arXiv:2303.00815v1 [cs.CL] 1 Mar 2023

软提示引导的联合学习用于跨领域情感分析

Jingli Shi[1], Weihua Li[1], Quan Bai[2], Yi Yang[3] 和 Jianhua Jiang[4]

[1]工程、计算机与数学科学学院，奥克兰理工大学，新西兰奥克兰 Wellesley Street East 55 号，邮编 1010。[2]技术、环境与设计学院，塔斯马尼亚大学，澳大利亚塔斯马尼亚州霍巴特 Churchill Ave，邮编 7005。[3]计算机科学学院，合肥工业大学，中国安徽省合肥市包河区屯溪路 193 号，邮编 230002。[4]管理科学与信息工程学院，吉林财经大学，中国吉林省长春市南关区，邮编 130117。

贡献作者：jingli.shi@aut.ac.nz；weihua.li@aut.ac.nz；quan.bai@utas.edu.au；yyang@hfut.edu.cn；jjh@jlufe.edu.cn；

摘要

方面术语提取是细粒度情感分析中的一项基础任务，旨在从产品或服务评论中识别客户的观点目标。传统监督模型在标注数据集上能够取得令人满意的结果，但应用于跨领域方面术语提取任务时，性能会大幅下降。现有的跨领域迁移学习方法要么将语言特征直接注入语言模型，使语言知识难以迁移到目标领域；要么依赖固定的预定义提示，而为所有潜在的方面术语跨度构建提示耗时费力。为解决这些局限，本文提出一种基于软提示的跨领域方面术语提取联合学习方法。具体而言，该方法融入外部语言学特征，通过多个目标学习源领域与目标领域之间的领域不变表示，从而弥合

方面术语分布各异的领域之间的差距。此外，所提出的方法对一组可迁移的软提示进行插值，这些软提示由多个有助于在目标领域检测方面术语的可学习向量组成。我们在基准数据集上进行了大量实验，实验结果证明了所提出方法在跨领域方面术语提取方面的有效性。

关键词：基于方面的情感分析，跨领域，软提示

1 引言

为了在业务发展中积累专业知识，分析客户的反馈以快速了解客户投诉或需求至关重要。作为评论分析的一种出色方法，基于方面的情感分析（ABSA）旨在从客户评论中提取方面和观点词，并识别它们对应的情感[34, 38]。本文聚焦于 ABSA 的一项关键子任务，即方面术语提取（ATE），该任务旨在从客户评论句子中识别观点目标。以图 1为例，该任务预期从句子“键盘”中检测方面术语 按键响应灵敏”。

近年来，随着 BERT 等预训练语言模型（PLM）的兴起，方面术语提取已在文献中得到广泛研究[13],BART[29], T5[45],GPT v1-3[6, 43, 44]。通过对预训练语言模型进行微调，方面术语提取任务取得了显著成果 [17, 47, 48, 53, 55]。然而，为了针对下游任务微调预训练语言模型，需要大量标注数据。数据标注工作既费力又耗时，这可能导致缺乏用于微调预训练语言模型的训练数据[27]。此外，由于可训练参数呈指数级增长，在实际应用中微调预训练语言模型变得越来越困难。为应对微调面临的挑战，一种名为提示调优的新学习方法应运而生，它将自然语言处理任务重新表述为完形填空式问答[28]。基于提示的学习无需更新预训练语言模型的任何参数，便已在许多自然语言处理任务（例如关系分类[10], 情感分类[30],命名实体识别[9]）上取得了出色的成果。通过手动设计提示，研究者也尝试将类似方法用于方面术语提取，以从评论中的每个文本片段检测方面术语[18, 30, 31]。如图1所示，为了提取方面术语键盘，研究者使用模板方面是__设计了一些提示。尽管微调和提示调优方法取得了成功，但二者都面临领域方面的挑战。对于采用微调方法的预训练语言模型而言，它们是在不针对特定领域的通用数据集上进行预训练的，因此在领域适应方面缺乏任务针对性，表现不佳[56]。对于基于提示的学习方法而言，枚举所有可能的方面术语片段成本高昂，而且现有模型无法在跨

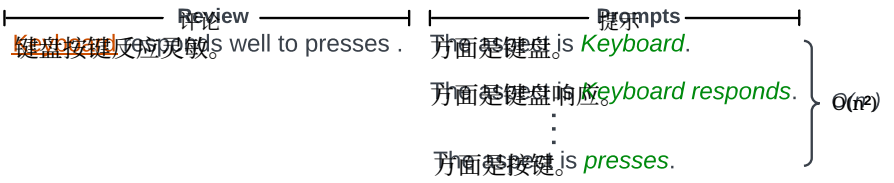

图1 – 方面术语提取提示调优模型的传统输入。

领域数据集上取得稳健的性能，因为不同领域的方面术语分布各异，而且提示的构建过程也很复杂。

为应对跨领域方面术语提取任务中的上述挑战，我们提出了一种联合学习方法。该方法首次将软提示与可迁移语言知识相结合，以解决领域自适应问题。所设计的软提示能够帮助预训练语言模型更好地适应目标领域中的方面术语分布，从而降低枚举所有可能方面术语跨度所带来的高昂成本。随后，我们设计了语言知识学习模块，用于学习跨领域的领域不变表示。通过将可学习提示和语言知识与上下文特征相结合，该提示方法能够生成更优的词元表示，从而进一步提升跨领域方面术语提取的性能。

本文的主要贡献总结如下：

- 据我们所知，这是首个采用基于软提示的联合学习方法解决跨域方面术语抽取任务的研究。
- 我们针对多个源领域设计了可学习提示，以实现高效的知识迁移。
- 实验结果表明，所提出的方法优于当前最先进的微调和提示调优模型。

本文其余部分安排如下。第2节回顾了跨领域方面术语提取的相关工作。第3 节正式定义相关概念并对问题进行形式化描述。第4节介绍所提出的方法。第5节展示并讨论实验工作与结果。最后，第6节介绍结论与未来工作。

2 相关工作

方面术语提取是一项备受关注的细粒度情感分析任务。然而，只有少数研究尝试关注方面术语提取的领域自适应。跨域方面术语抽取旨在将所学知识从源领域迁移到方面术语提取任务标注数据有限的目标领域。由于这项任务复杂，且目标域中的标注数据稀缺，跨域方面术语抽取已成为一项具有挑战性的任务。

现有方法可分为三类：基于规则的模型、微调预训练语言模型，以及提示调优预训练语言模型。

此类方法可能会受到实体跨度检测引发的错误传播、枚举所有可能文本跨度导致的高昂成本，以及忽略句子中词元标签之间相互依赖关系等问题的影响。

2.1 基于神经网络的模型

早期关于跨域方面术语提取的研究主要集中于人工设计的领域无关特征和神经网络模型 [15]。Jakob 等人将方面术语提取问题表述为信息抽取任务，并提出了一种基于条件随机场（CRF）的单领域和跨领域方面术语提取方法 [24]。Chernyshevich 设计了一个基于条件随机场的系统，该系统在混合的已标注训练数据上进行训练，用于检测所有特定领域测试集中的方面术语[12]。对于基于条件随机场的方法，如果训练数据集与测试数据集来自不同领域，便难以取得良好效果。为解决这一问题，Ding 等人提出了一种基于长短期记忆网络（LSTM）的方法，利用领域无关句法规则[15]。为弥合不同领域之间的差距，一种新型递归神经网络将领域不变依存关系用作枢轴信息，以减少领域偏移[49]。在后续研究中，Wang 等人扩展了先前的工作，将词表示和句法中心词关系输入条件域对抗网络[50]。另一项研究中，Wang 等人利用交互式记忆网络的局部和全局记忆交互，捕捉方面术语或观点词彼此之间，以及方面术语与观点词之间的内部相关性[51]。该方法利用辅助任务和域对抗网络对齐源域和目标域空间，以实现跨域方面术语提取。Marcacini 等人提出一种传导式学习方法，将源领域和目标领域中的已标注方面术语、未标注方面术语特征及语言信息结合起来[36]。所提出的方法能够解决因特征空间不同而导致的跨域方面术语提取模型不一致问题。为减少对外部语言资源的依赖，研究者提出一种对抗学习方法，通过对齐推断出的方面术语和观点词的相关向量，为每个词学习一个对齐权重[33]。尽管表现出色，基于神经网络的方法仍无法获得令人满意的领域不变特征，也未能充分利用目标领域中重要的监督信号，因此精确率较低。

2.2 基于语言模型的模型

近期研究发现，使用复杂的任务特定层微调语言模型，可以获取词义和几何依存句法关系，从而有助于跨域方面术语抽取任务[21]。Pereg等人通过自注意力机制将外部语言学信息融入语言模型，以用于跨域方面术语抽取[37]。所提出的方法

能够利用语言模型的内在知识，并借助外部引入的句法特征弥合源领域与目标领域之间的差距。基于BERT，Gong等人提出了一种融合基于特征的适配和基于实例的适配的端到端框架，显著提升了语言模型在方面术语提取任务上的表现[20]。Anand等人采用进化方法，自动学习方面词的语言模式，从而缓解了人工设计模式规则所带来的问题[1]。Mampilli等人将语言模型与注意力机制结合用于方面术语提取，该方法在域内和未见域数据集上均取得了良好效果[35]。Li等人提出了一种新型的生成式跨域数据增强框架，该框架利用源领域的标注数据生成目标领域的数据，用于方面术语提取模型的训练[32]。为解决目标领域数据集上的模型可扩展性和鲁棒性问题，Howard等人提出了一种新方法，可自动构建方面术语的领域专属知识图谱，并将这些图谱中的特征注入语言模型，以用于目标领域的方面术语提取[22]。Klein等人利用连接观点与相关方面词的句法关系，将语言模型中学到的知识迁移过来[26]。他们的分析和实验表明，句法关系能够很好地跨领域迁移。为迁移方面术语和情感知识，Dong等人提出了一种基于句法的BERT，以捕捉领域不变特征。然而，所有这些基于语言模型的方法都严重依赖标注资源；在小规模数据上微调语言模型的表现可能不稳定。此外，大多数方法仅将语言特征直接融入语言模型，无法在方面抽取中实现词级适配。

2.3 基于提示的模型

为应对语言模型规模不断增大所带来的学习挑战，研究者提出了基于提示的方法，利用语言提示和任务描述作为上下文，使基于方面的情感分析类似于语言建模。早期研究探索了硬模板，这些模板由人工针对单一领域中的基于方面的情感分析任务进行定义。Li等人首次将基于提示的模型引入基于方面的情感分析子任务，通过整合方面、观点和极性的特征来构建情感知识提示[30]。Gao等人提出了一个统一生成式框架，通过控制任务提示的类型来解决不同的基于方面的情感分析任务[18]。通过组合简单任务的提示，他们的方法能够将已学习的知识迁移到困难任务中。Li等人提出了一个基于提示的教师-学生网络，以缓解基本基于提示的模型中存在的过拟合问题[31]。Ben等人提出了一种基于示例的提示学习方法，可应用于未见领域中的多个任务，即谣言检测、多体裁自然语言推理和方面预测[4]。然而，手动设计提示需要领域知识。因此，研究者构建了软提示，使语言模型能够有效地执行特定任务；软提示由若干可学习向量组成，而非人类可解释的自然语言。

Wu 等人采用软提示而非固定预定义模板，为不同领域学习不同的表示；随后引入一种新颖的领域对抗训练机制，学习源领域与目标领域之间的领域不变特征，以用于情感分类任务[54]。Asai 等人提出一种多任务语言模型调优方法，通过软提示在不同任务之间迁移知识[2]。该模型具有很高的参数效率，并利用高资源数据集中的知识，在情感分类及其他自然语言处理任务上取得了出色的性能。现有的硬提示和软提示方法要么只关注单一领域，要么只能应用于情感分类，而非方面术语提取。

本文旨在缓解现有模型在跨域方面术语抽取中面临的挑战，提出一种联合学习方法，通过融合可训练软提示、领域不变特征以及可学习的语言特征，整合来自源领域的高质量可迁移知识。与以往工作不同，所提出的方法首次将软提示纳入联合训练，以解决跨域方面术语提取问题。软提示能够避免硬提示在所有潜在方面跨度上枚举提示查询所导致的耗时问题。可学习的语言特征可作为增强组件，弥合不同领域之间的差距，并进一步为方面术语提取任务捕获领域不变特征。该方法能够实现从源领域高效迁移知识，并在多个数据集上的跨域方面术语提取任务中取得出色表现。此外，对实验结果的分析表明，软提示和可学习的句法特征对性能提升有显著贡献。

3 预备知识

本节将介绍与跨领域方面术语提取相关的形式化定义，并基于这些定义对问题进行形式化表述。

3.1 问题形式化

形式化地说，所提出的方法将跨领域方面术语提取任务表述为序列标注问题。给定两个领域数据集，$\mathbb{D}_s$和 $\mathbb{D}_t$ 分别代表源领域和目标领域。对于源领域数据集，$\mathbb{D}_s = \{S_s^i, y_s^i\}_{i=1}^{N_s}$ 是 N_s 个标注句子，其中S_s^i 是第 i个句子，$y_s^i \in \{B, I, O\}$ 表示相应的方面标签。在目标领域数据集中，$\mathbb{D}_t = \{S_t^i\}_{i=1}^{N_t}$ 由 N_t 个未标注句子组成，其中 S_t^i 表示第 i个句子。跨域方面术语提取的目标是学习一个函数，使其能够学习源领域和目标领域之间的领域内知识和域不变知识，从而更好地预测目标领域测试集上的词元级标签。

4 基于软提示的联合学习模型

本节首先概述所提出的方法，然后从底层到顶层介绍整体架构中的各个模块，最后阐述跨域方面术语提取的学习目标。

我们基于特征的领域适应组件的整体架构如图所示 3。生成的提示与词嵌入和句法嵌入一起被编码为特征，并输入预训练语言模型。输出表示作为 Softmax 层的输入。除方面术语提取器外，我们还设计了一个句法学习模块，用于学习不同领域之间的结构对应关系。以下各小节将分别介绍每个模块。

4.1 输入嵌入

给定一个句子 $s = \{w_1, w_2, ..., w_n\}$，其中包含 n 个词，词序列被转换为连续嵌入 $E_s = \{e_1, e_2, ..., e_n\}$。对于每个嵌入$e_i$，它由三种类型的嵌入组成：(a) 词嵌入 e^w 通过预训练语言模型，使用公式（1）获得。(b) 句法嵌入 e^{pos}通过公式（2计算。为更有效地利用领域不变特征，随机将 25% 的原始词性标签替换为特殊词元 [MASK], ，并设计了句法学习模块来预测被掩码的词性标签。(c) 软提示嵌入通过公式（3）计算。受先前提示特征相关工作的启发，[3, 5, 60], 采用互信息自动提取提示。为筛选出与所有源领域相关的提示，计算提示与方面词元的 T5 嵌入之间的欧几里得距离，从而为每个训练输入生成 m 特征。

$$e^w = T5(\{w_1, w_2, ..., w_n\}) \tag{1}$$

$$e^{pos} = T5(\{t_1, [MASK], ..., t_n\}) \tag{2}$$

$$e^p = T5(\{p_1, ..., p_m\}) \tag{3}$$

4.2 软提示学习

提示调优是一种通过将下游任务转换为完形填空问题，把额外信息融入预训练语言模型的方法。提示是提示调优模型的主要组成部分。在所提出的方法中，提示是编码领域特定语义的方面术语。我们利用来自不同领域的提示来拓展共享语义空间，并反映不同领域之间的相似性与差异。

使用设计的提示对方面术语的预测进行形式化，见公式（5）。

$$\hat{y}^p = softmax(W^p * [e^w;\ e^{pos};\ e^p] + b^p), \tag{4}$$

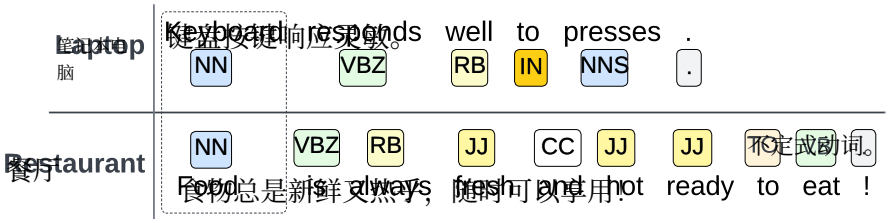

图 2 – 笔记本电脑和餐厅领域评论的词性标签。方面术语 键盘 和食物 具有相同的词性标签名词。

其中， W^p 是训练权重， b^p 是偏置向量。软提示调优的训练目标通过公式（6）中的交叉熵损失计算。

$$\hat{y}^p = softmax(W^p * [e^w;\ e^{pos};\ e^p] + b^p), \tag{5}$$

$$\mathscr{L}_{prompt} = \sum^{\mathbb{D}_s} \sum_{i}^{n} f(\hat{y}_i^p, y_i^p), \tag{6}$$

4.3 句法学习

不同领域中的方面术语通常具有相似的语言特征模式[11, 23, 42]。如图 2所示，领域笔记本电脑中的方面**键盘** 具有与领域**餐厅**中的方面**食物** 相同的词性标签名词，这表明这些方面术语在句法上相似。为了学习句法知识，将编码后的掩码特征 e^{pos} 输入 Softmax 层。预测的词性标签可通过公式（7）计算。

$$\hat{y}^{pos} = softmax(W^{pos} * [e^w;\ e^{pos};\ e^p] + b^{pos}), \tag{7}$$

其中， $\hat{}y^{pos} \in \mathbb{R}^{N^{pos}}$， N^{pos} 是词性标签的总数。 W^{pos} 是可学习的权重， b^{pos} 是偏置张量。为优化学习过程，交叉熵损失通过公式（8）计算。

$$\mathscr{L}_{syntax} = \sum^{\mathbb{D}_s} \sum_{i}^{n} I(i) * f(\hat{y}_i^{pos}, y_i^{pos}), \tag{8}$$

$$I(i) = \begin{cases} 1 & if\ token\ is\ masked \\ 0 & else \end{cases} \tag{9}$$

其中， $I(i)$ 是用于筛选掩码词元的指示函数。 y_i^{pos} 是输入句子中第 i 个词元的真实词性标签。

4.4 训练目标

给定源域数据集和目标数据集，方面术语提取模型与句法判别器经过联合训练，以优化软

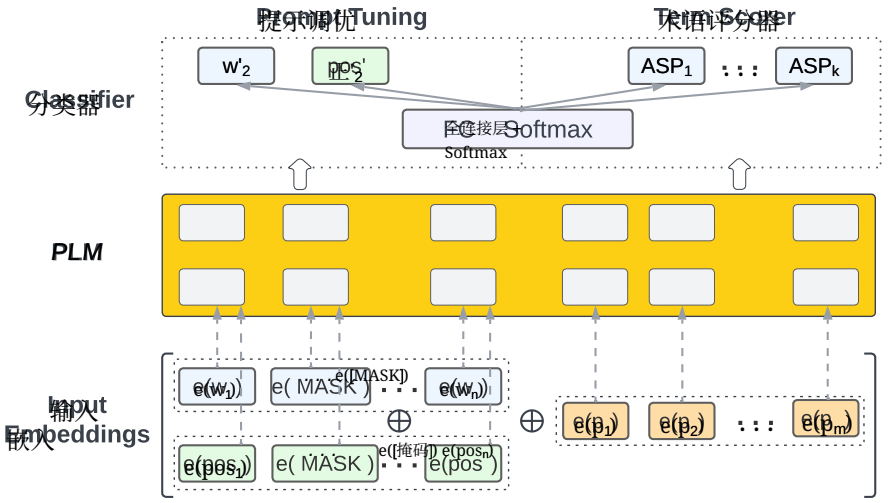

图 3 – 基于软提示的联合学习模型的总体架构。

提示嵌入、句法嵌入和方面术语预测器。最终训练目标通过对句法学习和多个领域知识增强的提示调优所产生的交叉熵损失进行加权求和得到，见公式（10）。

$$\mathscr{L}(\theta) = \alpha * \mathscr{L}_{prompt} + \beta * \mathscr{L}_{syntax} \tag{10}$$

其中， α 和 β 是权衡参数。

5 实验

在本节中，我们在三组数据集上进行了大量实验，以评估所提出的模型

5.1 数据集

我们的方法在两组领域不同的基准数据集上进行实验。对于第一组数据集 $\mathbb{G}1$, 其中包含四个领域：设备（$\mathbb{D}$）是所有数码设备评论的集合[46]。笔记本电脑（$\mathbb{L}$）和餐厅（$\mathbb{R}$）来自 SemEval ABSA 挑战赛[38–40],其中包含笔记本电脑和餐厅的客户评论。服务（$\mathbb{S}$）指网络服务的客户评论[23]。第一组数据集的基本统计信息见表1。第二组数据集 $\mathbb{G}2$ 包含三个领域：纸尿裤（$\mathbb{DI}$）、杀毒软件（$\mathbb{AS}$）和电子产品（$\mathbb{E}$），见表2。 $\mathbb{DI}$

表1 – 第一组数据集的统计信息。

领域	句子	训练集	Test
ℝ	6035	3877	2158
𝕃	3845	3045	800
𝔻	3836	2557	1279
𝕊	2239	1492	747

表2 – 第二组数据集的统计信息。

领域	句子	训练集	Test
𝔻𝕀	375	262	113
𝔸𝕊	380	266	114
𝔼	550	385	165

和 𝔸𝕊 用于观点挖掘[1] 由[14]。 𝔼 由我们的标注人员标注，最初收集用于跨领域情感分类[2]由 [61]。

5.1.1 实现与超参数

在所提出的方法中，我们使用 PyTorch 框架 [3] 来实现模型。T5-base [4] 用作基础语言模型。我们使用 Stanford NLPToolkit [5]（即 Stanza [41]）获取所有数据集的句法结构。所有实验均在单个 NVIDIA RTX A6000 GPU 加速器上进行。

T5-base 使用默认设置，例如，24 层自注意力层，每层具有 1024 维隐藏向量。[25] 使用 Adam 优化器，初始学习率为 2e-3。训练轮数设为 20，批次大小为 16。

5.2 基线方法

为验证所提方法的有效性，我们采用了几种具有竞争力的基线方法与模型进行比较。

- ***CrossCRF***[24] 是一种传统的序列标注方法，利用语言特征（即词类型、词性标签和依存关系）来检测方面术语，
  p使用的对象词项 g CRF.
- ***DP***[42] 通过一种基于自举的半监督方法，解决了两个问题，即观点词典扩展和观点目标抽取。利用依存句法分析器提取连接观点词与目标的依存关系，然后使用所识别出的关系来
  p以及初始的意 p见词典，并检测情 p感词。
- ***mSDA***[7] 是一种边缘化堆叠去噪自编码器，使用线性去噪器构建用于学习特征表示的模块。这种

[1] https://www.cs.uic.edu/ liub/FBS/Reviews-9-products.rar [2] https://github.com/paolazola/Cross-source-cross-domain-sentiment-analysis [3] https://pytorch.org/ [4] https://huggingface.co/t5-base [5] https://stanfordnlp.github.io/stanza/

方法可以解决计算成本高以及无法扩展到高维特征的问题。

•***FEMA***[57] 利用神经语言模型直接获取低维嵌入，从而学习对领域偏移更具鲁棒性的稠密特征表示。

• ***RNCRF***[52] 将递归神经网络和条件随机场整合到一个联合模型中，以检测方面术语和观点词。该统一框架能够在方面与观点词之间传播双向信息，并学习高层次的判别特征。

•***Hier-Joint***[15] 将基于规则的无监督方面术语提取与基于神经网络的监督方法相结合，以学习适用于不同领域的隐藏表示。

• ***RNSCN***[49] 是一种新颖的递归神经网络，可通过依存关系减少词级领域偏移问题。句法关系可作为源数据集和目标数据集之间不同领域的恒定枢轴信息。

• ***AD-SAL***[33] 首次探索了无监督领域自适应设置，用于联合提取方面术语和观点词。此外，本文提出了一种选择性对抗学习方法，为每个词学习一个对齐权重，从而实现细粒度领域自适应。

• ***BERT*** 直接微调基础 BERT[13] ，以预测跨领域方面术语提取任务的合并标签。

• ***TRNN-GRU***[50] 引入条件域对抗网络，以提高不同领域之间的知识可迁移性。此外，该方法将带有序列标注分类器的递归神经网络结合起来，对上下文影响进行建模，从而预测目标数据集中的方面术语。

• ***CrossBERT***[56] 在来自 Yelp 和亚马逊评论的混合数据集上对基础 BERT[13] 进行后训练，然后微调训练后的模型，以检测跨领域的方面术语。

• ***CrossBERT-UDA***[20] 是一个端到端框架，可针对跨域方面级情感分析任务执行基于特征和实例的适配。该方法能够利用语言学信息学习领域不变特征，并基于 BERT 进行词级实例加权。

•***SA-EXAL***[37] 将外部语言学信息融入基于 BERT 的自注意力机制中，通过利用 BERT 的内在知识与外部句法信息来弥合不同领域之间的差距。

• ***CDRG-Indep***[58] 旨在基于源领域中的带标签数据生成具有细粒度标注的目标域数据，然后采用 BERT 模型直接在生成的数据集上训练序列标注模型。

•***CDRG-Merge***[58] 与 CDRG-Indep 类似，不同之处在于训练策略：它将带标签的源域数据与生成数据合并，作为训练样本。

- ***AHF***[59] 将基于伪标签的半监督学习与对抗训练整合到一个统一网络中，用于跨域方面级情感分析任务。目标域数据用于训练域判别器并优化任务分类器。

- ***SynBridge***[11]是一种主动域适应模型，通过主动补充可迁移知识来迁移方面词。它通过识别句法角色并将其作为枢纽，构建句法桥梁，以识别跨领域词语的可迁移句法角色。

- ***SemBridge***[11] 与 SynBridge 类似，但 SemBridge 通过检索可迁移原型来连接跨领域的方面词。
- ***SDAM***[16] 是一种句法引导的域适应方法，利用句法结构相似性来构建伪训练数据。

- ***FMIM-BERT***[8] 是一种简单而有效的方法，基于互信息最大化，适用于跨域基于方面的情感分析任务。

5.3 实验结果与模型分析

我们在两组数据集上进行了跨域方面术语提取实验 $\mathbb{G}1$和 $\mathbb{G}2$，整体对比结果如表3 和4所示。可以看出，我们的方法在数据集$\mathbb{G}1$ 的大多数领域以及数据集 $\mathbb{G}2$的所有领域上均优于所有基线方法。与以往方法相比，我们的方法显著优于机器学习方法和基于模型的方法。然而，在领域适应 $\mathbb{L} \rightarrow \mathbb{R}$ 和 $\mathbb{D} \rightarrow \mathbb{R}$ 方面，我们的方法表现不如 SemBridge（分别低 0.007 和 0.006），这表明 SemBridge 能够捕获更多源领域的句法和语义知识，并将这些有意义的知识迁移至目标领域。不使用语义特征时，SynBridge 的性能相比所提出的方法有所下降。尽管如此，我们的方法仍优于大多数基于微调的模型，这表明基于软提示调优的方法既能学习域相关特征，也能学习域不变知识。出色的性能证明，基于提示调优的方法能够解决跨域方面术语提取问题。

表 4 展示了小规模数据集上的跨域方面术语提取结果。与基于微调的方法 AD-SAL 和 CrossBERT-UDA 相比，我们的方法在三个领域上均取得了最佳表现（绝对提升超过 5%）。这一提升表明，基于提示调优的方法在大规模和小规模数据集上都能取得有竞争力的表现。与提示调优模型相比，微调方法在源领域上训练域特定模型的难度更大，而提示调优模型则能根据提示的特征分布激活语言模型中的一些先验知识。

表3 – $\mathbb{G}1$ 上跨域方面术语提取的实验结果

模型	$\mathbb{R}\rightarrow\mathbb{L}$	$\mathbb{S}\rightarrow\mathbb{L}$	$\mathbb{D}\rightarrow\mathbb{L}$	$\mathbb{L}\rightarrow\mathbb{R}$	$\mathbb{S}\rightarrow\mathbb{R}$	$\mathbb{D}\rightarrow\mathbb{R}$	$\mathbb{R}\rightarrow\mathbb{D}$	$\mathbb{L}\rightarrow\mathbb{D}$	$\mathbb{S}\rightarrow\mathbb{D}$	$\mathbb{R}\rightarrow\mathbb{S}$	$\mathbb{L}\rightarrow\mathbb{S}$	$\mathbb{D}\rightarrow\mathbb{S}$
CrossCRF	0.197	0.116	0.242	0.282	0.170	0.659	0.211	0.299	0.097	0.088	0.086	0.045
DP	0.198	0.198	-	0.376	0.376	0.376	0.218	-	0.218	0.197	0.197	0.197
mDA	0.209	0.146	0.257	0.243	0.325	0.213	0.172	0.294	0.169	0.131	0.131	0.131
FEMA	0.266	0.150	0.268	0.350	0.376	0.207	0.229	0.296	0.187	0.108	0.148	0.088
RNCRF	0.243	-	0.406	0.409	-	0.346	0.243	0.315	-	-	-	-
Hier-Joint	0.317	0.300	0.362	0.467	0.520	0.504	0.320	0.316	0.334	0.198	0.234	0.235
RNSCN	0.266	0.189	-	0.356	0.332	0.346	0.333	-	0.220	0.200	0.166	0.200
AD-SAL	0.341	0.270	-	0.430	0.410	0.410	0.354	-	0.336	0.280	0.272	0.266
BERT	0.314	0.305	-	0.404	0.447	0.403	0.276	-	0.339	0.195	0.258	0.303
TRNN-GRU	0.402	-	0.517	0.538	-	0.512	0.373	0.412	-	-	-	-
CrossBERT	0.397	0.350	-	0.454	0.513	0.426	0.332	-	0.332	0.244	0.233	0.282
CrossBERT-UDA	0.439	0.348	-	0.495	0.471	0.427	0.349	-	0.321	0.331	0.279	0.280
SA-EXAL	0.476	-	0.477	0.547	-	0.545	0.405	0.422	-	-	-	-
CDRG-Indep	0.402	0.332	-	0.551	0.538	0.501	0.308	-	0.349	0.417	0.441	0.371
CDRG-Merge	0.466	0.395	-	0.600	0.563	0.527	0.326	-	0.369	0.424	0.471	0.418
AHF	0.557	0.448	-	0.646	0.591	0.597	0.502	-	0.478	0.438	0.427	0.444
SynBridge	0.551	0.453	-	0.653	0.584	0.628	0.533	-	0.539	0.327	0.337	0.381
SemBridge	0.579	0.451	-	0.662	0.593	0.636	0.553	-	0.546	0.350	0.350	0.377
SDAM	0.546	0.467	-	0.631	0.586	0.609	0.516	-	0.580	0.456	0.453	0.552
FMIM-BERT	0.494	0.424	-	0.634	0.592	0.573	0.397	-	0.376	0.514	0.549	0.528
Ours	0.593	0.480	0.527	0.655	0.612	0.630	0.563	0.434	0.586	0.528	0.555	0.570

表4 – 在 $\mathbb{G}2$上进行跨域方面术语提取的实验结果。

模型	$\mathbb{DI}\rightarrow\mathbb{AS}$	$\mathbb{E}\rightarrow\mathbb{AS}$	$\mathbb{DI}\rightarrow\mathbb{E}$	$\mathbb{AS}\rightarrow\mathbb{E}$	$\mathbb{E}\rightarrow\mathbb{DI}$	$\mathbb{AS}\rightarrow\mathbb{DI}$
AD-SAL	0.208	0.181	0.172	0.191	0.156	0.176
CrossBERT-UDA	0.244	0.201	0.195	0.213	0.160	0.196
Ours	0.322	0.312	0.279	0.313	0.213	0.251

表 5 – 在 $\mathbb{G}2$上进行跨域方面术语提取的消融研究。w/o 表示不含。

模型	$\mathbb{DI}\rightarrow\mathbb{AS}$	$\mathbb{E}\rightarrow\mathbb{AS}$	$\mathbb{DI}\rightarrow\mathbb{E}$	$\mathbb{AS}\rightarrow\mathbb{E}$	$\mathbb{E}\rightarrow\mathbb{DI}$	$\mathbb{AS}\rightarrow\mathbb{DI}$
-无句法	0.267	0.279	0.241	0.273	0.198	0.218
-无提示	0.244	0.258	0.261	0.253	0.171	0.226
仅使用 T5	0.196	0.218	0.133	0.236	0.119	0.164
Ours	0.322	0.312	0.279	0.313	0.213	0.251

5.4 进一步分析

5.5 消融研究

为分析各个组件（包括句法学习和提示）的作用，我们在数据集 $\mathbb{G}2$ 上进行了消融实验，实验结果如表 5所示。

5.5.1 句法学习的影响

在本小节中，我们通过消融研究验证句法学习的效果。表5 展示了数据集 $\mathbb{G}2$ 上的实验结果。我们发现，去掉句法学习组件后，我们的方法在所有目标领域上的结果均有所下降（分别为 -5.5%、-3.3%、-3.8%、-4%、-1.5%、-3.3 %）。这表明，语言特征对于捕捉领域间的域不变信息至关重要。域独立特征能够架起

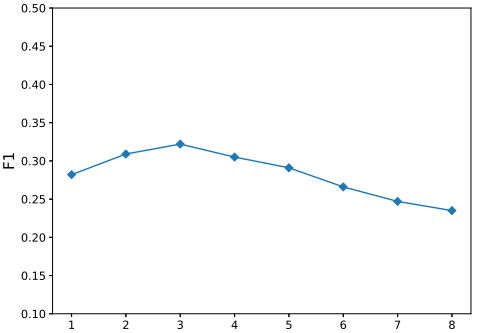

图 4 – 不同长度的软提示词元在 $\mathbb{DI}\rightarrow \mathbb{AS}$ 上的实验结果。

缩小领域间的差距，并促进跨领域方面词提取任务在目标领域中的预测。例如，使用领域 $\mathbb{DI}$ 中的一条输入句子“我们找到的 *Diaper Champ* 是最好的！”训练模型，其中方面术语为 $Diaper\ Champ$ ，词性标签为 名词。在源领域学习这一句法模式后，模型便更容易在目标领域 $\mathbb{AS}$ 的句子“这个 *Program* 带来的问题比病毒还多.....”中预测方面术语 $Program$。

5.5.2 提示的影响

我们通过从方法中移除提示，评估了提示的影响。表 5 展示了所有目标领域中不使用提示时的 F1分数。移除提示后，我们观察到所有领域的性能均显著下降（分别为 -7.8%、-5.4%、-1.8%、-6.0%、-4.2%、-2.5%），这表明所设计的提示能够用于拓展源领域的语义空间。共享的语义知识还能进一步提升跨领域方面词提取任务的性能。

正如先前研究所述[19], ，提示的选择可能会对模型性能产生巨大影响。因此，我们在领域 $\mathbb{DI} \rightarrow \mathbb{AS}$ 上使用不同数量的提示词元进行实验，以进一步研究软提示的影响。结果如图 4所示，提示词元的长度会影响领域 $\mathbb{DI} \rightarrow \mathbb{AS}$ 上的提示调优性能。我们的方法将提示词元长度设为 3，以实现跨域方面术语提取的最佳结果。

5.6 案例研究

为进一步展示所提模型的有效性，我们在数据集 $\mathbb{G}1$上进行了案例研究。表6 展示了 AD-SAL、CrossBERT-UDA 和我们的方法在跨域方面术语提取任务上的结果。在示例 1“*Straight-forward,*

表6 – AD-SAL、CrossBERT-UDA 和我们的方法在领域 $\mathbb{R}$ 上的方面术语提取结果。错误预测以标记 ✗ 表示。

输入 ($\mathbb{S}$->$\mathbb{R}$)	**AD-SAL**	**CrossBERT-UDA**	**Ours**
直截了当、毫无意外，非常不错 [日本料理]。	{[ ]}	{[ ]}	{[日本料理]}
虽然 [菜单],还不错，但不应该 花十分钟才拿到你的 [饮料] ，还 一份 [甜品披萨]要45。	{[披萨]✗}	{[菜单]}	{[菜单], [饮料], [甜品披萨]}
我吃过 [水母], [竹荚鱼], 还有 [蓝鳍金枪鱼] 和 [清酒鲑鱼籽卷] 等等，而且它们都很好吃。	{[水母], [马]✗, [金枪鱼]✗}	{[水母], [鲱鱼]✗, [鲑鱼]✗, [反卷寿司]✗}	{[水母], [竹荚鱼], [蓝鳍金枪鱼], [清酒鲑鱼籽卷]}
[食物]一流， [服务] 很 周到，而且 [氛围] 很棒。	{[食物], [服务]}	{[食物], [服务]}	{[食物], [服务], [氛围]}
尝尝 [排骨] , 滋滋作响的 [牛肉]，再搭配 配上 [椰浆饭]。	{[排骨], [牛肉]}	{[排骨], [牛肉], [米饭]✗}	{[排骨], [牛肉], [椰浆饭]}
他们有很好的 [牛油果鸡肉] 和美味的 [金枪鱼] 也不错。	{[鸡肉]✗, [金枪鱼]}	{[牛油果]✗, [金枪鱼]}	{[牛油果鸡肉 牛油果], [金枪鱼]}

no surprises, very decent Japanese food.”中，CrossBERT-UDA 和 AD-SAL 均未能识别方面术语日本料理。CrossBERT-UDA 提取出了三个方面术语中的一个，而 AD-SAL 在示例 2“*While there's a decent menu, it shouldn't take ten minutes toget your drink and 45 for a dessert pizza*”中仅错误地预测了一个方面术语。该例包含三个方面术语：菜单、饮料和甜品披萨。示例 3 和 6 中包含多个方面术语，其中大多数由多个词组成。AD-SAL 和 CrossBERT-UDA 只能识别这些方面术语中的部分词语。在示例 4 和 5 中，基线模型能够正确预测部分方面术语，而我们的方法则能识别全部方面术语。案例研究表明，我们的方法不仅能够准确检测多个方面术语，还能准确检测由多个词组成的方面术语。

6 结论与未来工作

本文提出一种新颖的基于软提示的跨领域方面术语抽取联合学习方法。现有方法要么基于机器学习或深度学习，要么基于硬提示；这些方法往往存在领域不变特征质量较低，或在小规模目标数据集上性能不稳定的问题。与以往方法不同，我们采用软提示学习不同领域的域内知识，以增强领域不变特征表示。我们不直接整合句法信息，而是设计了一种句法特征自监督学习方法，以学习领域之间的结构对应关系，从而缩小领域差异。我们在涵盖多个领域的两组数据集上开展实验，结果表明，与现有的跨领域方面术语抽取模型相比，我们的方法效果更佳。

未来，我们计划扩展模型，以完成更多基于方面的情感分析任务（例如，观点词提取、方面-观点词对提取、情感三元组提取等）。然而，由于方面、观点和情感极性之间存在复杂关系，设计一个能够在不同领域完成所有基于方面的情感分析子任务的统一框架，是一项具有挑战性的研究工作。同时，还可以进一步提升所提方法在小规模数据集上的性能，以增强其鲁棒性。

致谢。作者谨此感谢新西兰 Callaghan Innovation 提供的资金支持（CSITR1902，2020年）；没有这项支持，本研究便无法完成。我们感谢他们为推动新西兰科学技术发展所作的贡献。作者还谨此感谢 CAITO.ai 的宝贵合作及其对本项目的贡献。

参考文献

[1] Anand, D., Mampilli, B.S.：一种用于学习跨领域观点目标提取句法特征的新型进化方法。Applied Soft Computing **102**，107086（2021年）[2] Asai, A., Salehi, M., Peters, M.E., Hajishirzi, H.：用于参数高效多任务知识共享的软提示调优的注意力混合。arXiv 预印本 arXiv:2205.11961（2022年）[3] Ben-David, E., Oved, N., Reichart, R.：Pada：一种基于提示的自回归方法，用于适应未见领域。arXiv 预印本 arXiv:2102.12206（2021）[4]Ben-David, E., Oved, N., Reichart, R.：Pada：基于示例的提示学习，用于即时适应未见领域。《计算语言学协会汇刊》**10**，414–433（2022）[5] Ben-David, E., Rabinovitz, C., Reichart, R.：Perl：针对预训练深度上下文化嵌入模型的基于枢轴的领域自适应。《计算语言学协会汇刊》**8**，504–521（2020年）[6] Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J.D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., 等：语言模型是少样本学习器。神经信息处理系统进展 **33**，1877–1901（2020年）[7]Chen, M., Xu, Z., Weinberger, K., Sha, F.：用于领域自适应的边缘化去噪自编码器。arXiv 预印本 arXiv:1206.4683（2012）

软提示引导的跨领域情感分析联合学习 17[8] Chen, X., Wan, X.：一种用于无监督领域自适应基于方面的情感分析的简单信息方法。arXiv预印本 arXiv:2201.12549（2022）[9] Chen, X., Zhang, N., Li, L., Xie, X., Deng, S., Tan, C., Huang, F., Si, L., Chen, H.：Lightner：一种采用提示引导注意力的轻量级生成式框架，用于低资源命名实体识别。arXiv预印本 arXiv:2109.00720（2021）[10] Chen, X., Zhang, N., Xie, X., Deng, S., Yao, Y., Tan, C., Huang, F., Si, L., Chen, H.：Knowprompt：用于关系抽取的知识感知提示调优与协同优化。载于：2022年ACM Web会议论文集。第2778–2788页（2022）[11] Chen, Z., Qian, T.：基于桥接的主动领域自适应用于方面术语提取。载于：第59届计算语言学协会年会与第11届自然语言处理国际联合会议论文集（第1卷：长论文）。第317–327页（2021）[12] Chernyshevich, M., Belarus, I.：使用条件随机场进行跨领域产品特征抽取。载于：第8届国际语义评测研讨会论文集（SemEval 14）。第309–313页（2014）[13] Devlin, J., Chang, M.W., Lee, K., Toutanova, K.：BERT：用于语言理解的深度双向变换器预训练。载于：2019年北美计算语言学协会分会会议：人类语言技术论文集。第4171–4186页（2019）[14] Ding, X., Liu, B., Yu, P.S.：一种全面的基于词典的观点挖掘方法。载于：2008年国际网络搜索与数据挖掘会议论文集。第231–240页（2008）[15] Ding, Y., Yu, J., Jiang, J.：带辅助标签的循环神经网络用于跨领域观点目标抽取。载于：AAAI人工智能会议论文集。第31卷（2017）[16]Dong, A., Gao, C., Jia, Y., Liao, Q., Wang, X., Wang, L., Xiao, J.：句法引导的域适应用于基于方面的情感分析。arXiv预印本 arXiv:2211.05457（2022）[17] Gao, L., Wang, Y., Liu, T., Wang, J., Zhang, L., Liao, J.：用于方面–观点对抽取的问题驱动跨度标注模型。载于：AAAI人工智能会议论文集。第35卷，第12875–12883页（2021）

[18] Gao, T., Fang, J., Liu, H., Liu, Z., Liu, C., Liu, P., Bao,Y., Yan, W.：《Lego- absa：一种基于提示的可组装任务统一生成式框架，用于多任务方面级情感分析》。载于：第29届国际计算语言学会议论文集。第7002–7012页（2022年）[19] Gao, T., Fisch, A., Chen, D.：让预训练语言模型成为更好的少样本学习器。载于：计算语言学协会第59届年会及自然语言处理国际联合会议第11届会议论文集（第1卷：长论文）。第3816–3830页（2021）[20] Gong, C., Yu, J., Xia, R.：用于基于方面的情感分析的统一特征与实例领域自适应。载于：2020年自然语言处理实证方法会议（EMNLP）论文集。第7035–7045页（2020）[21] Hewitt, J., Manning, C.D.：一种用于在词表示中发现句法的结构探针。载于：2019年计算语言学协会北美分会年会：人类语言技术论文集，第1卷（长篇与短篇论文）。第4129–4138页（2019）[22] Howard, P., Ma, A., Lal, V., Simoes, A.P., Korat, D., Pereg, O., Wasserblat, M., Singer, G.：利用知识图谱增强的Transformer进行跨领域方面抽取。载于：第31届ACM信息与知识管理国际会议论文集。第780–790页（2022）[23] Hu, M., Liu, B.：客户评论的挖掘与摘要。载于：第十届ACM SIGKDD知识发现与数据挖掘国际会议论文集。第168–177页（2004）[24] Jakob, N., Gurevych, I.：使用条件随机场在单领域和跨领域设置下提取观点目标。载于：2010年自然语言处理实证方法会议论文集。第1035–1045页（2010）[25] Kingma, D.P., Ba, J.：Adam：一种随机优化方法。第3届国际学习表征会议论文集（2015）[26]Klein, A., Pereg, O., Korat, D., Lal, V., Wasserblat, M., Dagan, I.：基于观点的关系枢轴，用于跨领域方面术语提取。载于：第12届主观性、情感与社交媒体分析的计算方法研讨会论文集。第104–112页（2022）

[27] Le Scao, T., Rush, A.M.：一条提示的价值相当于多少个数据点？载于：计算语言学协会北美分会人类语言技术2021年会议论文集。第2627–2636页（2021年）[28] Lester, B., Al-Rfou, R., Constant, N.：规模对参数高效提示调优的作用。载于：2021年自然语言处理实证方法会议论文集。第3045–3059页（2021年）[29] Lewis, M., Liu, Y., Goyal, N., Ghazvininejad, M., Mohamed, A., Levy, O., Stoyanov, V., Zettlemoyer, L.：BART：用于自然语言生成、翻译和理解的去噪序列到序列预训练。载于：第58届计算语言学协会年会论文集。第7871–7880页（2020年）[30]Li, C., Gao, F., Bu, J., Xu, L., Chen, X., Gu, Y., Shao, Z., Zheng, Q., Zhang, N., Wang, Y., 等：SentiPrompt：通过情感知识增强提示调优，实现基于方面的情感分析。arXiv预印本 arXiv:2109.08306（2021年）[31] Li, H., Yang, L., Li, L., Xu, C., Xia, S.T., Yuan, C.：PTS：一种用于弱监督方面检测的基于提示的教师-学生网络。载于：2022年国际神经网络联合会议（IJCNN）。第1–8页。IEEE（2022年）[32] Li, J., Yu, J., Xia, R.：用于方面与观点联合抽取的生成式跨领域数据增强。载于：计算语言学协会北美分会人类语言技术2022年会议论文集。第4219–4229页（2022年）[33] Li, Z., Li, X., Wei, Y., Bing, L., Zhang, Y., Yang, Q.：通过选择性对抗学习实现可迁移的端到端基于方面的情感分析。载于：2019年自然语言处理实证方法会议与第9届自然语言处理国际联合会议（EMNLP-IJCNLP）论文集。第4590–4600页（2019年）[34] Liu, B.：情感分析与观点挖掘。《人类语言技术讲义》**5**(1), 1–167（2012年）[35] Mampilli, B.S., Anand, D.：使用多种嵌入技术和语言模型进行跨领域方面抽取。载于：第二届机器学习、物联网、智慧城市与应用国际会议论文集。第237–248页。施普林格（2022年）[36]Marcacini, R.M., Rossi, R.G., Matsuno, I.P., Rezende, S.O.：用于情感分析的跨领域方面抽取：一种传导式学习方法。《决策支持系统》**114**, 70–80（2018年）

20 软提示引导的跨领域情感分析联合学习[37] Pereg, O., Korat, D., Wasserblat, M.：句法感知的跨领域方面与观点术语抽取。载于：第28届国际计算语言学会议论文集。第1772–1777页（2020）[38] Pontiki, M., Galanis, D., Papageorgiou, H., Androutsopoulos, I., Manandhar, S., Al-Smadi, M., Al-Ayyoub, M., Zhao, Y., Qin, B., De Clercq, O.等：SemEval-2016任务5：基于方面的情感分析。载于：第10届语义评测国际研讨会论文集（SemEval 2016）。第19–30页（2016）[39]Pontiki, M., Galanis, D., Papageorgiou, H., Manandhar, S., Androutsopoulos, I.：SemEval-2015任务12：基于方面的情感分析。载于：第9届语义评测国际研讨会论文集（SemEval 2015）。第486–495页（2015）[40] Pontiki, M., Galanis, D., Pavlopoulos, J., Papageorgiou, H., Androutsopoulos, I., Manandhar, S.：SemEval-2014任务4：基于方面的情感分析。载于：第8届语义评测国际研讨会论文集（SemEval 2014）。第27–35页（2014）[41] Qi, P., Zhang, Y., Zhang, Y., Bolton, J., Manning, C.D.：Stanza：适用于多种人类语言的Python自然语言处理工具包。载于：第58届计算语言学协会年会：系统演示论文集。第101–108页（2020）[42] Qiu, G., Liu, B., Bu, J., Chen, C.：通过双重传播扩展观点词并抽取目标。《计算语言学》**37**(1), 9–27（2011）[43] Radford, A., Narasimhan, K., Salimans, T., Sutskever, I.等：通过生成式预训练提升语言理解（2018）[44] Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., Sutskever, I.等：语言模型是无监督多任务学习器。《OpenAI博客》**1**(8), 9（2019）[45] Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W., Liu, P.J.等：探索统一文本到文本转换器的迁移学习极限。《机器学习研究杂志》**21**(140), 1–67（2020）[46] Toprak, C., Jakob, N., Gurevych, I.：用户生成话语中观点的句子级与表达级标注。载于：第48届计算语言学协会年会论文集。第575–584页（2010）

软提示引导的跨领域情感分析联合学习 2[47] Venugopalan, M., Gupta, D.: 1 增强型引导式LDA模型结合基于BERT的语义强度，用于情感分析中的方面术语提取。《知识型系统》**246**，108668（2022年）[48] Wan, H., Yang, Y., Du, J., Liu, Y., Qi, K., Pan, J.Z.：用于基于方面的情感分析的目标方面情感联合检测。载于：AAAI人工智能会议论文集。第34卷，第9122–9129页（2020年）[49] Wang, W., Pan, S.J.：用于跨领域方面与观点联合提取的递归神经结构对应网络。载于：计算语言学协会第56届年会论文集（第1卷：长论文）。第2171–2181页（2018年）[50] Wang, W., Pan, S.J.：用于方面与观点提取的句法语义明确且可迁移的递归神经网络。《计算语言学》**45**（4），705–736（2019年）[51] Wang, W., Pan, S.J.：用于细粒度观点提取中领域自适应的可迁移交互式记忆网络。载于：AAAI人工智能会议论文集。第33卷，第7192–7199页（2019年）[52] Wang, W., Pan, S.J., Dahlmeier, D., Xiao, X.：用于基于方面的情感分析的递归神经条件随机场。载于：2016年自然语言处理实证方法会议论文集。第616–626页（2016年）[53] Wang, X., Xu, H., Sun, X., Tao, G.：结合微调与基于特征的方法进行评论方面抽取。载于：AAAI人工智能会议论文集。第34卷，第13951–13952页（2020年）[54] Wu, H., Shi, X.：用于跨领域情感分析的对抗式软提示调优。载于：计算语言学协会第60届年会论文集（第1卷：长论文）。第2438–2447页（2022）[55] Xu, H., Liu, B., Shu, L., Philip, S.Y.：用于方面抽取的双重嵌入与基于CNN的序列标注。载于：计算语言学协会第56届年会论文集。第592–598页（2018年）[56] Xu, H., Liu, B., Shu, L., Philip, S.Y.：用于评论阅读理解和基于方面的情感分析的BERT后训练。载于：2019年计算语言学协会北美分会年会：人类语言技术会议论文集，第1卷（长论文与短论文）。第2324–2335页（2019年）

[57] Yang, Y., Eisenstein, J.：利用特征嵌入进行无监督多领域适应。载于：2015年计算语言学协会北美分会人类语言技术会议论文集。第672–682页（2015年）

[58] Yu, J., Gong, C., Xia, R.：用于基于方面的情感分析的跨领域评论生成。载于：计算语言学协会论文集：ACL-IJCNLP 2021。第4767–4777页（2021）

[59] Zhou, Y., Zhu, F., Song, P., Han, J., Guo, T., Hu, S.：一种用于跨领域基于方面的情感分析的自适应混合框架。载于：AAAI人工智能会议论文集。第35卷，第14630–14637页（2021）[60]Ziser, Y., Reichart, R.：基于枢轴的语言建模，以改进神经领域适应。载于：2018年计算语言学协会北美分会人类语言技术会议论文集，第1卷（长论文）。第1241–1251页（2018年）[61] Zola, P., Cortez, P., Ragno, C., Brentari, E.：社交媒体跨来源和跨领域情感分类。《国际信息技术与决策》18(05)，1469–1499（2019年）