

文章编号:1007-5321(2021)05-0021-07

DOI:10.13190/j.jbupt.2020-276

# 一种面向目标的情感极性分析方法

王文竹, 肖波, 陈柯宏

(北京邮电大学 人工智能学院, 北京 100876)

**摘要:** 面向目标的情感分析是细粒度情感分析的重要任务之一,旨在预测句子中给定目标实体的情感极性。当前大多数研究方法忽略了句法结构信息,在情感判别时往往会关注无关词汇,从而使分类性能下降。为此,设计了一种新的引入句法结构的模型,该模型利用双向预训练编码器和作用于依存句法树的图卷积网络分别捕获文本的上下文信息和句法结构信息,并使用多头注意力机制进行信息聚合得到目标的情感分类表征。此外,还将该模型与现有的领域自适应方法相结合,同时向模型中引入领域知识和句法结构知识,进一步提升了模型效果。在几个常用的标准数据集上的实验结果表明了上述模型的有效性。

**关键词:** 目标情感分析;图卷积网络;基于深度自注意力网络的双向编码器;依存树  
**中图分类号:** TP391.1      **文献标志码:** A

## A Method for Targeted Sentiment Analysis

WANG Wen-zhu, XIAO Bo, CHEN Ke-hong

(School of Artificial Intelligence, Beijing University of Posts and Telecommunications, Beijing 100876, China)

**Abstract:** Targeted sentiment analysis (TSA) is a crucial task for fine-grained public opinion mining, which focuses on predicting the sentiment polarity towards a specific target in a given sentence. Most of existing works ignore the syntactic structure of the context sentence, and may pay attention to irrelevant context words when making sentiment judgments. To tackle the problem, a novel syntax aware model is proposed for TSA, which integrates the pre-trained bidirectional encoder representation from transformers models and a graph convolutional network over the dependency tree of the sentence to capture the context information and syntactic structure information of the sentence respectively. The proposed model uses the multi-head attention mechanism to aggregate the information to obtain the final target sentiment representation. The proposed model is also combined with the existing domain adaptive method to introduce domain knowledge and syntactic knowledge, which further improves the performance. The experimental results on several widely-used benchmark datasets demonstrate the effectiveness of the proposed model.

**Key words:** targeted sentiment analysis; graph convolutional network; bidirectional encoder representation from transformers; dependency tree

面向目标的情感分析(TSA, targeted sentiment analysis)作为文本信息挖掘的一项重要任务,在电

子商务、个性化推荐和产品分析等各种实际应用中都发挥着重要作用<sup>[1]</sup>。给定一个句子和其中的目标

收稿日期:2020-12-30

基金项目:国家自然科学基金项目(62076031)

作者简介:王文竹(1997—),女,硕士生。

通信作者:肖波(1975—),男,副教授,博士生导师, E-mail: xiaobo@bupt.edu.cn.

实体(如命名实体或名词短语),TSA 将针对该目标实体识别其情感极性(正面,负面或中立),即给定文本-目标实体对,预测文本中关于该实体的情感类别.与传统的仅对整个句子预测一个整体情感极性的情感分析任务不同,TSA 任务更为复杂,因为给定句子中可能有多个目标实体,而各个目标实体可能有各自不同的情感极性,在预测时需要做到针对每个特定目标寻找情感语境进行情感极性预测.

近年来,神经网络已广泛应用于 TSA<sup>[1]</sup>,神经网络模型可以有效地从目标和上下文中自动学习可用于情感分析任务的文本的低维表示.这类模型在结构设计上一般包含 1 个对文本进行向量表示的编码模块和 1 个用于关注目标情感信息的注意力交互模块.尽管现有的神经网络模型在 TSA 任务上获得了不错的成效,但当前大多数方法仅采用简单的上下文特征进行文本表示,很少考虑句子中的语法结构.因此,这些模型生成的针对目标的向量表示可能会错误地关注到语法上不相关的上下文单词上,导致做出错误的情感判断.例如,在句子“The food, though served with bad service, is actually great”中,目标“food”与其句法相关的情感词“great”距离较远,现有方法在学习“food”的表示时,很容易将与其语法结构上无关的上下文单词“bad”识别为其情感极性的线索,错误地判断出针对“food”的情感极性是负向,显然事实并非如此.

为此,探索了从多个角度向模型中引入外部信息,从而提升模型在 TSA 任务上的表现效果.首先设计了一种新颖的语法感知模型(SAM, syntax aware model),该模型使用预训练的基于深度自注意力网络的双向编码器(BERT, bidirectional encoder representation from transformers)作为上下文特征编码器,并利用作用于依存句法树的图卷积网络(GCN, graph neural network)和多头注意力机制向模型中引入语法信息.同时将 SAM 与领域自适应方法相结合,向模型中引入语法知识和领域知识,进一步提升模型效果.在 3 个常用的公开数据集上评估了上述模型的性能.实验结果表明,所提模型优于多个现有模型,并且当使用领域自适应的 BERT 权重时,SAM 在 2 个数据集上获得了最好性能.

## 1 相关工作

面向目标的情感分析任务也称为基于方面的情感分析,旨在检测句子中目标级别的情感,属于文本

分类问题.传统方法多采用诸如支持向量机等机器学习算法以监督方式对文本进行分类来解决这类问题.这类方法常常需要大量费时费力的特征工程和用于辅助情感分类的大量外来语料或词库,其效果也十分依赖和受限于特征工程的设计.

在近年来的工作中,神经网络在 TSA 任务中被广泛使用.一些工作使用循环神经网络(RNN, recurrent neural network)的变体,例如:长短期记忆网络(LSTM, long short term memory network)和门控制单元(GRU, gated recurrent unit)来对句子中的单词序列进行处理.例如,Tang 等<sup>[2]</sup>使用 2 个 LSTM 分别处理带有预测目标的左右上下文,得到左右上下文关于目标的向量表征,之后将这 2 个表征拼接在一起,来预测目标的情感极性.除了基于 RNN 的方法外,一些工作还使用卷积神经网络(CNN, convolutional neural network)结构来发现针对目标实体的描述性的多词短语,并进行目标的情感分类.刘全等<sup>[3]</sup>提出了一种结合 GCN 的分层网络模型,通过词语层和句子层的信息提取机制能获取特定方面在句子中的局部特征和整个评论中的长距离依赖关系,弥补了仅使用词语层信息的不足.最近,也有一些尝试使用诸如 BERT 的预训练语言模型来解决此任务的方法<sup>[4]</sup>.Rietzler 等<sup>[5]</sup>收集了用于学习领域知识的语料,然后使用两阶段微调 BERT 的方法在外部语料和任务数据之间进行领域知识的迁移学习.

在引入外部信息方面,早期的工作尝试在模型中加入人工设置的语法规则来确定目标与观点词之间的关系,但这些方法受限于人工定义的规则的数量和质量.近年来,人们逐渐尝试使用依存句法树来提供更全面的语法信息.Zhang 等<sup>[6]</sup>提出使用图卷积神经网络处理依存句法树,向模型中引入句法结构知识,并使用 LSTM 和 GCN 设计了一种针对目标的情感分析网络,但该工作使用 LSTM 作为特征提取器,未能充分利用预训练语言模型提取上下文信息的优势.

尽管当前的方法在 TSA 任务上相比于传统方法已经显示出了很大的进步,但现有模型未能同时充分利用文本的上下文信息、语法信息以及领域知识,学习到的用于情感分类的文本嵌入表示在表征能力上仍有不足,可以进一步通过引入其他外部信息进行增强.

## 2 语法感知模型

所提的 SAM 结构如图 1 所示,分别由 BERT 编

码层、图卷积层和信息聚合层 3 层组成。首先,将输入的“句子-目标实体对”拼接起来输入 BERT 编码层将单词映射到词嵌入向量表示。接着在 GCN 层,模型使用这些词嵌入向量和句子的依存句法树构建

依存图  $G$ ,使用 GCN 在  $G$  上对各节点词的嵌入向量进行更新。最后,更新后的节点词嵌入向量通过信息聚合层得到最终用于情感分类的向量表征并通过全连接层进行情感极性的识别。

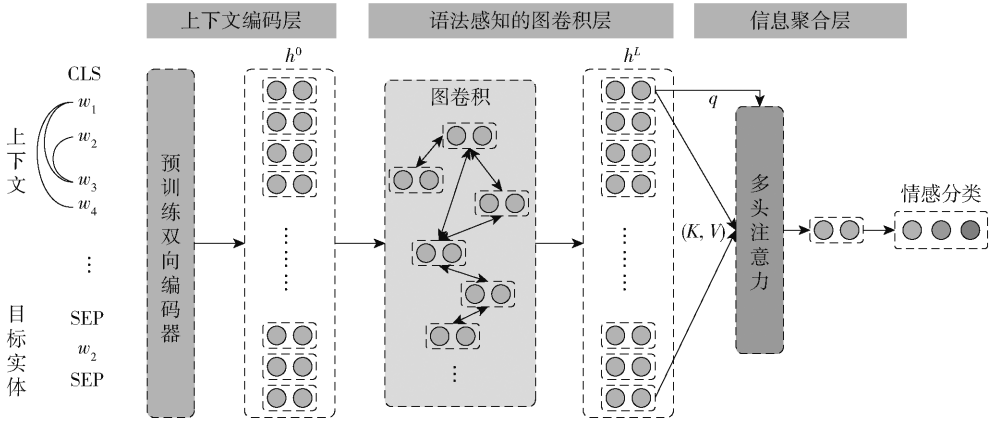


图 1 SAM 结构

2.1 上下文感知的 BERT 编码层

SAM 在上下文感知编码器层中采用 BERT 作为其特征提取器,因为预训练模型 BERT 相比于 RNN 和 CNN 具有更强的抽取通用上下文表征的能力,是目前 TSA 任务上效果最佳的特征提取模型。

对于一个含有  $n$  个单词的句子  $s = \{w_1, w_2, \dots, w_{t+1}, \dots, w_{t+T}, \dots, w_{n-1}, w_n\}$ ,其中  $\{w_{t+1}, \dots, w_{t+T}\}$  为含有  $T$  个单词的待预测目标实体。BERT 编码层在处理输入时,首先将句子和目标实体进行分词得到句子级分词表示 (sentence\_tokens) 和目标级分词表示 (target\_tokens),然后按照 BERT 模型的输入序列格式将“[CLS] + sentence\_tokens + [SEP] + target\_tokens + [SEP]”形式的序列输入 BERT 网络进行编码。BERT 编码层的输出是分词表示 (token) 的词嵌入向量序列,每个词嵌入向量都捕获其对应位置 token 的上下文信息。

2.2 语法感知的图卷积层

为了捕获句子中的句法信息,在此使用具有语

法感知的图卷积层。首先,使用现有的句法分析器<sup>[7]</sup>生成输入句子的依存句法树,依存句法树具有树形结构,SAM 可以根据依存句法树,构造如图 2 所示的依存句关系图  $G$ ,图中每个节点是从 BERT 编码层获得的 token 的词嵌入表示。图中节点之间的依存关系可以由邻接矩阵  $A$  表示,如果节点  $i$  在依存关系树中与节点  $j$  相连,则  $A_{ij} = 1$ 。对于一个一层的 GCN 网络,其卷积操作可以表示为

$$h_i = \sigma \left( \sum_{j=1}^n A_{ij} W h_j + b \right) \tag{1}$$

其中  $h_i$  和  $h_j$  分别为节点  $i$  和节点  $j$  的表征向量,  $W$  为线性变换的权重矩阵,  $b$  为线性变换的偏置量,  $\sigma$  为非线性的激活函数,多采用线性整流函数 (ReLU, rectified linear unit)。

为了使 GCN 有效地建模节点嵌入,在邻接矩阵中多使用无向连接,并且每个节点在  $G$  中都与其自身相连接。对于“[CLS]” “[SEP]” 以及所有“target\_tokens”对应的节点,它们与  $G$  中的每个节

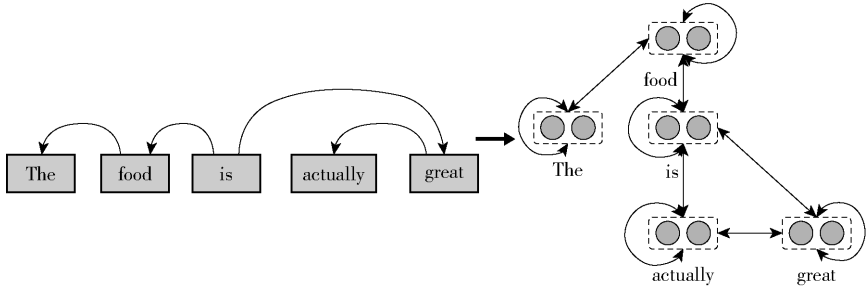


图 2 根据句子的依存句法树构造的依存句关系图  $G$

点都进行连接以收集全局信息. 需要注意的是, BERT 使用字节对编码算法进行分词, 因而可能会将一个单词拆分为多个子词, 例如“redeeming” → {“red”, “##deem”, “##ing”}. 在 SAM 中, 每个子词都具有与其在依存句法树中对应的单词相同的依赖关系. 接着, SAM 使用  $L$  层的 GCN 网络, 在图  $G$  上各节点的  $L$  阶邻居间传播信息. 在第  $l$  层中, 每个嵌入  $h_i^{(l)}$  的节点的更新可以表示为

$$h_i^{(l)} = \text{ReLU} \left( \sum_{j=1}^n A_{ij} \mathbf{W}^{(l)} h_j^{(l-1)} / d_i + b^{(l)} \right) \quad (2)$$

其中:  $h_j^{(l-1)}$  为  $l-1$  层 GCN 输出的词嵌入向量, 当  $l=1$  时,  $h_j^{(0)}$  为 BERT 编码层输出的词嵌入向量;  $d_i = \sum_{j=1}^n A_{ij}$  为图  $G$  中节点  $i$  的度;  $\mathbf{W}^{(l)}$  为第  $l$  层 GCN 的权重矩阵参数;  $b^{(l)}$  为第  $l$  层 GCN 的偏置量参数, ReLU 为激活函数. 值得一提的是, SAM 中的 GCN 网络是以残差学习方式学习的. 受深度神经网络<sup>[8]</sup>残差学习的启发, SAM 在 GCN 层周围采用了具有层归一化<sup>[9]</sup>的残差连接. 语法感知的 GCN 层的输出可以最终表示为

$$h^{(L)} = f(g(M(h^{(0)})) + h^{(0)}) \quad (3)$$

$$f(h_j^{(L)}) = \text{ReLU}(\mathbf{W}_{\text{fin}} h_j^{(L)} + b_{\text{fin}}) \quad (4)$$

其中:  $h^{(0)}$  和  $h^{(L)}$  为图卷积层的输入和输出向量,  $g(\cdot)$  为图卷积操作,  $M(\cdot)$  为层归一化,  $f(\cdot)$  为一个时间分布的前馈层, 它对残差连接后的输出进行线性变换,  $\mathbf{W}_{\text{fin}}$  和  $b_{\text{fin}}$  为前馈层的权重矩阵和偏置参数.

### 2.3 信息聚合层

在信息聚合层中, SAM 使用多头注意力机制来聚合 GCN 层的序列输出  $h^{(L)}$ , 并生成用于情感分类的最终表示向量  $r$ . 给出查询向量  $q$  和一系列的键值对  $(K, V)$ , 其中  $K$  和  $V$  分别为按照序列维度堆叠起来的键矩阵和值矩阵. 注意力机制通过计算  $V$  序列的加权平均来聚合输入得到输出向量, 其中  $V$  的权重是通过  $q$  和  $K$  的运算得到. 对于 SAM, 输入中的“[CLS]”对应的 GCN 层词嵌入输入  $h_0^{(L)}$  作为  $q$ , 而 GCN 层输出的序列  $h^{(L)}$  用作  $(K, V)$ . 将  $q, K, V$  分别进行多次的线性映射得到多个版本的  $(q, K, V)$  三元组. 一个三元组对应多头注意力机制中的一个头. 对每个头, 都进行如下的注意力操作:

$$h = a(q, K, V) = s \left( \frac{qK^T}{\sqrt{d_k}} \right) V \quad (5)$$

其中:  $a$  为注意力操作,  $s$  为 softmax 函数,  $d_k$  为键嵌

入向量的维度大小,  $1/\sqrt{d_k}$  为缩放点积中的缩放因子,  $h$  为多头注意力中的头表示.

最终的表示向量  $r$  是由多头注意力的结果拼接到一起, 然后经过线性映射得到的:

$$r = \sigma(l[h_1; h_2; \dots; h_n]) \quad (6)$$

其中:  $[h_1; h_2; \dots; h_n]$  为对  $h_1, h_2, \dots, h_n$  进行向量拼接操作,  $l$  为线性映射.

### 2.4 训练

式(6)得到的情感表示  $r$  经过全连接和 softmax 层, 生成不同情感标签上的概率分布. 目标实体的情感极性预测结果取概率得分最高的标签. SAM 通过反向传播进行端到端训练, 并使用  $L_2$  正则化, 最小化交叉熵损失为

$$L = - \sum_{y \in C} I(\hat{y} = y) \ln(P(\hat{y} = y)) + \lambda \|\Theta\|^2 \quad (7)$$

其中:  $I(\cdot)$  为指示函数,  $C$  为标签集,  $\hat{y}$  为预测的标签,  $y$  为真实标签,  $\lambda$  为  $L_2$  正则化系数,  $\Theta$  为训练参数集合.

## 3 实验结果分析

### 3.1 数据集与实验设定

实验中采用 3 个广泛使用的数据集: Laptop, Restaurant 和 Twitter 对 SAM 进行性能评估. 其中, 前 2 个数据集是来自 SemEval 2014 Task 4<sup>[10]</sup> 的特定领域数据集, 分别包含笔记本电脑和餐厅评论. Twitter 数据集中包含 Twitter 帖子, 是由 Dong 等<sup>[11]</sup>收集的. 遵循先前的工作<sup>[2]</sup>, 数据集中删除了极性标签相冲突的样本. 3 个数据集的标签集由 3 个情感极性组成: 正向, 中性和负向. 表 1 给出了 3 个数据集的总体数据情况, 包括每个标签类别中训练和测试实例的数量.

表 1 各数据集的样本数量情况

数据集	正向		中性		负向	
	训练集	测试集	训练集	测试集	训练集	测试集
Laptop	994	341	464	169	870	127
Restaurant	2 164	728	637	196	807	196
Twitter	1 561	173	3 127	346	1 560	173

对于所有实验, 与其他进行比较的模型一样, BERT 编码器层的权重从预训练的 BERT 模型或从领域自适应的 BERT 模型 (BERT-ADA, BERT with domain adaptation) 进行初始化. GCN 层的深度设置为 2, 这是在试点研究中表现最好的深度. 为简单起



见, SAM 的所有隐藏状态维度都设置为 768, 这是基于 BERT 模型的默认隐藏状态维度设置的. 在信息聚合层中, 多头的数量设置为 12. SAM 针对所有数据集都使用 Adam 优化器进行 5 次迭代训练, 批大小设置为 16,  $L_2$  正则化的系数为  $10^{-5}$ , 学习率为  $2 \times 10^{-5}$ .

实验将准确性 (Acc) 和 F1 分数作为评估指标. 其中准确性是指在测试集中预测正确的样本数占整个样本集合总数的比率, F1 分数是一种常用的多分类评价指标. 对于标签类别为阳性、阴性的二分类, 给定特定数据集, 实际数据类别和预测类别有 4 种组合: 真阳性 TP (真实类别为阳性且预测为阳性), 真阴性 TN (真实类别为阴性且预测为阴性), 假阳性 FP (真实类别为阴性却错误的预测为阳性) 和假阴性 FN (真实类别为阳性却错误的预测为阴性). 二分类指标 F1 分数的计算过程为

$$p = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (8a)$$

$$r = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (8b)$$

$$F1 = 2 \frac{pr}{p + r} \quad (8c)$$

其中:  $n_{TP}$ ,  $n_{FP}$  和  $n_{FN}$  分别表示分类结果中 TP, FP 和 FN 的样本数量. 多分类任务 (例如情感分析属于三分类任务) 中多采用宏平均 F1 分数, 即将多分类问题看作多个二分类的问题, 对每个类别分别计算 F1 分数, 然后对多个 F1 求平均得到.

SAM 使用 PyTorch 来实现, 所有实验在一台安装 1 块 GeForce RTX 2080ti GPU 的 Linux 机器上进行.

### 3.2 对比模型

为了验证 SAM 的有效性, 实验将其与一系列强大的基线模型和当前最新模型进行了比较:

文献[12]提出了一种基于层次注意力的位置感知网络 (HAPN, hierarchical attention based position-aware network), 该网络引入位置嵌入来学习句子的位置感知表示, 并进一步生成目标的上下文表示.

文献[13]设计了一个交互式多任务学习网络 (IMN, interactive multi-task learning network), 该网络能够同时在 token 级别和文档级别学习目标提取任务和情感分类任务.

文献[14]使用双向 LSTM 捕获句子中的上下文信息. 提出了一种多粒度注意力网络 (MGAN, multi-granularity alignment network) 来生成表示, 以有效地捕获目标和上下文之间的交互.

文献[15]利用 LSTM 和注意力网络提取最终表示. 在训练期间, 它使用渐进式自监督的注意力学习方法来自动挖掘有用的注意力监督信息, 以完善注意力机制. 所提的注意力监督信息的转换网络 (TNet-AS, transformation network with attention supervision information) 在 Twitter 数据集上的表现尤其出色.

文献[4]直接在下流的面向目标情感分类任务上构建了预训练 BERT 句子对模型 (BERT-SPC, BERT-sentence pair classification). 它采用序列 “[CLS] + context\_tokens + [SEP] + target\_tokens + [SEP]” 作为句子对输入, 并且将 “[CLS]” 对应的表示馈送到全连接层以进行情感分类.

文献[5]采用两步微调程序来使预训练的 BERT 适应特定领域的任务: 首先使用语言模型任务在特定领域数据集上对预训练 BERT 模型进行微调, 然后在下流分类任务上对经过微调的模型进行训练. 它提出了在 Laptop 数据集上微调过的领域自适应模型 BERT-ADA-Lapt, 以及在 Restaurant 数据集上微调过的领域自适应模型 BERT-ADA-Rest, 这 2 个模型分别是目前 Laptop 数据集和 Restaurant 数据集上表现最好的模型.

### 3.3 实验结果分析

本节对比了 SAM 与其他现有模型的性能表现. 需要注意的是, BERT-ADA-Lapt 和 BERT-ADA-Rest 使用外部特定领域的数据集来微调 BERT 模型以获得更好的领域适应性, 而 SAM 则未使用外部数据集信息. 公平起见, 相应地进一步实现了 SAM-ADA-Lapt 模型和 SAM-ADA-Rest 模型, 它们具有与 SAM 完全相同的模型架构, 但是在 BERT 编码层使用了 BERT-ADA-Lapt 和 BERT-ADA-Rest 微调后的 BERT 权重. 比较结果如表 2 所示.

由表 2 可知, 所提的 SAM 优于大部分未使用外部领域适应数据集进行预训练的模型, 其中在 Laptop 和 Restaurant 数据集的 2 种指标上, SAM 相较于其他未使用外部数据集进行预训练的方法, 获得了更好的效果. 当使用额外的领域适应数据集时, SAM-ADA-Lapt/Rest 模型进一步提高了原始 BERT-ADA-Lapt/Rest 模型的效果, 甚至使用来自不同领

表 2 模型性能比较

%

模型	Laptop 数据集		Restaurant 数据集		Twitter 数据集	
	Acc	F1	Acc	F1	Acc	F1
HAPN	77.27	—	82.23	—	—	—
IMN	75.30	72.02	83.89	75.66	—	—
MGAN	76.21	71.42	81.49	71.48	74.62	73.53
TNet-AS	77.62	73.84	81.53	72.90	78.61	77.72
BERT-SPC	78.99	75.03	84.46	76.98	73.55	72.14
SAM	80.06	76.44	86.11	80.32	76.04	74.92
BERT-ADA-Lapt	79.19	74.18	85.51	78.09	74.13	72.83
SAM-ADA-Lapt	80.94	77.27	87.20	81.46	76.42	75.38
BERT-ADA-Rest	78.60	74.09	87.14	80.05	75.04	73.64
SAM-ADA-Rest	80.63	76.97	89.13	84.00	76.24	75.12

域数据集的预训练权重也能很好地泛化(在 Twitter 数据集上使用外部 Restaurant/Laptop 数据集预训练的 BERT 权重),这表明了所提出网络结构的有效性. 对比使用 BERT 的 SAM 和使用 LSTM 作为上下文信息提取器的 IMN 可以发现,使用学习了通用语言表征的预训练语言模型能够获得更好的信息抽取效果. 在同时引入了句法结构信息和领域知识信息后,SAM-ADA-Lapt 和 SAM-ADA-Rest 分别在 Laptop 和 Restaurant 数据集上取得了新的最好性能. 结果表明了 SAM 结构的有效性,以及同时引入多种外部知识能够学习到更好的目标实体情感表征.

3.4 消融实验

进一步研究 SAM 的各个不同组件对模型表现

的影响. 没有 GCN 层和信息聚合层的 BERT-SPC 模型<sup>[4]</sup>可以作为消融实验的原始基准模型. 在基准模型的基础上,可分别加入 SAM 中的 GCN 层和信息聚合层得到 2 个模型变体,用于研究 SAM 的不同部分的影响. 将 GCN 层添加上来,即在 BERT-SPC 模型的分层(完全连接层)之前插入 GCN 层,使用最终得到的“[CLS]”表示进行最终分类,这样就得到了相应新模型,命名为“BERT-SPC-GCN”. 类似地,通过将基于多头注意力(MHA,multi-head attention)的信息聚合层添加到基线模型中,来实现另一个新模型,命名为“BERT-SPC-MHA”. 将这些消融模型在 3 个数据集上进行了验证,并报告其准确性和 F1 得分. 消融实验结果如表 3 所示.

表 3 消融实验结果

%

模型	Laptop 数据集		Restaurant 数据集		Twitter 数据集	
	Acc	F1	Acc	F1	Acc	F1
BERT-SPC	78.99	75.03	84.46	76.98	73.55	72.14
BERT-SPC-GCN	79.87	75.97	85.68	79.03	75.92	74.82
BERT-SPC-MHA	79.75	76.03	85.50	79.23	76.18	74.91
SAM	80.06	76.44	86.11	80.32	76.04	74.92

由表 3 可知,添加 GCN 层以捕获句法信息可以提高数据集的准确性和 F1 分数的性能,从而验证了 GCN 层的有效性. 在添加信息聚合层后, BERT-SPC-MHA 在 3 个数据集上相较于基准模型的表现得分都更高,这表明了多头注意力机制在聚合序列信息方面的有效性. 在同时添加 GCN 层和信息聚合层时,就得到了提出的 SAM,并且在各个数据集上获得显著的性能提升,这表明了 SAM 结构设计的有效性.

4 结束语

面向目标的情感分析是细粒度情感分析的重要任务之一,旨在预测句子中给定目标实体的情感极性. 大多数现有工作都使用循环神经网络和注意力机制对目标的情感表示进行建模,而没有充分考虑文本的上下文信息、语法信息和领域知识等其他可以利用的信息. 笔者以此为切入点,从多个角度向 TSA 任务中引入外部信息,设计有效的模型 SAM,

并将 SAM 与领域自适应方法进行结合,向 TSA 任务引入多种外部信息,包括:预训练模型的通用上下文表征信息,文本的句法结构信息,以及领域知识信息,从而学习到增强的目标实体情感表示,提升模型在 TSA 任务上的表现效果. SAM 在 BERT 结构的基础上进行的设计并充分保有了 BERT 方便性和易用性. 其中的所有运算都可以通过矩阵乘法有效地实现,使其非常适合在 GPU 上进行批量处理计算和并行训练. 在多个公开数据集上的实验结果表明了该模型的有效性.

## 参考文献:

- [1] 张严, 李天瑞. 面向评论的方面级情感分析综述[J]. 计算机科学, 2020, 47(6): 194-200.  
Zhang Yan, Li Tianrui. Review of comment-oriented aspect-based sentiment analysis[J]. Computer Science, 2020, 47(6): 194-200.
- [2] Tang Duyu, Qin Bing, Feng Xiaocheng, et al. Effective LSTMs for target dependent sentiment classification[C]//COLING 2016: 26th International Conference on Computational Linguistics. Osaka: ACL, 2016: 3298-3307.
- [3] 刘全, 梁斌, 徐进, 等. 一种用于基于方面情感分析的深度分层网络模型[J]. 计算机学报, 2018, 41(12): 2637-2652.  
Liu Quan, Liang Bin, Xu Jin, et al. A deep hierarchical neural network model for aspect-based sentiment analysis[J]. Chinese Journal of Computers, 2018, 41(12): 2637-2652.
- [4] Song Youwei, Wang Jiahai, Jiang Tao, et al. Attention encoder network for targeted sentiment classification[C]//28th International Conference on Artificial Neural Networks (ICANN). Munich: Springer, 2019: 93-103.
- [5] Rietzler A, Stabinger S, Opitz P, et al. Adapt or get left behind: domain adaptation through BERT language model finetuning for aspect-target sentiment classification[C]//12th Language Resources and Evaluation Conference. Marseille: ELRA, 2020: 4933-4941.
- [6] Zhang Chen, Li Qiuchi, Song Dawei. Aspect-based sentiment classification with aspect-specific graph convolutional networks[C]//Conference on Empirical Methods in Natural Language Processing and 9th International Joint Conference on Natural Language Processing. Hong Kong: ACL, 2019: 4568-4578.
- [7] Chen Danqi, Manning C. A fast and accurate dependency parser using neural networks[C]//2014 Conference on Empirical Methods in Natural Language Processing. Doha: ACL, 2014: 740-750.
- [8] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE Computer Society, 2016: 770-778.
- [9] Xu Jingjing, Sun Xu, Zhang Zhiyuan, et al. Understanding and improving layer normalization[C]//Advances in Neural Information Processing Systems. Vancouver: NIPS, 2019: 4381-4391.
- [10] Pontiki M, Galanis D, Pavlopoulos J, et al. Semeval-2014 task 4: aspect based sentiment analysis[C]//8th International Workshop on Semantic Evaluation. Dublin: ACL&DCU, 2014: 27-35.
- [11] Dong Li, Wei Furu, Tan Chuanqi, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]//52nd Annual Meeting of the Association for Computational Linguistics. Baltimore: ACL, 2014: 49-54.
- [12] Li Lishuang, Liu Yang, Zhou Anqiao. Hierarchical attention based position-aware network for aspect-level sentiment analysis[C]//22nd Conference on Computational Natural Language Learning. Brussels: ACL, 2018: 181-189.
- [13] He Ruidan, Lee W S, Ng H T, et al. An interactive multi-task learning network for end-to-end aspect-based sentiment analysis[C]//57th Annual Meeting of the Association for Computational Linguistics. Florence: ACL, 2019: 504-515.
- [14] Li Zheng, Wei Ying, Zhang Yu, et al. Exploiting coarse-to-fine task transfer for aspect-level sentiment classification[C]//AAAI Conference on Artificial Intelligence. Palo Alto: AAAI, 2019: 4253-4260.
- [15] Tang Jialong, Lu Ziyao, Su Jinsong, et al. Progressive self-supervised attention learning for aspect-level sentiment analysis[C]//57th Annual Meeting of the Association for Computational Linguistics. Florence: ACL, 2019: 557-566.