

面向方面级情感分析的渐进式跨域方法研究

秦涛^{1*}, 周源坤¹, 王平辉¹, 管晓宏^{1,2}

1. 西安交通大学智能网络与网络安全教育部重点实验室, 西安 710049

2. 清华大学智能与网络化系统研究中心, 北京 100084

* 通信作者. E-mail: qin.tao@mail.xjtu.edu.cn

收稿日期: 2025-5-9; 修回日期: 2025-07-15; 接受日期: 2025-08-29; 网络出版日期: 2025-12-15

国家重点研发项目(批准号: 2023YFC3306100)、国家自然科学基金(批准号: 62172324)、陕西省重点研发计划(批准号: 2023-YBKY-269)和西咸新区科技创新计划(批准号: RGZN-2023-002, 2022-ZDJS-001)资助项目

摘要 方面级情感分析旨在挖掘文本中不同方面或特定对象的情感倾向, 在舆情监管、商业推广、决策支持等领域具有重要应用价值。方面级情感分析方法通常依赖大量标注数据, 然而在标注成本高昂或标注数据匮乏的应用场景中, 模型性能往往显著下降, 跨域迁移方法成为缓解该问题、提升模型泛化能力的有效途径。跨域方面级情感分析通常生成有标注的目标域数据, 并利用这些数据训练跨域模型。然而, 现有方法面临着生成数据与原始目标域数据语义偏差大、句式单一、伪标签质量差等问题, 这些低质数据会限制模型学习目标域特征, 导致迁移效果不佳。据此, 本文提出了面向方面级情感分析的渐进式跨域分析方法, 该方法通过4个阶段实现渐进式跨域适配: 获取高质量目标域伪标签、生成与伪标签对齐的目标域文本、优化目标域生成文本、融合源域数据实现域迁移。在此过程中, 模型参数在多个任务间传递, 以实现渐进式跨域, 同时生成高质量的目标域有标签数据实现最终的域迁移。结合多个公开数据集的实验结果显示, 在跨域方面级情感三元组抽取任务中, 与现有跨域方法相比, 本文所提方法平均F1值提升1.28%; 与不跨域方法相比平均F1值提升9.57%, 证明了本文所提方法的有效性。

关键词 方面级情感分析, 跨域迁移, 多阶段渐进式, 语言模型

1 引言

方面级情感分析旨在挖掘文本中不同方面或特定对象的情感倾向, 涉及方面、情感词和情感倾向等多个要素^[1~4]。例如, 给定句子“*The screen is excellent*”, 其中的方面是“*screen*”, 情感词是“*excellent*”, 相应的情感极性为正向。由于不同领域在方面和观点表达上的差异性^[5~8], 现有方法在将一个领域训练的模型应用于其他领域时常常表现不佳。此外, 为每个领域均标注数据代价高昂且耗时, 这限制了方面级情感分析模型的跨域应用。

为实现方面级情感分析模型的跨域迁移, 现有方法^[9~12]多专注于挖掘两个领域的共同特征, 缩小源域和目标域数据的域差异, 进行领域特征对齐以实现平稳的域迁移。但现有方法主要存在以下问题。(1) 针对目标域数据未标注的问题, 许多研究尝试利用已有模型为其生成伪标签, 并据此训练跨域模型。然而, 由于伪标签由异源模型生成, 常存在噪声, 且与目标域文本之间存在语义偏差, 易导致模型在目标域上误差较大。(2) 当前方法普遍

引用格式: 秦涛, 周源坤, 王平辉, 等. 面向方面级情感分析的渐进式跨域方法研究. 中国科学: 信息科学, 2026, 56: 76–90, doi: 10.1360/SSI-2025-0180

Qin T, Zhou Y K, Wang P H, et al. Research on methods for progressive cross-domain aspect-based sentiment analysis. Sci Sin Inform, 2026, 56: 76–90, doi: 10.1360/SSI-2025-0180

将跨域各阶段任务分开建模,训练时重新初始化模型,缺乏统一的参数传递机制,导致方面级情感分析知识在迁移过程中难以连续积累,限制了模型对目标域特征的适应能力。

针对伪标签噪声与语义偏差问题,可从提升伪标签质量和增强伪标签与目标域文本的一致性两方面入手。前者可借助域对抗训练^[13,14]框架,通过引导模型学习域无关特征,减少源域与目标域的分布差异,从而生成更准确的伪标签。后者则可基于已有伪标签重建目标域文本,使其内容与标签保持语义一致,进而构建语义对齐的目标域伪标注数据集,在生成目标域的数据时,也可以利用自然语言推理技术进行数据过滤,把控目标域生成数据质量,有效提升跨域训练的稳定性与鲁棒性。为实现跨阶段任务的连续建模,可以构建基于语言模型的统一生成式框架,将方面级情感分析任务统一转化为文本生成问题。同时,语言模型^[15~18]具备丰富的常识知识,对多领域语法差异具有较强容忍度,在跨域场景下仍能有效捕捉情感信息,适合作为统一的跨域建模基础。更进一步,可引入参数传递机制,在跨域各阶段始终采用同一模型进行持续微调,该策略能有效避免不同阶段间表征空间不一致的问题,确保方面级情感分析知识在训练过程中稳定积累与迁移,提升模型对目标域特征的适应能力与跨域整体性能。

基于上述分析,本文设计了一种面向方面级情感分析的渐进式跨域应用框架。该框架利用预训练语言模型,将方面级情感分析任务转换为文本生成任务,并把跨域过程分解为4个阶段:获取高质量目标域伪标签、生成与伪标签对齐的目标域文本、优化目标域生成文本、融合源域数据实现迁移。在此过程中,模型参数在上述4个任务间传递,传递机制主要通过显式的参数共享,如第2阶段使用第1阶段模型训练后的参数,第4阶段使用第2阶段模型训练后的参数,使得训练的过程是渐进的。同时,对于这些阶段中的方面级情感分析任务(如情感三元组抽取、情感文本重建等),通过指令微调技术统一转化为文本生成任务。任务引导既能够规范模型获得预期输出,也能够循序推动模型,以实现渐进式跨域,生成高质量的目标域有标注数据供最终的域迁移。随后选取方面词抽取和方面级情感三元组抽取两个任务验证所设计框架在跨域下的性能。跨域方面词抽取验证分析使用的数据集包括4个领域:电脑(L)、餐厅(R)、数字设备(D)和网络服务(S),来自SemEval挑战赛。跨域方面级情感三元组抽取验证分析使用的数据集包括3份餐厅评论数据集:14res, 15res和16res和一份电脑评论数据集14lap。在实验过程中,可选一个电脑评论数据集作为源域,3个餐厅评论数据集分别作为目标域,也可以倒转过来,最终形成6个跨域实验。最后选取特征与样本自适应、评论重构与伪标签生成和仅在源域上进行训练而不执行迁移的三大类8种方法作为基线对本文所提方法进行性能评估。实验结果表明,与现有跨域三元组抽取方法相比,本文所提方法平均F1值提升1.28%,与不跨域方法相比平均F1提升9.57%,验证了所提方法的有效性。

本文的主要贡献如下。

(1) 设计了面向方面级情感分析的渐进式跨域框架,该框架利用预训练语言模型,结合指令模板,将跨域方面级情感分析建模成文本生成任务,统一了各类方面级情感分析子任务的模型结构。

(2) 充分利用源域与目标域的域无关特征,提升目标域伪标签的生成质量。同时基于伪标签获取语义对齐的目标域文本,产生噪声更少、语义对齐的目标域标注数据。

(3) 通过对模型在不同方面级情感分析任务中微调,不断加深模型对方面级情感分析任务的认知,使模型在有限的数据中充分学习任务特征。

本文后续的组织结构如下,第2节介绍了相关工作,梳理现有的跨域方面级情感分析研究,并总结各类方法的优缺点。第3节介绍了本文所提方法中各个阶段的具体设计与算法描述。第4节给出了实验结果与分析。最后对本文研究工作进行了总结并探讨了其局限性。

2 相关工作

2.1 基于特征转移的跨域方法

这类方法利用常见的情感种子词和预定义规则作为枢轴关联不同领域中的特定词汇。Qiu等^[19]提出了一种自举扩展情感词典的半监督方法,利用句法依赖分析器解析情感词与情感目标之间的关系,并不断扩展初始

情感词典和提取情感目标. Li 等^[20]提出了一个两步领域适应框架, 用于在目标域中共同提取情感词典和主题词典. 第1步在目标域中生成若干高置信度的情感种子和主题种子, 第2步利用关系自适应自举算法, 扩展目标领域中的种子词典. 除了规则类方法之外, 也可以通过手动标注评论中的所有情感词, 并设计神经模型以捕捉词与情感之间的关系. Jakob 等^[21]将多种特征作为条件随机场模型的输入, 包括词性、依赖关系等领域无关的语法特征. 通过引入这些领域无关的特征, 模型能够更好地处理跨域问题. 类似地, Chernyshevich^[22]使用了多种与领域无关的特征对条件随机场模型进行训练, 包括词性、命名实体特征、语义标签等. Ding 等^[5]使用一些定义明确的语法规则来提取辅助标签, 并通过让模型学习这些标签作为辅助任务, 提升跨领能力. Wang 等^[6]设计了基于依存树的跨域递归神经网络框架, 利用依赖关系作为桥梁, 结合依赖关系分类的辅助任务学习领域无关的特征表示, 并通过自编码器缓解解析树噪声. Wang 等^[7]进一步设计了可迁移交互记忆网络, 引入域对抗机制和交互建模任务, 在全局情感记忆中学习跨域共享表示, 并对齐三类目标词间的交互类型. Li 等^[23]和 Du 等^[9]设计了对抗学习机制, 提升对关键词的迁移效果. Zhao 等^[24]设计了包含特征适应与伪标签适应双阶段的迁移框架, 先将源域模型迁移到目标域语义空间, 再通过伪标签和锚点机制反向对齐源域模型. Chen 等^[25]则通过检索目标域中具有相似句法语义角色的目标词原型, 引导源域词语表征融合目标域信息, 实现细粒度的领域适配.

虽然基于特征转移的跨域方法取得了一定进展, 但它们仍然面临域间差异显著的难题, 尤其是在不同领域情感目标和语境差异较大的情况下, 模型的泛化能力受限. 这些方法在处理领域间高维语义差异、噪声问题和伪标签不确定性时仍然存在局限. 在实际应用中, 如何平衡特征对齐和模型复杂度, 仍然是一个值得进一步探索的问题.

2.2 基于数据转移的跨域方法

与基于特征的转移方法注重于特征选择、模型和算法设计相比, 基于数据转移方法更关注数据本身, 可以大致分为样本加权和数据增强两种方式. 样本加权通过对原始数据进行加权处理, 使与目标域相似的样本具有更大的权重, 进而使源域的数据分布更接近目标域, 最终减小不同领域之间的差异; 数据增强通过补充目标域相似数据, 简单而有效地提高了模型的跨领能力. Xia 等^[26]通过利用最大似然和最小统计距离来确定样本的最优权重. Gong 等^[27]结合 BERT, 利用词性与依存信息作为自监督信号, 并引入实例加权方法动态学习词语重要性, 从而增强领域共享特征. Yu 等^[28]先通过源域标签提取出域无关语句, 再利用 BERT 的掩码语言模型能力, 将提前提取的目标域词汇填充到上下文中生成目标域样本. Yu 等^[29]提出三阶段迁移框架, 首先利用源域与目标域数据训练初始领域适应模型, 生成目标域伪标签; 其次通过领域自适应语言模型在源域与伪标签数据上联合训练提升表示能力, 最后以自回归生成方式构造大量高质量带标签的目标域数据用于增强目标域模型训练. Deng 等^[30]进一步提出统一的双向生成框架, 实现文本到标签与标签到文本的双向建模, 在提升迁移能力的同时增强了数据多样性. Wang 等^[31]在此基础上, 引入自然语言生成优化与组合式数据多样化策略, 进一步提高生成数据的质量与覆盖范围, 为跨域模型训练提供更可靠的伪标注数据支撑.

基于数据转移的方法通过调整源域数据或生成目标域数据来减小领域间的差异, 但仍然难以避免目标域与源域之间的固有差距, 尤其是在目标域样本的生成质量和多样性无法充分保证时, 可能导致模型对目标域的适应能力不足. 其次, 这类方法依赖于大量的目标域数据生成和伪标签的构建, 但如何确保这些生成数据的准确性和代表性, 避免引入噪声, 依然是一个挑战.

3 面向方面级情感分析的渐进式跨域方法

3.1 问题定义

跨域迁移任务的具体目标是利用源域的标注数据来处理目标域中未标注的数据. 假设源域的标注数据集表示为 $D_S = \{(x_i^S, y_i^S)\}_{i=1}^{N_S}$, 而目标域的未标注数据集为 $D_U = \{x_i^U\}_{i=1}^{N_U}$. (x_i^S, y_i^S) 表示带有标签 y_i^S 的源域样本 x_i^S , 而 x_i^U 则代表目标域中未标注的样本, N_S 和 N_U 分别表示源域和目标域训练集的样本数量. 跨域迁移的最

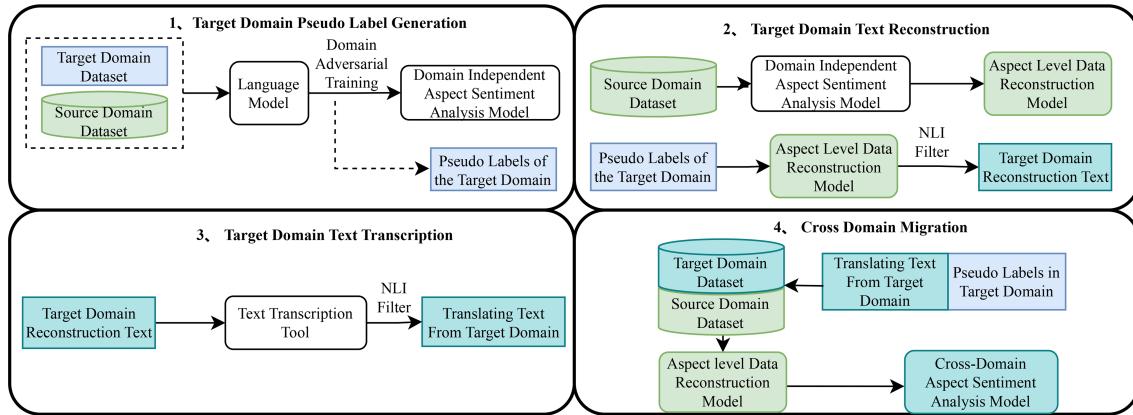


图1 (网络版彩图) 面向方面级情感分析的渐进式跨域框架.

Figure 1 (Color online) The framework of progressive cross domain aspect sentiment analysis.

终目标是对目标域的测试集 $D_T = \{x_i^T\}_{i=1}^{N_T}$ 进行高效的方面级情感分析, D_U 和 D_T 同属于目标域数据集, 其中 D_U 表示目标域未标注数据的训练集, D_T 表示目标域未标注数据的测试集, N_T 为目标域测试集样本数量.

3.2 整体框架

本文使用预训练语言模型, 结合指令微调技术, 在所设计的跨域框架下完成方面级情感分析任务. 为实现这一目标, 所设计框架包括 4 个阶段: 目标域伪标签生成阶段、目标域文本重建阶段、目标域文本转写阶段和跨域迁移阶段, 如图 1 所示.

第 1 阶段采用域对抗神经网络, 利用源域带标注的数据微调预训练的语言模型, 以完成方面级情感分析任务. 通过域对抗机制, 语言模型能够有效学习到源域和目标域的领域无关的任务特征表示, 从而提升目标域伪标签的生成质量. 第 2 阶段利用源域的标注数据, 微调语言模型, 执行方面级情感文本重建任务. 随后, 使用该模型为目标域生成相应的重建文本, 以此将目标域伪标签与目标域的文本进行对齐, 减少后续目标域生成数据的噪声. 第 3 阶段基于第 2 阶段提供的目标域重建文本, 使用文本转写工具进行文本转写, 进一步提高目标域句式的多样性和表达的丰富性. 在转写过程中, 既要确保目标域重建文本与标签的对应性, 也要确保转写文本与原目标域重建文本的语义一致性. 经过过滤的转写文本和目标域伪标签一起组成了最终的目标域标注数据. 第 4 阶段将新构建的高质量目标域数据集与源域数据集合并, 在方面级情感分析任务上对大语言模型进行指令微调. 通过上述 4 个阶段的系统性训练和优化, 实现模型向目标域的有效迁移.

(1) 目标域伪标签生成阶段. 该阶段采用域对抗神经网络来生成目标域的高质量伪标签, 以缓解域偏移所带来的负面影响. 域对抗神经网络由特征提取器、标签预测器和域判别器 3 部分构成. 其中, 特征提取器对应于所使用的语言模型的编码器部分, 负责将输入文本映射为具有判别能力的语义特征表示; 标签预测器则对应于语言模型的解码器部分, 基于特征提取器得到的特征来预测方面级情感标签, 确保模型能够准确完成目标任务; 域判别器基于特征提取器提取的特征预测当前输入样本所属的领域, 即区分源域与目标域.

在训练过程中, 我们对特征提取器和域判别器施加对抗性约束: 一方面标签预测器通过监督学习来提高在方面级情感任务上的准确性; 另一方面, 域判别器试图精确判断样本所属的领域, 而特征提取器则努力生成能够混淆域判别器的领域无关特征. 最终, 通过博弈式的训练策略, 我们期望域判别器无法准确区分特征提取器生成特征的所属领域, 即特征提取器成功捕捉了与具体领域无关、仅与任务相关的特征. 当特征提取器提取出域无关的特征后, 标签预测器在目标域能生成准确性较高的伪标签, 较少受到领域偏移的影响, 有利于提升后续领域自适应过程的整体性能.

(2) 目标域文本重建阶段. 在此阶段, 利用源域数据进一步微调模型上一阶段的语言模型. 以方面级情感文本重建为微调任务, 使模型能够利用已有的标签信息预测相应的文本表达形式. 在微调后, 模型将基于上一阶段生成的目标域伪标签, 生成目标域的重建文本.

一方面,方面级情感文本重建任务使模型显式建模方面与情感之间的结构性依赖关系.在生成过程中,模型需恢复各组成成分的语义位置与语法功能,从而深化对任务中属性间关系与句法结构的理解,提升对任务语义的把握能力.另一方面,尽管前一阶段的伪标签是基于域无关特征生成的,具有一定的迁移能力,但其语义可能与目标域原始文本存在偏差,导致标签与文本之间对齐不准确,影响模型对关键任务特征的学习.通过引导模型生成与伪标签语义一致的目标域文本,可有效缓解上述偏差,增强伪标签与输入之间的语义一致性,为后续训练提供更可靠的数据基础.

由于重建文本生成的不确定性,需要检查生成的重建文本与伪标签的对应情况,并进行筛选:(i)检查伪标签中的所有词是否都出现在了重建文本中,如果存在遗漏,则不使用该重建文本;(ii)使用预训练的自然语言推理模型,以目标域原始文本为前提,目标域重建文本为假设,判断二者之间的关系,仅保留推理结果不为矛盾关系的重建文本.本阶段形成的目标域重建文本与伪标签存在良好的对应性.

(3) 目标域文本转写阶段.在第2阶段中,由于目标域文本的重建过程完全依赖标签信息,这种方法容易造成文本句式结构简单化、单调化,缺乏语言表达的多样性,从而可能降低在实际应用中的效果.因此,为了进一步提升目标域文本的质量,本阶段对目标域重建文本进行转写,以丰富其表达方式.

利用预训练的文本转写模型,通过指令微调引导模型对目标域重建文本进行转写.转写的目的是生成更自然,句法更多样的文本,并保证转写过程中不遗失伪标签内容,也不偏离原句语义.然而,转写文本可能存在以下问题:(i)转写模型未遵循指令要求,生成的文本未完整包含伪标签的内容;(ii)转写的文本与原重建文本之间可能出现语义矛盾或内容不相关.解决上述问题的策略为:(i)在转写完成后,检查伪标签中的全部词汇是否均出现在转写文本中,若存在遗漏情况,则舍弃该文本;(ii)使用预训练的自然语言推理模型,以目标域重建文本为前提,目标域转写文本为假设,判断二者之间的关系,仅保留推理结果不为矛盾关系的转写文本.

最终将经过上述严格筛选的目标域转写文本与对应的伪标签组合,形成目标域标注数据集.此方法生成的目标域文本具备更丰富的句式结构和语言表达多样性,同时保持与重建文本的一致语义,确保了文本与伪标签之间的高度对应性,具备多样性强、质量高的特点.

(4) 跨域迁移阶段.第3阶段构建的跨域方面级情感分析数据集融合了源域的有标注数据和目标域的未标注数据,利用该数据微调第2阶段的模型,得到跨域方面级情感分析模型.

3.3 算法描述

(1) 目标域伪标签生成阶段.域对抗神经网络包含:特征提取器 $F(\cdot)$,负责将输入文本映射为语义特征表示.标签预测器 $C(\cdot)$,基于特征提取器的输出,预测具体的标签.域判别器 $D(\cdot)$,根据特征提取器输出的特征,判别样本来自源域 D_S 还是目标域 D_U ,并提供梯度信号以实现对抗式训练.

由于方面级情感分析可以视为序列到序列的生成式任务,微调的语言模型可分为编码器和解码器两部分

$$LM_{\text{base}} = LM_{\text{encoder}} + LM_{\text{decoder}}. \quad (1)$$

LM_{encoder} 提取输入文本特征,作为特征提取器 $F(\cdot)$. LM_{decoder} 根据编码器输出特征预测标签,作为标签预测器 $C(\cdot)$.

对于源域数据 D_S ,模型的监督损失定义为

$$\mathcal{L}(LM_{\text{base}}) = \mathcal{L}(F, C) = - \sum_{i=1}^{N_S} \log P(y_i^S \mid \text{Tmpl}(\mathcal{M}^{\text{aste}}, \mathcal{F}^{\text{aste}}, x_i^S), \theta), \quad (2)$$

其中 $\text{Tmpl}(\cdot)$ 为指令模版,包括任务定义 $\mathcal{M}^{\text{aste}}$,输出格式 $\mathcal{F}^{\text{aste}}$ 和输入 x_i^S .

域判别器 D 由全连接层和 softmax 层构成,以特征提取器 F 输出的特征 H_{feat} 为输入,输出样本属于源域或目标域的概率:

$$d_i = \text{softmax}(W H_{\text{feat}} + b). \quad (3)$$

域判别器的二元交叉熵损失表示为

$$\mathcal{L}(F, D) = - \sum_{i=1}^{N_s+N_u} [z_i \log d_i + (1 - z_i) \log(1 - d_i)], \quad (4)$$

其中, z_i 是样本的真实域标签 (源域: $z_i = 0$, 目标域: $z_i = 1$), d_i 表示域判别器预测的样本属于目标域的概率.

最终, 域对抗网络的总体优化目标可表示为

$$\min_{F, C} \max_D (\mathcal{L}_y(F, C) - \lambda \mathcal{L}_d(F, D)). \quad (5)$$

在优化时, 首先固定特征提取器 F 和标签预测器 C , 更新域判别器 D 以提高区分源域与目标域的能力, 增加 \mathcal{L}_d . 然后固定域判别器 D , 更新特征提取器 F 和标签预测器 C , 使得 F 能够隐藏域相关信息, 从而减小 \mathcal{L}_d , 同时继续优化监督任务目标 \mathcal{L}_y . 在多轮循环优化后获得具备域泛化性的模型.

通过上述过程, 获得了域无关的方面级情感分析模型 LM_{aste}^S , 并将其应用于目标域数据 x_i^U 生成伪标签. 为了缓解源域与目标域之间的域偏移问题, 避免模型生成不存在于目标域原始文本中的单词, 采用限制性解码策略确保预测输出仅来源于原文本的单词集合 \mathcal{U}_i , 限制性解码策略表示为

$$\hat{y}_i^U = \underset{y \subseteq \mathcal{U}_i}{\text{argmax}} p(y \mid \text{Tmpl}(\mathcal{M}^{\text{aste}}, \mathcal{F}^{\text{aste}}, x_i^U)). \quad (6)$$

通过以上限制性解码生成高质量伪标签, 用于下一阶段的训练.

(2) 目标域重建文本生成阶段. 首先, 利用源域数据 D_S 构建方面级情感文本重建任务的指令模板, 对上阶段的语言模型 LM_{aste}^S 进行微调, 损失函数定义为

$$\mathcal{L} = - \sum_{i=1}^{N_S} \log P(x_i^S \mid \text{Tmpl}(\mathcal{M}^{\text{astr}}, \mathcal{F}^{\text{astr}}, y_i^S), \theta). \quad (7)$$

通过此过程获得源域方面级情感文本重建模型 LM_{astr}^S . 模型在源域微调完成后, 可基于目标域伪标签 \hat{y}_i^U 生成方面级情感文本. 为鼓励模型使用更为多样化的词汇和表达方式, 预测解码时不再限制单词集, 采用模型的词汇全集 \mathcal{V} :

$$\hat{x}_i^U = \underset{x \subseteq \mathcal{V}}{\text{argmax}} p(x \mid \text{Tmpl}(\mathcal{M}^{\text{astr}}, \mathcal{F}^{\text{astr}}, y_i^U)). \quad (8)$$

对重建文本进行质量筛选, 首先是伪标签成分完整性检查: 对于每个生成的重建文本 \hat{x}_i^U , 确保伪标签 \hat{y}_i^U 中的所有词全部出现在重建文本中, 即

$$\{\hat{x}_i^U \mid \forall w \in \hat{y}_i^U, w \in \hat{x}_i^U\}. \quad (9)$$

其次, 使用预训练的自然语言推理模型 M_{NLI} , 将目标域原始文本 x_i^U 作为前提, 目标域重建文本 \hat{x}_i^U 作为假设, 进行推理过滤. 具体过程如下:

$$P(c_i \mid x_i^U, \hat{x}_i^U) = M_{\text{NLI}}(x_i^U, \hat{x}_i^U), \quad c_i \in \{\text{蕴涵, 矛盾, 中立}\}. \quad (10)$$

根据最大概率对应的标签确定两文本之间的关系, 并过滤掉矛盾的数据, 得到最终的目标域重建文本数据:

$$\{\hat{x}_i^U \mid c_i \notin \{\text{矛盾}\}\}_{i=1}^{N_U}. \quad (11)$$

通过上述两项严格筛选, 能够有效保证目标域生成的重建文本与伪标签之间的对应关系.

(3) 目标域数据重构阶段. 通过前两个阶段, 生成的目标域有标注数据集为 $D_U^{\text{raw}} = \{(\hat{x}_i^U, \hat{y}_i^U)\}$. 为进一步丰富目标域重建文本的表达, 使用预训练的文本转写模型 M_{Par} 对目标域重建文本 \hat{x}_i^U 进行转写, 使用指令模板确保转写结果包含标签 \hat{y}_i^U 内容:

$$\bar{x}_i^U = M_{\text{Par}}(\hat{x}_i^U, \hat{y}_i^U). \quad (12)$$

表 1 SemEval 数据集的语句数量与三元组数量统计.

Table 1 Statistics on the number of sentences and triples in SemEval dataset.

	14lap		14res		15res		16res	
	Sentences	Triples	Sentences	Triples	Sentences	Triples	Sentences	Triples
Training set	906	1460	1266	2338	605	1013	857	1394
Development set	219	346	310	577	148	249	210	339
Test set	328	543	492	994	322	485	326	514

对目标域的转写文本进行数据过滤, 使用伪标签成分完整性检查和自然语言推理检查, 过程同式(9)~(11). 将过滤后的目标域转写文本与目标域伪标签组合, 形成目标域有标注数据集:

$$D_U^{\text{final}} = \{(\bar{x}_i^U, \hat{y}_i^U)\}. \quad (13)$$

(4) 跨域迁移阶段. 将源域有标注数据集 D_S 与目标域伪标注数据集 D_U^{final} 组合, 构建跨域方面级情感数据集 D_{S+U} 对第 2 阶段中微调后的模型 LM_{astr}^S 再次指令微调, 损失函数定义为

$$\mathcal{L} = - \sum_{i=1}^{N_{S+U}} \log P(y_i^{S+U} \mid \text{Tmpl}(\mathcal{M}^{\text{aste}}, \mathcal{F}^{\text{aste}}, x_i^{S+U}), \theta). \quad (14)$$

前两个阶段的微调, 使模型充分理解了方面级情感文本与方面级情感三元组之间的关系. 在此基础上, 利用最终的跨域方面级情感数据集对模型进行微调, 使其能够稳定地提取目标域相关特征, 形成跨域方面级情感三元组抽取模型 LM_{aste}^{S+U} .

4 实验结果与分析

本节从多个任务类型、多个数据集和多个情感维度 3 个方面对所提方法的鲁棒性和通用性进行验证分析, 利用对比实验验证所提方法的有效性, 利用消融实验和参数分析验证框架各模块设置的合理性, 利用案例分析直观分析所提方法的效果.

4.1 数据集

在多个任务类型方面, 本文选取方面词抽取和方面级情感三元组抽取两个任务验证本文所设计框架的跨域性能. 跨域方面词抽取任务实验使用的数据集包括 4 个领域: 电脑 (L)、餐厅 (R)、数字设备 (D) 和网络服务 (S). 其中, 电脑和餐厅的数据来自 SemEval 挑战赛 2014, 2015 和 2016 年, 由 Pontiki 等^[32] 收集整理, 数字设备的评论由 Toprak 等^[33] 收集整理, 网络服务的评论由 Hu 等^[34] 整理. 跨域方面级情感三元组抽取任务实验使用的数据集具体包括 3 份餐厅评论数据集, 分别为 14res, 15res 和 16res, 一份电脑评论数据集, 14lap. 数据源自 Xu 等^[35] 和 Peng 等^[36] 重新标注和校准的版本, 具体的数据集统计信息如表 1 所示. 在实验过程中, 可以选一个电脑评论数据集作为源域, 3 个餐厅评论数据集分别作为目标域, 也可以倒转过来, 最终形成 6 个跨域实验. 这些数据集是目前情感分析领域公开的权威数据集, 其中情感维度包括正向、中立和负向 3 个维度, 可以实现多阈、多情感倾向下的算法稳定性测试.

4.2 对比方法

对比方法主要包括特征与样本自适应方法, 如 BERT-UDA; 评论重构与伪标签生成方法, 如 CDRG; 生成式跨域情感建模方法, 如 GAS. 为突出跨域与非跨域方法在效果上的差异, 本文选取了 SpanASTE 和 RoBMRC 作为对比方法, 仅在源域上进行训练而不执行迁移.

(1) BERT-UDA^[27]. 该方法通过特征自适应和样本自适应, 提升模型的跨域泛化能力. 特征自适应通过引入自监督信号, 样本自适应设计一个领域判别器, 对源领域中每个词进行动态评分.

(2) CDRG^[28]. 该方法为两步法: 其一为领域泛化, 首先识别评论中的领域特定属性, 然后将这些属性掩码掉, 得到一个领域无关的中间评论; 其二为领域特化, 将中间评论作为输入生成目标领域的评论.

(3) GAS^[37]. 该方法提出一种统一生成式框架. 该框架包括两种建模范式: 注释式建模和抽取式建模. 注释式建模在原句中插入标签信息构建带注释的目标句, 抽取式建模将输入句子直接对应的情感标签内容构造成目标句.

(4) DA2LM^[29]. 该方法主要包括 3 个阶段. 阶段一, 利用源领域数据训练领域适应模型并为目标领域的数据生成伪标签. 阶段二, 模型在带标签的源数据和伪标签目标域数据上进行训练. 阶段三, 采用自回归生成方式和基于概率的生成策略, 自动生成大量带标签的目标领域数据用于域迁移.

(5) BGCA^[30]. 该方法提出了一个双向生成式跨领域细粒度情感分析框架. 先通过源域数据训练出基础模型, 并为目标域生成伪标签. 再用源域训练一个标签到文本的模型, 然后用该模型生成与目标领域伪标签相匹配的新句子. 利用最终的源域和目标域数据训练跨域模型.

(6) RSDA^[31]. 该方法在 BGCA 的基础上对目标域数据进行优化筛选, 获得高质量目标域数据, 提升目标域数据多样性. 利用最终的源域和目标域数据训练跨域模型.

(7) SpanASTE^[38]. 该方法首次在方面观点的情感关系预测中显式建模了跨度与跨度之间的交互关系. 该模型不仅能有效处理多词组成的方面或观点, 还能兼容单词级的表达, 提高了现有方面级情感分析方法的效果.

(8) RoBMRC^[39]. 该方法提出了一种针对方面级情感三元组抽取的鲁棒优化 BMRC 模型. BMRC 通过双向查询处理方面、意见和情感的复杂关系, 该模型通过引入排他分类器以避免查询干扰与优化分词、跨度匹配规则和概率生成策略实现 BMRC 改进.

4.3 实验设置与评价指标

实验使用 T5-base 模型进行跨域迁移. 优化器选用 Adam, 学习率为 $3e-5$, 训练的批大小为 16, 文本生成损失使用交叉熵损失. 在第 1 阶段, 模型的训练轮数为 15 轮, 对抗损失采用交叉熵损失, 训练时以 λ 控制对抗损失的权重, λ 逐步线性增长, 最大值为 0.1. 在第 2 阶段, 使用第 1 阶段模型参数训练 15 轮, 筛除低质量目标域重建文本的 NLI 模型为 deberta-v3-base-tasksource-nli^[40]. 在第 3 阶段, 使用文本转写模型 t5-paraphraser^[41], 模型温度设置为 0.7, 通过指令模板和标签检查保证转写不缺失标签内容, 再使用第 2 阶段 NLI 模型筛选矛盾的转写文本. 第 4 阶段, 使用第 2 阶段的模型参数训练 15 轮, 得到最终的跨域模型. 在评价指标方面, F1 作为精确率和召回率的调和平均, 被广泛用于综合评估模型的性能, 本文也采用其作为评价指标.

4.4 实验结果及分析

(1) 跨域方面词抽取. 表 2 给出了本文所提方法与其他主流方法在跨域方面词抽取任务中的性能对比实验分析. 从实验结果可知, 特征与样本自适应方法 BERT-UDA 性能最差. BERT-UDA 平均 F1 分数仅为 42.97%, 各个域间性能表现的方差也较小. 这说明该方法在多数迁移对上处于劣势且性能不好, 尤其在 $R \rightarrow S$ 和 $L \rightarrow S$ 迁移方向上表现较弱. 这进一步证实其依赖词性和依存关系特征进行迁移的方式在领域差异显著的场景下存在局限性; 评论重构与伪标签生成方法中, CDRG 虽在 $L \rightarrow R$ 和 $L \rightarrow S$ 上取得较好成绩, 但整体平均分为 49.90%, 略逊于后续生成式方法. DA²LM 则在多个方向表现突出, 其中 $S \rightarrow R$ 和 $L \rightarrow R$ 为当前最高, 表明其伪标签生成策略在部分迁移场景中具有良好迁移能力; 生成式方法中, GAS 表现不佳, 说明其单一生成策略尚无法有效适应跨域抽取任务. BGCA 在多项指标中接近 DA²LM, 验证了其双向生成框架的有效性. RSDA 则在多个迁移对中取得次优成绩, 证明其两阶段数据增强策略在多样性和精度之间取得了良好平衡. 本文方法在所有迁移方向上均取得较好的结果, 平均性能提升 0.62%, 性能变化方差最大是因为 $R \rightarrow D$ 和 $S \rightarrow D$ 场景下表现不佳, 这是由于 D 作为目标域时数据量较少造成. 所提方法在其他域间迁移性能较好, 表明其方法在各领域间迁移时具有更好的稳健性与通用性, 尤其在 $D \rightarrow R$, $D \rightarrow S$ 和 $L \rightarrow S$ 等高难度任务上均取得领先, 体现了构造的目标域数据集与源域有较好的相容性, 能够在保证模型性能的同时实现跨域平滑.

(2) 跨域方面级情感三元组抽取. 表 3 给出了不同方法在跨域方面级情感三元组抽取任务中的性能实验分

表2 不同方法在跨域方面词抽取任务上的F1值(%)对比分析. 最优结果加粗表示.

Table 2 Comparative analysis of F1 scores (%) for cross domain aspect extraction tasks. The best results are highlighted in bold.

ATE	S→R	S→L	S→D	R→S	R→L	R→D	D→R	D→S	L→R	L→S	Mean	Variance
BERT-UDA	56.08	43.98	38.36	34.62	46.87	40.34	50.54	34.52	51.91	32.49	42.97	7.77
CDRG	60.20	39.49	38.59	49.97	55.50	34.89	57.51	43.19	68.63	51.07	49.90	10.24
GAS	54.61	35.12	35.81	30.99	43.50	39.29	53.40	33.34	49.06	29.64	40.48	8.72
DA ² LM	65.78	44.96	43.24	43.41	54.55	44.29	63.86	38.20	68.72	41.06	50.81	10.83
BGCA	63.20	46.15	38.24	45.86	57.13	37.15	65.33	54.07	69.53	44.85	52.15	10.83
RSDA	63.69	47.47	39.12	49.82	58.15	38.25	66.74	54.45	68.69	51.48	53.79	10.12
OURS	65.78	49.58	39.91	49.24	60.38	37.04	67.55	53.57	71.37	49.66	54.41	11.00

表3 不同方法在跨域方面级情感三元组抽取任务上的F1值(%)对比分析. 最优结果加粗表示.

Table 3 Comparative analysis of F1 scores (%) for cross domain triple extraction tasks. The best results are highlighted in bold.

ASTE	R14→L14	R15→L14	R16→L14	L14→R14	L14→R15	L14→R16	Mean	Variance
SpanASTE	45.83	42.50	40.57	57.24	49.02	55.77	48.49	6.86
RoBMRC	43.90	40.19	37.81	57.13	45.62	52.05	46.12	7.29
GAS	49.57	43.78	45.24	64.40	56.26	63.14	53.73	8.91
BGCA	53.64	45.69	47.28	65.27	58.95	64.00	55.80	8.32
RSDA	54.66	48.39	50.96	66.15	60.52	66.36	57.67	7.89
OURS	55.44	49.86	49.37	68.71	61.58	68.74	58.95	8.77

析. 从实验结果可见, SpanASTE 和 RoBMRC 这两种未经跨域处理的方法性能远不及专门设计的跨域迁移方法, 充分体现出源域和目标域之间存在显著的差异不应被忽略. 此外, 本文提出的方法在绝大多数跨域设置中取得了最佳的平均性能, 相较于 RSDA 方法有 1.28% 的提升, 仅在 R16→L14 场景中略低于 RSDA 方法, 这一现象可能源于 RSDA 所采用的数据增强策略在特定复杂场景下具备一定的优势. 但整体而言, 本文提出的方法依然展现出更为优异且稳定的性能表现.

4.5 消融实验及参数分析

(1) 阶段消融. 本文提出的跨域迁移方法包含 4 个阶段, 前 3 个阶段逐步优化目标域数据以构建高质量的目标域数据, 最终在第 4 阶段实现跨域方面级情感分析. 为探讨各阶段的贡献, 本节对前 3 阶段分别进行消融实验, 结果见表 4. “消融阶段二”, 即为不重建目标域文本, 后续直接使用原目标域的文本在阶段 3 进行文本转写. 结果显示, 模型的平均 F1 值下降了 2.23%, 原因是源域和目标域之间存在域差异, 伪标签存在部分噪声, 直接将目标域文本和伪标签用于训练会带入大量噪声, 导致模型学习错误模式. 通过目标域文本重建, 重建文本与伪标签具有更好的一致性, 减小对后续的错误传递. “消融阶段三”, 即为不进行文本转写, 模型的平均 F1 值下降了 1.63%, 表明单一简短的句式难以应对预测时的多样化句式, 通过转写生成多样句式能提升模型泛化能力, 有助于模型在最终三元组预测上效果提高. “无跨域” 即为在源域训练好模型, 直接用于目标域预测, 模型的效果非常差, 平均 F1 值下降了 9.57%, 表明了源域和目标域存在域偏移不能忽略.

(2) 各阶段中子模块消融. 本文提出的跨域迁移方法在各个阶段都包含特定的模块设计, 为明确这些模块对跨域迁移性能的具体影响, 本节进行了不同模块的消融实验, 结果见表 5. “消融 DANN” 指的是在目标域伪标签生成阶段, 不使用域对抗网络来获取目标域的伪标签, 而是直接用源域训练好的模型来获取目标域的伪标签. 实验发现平均 F1 值下降 2.38%, 原因是 DANN 通过领域对抗有效缓解了源域与目标域的分布差异, 促使模型学习更多域无关特征, 从而提高目标域泛化能力. 若仅用源域模型, 则易于学习源域特定特征, 限制目标域的泛化表现. “消融参数传递” 指各迁移阶段训练前均重新初始化模型参数, 不继承前一阶段训练后的参数. 实验表明模型平均 F1 值下降 1.06%, 表明跨阶段参数共享对保持任务连续性和知识积累的重要性. 持续微调过程使模型各

表4 阶段消融对跨域方面级情感三元组抽取 F1 值 (%) 的影响.

Table 4 Impact of stage ablation on F1 scores (%) for cross domain aspect-level sentiment triple extraction.

ASTE	R14→L14	R15→L14	R16→L14	L14→R14	L14→R15	L14→R16	Mean	Variance
OURS	55.44	49.86	49.37	68.71	61.58	68.74	58.95	8.77
Ablation of phase 2	53.16	46.40	46.81	67.64	60.27	66.05	56.72	9.34
Ablation of phase 3	52.94	46.89	46.69	67.52	61.51	68.36	57.32	9.84
No-cross-domain	44.99	36.81	39.93	59.56	55.01	59.98	49.38	10.14

表5 各阶段中子模块消融对跨域方面级情感三元组抽取 F1 值 (%) 的影响.

Table 5 Impact of sub-module ablation at different stages on F1 scores (%) for cross domain aspect-level sentiment triplet extraction.

ASTE	R14→L14	R15→L14	R16→L14	L14→R14	L14→R15	L14→R16	Mean	Variance
OURS	55.44	49.86	49.37	68.71	61.58	68.74	58.95	8.77
Ablation of DANN	53.64	48.02	44.80	66.15	60.90	65.91	56.57	9.14
Ablation of parameter transmission	55.28	46.50	48.89	67.44	60.97	68.24	57.89	9.22
Ablation of NLI filter	53.81	47.64	48.67	66.04	59.10	68.35	57.27	8.74
Ablation of source domain supervision	52.23	45.64	46.63	65.22	59.00	65.45	55.70	8.85

阶段保持一致的表示空间, 促进源域知识顺畅迁移并适应目标域特征, 有效提升最终迁移效果. “消融 NLI 过滤”指对目标域重建和转写文本不再使用自然语言推理方法进行质量控制. 实验结果显示平均 F1 值下降 1.68%, 说明未经 NLI 过滤的文本可能含有与原标签语义不符甚至矛盾的内容, 这种错误的标签 – 文本对会误导模型, 降低迁移效果. “消融源域指导”指最终训练模型时, 仅使用生成的目标域伪标注数据, 而不加入源域真实数据. 实验发现平均 F1 值下降 3.25%, 原因在于目标域伪标签虽经多阶段优化, 仍不可避免地存在噪声与不确定性. 源域数据为人工标注, 质量更高且更加稳定, 去除源域数据意味着完全依赖伪标注, 模型易学习到有偏差的决策边界, 最终影响整体迁移性能.

(3) 目标域文本重构参数分析. 为了评估本文方法生成的目标域数据在跨域任务中的有效性与可靠性, 本节将探索目标域生成样本数量对最终模型性能的影响. 因此在训练最终跨域模型时, 不使用源域数据, 仅使用生成的目标域有标签数据来训练最终模型, 完成方面级情感三元组抽取任务. 通过设置不同数量的可用目标域有标签数据, 在数据集的 6 个跨域方向进行评估, 观察模型的 F1 值变化. 实验结果如图 2 所示. 实验结果显示, 随着可用的生成样本数量的增加, 模型性能呈现出上升趋势. 这一结果表明, 本文方法生成的目标域数据具备较高的语义可信度与任务一致性, 即使在完全没有源域数据参与训练的情况下, 也能够独立支撑起跨域建模过程. 当生成样本数量达到一定规模后, 性能出现趋于平稳的现象, 这是因为更多的样本数量未能提升样本质量与多样性, 数据出现边际收益递减效应.

(4) 转写文本质量的参数分析. 在本文跨域方法的第 3 阶段引入了文本转写模块, 对第 2 阶段生成的目标域重建文本进行转写, 以增强文本表达的自然性和丰富性. 为验证该模块的有效性, 本节使用 GPT-2 模型^[42] 计算文本改写前后的困惑度 (perplexity). 困惑度^[43]是语言模型衡量文本预测难度的指标, 其数值越低, 表示语言模型对该文本的预测越容易, 即该文本更符合自然语言的统计规律, 更加通顺自然. 表 6 给出了在 6 个跨域方向上, 目标域重建文本与转写文本的困惑度比较. 结果表明, 引入文本转写模块后, 目标域文本的平均困惑度由 230.98 显著下降至 111.96, 表明转写后的文本在语言流畅性与语法合理性方面均有明显提升. 更自然的语言表达有助于模型更准确地捕捉文本的语法结构与语义信息, 避免因语言不规范而产生的理解偏差. 在跨领域任务中, 规范且自然的语言表达能够有效减少源域与目标域之间的风格差异, 提升模型对目标域的适应性. 同时, 由消融实验表 4 的结果可知, 引入文本转写阶段后, 最终三元组抽取任务的平均 F1 值由 57.32% 提高至 58.95%. 这进一步验证了转写通过提升目标域文本的质量, 提升了后续三元组抽取任务的性能.

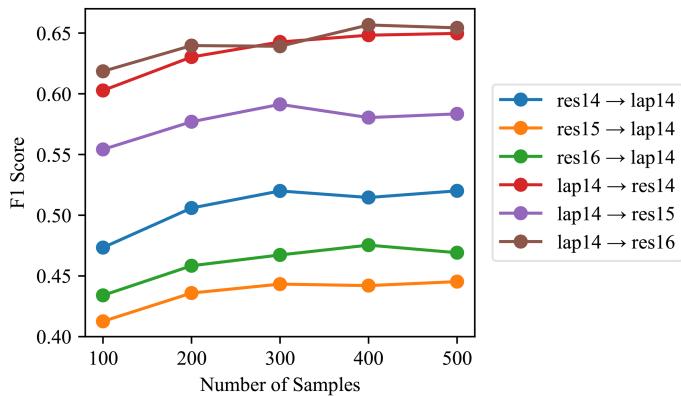


图 2 (网络版彩图) 不同数量的目标域生成样本对跨域方面级情感三元组抽取 F1 值的影响.

Figure 2 (Color online) Impact of different numbers of target domain generating samples on cross domain aspect triplet extraction (F1).

表 6 目标域文本转写前后的困惑度对比.

Table 6 Perplexity comparison on target domain text transcription.

Perplexity	R14→L14	R15→L14	R16→L14	L14→R14	L14→R15	L14→R16	Mean	Variance
Reconstruct text	170.90	166.02	339.59	202.91	202.99	302.46	230.98	72.53
Transcribe text	120.89	130.42	122.43	99.30	101.12	97.61	111.96	14.23

4.6 案例分析

为直观度量本文所提出的跨域方面级情感分析方法的效果, 我们选取 6 组具有代表性的样例进行案例分析, 并将所提方法的预测结果与两种典型的跨域基线模型 GAS 与 RSDA 进行对比. 表 7 给出了输入句子及其对应的真实方面 - 情感三元组标签, 其中前 3 个样例来自源域 L14, 目标域为 R16 (L14→R16), 后 3 个则相反 (R16→L14). 表 8 则列出了不同模型的预测结果. 在例 1 中, GAS 未能识别出同样显著的褒义情感词 “good”, 反映出其对多属性并列情感表达的建模能力存在一定局限. 而本文方法成功识别出所有三元组, 归因于第 3 阶段的句式转写生成了更多样化的结构, 增强了模型对复杂句式的理解能力, 从而更完整地抽取出三元组信息. 在例 2 中, GAS 与 RSDA 均错误地将情感极性预测为中性, 主要原因在于它们未能正确解析短语 “speaks for itself” 所蕴含的正向隐喻评价. 相比之下, 本文方法在处理隐喻性或非直白表达方面具有更强的语义理解能力. 例 3 中, GAS 与 RSDA 均将情感词预测为 “joke”, 而忽略了更直接表达负面情绪的词汇 “overpriced”. 本方法则成功识别, 表现出更强的情感对齐能力. 这一优势主要源于第 2 阶段的文本重建机制, 引导模型更加关注明确、直接的情感表达, 降低了情感误判. 在例 4 和 5 中, GAS 与 RSDA 在方面词抽取上均出现错误, 将背景信息误识为评价对象. 而本文方法则准确识别出正确的方面词, 说明其在方面抽取任务中具有更高的准确性. 该能力得益于第 3 阶段生成的多样句式结构, 提升了模型对句中语义核心的抽象与定位能力. 例 6 中, 两个基线模型均未正确判断三元组的情感极性, 而本文方法准确识别出正确信息, 体现出其在细粒度情感判别方面的优势. 这一能力主要得益于第 1 阶段在源域数据上的高质量监督训练, 为模型提供了更精确的情感识别基础.

5 泛化性讨论

5.1 基座模型的影响

为度量不同的基座模型对本文所提方法的影响, 我们选取 Qwen1.5-4B 作为基座模型, 并和 T5-base 作为基座模型的实验结果进行对比分析. 表 9 给出了实验结果, 由结果可以看出, 本文所提算法对基座模型的依赖性不强, 随着基座模型参数规模的增大, 本文所提模型的性能得到一定提升, 但是模型规模的增大也带来了计算复杂

表 7 具体案例分析.

Table 7 Case study.

ID	Sentence	Ground truth
1	This is some really good, inexpensive sushi.	(sushi, good, POS) (sushi, inexpensive, POS)
2	Even though the place is not beautiful, the food speaks for itself.	(place, not beautiful, NEG) (food, speaks for itself, POS)
3	It was totally overpriced-fish and chips was a joke.	(fish and chips, overpriced, NEG)
4	I got this at an amazing price from Amazon and it arrived just in time.	(price, amazing, POS)
5	Working with Mac is so much easier, so many cool features	(working, easier, POS) (features, cool, POS)
6	It is easy to go from one keyboard to another.	(keyboard, easy, NEU)

表 8 对比本模型与其他模型的跨域方面级情感三元组抽取效果.

Table 8 Comparison of cross domain aspect sentiment triplet extraction using different models.

ID	GAS	RSDA	OURS
1	(sushi, inexpensive, POS)	(sushi, good, POS) (sushi, inexpensive, POS)	(sushi, good, POS) (sushi, inexpensive, POS)
2	(place, not beautiful, NEG)	(place, not beautiful, NEG) (food, speaks for itself, NEU)	(place, not beautiful, NEG) (food, speaks for itself, POS)
3	(fish and chips, joke, NEG)	(fish and chips, joke, NEG)	(fish and chips, overpriced, NEG)
4	(Amazon, amazing price, POS)	(price, amazing, POS)	(price, amazing, POS)
5	(Mac, easier, POS) (features, cool, POS)	(working with Mac, easier, POS) (features, cool, POS)	(working, easier, POS) (features, cool, POS)
6	(keyboard, easy, POS)	(keyboard, easy, POS)	(keyboard, easy, NEU)

表 9 不同基座模型对跨域方面级情感三元组抽取 F1 值 (%) 的影响.

Table 9 Impact of different base models on F1 scores (%) for cross domain aspect-level sentiment triplet extraction.

Base model	R14→L14	R15→L14	R16→L14	L14→R14	L14→R15	L14→R16	Mean	Variance
T5-base	55.44	49.86	49.37	68.71	61.58	68.74	58.95	8.77
Qwen1.5	56.12	50.75	50.02	69.13	62.11	69.31	59.56	8.64

度的增加.

5.2 复杂度讨论

所提框架的时间复杂度主要集中在语言模型的多次训练上. 耗时阶段主要为 1, 3 和 4 阶段, 由于本文将方面级情感分析任务通过指令微调建模为文本生成任务, 时间复杂度统一可以表示为 $O(N \times L \times H^2)$, 其中 N 是序列长度、 L 是层数、 H 是隐藏层维度. 具体而言, 时间复杂度主要与所用基座模型大小、处理的数据量和训练的轮数相关. 若使用参数规模较大的基座模型, 虽然可以提升框架的准确度, 但将提升计算时间复杂度, 降低所提模型的可部署性. 资源消耗则主要和模型参数存储、数据集存储、中间激活值和优化器状态几个因素相关.

为了优化时空复杂度, 首先可以尝试使用 LoRA 等参数高效微调方法来减少模型需要梯度更新的参数量, 从而优化算法的复杂度. 再者针对语言模型庞大的参数量, 可以通过量化技术来减轻显存压力, 以适用于更低显存的设备; 最后也可以合领域泛化及数据蒸馏等策略, 设计更高效的跨域适配机制, 以减少训练成本.

6 总结

针对跨域方面级情感分析任务中存在的目标域标注数据稀缺、伪标签质量不高和跨域过程不平稳等问题,本文提出了一种面向方面级情感分析的渐进式跨域框架.该方法通过4个关键阶段实现跨域适配:首先利用源域数据进行文本预测标签训练,并生成目标域伪标签;其次利用源域标签指导的文本重建模型生成目标域重建文本,保证伪标签与目标域文本的对齐;随后对目标域生成的数据进行文本转写与质量筛选,以提升文本的多样性和准确性.最终,利用优化后的目标域数据和源域数据联合训练模型,提升模型对目标域的适应能力.在此过程中,使用同一个模型连续微调,确保方面级情感分析知识在训练过程中稳定积累与迁移.结合多个公开数据集的实验结果表明,与现有跨域三元组抽取方法相比,本文所提方法平均F1值提升1.28%;与不跨域方法相比平均F1提升9.57%.然而,本文提出的跨域方法多阶段的训练过程在时间和资源消耗方面存在不足,可能制约其在工业规模下的实际应用.未来可探索结合领域泛化及数据蒸馏等策略,开发更为高效的跨域适配机制,以减少训练成本、提高部署可行性.

参考文献

- 1 Kaur A, Gupta V. A survey on sentiment analysis and opinion mining techniques. *J Emerg Technol Web Intell*, 2013, 5: 367–371
- 2 Wang T, Yang W Z. Review of text sentiment analysis methods. *Comput Eng Appl*, 2021, 57: 11–24 [王婷, 杨文忠. 文本情感分析方法研究综述. *计算机工程与应用*, 2021, 57: 11–24]
- 3 Zhang Y, Li T R. Aspect-level sentiment analysis for reviews: a survey. *Comput Sci*, 2020, 47: 194–200 [张严, 李天瑞. 面向评论的方面级情感分析综述. *计算机科学*, 2020, 47: 194–200]
- 4 Tan C P. Review of fine-grained sentiment analysis based on text. *J Acad Libraries*, 2022, 40: 85–99 [谭翠萍. 文本细粒度情感分析研究综述. *大学图书馆学报*, 2022, 40: 85–99]
- 5 Ding Y, Yu J, Jiang J. Recurrent neural networks with auxiliary labels for cross-domain opinion target extraction. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 2017
- 6 Wang W, Pan S J. Recursive neural structural correspondence network for cross-domain aspect and opinion co-extraction. In: *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*, 2018. 2171–2181
- 7 Wang W, Pan S J. Transferable interactive memory network for domain adaptation in fine-grained opinion extraction. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019. 7192–7199
- 8 Zhang K. Research on methods of text semantic understanding in complex scenes. Dissertation for Ph.D. Degree. Hefei: University of Science and Technology of China, 2023 [张凯. 复杂场景下的文本语义理解方法研究. 博士学位论文. 合肥: 中国科学技术大学, 2023]
- 9 Du Y P, Liu Y, He M. Cross-domain aspect-level sentiment analysis based on adversarial distribution alignment. *Pattern Recognition Artif Intell*, 2021, 34: 87–94 [杜永萍, 刘杨, 贺萌. 基于对抗式分布对齐的跨域方面级情感分析. *模式识别与人工智能*, 2021, 34: 87–94]
- 10 Wang Y H. Research and application on aspect-based textsentiment analysis algorithm based on transferlearning. Dissertation for Master Degree. Lanzhou: Northwest Normal University, 2020 [王玉环. 基于迁移学习的方面级文本情感分析算法研究与应用. 硕士学位论文. 兰州: 西北师范大学, 2020]
- 11 Liu T, Feng A, Gao Z J. Cross domain aspect-based sentiment analysis based on late prompt and instance adaption. *Soft Guide*, 2025, 24: 29–34 [刘涛, 冯翱, 高正杰. 基于后提示与实例适应的跨域方面情感分析. *软件导刊*, 2025, 24: 29–34]
- 12 He Z H. Deep learning and domain adaptive based fine-grained sentiment analysis research. Chengdu: Southwest Jiaotong University, 2023 [何智豪. 基于深度学习和领域自适应的细粒度情感分析研究. 硕士学位论文. 成都: 西南交通大学, 2023]
- 13 Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of Advances in Neural Information Processing Systems*, 2014
- 14 Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks. *J Mach Learn Res*, 2016, 17: 1–35
- 15 Che W X, Dou Z C, Feng Y S, et al. Towards a comprehensive understanding of the impact of large language models on natural language processing: challenges, opportunities and future directions. *Sci China Inform Sci*, 2023, 53: 1645–1687 [车万翔, 窦志成, 冯岩松, 等. 大模型时代的自然语言处理: 挑战、机遇与发展. *中国科学: 信息科学*, 2023, 53: 1645–1687]
- 16 Radford A, Narasimhan K, Salimans T, et al. Improving language understanding by generative pre-training. 2018. <https://api.semanticscholar.org/CorpusID:49313245>
- 17 Achiam J, Adler S, Agarwal S, et al. GPT-4 technical report. ArXiv:2303.08774
- 18 Yang G. A literature review on the explosion and application of GPT technology. *Digit Commun World*, 2025, 1: 187–189 [杨光.

- 从 GPT 技术爆发到应用的文献综述. 数字通信世界, 2025, 1: 187–189]
- 19 Qiu G, Liu B, Bu J, et al. Opinion word expansion and target extraction through double propagation. *Comput Linguist*, 2011, 37: 9–27
- 20 Li F, Pan S J, Jin O, et al. Cross-domain co-extraction of sentiment and topic lexicons. In: *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics*, 2012. 410–419
- 21 Jakob N, Gurevych I. Extracting opinion targets in a single and cross-domain setting with conditional random fields. In: *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, 2010. 1035–1045
- 22 Chernyshevich M. IHS R&D belarus: cross-domain extraction of product features using CRF. In: *Proceedings of the 8th International Workshop on Semantic Evaluation*, 2014. 309–313
- 23 Li Z, Li X, Wei Y, et al. Transferable end-to-end aspect-based sentiment analysis with selective adversarial learning. *ArXiv:1910.14192*
- 24 Zhao Z, Ma Z, Lin Z, et al. Source-free domain adaptation for aspect-based sentiment analysis. In: *Proceedings of the Joint International Conference on Computational Linguistics, Language Resources and Evaluation*, 2024. 15076–15086
- 25 Chen Z, Qian T. Retrieve-and-edit domain adaptation for end2end aspect based sentiment analysis. *IEEE/ACM Trans Audio Speech Language Process*, 2022, 30: 659–672
- 26 Xia R, Yu J, Xu F, et al. Instance-based domain adaptation in NLP via in-target-domain logistic approximation. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 2014
- 27 Gong C, Yu J, Xia R. Unified feature and instance based domain adaptation for aspect-based sentiment analysis. In: *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2020. 7035–7045
- 28 Yu J, Gong C, Xia R. Cross-domain review generation for aspect-based sentiment analysis. In: *Proceedings of Findings of the Association for Computational Linguistics*, 2021. 4767–4777
- 29 Yu J, Zhao Q, Xia R. Cross-domain data augmentation with domain-adaptive language modeling for aspect-based sentiment analysis. In: *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, 2023. 1456–1470
- 30 Deng Y, Zhang W, Pan S J, et al. Bidirectional generative framework for cross-domain aspect-based sentiment analysis. *ArXiv:2305.09509*
- 31 Wang H, He K, Li B, et al. Refining and synthesis: a simple yet effective data augmentation framework for cross-domain aspect-based sentiment analysis. In: *Proceedings of Findings of the Association for Computational Linguistics*, 2024. 10318–10329
- 32 Pontiki M, Galanis D, Pavlopoulos J, et al. Semeval-2014 task 4: aspect based sentiment analysis. In: *Proceedings of the 8th International Workshop on Semantic Evaluation*, 2014. 27–35
- 33 Toprak C, Jakob N, Gurevych I. Sentence and expression level annotation of opinions in user-generated discourse. In: *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*, 2010. 575–584
- 34 Hu M, Liu B. Mining and summarizing customer reviews. In: *Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2004. 168–177
- 35 Xu L, Li H, Lu W, et al. Position-aware tagging for aspect sentiment triplet extraction. *ArXiv:2010.02609*
- 36 Peng H, Xu L, Bing L, et al. Knowing what, how and why: a near complete solution for aspect-based sentiment analysis. In: *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020. 8600–8607
- 37 Zhang W, Li X, Deng Y, et al. Towards generative aspect-based sentiment analysis. In: *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
- 38 Xu L, Chia Y K, Bing L. Learning span-level interactions for aspect sentiment triplet extraction. *ArXiv:2107.12214*
- 39 Liu S, Li K, Li Z. A robustly optimized bmrc for aspect sentiment triplet extraction. In: *Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2022. 272–278
- 40 Sileo D. tasksrource: structured dataset preprocessing annotations for frictionless extreme multi-task learning and evaluation. *ArXiv:2301.05948*
- 41 Vorobev M K V, Kuznetsov M. A paraphrasing model based on ChatGPT paraphrases. 2023. https://huggingface.co/humarin/chatgpt-paraphraser_on_T5_base
- 42 Radford A, Wu J, Child R, et al. Language models are unsupervised multitask learners. *OpenAI blog*, 2019, 1: 9
- 43 Jurafsky D, Martin J H. Speech and language processing (3rd ed. draft). 2025. <https://web.stanford.edu/~jurafsky/slp3/>

Research on methods for progressive cross-domain aspect-based sentiment analysis

Tao QIN^{1*}, Yuankun ZHOU¹, Pinghui WANG¹ & Xiaohong GUAN^{1,2}

1. MOE Key Laboratory of Intelligent Network and Network Security, Xi'an Jiaotong University, Xi'an 710049, China

2. Center for Intelligent and Networked Systems, Tsinghua University, Beijing 100084, China

* Corresponding author. E-mail: qin.tao@mail.xjtu.edu.cn

Abstract Aspect-based sentiment analysis (ABSA) aims to extract sentiment polarities associated with different aspects or specific targets, and are widely used for public opinion monitoring, business intelligence, and decision-making support. Traditional cross-domain ABSA methods typically focus on generating labeled data for the target domain and using them to train cross-domain models. However, these approaches often encounter challenges such as significant semantic deviations between the generated and original target domain texts, limited sentence structure diversity, and low-quality pseudo-labels. These limitations hinder the model's ability to effectively learn target-domain features, resulting in suboptimal transfer performance. To address these challenges, this paper proposes a framework for progressive cross-domain ASBA, which consists of four sequential stages: (1) generating high-quality pseudo-labels for the target domain, (2) reconstructing target-domain texts aligned with the pseudo-labels, (3) refining the reconstructed texts to enhance diversity and quality, and (4) performing final cross-domain adaptation through joint training with source-domain data. Model parameters are progressively transferred across stages, facilitating progressive domain adaptation while generating high-quality labeled target-domain data. Extensive experiments conducted on four public benchmark datasets demonstrate the effectiveness of the proposed method. For the cross-domain triplet extraction task, the proposed method outperforms existing cross-domain approaches by an average of 1.28% in F1 score, and surpasses non-transfer models by an average of 9.57%, highlighting its superior cross-domain generalization capabilities.

Keywords aspect-based sentiment analysis, cross-domain application, multi-stages and progressive, language model