

结合预训练模型和数据增强的跨领域属性级情感分析研究

陈舸, 王中卿

引用本文

陈舸, 王中卿. 结合预训练模型和数据增强的跨领域属性级情感分析研究[J]. 计算机科学, 2025, 52(8): 300-307.

CHEN Ge, WANG Zhongqing. [Cross-domain Aspect-based Sentiment Analysis Based on Pre-training Model with Data Augmentation](#) [J]. Computer Science, 2025, 52(8): 300-307.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[结合评价对象信息的评论摘要研究](#)

Study on Opinion Summarization Incorporating Evaluation Object Information

计算机科学, 2025, 52(7): 233-240. <https://doi.org/10.11896/jsjcx.240600144>

[BiGCN-TL:软件错误部分定位场景下二分图图卷积神经网络Transformer定位模型](#)

BiGCN-TL: Bipartite Graph Convolutional Neural Network Transformer Localization Model for Software Bug Partial Localization Scenarios

计算机科学, 2025, 52(6A): 250200086-11. <https://doi.org/10.11896/jsjcx.250200086>

[基于FLIP与联合相似性保持的跨模态哈希检索](#)

FLIP-based Joint Similarity Preserving Hashing for Cross-modal Retrieval

计算机科学, 2025, 52(6A): 240400151-10. <https://doi.org/10.11896/jsjcx.240400151>

[基于语义增强的装备事件抽取方法](#)

Equipment Event Extraction Method Based on Semantic Enhancement

计算机科学, 2025, 52(6A): 240900096-9. <https://doi.org/10.11896/jsjcx.240900096>

[基于MacBERT的融合依存句法信息和多视角词汇信息的中文命名实体识别方法](#)

MacBERT Based Chinese Named Entity Recognition Fusion with Dependent Syntactic Information and Multi-view Lexical Information

计算机科学, 2025, 52(6A): 240600121-8. <https://doi.org/10.11896/jsjcx.240600121>

结合预训练模型和数据增强的跨领域属性级情感分析研究

陈 舸 王中卿

苏州大学计算机科学与技术学院 江苏 苏州 215006

(20245227045@stu.suda.edu.cn)

摘要 属性级情感分析(ABSA)是一项细粒度情感分析任务,旨在识别文本中的具体属性并探测其情感倾向。针对 ABSA 模型因无法适应不同领域的语言风格而导致性能不佳以及目标领域缺乏标注数据的问题,提出了一种结合预训练模型的跨领域属性级情感分析方法。该方法利用预训练模型对目标领域文本进行标签生成,再利用大语言模型重新生成更具目标领域风格的自然语句,最后将生成的样本和源领域样本组合训练,以对目标领域进行预测。在 SemEval 语料库的 restaurant 和 laptop 数据集以及一个公开的网络服务评论数据集上进行实验,结果表明,与现有跨领域情感分析方法相比,所提方法在 F_1 值上至少提升了 5.33%,充分证明了该方法的有效性。

关键词: 跨领域情感分析; 预训练模型; T5; GPT

中图分类号 TP391

Cross-domain Aspect-based Sentiment Analysis Based on Pre-training Model with Data Augmentation

CHEN Ge and WANG Zhongqing

School of Computer Science and Technology, Soochow University, Soochow, Suzhou 215006, China

Abstract Aspect-based Sentiment Analysis(ABSA) is a fine-grained sentiment analysis task, which aims at identifying specific aspects in text and exploring their sentiment orientation. To solve the problem of poor performance of ABSA model due to its inability to adapt to different domain language styles and lack of labeled data in target domain, this paper proposes a cross-domain aspect-based sentiment analysis method combined with pre-trained model. The pretraining model is used to generate labels for the target domain text, and the large language model is used to regenerate natural sentences with more target domain style. Finally, the generated samples and source domain samples are combined for training to predict the target domain. This experimental results on the restaurant and laptop datasets from the SemEval corpus, as well as a publicly available Web service review dataset show that, compared to existing cross-domain sentiment analysis methods, the proposed method achieves at least a 5.33% improvement in F_1 score, fully demonstrating its effectiveness.

Keywords Cross-domain ABSA, Pre-training model, T5, GPT

1 引言

随着互联网的飞速发展,大量包含情感倾向的文本涌现,情感分析已经广泛渗透到各个领域,包括电商、外卖、服务业等。然而,由于海量的信息,传统的人工识别方法效率显然已经满足不了现代需求,因此越来越多的研究者转向于深入研究情感分析。情感分析是一项重要的自然语言处理任务,从情感分析的粒度来看,可以分为粗粒度情感分析和细粒度情感分析。相较于粗粒度情感分析,细粒度情感分析能够提供更精细准确的分析结果,所以其成为当下自然语言处理研究中的热点。目前,已有很多国内外学者致力于属性级情感分析的研究,并取得了许多研究成果。但以往的方法在面对复杂语境或多个属性词时,可能会出现语义歧义或信息丢失等问题,在跨领域情感分析上也缺乏领域适应能力。

先前的细粒度情感分析研究仍存在许多问题与挑战。首先,以往的研究很多使用非端到端的方式进行 ABSA 任务,这种方式更容易因某个阶段的误差而影响整体预测的准确性。其次,由于不同领域的语言风格和表达方式存在差异,在进行跨领域情感分析任务时,难以捕捉相关的语言特征。因此,在先前的情感分析中,跨领域情感分析一直是一项挑战,虽然已有一些研究尝试引入领域适应方法来解决该问题,如加入领域无关特征、知识迁移等方法,但都未捕获目标领域的风格特征。最后,在细粒度情感分析中,往往需要对文本的属性、情感、观点等元素进行细粒度的标注,然而,为所有领域的文本进行人工标注需要耗费大量的时间和成本。

为了缓解端到端方式的误差影响以及跨领域 ABSA 的领域差异和缺乏标注数据问题,本文提出了一种结合预训练模型的跨领域 ABSA 框架,以序列到序列的方式进行属性词

抽取和情感分类任务,并使用一种跨领域文本生成方法增强数据,为模型训练提供高质量的、具有目标领域风格特征的标注数据。具体而言,本文首先利用源领域数据集对 T5 模型进行训练,使用训练后的模型在目标领域数据上抽取属性词,并与源领域情感极性结合作为伪标签。利用 OpenAI GPT 模型生成具有目标领域风格的文本,与伪标签配对作为增强数据集。增强后的数据集不仅融合了源领域和目标领域

特征,丰富了数据的多样性,而且通过生成领域特定文本,帮助模型捕获了目标领域特有的语言风格和特征,进一步提高了模型在目标领域中的适应能力。在 SemEval 数据集以及 Hu 等^[1]提供的数据集上的实验结果,验证了本文模型的有效性。表 1 是一则任务示例,其中生成的样本更符合 Restaurant 领域的语言风格,有利于模型学习相关的领域知识。

表 1 任务示例
Table 1 Task example

| 训练集样本 (Laptop) | 生成样本 (Restaurant) | 测试集样本 (Restaurant) |
|--|--|--|
| Oh yeah, don't forget the expensive shipping to and from HP. (shipping, negative) | Oh no, the thalia at that restaurant is always overpriced. (thalia, negative) | The bread is top notch as well. (bread, positive) |

本文的主要贡献如下:

1) 将属性词抽取与情感分类任务整合到一个序列到序列模型中,避免了传统非端到端方法中多阶段处理导致的误差传播问题。

2) 使用生成模型构建符合目标领域风格的增强数据集,有效地捕获了特定领域的语言特征,使模型能适应不同领域的的数据,缓解领域差异及特定领域数据稀缺问题。

2 相关工作

2.1 细粒度情感分析

早期细粒度情感分析主要以非端到端方式进行,这些方法往往费时耗力且容易产生传播误差。Wang 等^[2]采用两个基于注意力机制的模型来分别抽取属性词和观点词,引入注意力耦合来获取属性和观点之间的关系。然而,注意力机制可能会引入噪声,针对此问题, Hu 等^[3]提出了约束注意力网络(Constrained Attention Network, CAN),通过对多个属性词进行正交规范化,并对每个单独属性词进行稀疏规范化,有效缓解了注意力机制的缺陷。Li 等^[4]提出了一种两层双向 LSTM 模型,第一层负责捕获属性词的边界信息,第二层负责预测标签。Peng 等^[5]提出一个双阶段框架进行细粒度情感分析,在第一阶段使用通用框架预测情感信息,在第二阶段利用第一阶段获取的情感信息来进行情感元素抽取。

随着深度学习技术的不断进步和模型的发展,研究者开始尝试将端到端的模型应用于 ABSA 任务。Xu 等^[6]构造了一个使用序列标注的联合模型来抽取情感元素,通过位置感知标记捕获属性词、观点词,及其之间的关系。Wu 等^[7]通过一个统一的网格化标注框架(Grid Tagging Scheme, GTS),以端到端的方式来进行情感元素抽取任务,该框架将情感多元组抽取任务形式化为一个统一的标注任务,并通过特定解码策略生成结果。Zhang 等^[8]提出一种统一的生成方法来解决各种 ABSA 问题,制定标注式和抽取式两种范式建模,将原始任务转换成生成任务,使得模型的准确率得到进一步提升。Zhang 等^[9]使用一个统一的生成框架预测 4 个基于属性的情感元素,包括属性词、观点词、属性类别和情绪极性。Bai 等^[10]在情感四元素抽取任务上进一步引入软提示方法,通过考虑不同模板之间的相关性来提高情感四元素预测的准确性。Chen 等^[11]使用图神经网络进行情感分析任务,融合了

基于片段感知的语义图学习和基于语法的潜在图学习,通过去除不相关的上下文和依赖关系,以捕获复杂图结构。

2.2 跨领域情感分析

传统的 ABSA 模型通常会在特定领域进行训练和测试,当面对其他领域时,会因为不同领域的语言、术语和情感表达方式的差异而使模型性能下降。为了解决这个问题,研究人员开始探究领域适应技术。目前领域适应技术主要分为两类:基于特征的适应和基于数据的适应。

基于特征的适应通过学习领域无关特征,使模型更好地处理跨领域问题。Jakob 等^[12]将多种特征作为 CRF-based 模型的输入,包括词性、依存关系等领域无关的语法特征,通过对领域无关特征的学习增强模型的领域适应能力。Chernyshevich 等^[13]同样使用了多种领域无关特征对 CRF-based 模型进行训练,相较于以往研究,其使用了更多特征,包括命名实体特征、语义标签等,丰富了领域无关特征。Ding 等^[14]在引入领域无关特征的基础上,添加了一些定义明确的语法规则来辅助特征提取,并让模型学习适用于不同领域的隐藏表示,大幅度提高了模型的稳定性。

基于数据的适应方法更加关注对数据的处理而非对模型和算法的设计,利用源领域的标注数据和目标领域的未标注数据进行知识迁移来提高对目标领域的适应性。Yu 等^[15]提出了一种基于源领域的标注数据生成具有细粒度注释的目标领域数据的领域自适应范式,通过屏蔽源领域的特定属性将源领域文本转换为独立文本,再使用目标领域预训练的掩码语言模型将独立文本转换成目标领域文本。Su 等^[16]通过梯度数据选择丢弃不可迁移的样本,使可迁移样本更频繁地被采样到。Deng 等^[17]设计了一个双向生成框架,利用序列到序列(Sequence to Sequence, S2S)的模型生成目标领域的伪标签和与伪标签适应的文本,提供了更可靠的增强数据并缓解了预测噪声。

然而很少有人探索如何将端到端模型与基于数据的跨领域适应方法相结合,以解决传播误差和跨领域差异问题。本文使用预训练模型进行数据生成,利用生成的带有目标领域特征的高质量增强数据进一步训练端到端模型,通过捕获目标领域风格特征来提高模型的领域适应能力,优化了跨领域细粒度情感分析的准确度。

3 结合预训练模型的跨领域属性级情感分析

本文提出了一种结合预训练模型的跨领域属性级情感分析方法来进行属性词和情感极性联合抽取任务。具体而言,给定一段由 n 个单词组成的句子 $x = \{\omega_1, \omega_2, \dots, \omega_n\}$, 属性级情感分析任务的目的就是抽取句子 x 的属性词 $a = \{\omega_l, \dots, \omega_r\}$, 并判断其情感极性 p , 其中 $p \in \{\text{positive}, \text{negative}, \text{neutral}\}$ 。例如, 从句子 “It’s a great place to people

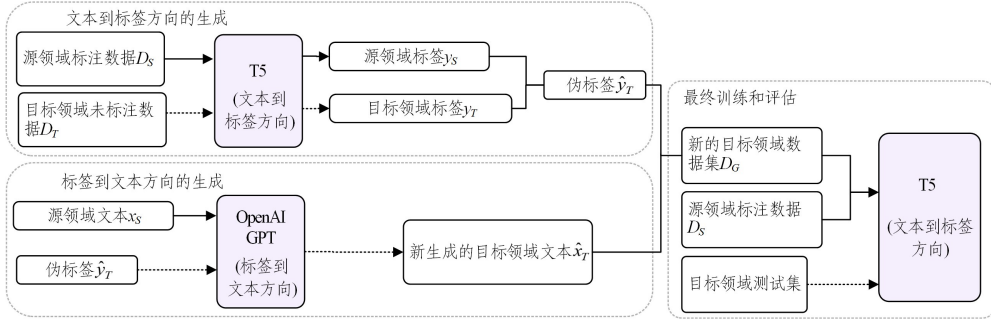


图1 总体框架示意图

Fig. 1 Overall framework diagram

3.1 模型

3.1.1 T5 模型

T5 模型^[18]是一种基于编码器-解码器架构的自然语言处理模型。其核心在于,将各种 NLP 任务都转换为文本到文本的生成任务,以序列到序列的方式统一解决问题。T5 的编码器和解码器都由多个 Transformer 堆叠而成,详细结构和流程如图 2 所示。该模型用于第一阶段伪标签的生成以及第三阶段的最终训练和评估。




图2 标签生成框架

Fig. 2 Framework of tag generation

3.1.2 序列表示

T5 模型将所有的任务都转换为文本到文本的转换任务,因此模型的输入和输出都是文本序列。为了促进端到端的学习,本文为数据集设计了双标签,分别是属性项标签 a 和情感极性标签 p 。通过适合的投影函数将标签对 (a, p) 线性化成等价的目标序列,如图 3 所示。由于属性词已经是自然语言文本形式,因此它的投影函数只是维持其原本格式,投影函数如下:

$$P_{\text{aspect}}(\text{aspect}) = \text{aspect} \quad (1)$$

而对于情感极性,投影函数如下:

$$P_{\text{polarity}}(\text{polarity}) = \begin{cases} \text{positive}, & \text{if } \text{polarity} = 1 \\ \text{neutral}, & \text{if } \text{polarity} = 0 \\ \text{negative}, & \text{if } \text{polarity} = -1 \end{cases} \quad (2)$$

通过将原始标签转换为自然语言表达,确保整个线性化

watch.”中抽取属性词 “place”, 并判断其情感极性为 positive (积极的)。本文方法总体框架如图 1 所示,其主要由 3 部分组成。在第一部分中,利用 T5 模型进行文本到标签方向的生成,并组合成伪标签。在第二部分中,利用 OpenAI GPT 模型进行标签到文本方向的生成,通过上一步生成的伪标签以及目标领域信息生成符合目标领域风格的新文本。最后,将生成的标签和文本组合作为增强数据集,扩充到源领域数据集 中进行最终的训练和评估。

目标序列的一致性。这种转换过程使得生成模型能够更好地利用情感极性的语义信息,从而提高了模型对文本的理解和表达能力。




图3 标签对转换为目标序列

Fig. 3 Tag pairs convert target sequence

3.1.3 S2S 的学习

S2S 是一种用于序列到序列学习的编码器-解码器架构。T5 模型中的 S2S 由 Transformer 编码器-解码器构成,解码器的目标是对于给定的编码输入表示,给出目标序列 y 的条件概率分布 $p_{\theta}(y|e)$, 该条件概率分布由 θ 参数化。

给定输入序列 $X = \{x_1, x_2, \dots, x_n\}$, 在第 i 个时间步中,解码器的输出 y_i 是基于编码器的输入 e 和第 i 步之前的输出 $y_{<i}$ 计算得出的,其计算式如下:

$$e = f_{\text{enc}}(\{x_1, x_2, \dots, x_n\}) \quad (3)$$

$$y_i = f_{\text{dec}}(e, y_{<i}) \quad (4)$$

其中, $f_{\text{enc}}(\cdot)$ 表示编码器计算, $f_{\text{dec}}(\cdot)$ 表示解码器计算。

解码器使用 softmax 函数得到下一个 Token 的概率分布,其计算式如下:

$$p_{\theta}(y_{i+1} | e, y_{<i+1}) = \text{softmax}(\mathbf{W}^T y_i) \quad (5)$$

其中, \mathbf{W} 将 y_i 映射到一个向量,用于计算整个词汇表上的概率分布。

3.2 跨领域数据增强方法

本节将详细介绍基于两种预训练生成模型的跨领域数据增强方法。该方法包括两个部分,即文本到标签方向的生成和标签到文本方向的生成。通过这两个阶段来生成领域适应

样本,过滤出优质样本后扩充到训练集上,使模型能更好地应对目标领域风格的文本,提高其在目标领域中的表现。在文本至标签的生成阶段,首先对源领域的标注数据集进行学习,随后使用训练好的模型对目标领域的未标注数据集进行预测,尽管这一步可能会由于错误预测产生一定的噪声,但后续会制定策略缓解噪声的影响。随后将组合生成的目标领域属性词以及源领域数据中对应的情感极性作为伪标签。在标签至文本的生成阶段,利用上一步生成的伪标签和源领域文本等相关信息,生成含有标签信息以及目标领域信息的自然语句,使文本更贴合标签,以减少预测噪声。最后,本文设计过滤方法去除低质量的生成样本,并将过滤后的样本扩充至源领域数据集,进行最终训练和评估。图4为数据增强方法的示例图。

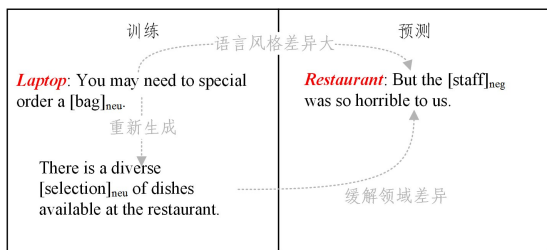


图4 数据增强方法示例

Fig. 4 Example of data enhancement method

3.2.1 文本到标签方向

文本到标签方向的任务旨在对每个句子进行属性词和情感极性的联合抽取。具体来说,首先使用源领域数据集 D_S 对 T5 模型进行训练,再利用该模型对目标领域文本进行预测,得到标签 $y_T = (a_T, p_T)$,其中 a_T 为目标领域属性词, p_T 为目标领域情感倾向。最后将目标领域标签 y_T 和源领域数据集 D_S 进行配对,得到伪标签 $\hat{y}_T = (a_T, p_S)$,其中 p_S 为源领域情感倾向。

例如,源领域为 laptop 领域,目标领域为 restaurant 领域,首先对 T5 预训练模型进行微调,在 laptop 数据集上进行训练,然后对 restaurant 领域的未标注数据集进行预测。具体地,在文本“they bring a sauce cart up to your table and offer you up to 7 or 8 choices of sauces for your steak.”中,提取出属性词为“sauce cart”,情感极性为“neutral”。图5给出了详细的任务示意图。




图5 文本到标签任务示意图

Fig. 5 Diagram of text to label task

该实验使用 T5 预训练模型进行训练和预测,采用经典的 Transformer 编码器-解码器架构。输入文本 x ,编码器负责将其转换为一个上下文编码序列 e ,解码器将这个编码序列转换为输出文本序列 y 的条件概率分布 $p_\theta(y|e)$ 。其中, θ 是可训练的参数。

首先,使用预训练的参数权值来初始化 θ ,然后对源领域标注数据集 D_S 的输入输出对 $\{x_S, y_S\}$ 进一步训练来微调参数,使得它的概率分布 $p_\theta(y_S|e)$ 的对数似然值最大化:

$$\max_{\theta} \log p_\theta(y_S|e) = \sum_{i=1}^n \log p_\theta((y_S)_i | e, (y_S)_{<i}) \quad (6)$$

其中, n 为输出文本序列 y_S 的长度。

对源领域标注数据集 D_S 进行训练后,直接对目标领域未标注数据集 D_T 进行预测,提取目标领域的情感元组 $y_T = (a_T, p_T)$ 。由于后续要基于源领域文本 x_S 生成目标领域新文本 \hat{x}_T ,因此需要让情感极性与源领域文本相符合。先通过填充或截断使目标领域标签 y_T 的长度等同于源领域标注数据集 D_S 的长度,再让它们两两配对。配对完成后,将抽取的目标领域标签 y_T 中的属性词和源领域标签 y_S 中的情感极性组成伪标签 $\hat{y}_T = (a_T, p_S)$,并将源领域文本 x_S 中的属性词 a_S 替换为目标领域属性词 a_T ,流程如图6所示。下一步,利用伪标签 \hat{y}_T 和替换后的源领域文本 x' 来重新生成文本。

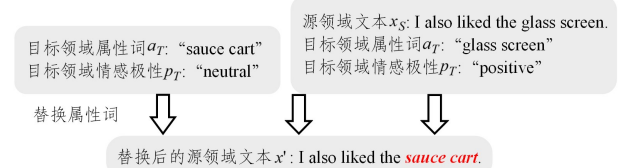


图6 源领域和目标领域数据配对

Fig. 6 Source domain and target domain data pair

3.2.2 标签到文本方向

虽然文本到标签的模型可以直接应用于目标领域的预测,但其在训练过程中并没有学习到目标领域的知识,使得模型性能不佳。以上述生成的目标领域伪标签 y_T 结合目标领域文本 x_T 进行训练虽然可以解决这个问题,但是模型在生成伪标签 y_T 时,可能会产生错误预测,导致伪标签质量不佳。因此,本文通过标签到文本的生成,产生与伪标签 \hat{y}_T 相匹配的文本,并设计过滤方法去除一些低质量的样本,以缓解上述问题的影响。

标签到文本阶段的任务旨在通过目标领域相关信息和标签信息,使源领域文本重新生成与目标领域相关的文本。具体来说,首先使用目标领域属性词 a_T 替换源领域文本 x_S 中的属性词 a_S ,得到替换后的文本 x' ;然后向 OpenAI GPT 模型输入替换后的文本 x' 、伪标签 $\hat{y}_T = (a_T, p_S)$ 以及目标领域信息,生成新的目标领域文本 \hat{x}_T 。

例如,给定标签元组 (“sauce cart”, positive) 以及源领域文本 “I also liked the [glass screen]_{pos}”,其中目标领域为 restaurant,源领域为 laptop。首先对源领域文本进行简单的随机属性词替换,将源领域属性词 glass screen 替换为目标领域属性词 sauce cart,得到句子 “I also liked the [sauce cart]_{pos}”,然后进行跨领域风格复述,通过将目标领域、伪标签等信息输入给 OpenAI GPT 模型,使其生成 restaurant 领域相关的新文本 “The sauce cart was another favorite of mine.”。新生成的文本不仅包含了目标领域知识,而且与伪标签 (“sauce cart”, “positive”) 的关联性更强。图7给出了任务示意图。

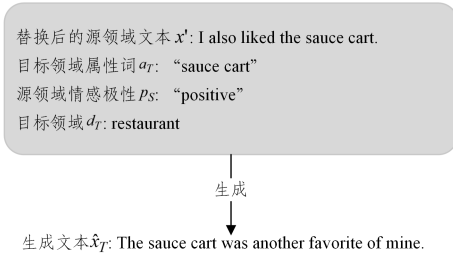


图7 标签到文本任务示意图

Fig. 7 Diagram of label to text task

该实验通过 OpenAI 接口调用 GPT 模型进行文本生成任务,通过向模型输入带有目标领域相关信息的提示词以及原文本,生成与目标领域相关的新文本。OpenAI GPT 同样是一种基于 Transformer 架构的文本到文本模型,因此将输入元素线性化为一个自然语言句子作为 GPT 模型的输入,如图 8 所示。

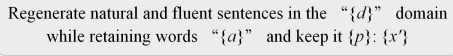


图8 OpenAI GPT 的输入文本格式

Fig. 8 Input text format of OpenAI GPT

然后,将生成的文本 \hat{x}_T 伪标签和 \hat{y}_T 组合成增强数据集 D_G 。由于 D_G 中的属性词和文本都来自目标领域,因此可以将其作为连接源领域和目标领域的桥梁,实现跨领域的知识迁移。

3.3 过滤低质量生成样本

由于在文本到标签和标签到文本两个方向的生成过程中都有可能产生错误预测和误差,为了减小这些错误的负面影响,本文设计了过滤方法以消除 D_G 中低质量的样本。理想情况下的 D_G 应满足以下要求:

- 1) 标签包含属性词和情感极性;
- 2) 文本包含标签中的属性词;
- 3) 文本中对属性词的情感倾向符合标签中的情感极性。

针对上述要求,本文进行了如下处理:

- 1) 过滤掉标签 \hat{y}_T 中含有无效格式,或者文本 \hat{x}_T 中不含标签属性词的样本;
- 2) 利用文本到标签的训练模型对数据集 D_G 进行预测,消除预测错误的样本。

最后,将源领域数据集 D_S 和过滤后的生成数据集 D_G 结合作为最终的训练数据集,在 T5 预训练模型上进行训练。对源领域标注数据集 D_S 和生成数据集 D_G 的输入输出对 $\{x_{s,G}, y_{s,G}\}$ 进一步训练以微调参数 θ ,使其对数似然值最大化:

$$\max_{\theta} \log p_{\theta}(y_{s,G} | e) = \sum_{i=1}^n \log p_{\theta}((y_{s,G})_i | e, (y_{s,G})_{<i}) \quad (7)$$

其中, n 为输出文本序列 $y_{s,G}$ 的长度。

4 实验

4.1 数据集

本实验使用 SemEval 语料库的 restaurant 2014—2016, laptop2014 以及 2004 年 Hu 等^[1]介绍的来自网络服务的评

论 service 这 3 个领域的数据集。通过 restaurant(R), laptop(L), service(S) 这 3 个领域的两两组合,进行跨领域的属性词和情感联合抽取任务。数据集标注了实体属性及其情感极性,包括积极(Positive)、中立(Neutral)和消极(Negative)。数据集集中的基本信息统计如表 2 所列。

表2 数据集基本信息统计

Table 2 Dataset basic information statistics

| 数据集 | 领域 | Train | Test | Dev |
|-----|------------|-------|------|-----|
| L | laptop | 3045 | 800 | 304 |
| R | restaurant | 3877 | 2158 | 387 |
| S | service | 1492 | 747 | 149 |

4.2 实验参数设置

本实验采用 t5-base 作为预训练模型,以 Transformer 结构为基础,使用了经典的编码器-解码器架构。输入的最大序列长度设置为 128,嵌入维度设置为 768。训练上, batch size 设为 16,学习率设为 3×10^{-4} ,所有实验的训练周期数为 20,使用 Adam 优化器更新模型参数,联合损失函数采用 L2 正则化。

4.3 评估方法

本实验采用 F_1 值作为评估指标, F_1 值结合了精确度(Precision)和召回率(Recall)两个指标,其计算式如下:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$F_1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (10)$$

其中, TP 为正类样本被预测为正类的数量, FP 为负类样本被预测为正类的数量, FN 为正类样本被预测为负类的数量。

F_1 作为精确率和召回率的综合评价,可以全面地评估模型的性能,只有所有预测元素与黄金标签完全相同时,预测才被认为正确。在实验对比结果中, F_1 值越高,说明实验模型的效果越好,情感分析结果越准确。

4.4 对比实验

为了验证本文方法的有效性,选择以下几个经典模型作为基准模型,与本文方法在属性词抽取和情感分类任务上进行对比。实验选取的对比模型具体如下。

Hier-Joint^[14]: 一种基于循环神经网络(Recurrent Neural Network, RNN)的方法,结合了辅助标签来解决跨领域观点目标提取任务。辅助标签是指在训练过程中利用其他数据源提供的标签信息,帮助模型更好地学习目标提取任务。

RNSCN^[2]: 一种基于递归神经网络的结构对应网络,用于跨领域方面和意见共同提取。该模型能够从跨领域的语料库中学习方面和意见之间的结构对应关系,以提高方面和意见的提取效果。

AD-SAL^[19]: 使用一种选择性对抗性学习方法,以实现细粒度领域自适应的局部语义对齐。

AHF^[20]: 一种自适应混合框架,用于跨领域方面导向情感分析。该框架结合了不同的方面导向情感分析方法,包括基于规则的方法、基于统计的方法和基于深度学习的方法,并根据不同领域的特点和需求自适应地选择合适的方法。

GAS^[8]:一种基于条件生成的框架,通过将方面信息作为条件输入到生成式模型中,生成与该方面相关的情感文本。

利用本文方法与上述方法在 4.1 节介绍的数据集上进行对比实验,实验结果如表 3 所列。

表 3 对比实验结果

Table 3 Comparison experimental results

| 方法 | L→R | S→R | R→L | S→L | L→S | R→S |
|------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Hier-Joint | 33.54 | 31.10 | 20.72 | 22.65 | 13.90 | 15.56 |
| RNSCN | 35.65 | 33.21 | 26.63 | 18.87 | 16.59 | 20.04 |
| AD-SAL | 43.04 | 41.03 | 34.13 | 27.04 | 27.20 | 28.01 |
| AHF | 43.49 | 46.55 | 34.89 | 29.01 | 33.05 | 33.23 |
| GAS | 49.06 | 54.61 | 43.50 | 35.12 | 29.64 | 30.99 |
| Ours | 67.02 | 66.53 | 58.19 | 47.19 | 59.72 | 59.86 |

从表 3 中可以得出以下结论:

1) 在与其他方法的对比中,本文方法都获得了较高的 F_1 分数,充分说明了本文方法能够很好地适用于跨领域细粒度情感分析任务,证明了本文模型的性能和跨领域数据增强方法的有效性。

2) 基于预训练模型的方法的 F_1 分数显著高于其他神经网络模型,这是因为预训练模型通过大规模的语言模型预训练,成功地捕捉了更为丰富的语义表示,使得细粒度情感分析的结果得到了很大的提升。

3) 在除了本文方法之外的其他方法中,与本文同样基于 T5 预训练模型的气模型,相较于其他模型的表现更佳,这说明了序列到序列的生成模型具有更好的泛化能力,并验证了端到端方法相较于非端到端方法的优势。

4.5 消融实验

为了验证本文方法各个模块的性能,本节进行了消融实验。

self-training:直接使用 3.2 节提到的文本到标签方向生成的目标领域伪标签 $y_T = (a_T, p_T)$ 进行自训练,而不进行标签到文本方向的生成。

text-to-label:直接使用 3.2 节文本到标签方向的生成模型进行实验,即使用源领域原始数据集训练的模型在目标领域进行评估。

w/o filter:在本文方法的基础上仅去除 3.3 节提到的过滤步骤。

消融实验结果如表 4 所列。

表 4 消融实验结果

Table 4 Results of ablation study

| 方法 | L→R | S→R | R→L | S→L | L→S | R→S |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Ours | 67.02 | 66.53 | 58.19 | 47.19 | 59.72 | 59.86 |
| -self-training | 63.13 | 64.41 | 53.59 | 39.71 | 56.67 | 51.94 |
| -text-to-label | 65.40 | 63.91 | 55.50 | 44.74 | 53.47 | 53.89 |
| -w/o filter | 66.53 | 57.63 | 53.79 | 42.05 | 55.69 | 57.08 |

由表 4 的实验结果可以看出:

1) 去除任一模块,跨领域情感分析的 F_1 分数都发生了不同程度的下降,充分说明了所有模块都在本文方法中产生了正向效果。

2) self-training 和 text-to-label 方法下的 F_1 分数相比本文方法都有下降,且相比其他模块下降更为明显。这说明使

用增强后的数据训练模型远比增强前的数据效果好,验证了本文提出的跨领域数据增强方法可以有效学习目标领域知识,以提高样本多样性并实现领域自适应。

3) w/o filter 方法相比本文方法效果下降,说明本文设计的数据过滤方法能够有效提高数据质量,缓解预测噪声。

4.6 不同数据增强方法对结果的影响

为了充分验证本文提出的数据增强方法的有效性,选取了以下几个跨领域数据增强方法作为对比,在属性词抽取和情感分类任务上进行了对比实验。选取的对比方法如下。

BERT_{B/E}-UDA^[21]:结合生成式模型和对抗训练技术,生成具有多样性和一致性的跨领域评论文本。其中 BERT_B 和 BERT_E 分别表示基于原始的 BERT 模型和持续训练的 BERT 模型。

BERT_{B/E}-CDRG^[15]:在 BERT_{B/E}-UDA 的基础上,进一步引入了自训练策略,通过生成伪标签并利用这些标签重新训练新模型,以提升跨领域数据增强的效果。

GCDDA^[22]:该方法首先利用源领域删除领域特定片段后的样本训练 BART 模型,随后利用训练好的模型生成目标领域的句子并预测其标签,使用生成的样本进行扩充从而实现跨领域数据增强。

DA²LM^[23]:通过领域自适应语言模型将标签和样本的生成过程统一起来,旨在学习领域不变的上下文和注释,从而提高数据的领域适应性。

BGCA^[17]:提出了一个统一的双向生成框架,利用 T5 模型双向训练生成目标领域的标签和文本,从而扩充数据集,提升模型在跨领域任务上的性能。

根据表 5 的结果,可以得出以下结论:

1) 本文提出的跨领域数据增强方法在与其他数据增强方法的对比实验中取得了更高的 F_1 分数,充分说明了本文方法能够有效提供高质量的增强数据,实现领域知识迁移,从而提高模型的领域适应能力。

2) 在 BERT 模型的 4 个变体中,BERT_E 的 F_1 分数高于 BERT_B,说明持续训练可以帮助模型进一步优化参数,使其更好地适应跨领域情感分析任务。

3) 在除了本文方法之外的其他方法中,BGCA 框架相较于其他模型表现出更佳的性能。该方法同样采用了端到端的 ABSA 模型以及基于数据的领域适应方法。这一发现验证了端到端模型的有效性,它能够减少错误传播,提高整体模型性能;同时也证明了基于数据的领域适应方法的有效性,它能够更好地学习目标领域的知识,从而减少预测噪声。

表 5 不同数据增强方法的 F_1 分数Table 5 F_1 scores of different data enhancement methods

| 方法 | L→R | S→R | R→L | S→L | L→S | R→S |
|---------------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| BERT _B -UDA | 45.46 | 47.09 | 33.68 | 34.77 | 27.89 | 33.12 |
| BERT _E -UDA | 49.52 | 53.97 | 43.95 | 35.76 | 27.78 | 30.67 |
| BERT _B -CDRG | 49.79 | 47.92 | 38.68 | 33.69 | 38.14 | 35.14 |
| BERT _E -CDRG | 57.96 | 53.09 | 45.66 | 35.06 | 42.96 | 40.85 |
| GCDDA | 50.50 | 55.66 | 47.79 | 36.53 | 27.22 | 32.07 |
| DA ² LM(LSTM) | 59.47 | 56.26 | 42.49 | 36.54 | 35.93 | 40.38 |
| DA ² LM(GPT-2) | 60.39 | 58.64 | 42.91 | 36.97 | 36.84 | 40.44 |
| BGCA | 61.69 | 56.39 | 45.52 | 36.40 | 39.76 | 43.20 |
| Ours | 67.02 | 66.53 | 58.19 | 47.19 | 59.72 | 59.86 |

4.7 误差分析与案例研究

为了深入了解模型预测错误的情形,本节进行了误差分析和案例研究。首先对属性词抽取和情感分类两个子任务的 F_1 分数进行了分析,具体结果如表 6 所列。

表 6 属性词抽取和情感分类子任务的 F_1 分数

Table 6 F_1 scores of subtasks attribute word extraction and sentiment classification

| 任务 | L→R | S→R | R→L | S→L | L→S | R→S |
|-----|-------|-------|-------|-------|-------|-------|
| ATE | 76.24 | 76.06 | 68.22 | 62.10 | 70.83 | 66.31 |
| SA | 84.13 | 83.19 | 79.71 | 70.90 | 84.72 | 85.42 |

由表 6 可以观察到,属性词抽取任务相比情感分类任务更容易产生错误。通过对预测错误样本的观察,我们发现当目标属性词为多个单词的短语时,相比单个单词的属性词更容易出现预测错误,如图 9 中的 Example-1 所示。此外,模型还经常将单词的特殊形式预测为其原形,例如将复数预测为单数,将过去式动词预测为动词原形等,如图 9 中的 Example-2 所示。这些情况说明了模型在处理属性词抽取任务时可能存在一些挑战,如处理多词短语和词形变化。而对于情感分类任务,模型常常会混淆正面和中性的类别,这可能是由数据集中标签分布不均衡导致的。这些发现为进一步改进模型提供了方向。

| |
|---|
| <p>Example-1</p> <p>Sentence: <i>web surfing</i> is smooth and seamless.</p> <p>Target: <i>web surfing</i>, positive</p> <p>Prediction: <i>surfing</i>, positive</p> |
| <p>Example-2</p> <p>Sentence: i've had my computer for 2 weeks already and it works perfectly.</p> <p>Target: <i>works</i>, positive</p> <p>Prediction: <i>work</i>, positive</p> |

图 9 属性词预测错误样例

Fig. 9 Examples of aspect prediction error

结束语 目前,情感分析已广泛应用于各个领域,然而由于不同领域之间情感表达、语言风格和语境的显著差异,传统方法难以应对跨领域的情感分析任务。此外,手动标注新领域的的数据既耗时又成本高昂,限制了模型在不同领域的适应能力和可扩展性。本文针对上述问题展开探讨,提出了一种跨领域细粒度情感分析方法,利用 T5 预训练模型进行属性词和情感极性联合抽取任务,并通过生成标签和文本来进行数据增强,实现跨领域适应。实验结果表明,本文方法与其他对比方法相比,在 F_1 指数上有显著提升,充分证明了本文方法的有效性。

虽然本文通过生成增强数据提高了跨领域情感分析的性能,但生成的文本与真实的目标领域文本在细节和风格上仍可能存在差异。此外,目前本文方法主要针对情感二元组抽取,但尚未尝试其他 ABSA 子任务,例如情感三元组或四元组的抽取。在未来的工作中,我们将继续进行优化工作,进一步提高跨领域情感分析模型的性能和适应性,探索更多情感元素的联合抽取任务,并尝试在更多语种和其他领域进行研究,进一步提高跨领域情感分析模型的性能。

参考文献

[1] HU M, LIU B. Mining and summarizing customer reviews[C]//

Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2004:168-177.

[2] WANG W, PAN S J, DAHLMEIER D, et al. Coupled multi-layer attentions for co-extraction of aspect and opinion terms[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2017:3316-3322.

[3] HU M, ZHAO S, ZHANG L, et al. CAN: Constrained attention networks for multi-aspect sentiment analysis[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. 2019:4601-4610.

[4] LI X, BING L, LI P, et al. A unified model for opinion target extraction and target sentiment prediction[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2019:6714-6721.

[5] PENG H, XU L, BING L, et al. Knowing what, how and why: A near complete solution for aspect-based sentiment analysis[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020:8600-8607.

[6] XU L, LI H, LU W, et al. Position-aware tagging for aspect sentiment triplet extraction[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. 2020:2339-2349.

[7] WU Z, YING C, ZHAO F, et al. Grid tagging scheme for aspect-oriented fine-grained opinion extraction[C]// Findings of the Association for Computational Linguistics: EMNLP 2020. 2020:2576-2585.

[8] ZHANG W, LI X, DENG Y, et al. Towards generative aspect-based sentiment analysis[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. 2021:504-510.

[9] ZHANG W, DENG Y, LI X, et al. Aspect sentiment quad prediction as paraphrase generation[C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. 2021:9209-9219.

[10] BAI Y, XIE Y, LIU X, et al. BvSP: Broad-view Soft Prompting for Few-Shot Aspect Sentiment Quad Prediction[C]// Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. 2024:8465-8482.

[11] CHEN B, OUYANG Q, LUO Y, et al. S² GSL: Incorporating Segment to Syntactic Enhanced Graph Structure Learning for Aspect-based Sentiment Analysis[C]// Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. 2024:13366-13379.

[12] JAKOB N, GUREVYCH I. Extracting opinion targets in a single and cross-domain setting with conditional random fields [C]// Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing. 2010:1035-1045.

[13] CHERNYSHEVICH M, BELARUS I. Cross-domain extraction of product features using conditional random fields[C]// Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014). 2014:309-313.


[14] DING Y, YU J, JIANG J. Recurrent neural networks with auxiliary labels for cross-domain opinion target extraction[C]// Pro-

ceedings of the AAAI Conference on Artificial Intelligence. 2017:3436-3442.


- [15] YU J, GONG C, XIA R. Cross-domain review generation for aspect-based sentiment analysis[C]// Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021. 2021: 4767-4777.
- [16] SU Y, ZHOU X B. Cross-domain Sentiment Analysis Based on Gradient Data Selection[J]. Software guid, 2023, 22(5): 50-56.
- [17] DENG Y, ZHANG W, PAN S J, et al. Bidirectional generative framework for cross-domain aspect-based sentiment analysis [C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023: 12272-12285.
- [18] 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.
- [19] LI Z, LI X, WEI Y, et al. Transferable end-to-end aspect-based sentiment analysis with selective adversarial learning[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. 2019: 4590-4600.
- [20] 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.
- [21] GONG C, YU J, XIA R. Unified feature and instance based domain adaptation for aspect-based sentiment analysis[C]// Pro-

ceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. 2020: 7035-7045.

- [22] LI J, YU J, XIA R. Generative cross-domain data augmentation for aspect and opinion co-extraction [C] // Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2022: 4219-4229.
- [23] YU J, ZHAO Q, XIA R. Cross-domain data augmentation with domain-adaptive language modeling for aspect-based sentiment analysis[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023: 1456-1470.



CHEN Ge, born in 2001, postgraduate, is a member of CCF(No. V5365G). Her main research interests include sentiment analysis and so on.



WANG Zhongqing, born in 1987, Ph.D., associate professor. His main research interests include natural language processing, sentiment analysis and information extraction.

(责任编辑:喻藜)