 6 组跨领域数据上的困惑度数值。实验结果表明, 本文方法生成的数据在困惑度指标上显著优于 GCDDA, 展现出更强的领域特异性。




图 2 困惑度对比

Fig. 2 Perplexity comparison

最大平均差异(Maximum Mean Discrepancy, MMD)。在量化分析生成数据与目标领域数据分布差异时, 采用最大平均差异(MMD)作为评估指标。表 4 中最后一列结果显示, 本文方法生成的数据与目标领域测试数据的分布更加接近, 这

进一步证明了本文提出的方法在生成符合真实目标领域数据分布方面的优势。

3.6 参数分析

如 2.4 节所述, 通过使用不同的随机种子对输入句子进行掩码处理, 并生成目标领域样本实例, 可以有效提升生成数据的多样性。为进一步验证这一策略的有效性, 本小节对生成句子数量与数据增强效果之间的关系进行深入分析。图 3 对




图 3 参数分析

Fig. 3 Parameter study

比了另一数据增强方法(GCDDA)与本文提出的框架在生成不同规模增强数据时的平均 F1 分数变化趋势。结果表明, 当生成句子的数量设为 3 时, 两种方法均达到了最佳性能。这表明, 从单一源句生成 3 个目标句的策略在数据多样性与模型性能之间实现了最佳平衡。

3.7 案例分析

表 5 展示了本文框架在跨领域数据集上生成的方面词和情感词示例。值得注意的是, 这些词均来自生成数据集, 并未出现在源领域或目标领域的训练数据中。这表明, 本文方法能够充分利用生成模型 BART, 结合源领域的标注数据与目标领域的伪标注数据, 生成新的方面词与情感词, 有效丰富训练数据, 从而提升模型的预测性能。

表 5 案例分析

Table 5 Case study

	windows 8, screen size, inside-out system, deco, macbook pro,
R→L	15 inch, technical service, pcs type cables, wireless devices, over weight, digital graphics, hard drive
	unit's interface and hidden menus, apex product, dvd, mp3
R→D	player, memory card, radio software, cameras, creative product, moveable lcd
L→R	japanese sauce, dining menu, customer service, sandwiches, cleaner environment, restaurant quality

进一步分析发现, 在目标领域的生成数据中, 许多方面词和情感词能够准确反映目标领域特有的语义特征。例如, 在餐饮领域评论中, 生成的“restaurant quality”等词汇准确表达了该领域中的核心属性。然而, 部分生成数据中也出现了错误或不符合预期的情况。这主要是因为本文提出的数据增强框架基于生成模型, 而非简单的单词替换技术。在数据生成过程中, 生成模型可能会误解上下文或偏离正确的情感表达, 导致生成的方面词和情感词与实际情境不符。为了应对这一问题, 本文引入了熵过滤器, 通过衡量生成样本的分布不确定性, 对生成数据进行筛选与优化, 从而去除不符合预期的内容, 确保生成数据的准确性与一致性, 进一步提升生成数据的质量。

4 结论

本文提出了一种基于 BART 的跨领域数据增强框架

(BART-CDDA),以应对跨领域方面级情感分析中目标领域细粒度标注数据稀缺的问题.框架集成了BERT-BiLSTM-CRF模型与Transformer编码器,显著提升了模型在目标领域的语义特征表示能力,从而生成更精准的数据伪标注.此外,框架利用BART模型的生成能力,为目标领域生成高质量标注数据,解决了数据稀缺问题.为进一步提升生成数据的质量,引入熵最小化过滤器对句子进行筛选与优化,确保输出数据的可靠性.实验结果表明,在3个基准数据集上,所提方法能够生成与目标领域语义高度相关的数据,验证了其在方面级情感分析任务中的有效性和适用性.

References:

- [1] Liu P, Joty S, Meng H. Fine-grained opinion mining with recurrent neural networks and word embeddings[C]//Conference on Empirical Methods in Natural Language Processing, 2015:1433-1443.
- [2] Li X, Bing L, Li P, et al. Aspect term extraction with history attention and selective transformation[C]//27th International Joint Conference on Artificial Intelligence, 2018:4194-4200.
- [3] Wu M, Wang W, Pan S J. Deep weighted maxsat for aspect-based opinion extraction[C]//Conference on Empirical Methods in Natural Language Processing, 2020:5618-5628.
- [4] Wang J, Li X, An X. Modeling multiple latent information graph structures via graph convolutional network for aspect-based sentiment analysis[J]. *Complex & Intelligent Systems*, 2023, 9(4): 4003-4014.
- [5] Wang W, Pan S J. Recursive neural structural correspondence network for cross-domain aspect and opinion co-extraction[C]//56th Annual Meeting of the Association for Computational Linguistics, 2018:2171-2181.
- [6] Li Z, Li X, Wei Y, et al. Transferable end-to-end aspect-based sentiment analysis with selective adversarial learning[C]//Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019:4590-4600.
- [7] Gong C, Yu J, Xia R. Unified feature and instance based domain adaptation for aspect-based sentiment analysis[C]//Conference on Empirical Methods in Natural Language Processing, 2020: 7035-7045.
- [8] Chen Z, Qian T. Bridge-based active domain adaptation for aspect term extraction[C]//59th Annual Meeting of the Association for Computational Linguistics (ACL) and the 11th International Joint Conference on Natural Language Processing, 2021:317-327.
- [9] Mao Y, Shen Y, Yang J, et al. Seq2path: generating sentiment tuples as paths of a tree[C]//Findings of the Association for Computational Linguistics, 2022:2215-2225.
- [10] Chen D Z, Faulkner A, Badyal S. Unsupervised data augmentation for aspect-based sentiment analysis[C]//29th International Conference on Computational Linguistics, 2022:6746-6751.
- [11] Yu J, Zhao Q, Xia R. Cross-domain data augmentation with domain-adaptive language modeling for aspect-based sentiment analysis[C]//61st Annual Meeting of the Association for Computational Linguistics, 2023:1456-1470.
- [12] Hu M, Liu B. Mining opinion features in customer reviews[C]//19th National Conference on Artificial Intelligence, 2004:755-760.
- [13] Popescu A M, Etzioni O. Extracting product features and opinions from reviews[J]. *Natural Language Processing and Text Mining*, 2007:9-28, doi:10.1007/978-1-84-628-754-1_2.
- [14] Chen S, Wang Y, Liu J, et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021:12666-12674.
- [15] Jakob N, Gurevych I. Extracting opinion targets in a single and cross-domain setting with conditional random fields[C]//Conference on Empirical Methods in Natural Language Processing, 2010: 1035-1045.
- [16] Titov I, McDonald R. Modeling online reviews with multi-grain topic models[C]//17th International Conference on World Wide Web, 2008:111-120.
- [17] Zhou Y, Zhu F, Song P, et al. An adaptive hybrid framework for cross-domain aspect-based sentiment analysis[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021:14630-14637.
- [18] Devlin J, Chang M W, Lee K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[C]//Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, 2019:4171-4186.
- [19] Lewis M, Liu Y, Goyal N, et al. BART: denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[C]//58th Annual Meeting of the Association for Computational Linguistics, 2020:7871-7880.
- [20] Raffel C, Shazeer N, Roberts A, et al. Exploring the limits of transfer learning with a unified text-to-text transformer[J]. *Journal of Machine Learning Research*, 2020, 21(140):1-67.
- [21] Liu P, Yuan W, Fu J, et al. Pre-train, prompt, and predict: a systematic survey of prompting methods in natural language processing[J]. *ACM Computing Surveys*, 2023, 55(9):1-35.
- [22] Da' u A, Salim N. Aspect extraction on user textual reviews using multi-channel convolutional neural network[J]. *PeerJ Computer Science*, 2019, 5:e191, doi:10.7717/PEERJ-CS.191.
- [23] Huang L, Wang P, Li S, et al. First target and opinion then polarity: enhancing target-opinion correlation for aspect sentiment triplet extraction[J]. *arXiv preprint arXiv:2102.08549*, 2021.
- [24] Blitzer J, McDonald R, Pereira F. Domain adaptation with structural correspondence learning[C]//Conference on Empirical Methods in Natural Language Processing, 2006:120-128.
- [25] Yu J, Jiang J. Learning sentence embeddings with auxiliary tasks for cross-domain sentiment classification[C]//Conference on Empirical Methods in Natural Language Processing, 2016:236-246.
- [26] Ziser Y, Reichart R. Neural structural correspondence learning for domain adaptation[C]//21st Conference on Computational Natural Language Learning, 2017:400-410.
- [27] Ziser Y, Reichart R. Pivot based language modeling for improved neural domain adaptation[C]//Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, 2018:1241-1251.
- [28] Ziser Y, Reichart R. Task refinement learning for improved accuracy and stability of unsupervised domain adaptation[C]//57th Annual Meeting of the Association for Computational Linguistics, 2019:5895-5906.
- [29] Alam F, Joty S, Imran M. Domain adaptation with adversarial training and graph embeddings[C]//56th Annual Meeting of the Association for Computational Linguistics, 2018:1077-1087.

- [30] Du C, Sun H, Wang J, et al. Adversarial and domain-aware BERT for cross-domain sentiment analysis [C]//58th Annual Meeting of the Association for Computational Linguistics, 2020:4019-4028.
- [31] Fang H, Wang S, Zhou M, et al. Cert: contrastive self-supervised learning for language understanding [J]. arXiv preprint arXiv: 2005.12766, 2020.
- [32] Giorgi J, Nitski O, Wang B, et al. DeCLUTR: deep contrastive learning for unsupervised textual representations [C]//59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021:879-895.
- [33] Li T, Chen X, Zhang S, et al. Cross-domain sentiment classification with contrastive learning and mutual information maximization [C]//IEEE International Conference on Acoustics, Speech and Signal Processing, 2021:8203-8207.
- [34] Li F, Pan S J, Jin O, et al. Cross-domain co-extraction of sentiment and topic lexicons [C]//50th Annual Meeting of the Association for Computational Linguistics, 2012:410-419.
- [35] Ding Y, Yu J, Jiang J. Recurrent neural networks with auxiliary labels for cross-domain opinion target extraction [C]//AAAI Conference on Artificial Intelligence, 2017:3436-3442.
- [36] Pereg O, Korat D, Wasserblat M. Syntactically aware cross-domain aspect and opinion terms extraction [C]//28th International Conference on Computational Linguistics, 2020:1772-1777.
- [37] WU X, XIA H B, LIU Y. Contrastive learning based multi-view feature fusion model for aspect-based sentiment analysis [J]. Pattern Recognition and Artificial Intelligence, 2024, 37 (10): 910-922.
- [38] Yu J, Gong C, Xia R. Cross-domain review generation for aspect-based sentiment analysis [C]//Findings of the Association for Computational Linguistics, 2021:4767-4777.
- [39] Deng Y, Zhang W, Pan S J, et al. Bidirectional generative framework for cross-domain aspect-based sentiment analysis [C]//61st Annual Meeting of the Association for Computational Linguistics, 2023:12272-12285.
- [40] Coulombe C. Text data augmentation made simple by leveraging nlp cloud apis [J]. arXiv preprint arXiv:1812.04718, 2018.
- [41] Wei J, Zou K. Eda: easy data augmentation techniques for boosting performance on text classification tasks [C]//Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019: 6382-6388.
- [42] CHEN Z, QIAN T Y, LI W L, et al. Low-resource aspect-based sentiment analysis: a survey [J]. Chinese Journal of Computers, 2023, 46(7): 1445-1472.
- [43] Dai X, Adel H. An analysis of simple data augmentation for named entity recognition [C]//28th International Conference on Computational Linguistics, 2020:3861-3867.
- [44] Chen Z, Qian T. Description and demonstration guided data augmentation for sequence tagging [J]. World Wide Web, 2022, 25 (1): 175-194.
- [45] Wang Q, Wen Z, Zhao Q, et al. Progressive self-training with discriminator for aspect term extraction [C]//Conference on Empirical Methods in Natural Language Processing, 2021:257-268.
- [46] Wang B, Ding L, Zhong Q, et al. A contrastive cross-channel data augmentation framework for aspect-based sentiment analysis [C]//29th International Conference on Computational Linguistics, 2022: 6691-6704.
- [47] Li J, Yu J, Xia R. Generative cross-domain data augmentation for aspect and opinion co-extraction [C]//Conference of the North American Chapter of the Association for Computational Linguistics, 2022:4219-4229.
- [48] Li J, Jia R, He H, et al. Delete, retrieve, generate: a simple approach to sentiment and style transfer [C]//Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2018:1865-1874.
- [49] Li X, Bing L, Zhang W, et al. Exploiting BERT for end-to-end aspect-based sentiment analysis [C]//5th Workshop on Noisy User-generated Text, 2019:34-41.
- [50] Pontiki M, Galanis D, Pavlopoulos J, et al. SemEval-2014 task 4: aspect based sentiment analysis [C]//8th International Workshop on Semantic Evaluation, 2014:72-75.
- [51] Pontiki M, Galanis D, Papageorgiou H, et al. SemEval-2015 task 12: aspect based sentiment analysis [C]//9th International Workshop on Semantic Evaluation, 2015:486-495.
- [52] Hu M, Liu B. Mining and summarizing customer reviews [C]//10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2004:168-177.
- [53] Wang W, Pan S J. Syntactically meaningful and transferable recursive neural networks for aspect and opinion extraction [J]. Computational Linguistics, 2020, 45(4): 705-736.
- [54] WANG D X, LI W J. Cross-domain aspect word extraction combining BRCNN and semantic information [J]. Journal of Chinese Computer Systems, 2024, 45(12): 2936-2943.
- [55] LIU D G, YOU J G, GENG Q Q. Cross-domain aspect term extraction fusing global and local semantics [J]. Computer Engineering, 2024:1-10, doi:10.19678/j.issn.1000-3428.0069205.

附中文参考文献:

- [37] 伍星, 夏鸿斌, 刘渊. 基于对比学习的多视角融合方面级情感分析模型 [J]. 模型识别与人工智能, 2024, 37(10): 910-922.
- [42] 陈壮, 钱铁云, 李万理, 等. 低资源方面级情感分析研究综述 [J]. 计算机学报, 2023, 46(7): 1445-1472.
- [54] 王登雄, 李卫疆. BRCNN 与语义信息结合的跨领域方面词抽取 [J]. 小型微型计算机系统, 2024, 45(12): 2936-2943.
- [55] 柳大格, 游进国, 耿齐祁. 融合全局与局部语义的跨领域方面词抽取 [J/OL]. 计算机工程, <https://doi.org/10.19678/j.issn.1000-3428.0069205>.