

结合短语与句法特征的方面级情感分析

孙 涛^{1*}
SUN Tao

摘 要

当前方面级情感分析领域,句子中同时存在多种差异情感极性时,方面词的情感判别会受到情感噪声的影响。为此,文章提出了一种结合短语与句法特征的方面级情感分析方法(combining phrase and syntactic features for aspect-based sentiment analysis, Phrase-ABSA)。该框架分别由四个模块组成:语义模块、句法模块、构成模块、情感查询模块。其中,语义模块采用 BERT 模型和多头注意力学习丰富的上下文信息并进行单词表征;句法模块采用依存图和 GCN 获取单词之间的句法依赖关系;构成模块采用构成树和异构图神经网络(heterogeneous graph neural network, HGNN)学习单词之间的层次依赖关系,并进一步获取方面词的短语表征,避免情感噪声的影响;构成模块利用 Cross Attention 实现方面词短语的情感极性查询。在 Lap14、Rest14、Twitter、MAMS 公开数据集上进行实验验证,实验结果表明 Phrase-ABSA 的整体性能要优于基线模型。

关键词

方面级情感分析;情感噪声;句法依赖;层次依赖

doi: 10.3969/j.issn.1672-9528.2025.09.013

0 引言

随着互联网信息技术的快速发展,微博、知乎、推特等社交媒体平台每天会产生海量的用户评论信息。这些评论包含丰富的价值,例如,生产者-消费者领域,挖掘用户评论不仅能作为反馈信息给生产商改进产品缺陷,而且还能为消费者购买商品提供指导建议。如何有效地管理和挖掘互联网上海量的用户评论信息引起研究者的关注。其中,方面级情感分析技术(aspect based sentiment analysis, ABSA)^[1]能有效抽取评论中的方面词和判别对应的情感极性,被广泛应用于评论文本挖掘。ABSA 不仅是自然语言处理领域的一项研究任务,而且还是数据挖掘的一项重要课题。然而,当句子中同时存在多种情感极性时,ABSA 技术会受到句子结构的影响而面临情感噪声的问题。

针对上述问题提出一种融合短语与句法特征的方面级情感分析模型,称为 Phrase-ABSA。该方法利用构成树将句子划分为独立的短语,避免由句子结构带来的情感噪声带来的影响。此外,模型采用关系图注意力网络(relational Graph attention network, R-GAT)^[2]实现句法特征学习,并利用异构图神经网络(heterogeneous graph neural networks, HGNN)^[3]捕获句子的构成特征。最后,利用构成短语特征来查询特定方面词的情感极性。

1 相关工作

早期 ABSA 任务研究围绕注意力机制和循环神经网络来实现 ABSA 任务。采用循环神经网络模型来捕获文本序列之间的长距离依赖关系,然后利用 Attention 为单词分配权重,进而捕获关键单词的上下文情感。Tang 等人^[4]提出多跳的深度记忆网络模型,其利用 LSTM 对句子上下文进行表征,后设计多层注意力和线性捕获关键上下文。Fan 等人^[5]利用一种多粒度注意机制来捕捉方面与上下文之间的词级交互。虽然上述方法能有效地捕获文本的上下文信息,但是 LSTM 表征无法有效应对一词多义问题且 Attention 容易受到句子噪声影响。

近几年,随着 BERT^[6]预训练模型对文本的表征取得显著的性能提升,研究者尝试使用预训练方法来实现 ABSA 任务。该方法在上游任务中利用 BERT 实现单词的表征,然后在下游任务采用神经网络实现方面词情感判别。Sun 等人^[7]为方面词构建一个辅助句子,将 ABSA 任务转化为句子对分类任务。Wu 等人^[8]提出一种上下文引导 BERT 的方法,其能有效地为不同上下文分配注意力权重。上述方法基于 BERT 预训练模型能有效解决一词多义问题并获得更准确的语义表征,但是上述方法以端到端的形式将句子转化为序列表征,而忽略句子的结构特征。

有研究者提出利用句法知识与图神经网络的方法。依

1. 河北华北石油天成实业集团有限公司 河北任丘 062552

存句法关系能描述单词之间的依赖关系进而构建句子的图结构,结合 GCN 能有效实现节点之间的特征交互。Li 等人^[9]设计句法图和语义图结构的对偶图框架,其中利用注意力分配权重的词向量作为语义信息以及依存关系作为句法信息。Tian 等人^[10]提出了一种类型感知图卷积网络,该网络中使用 Attention 区分句法图中不同边关系。上述研究者利用句法知识与图神经网络能有效捕获句子的语义和结构之间的依赖关系,但是句子中存在的情感噪声会影响模型的性能。

综上所述,BERT 预训练模型能更准确的表征语义,而图神经网络能有效地捕获句子的结构特征信息,但会受到句子中情感噪声的影响。针对上述问题,提出一种融合短语与句法特征的方面级情感分析框架 Phrase-ABSA,其利用构成树将句子划分为多个独立短语,进而避免不同情感噪声带来的影响。

2 模型概述

Phrase-ABSA 框架的整体结构如图 1 所示,其中主要包括四个模块:语义模块、句法模块、构成模块、情感查询模块。




图 1 Phrase-ABSA 框架的整体结构

首先,语义模块利用 BERT 预训练模型将单词转化为词向量表征,然后采用多头注意力机制为词向量分配注意力权重。句法模块利用解析器计算单词之间的依存关系,并进一步构建为句法关系图(包含边特征),然后利用 R-GAT 模型捕获图中节点之间的依赖关系和学习句子的结构特征。构成

特征模块利用解析器将句子转化为构成树,并利用异构图学习句子的层次特征,最后依据构成树的层次划分将句子划分为多个独立的短语。情感查询模块利用交叉注意力机制实现方面词所在短语对全局语义信息的查询,并最终实现特定方面词的情感极性判别。

2.1 语义模块

语义模块首先使用 BERT 预训练模型将单词转化为动态词向量表征,然后使用多头注意力机制为词向量分配相应的权重,以此有利于模型关注重要单词。当输入句子 $X = \{w_1, w_2, \dots, w_n\}$, 语义模块的详细计算过程为:

$$H^w = \text{BERT}(X) \quad (1)$$

$$\text{head} = \text{Softmax}\left(\frac{(H^w \cdot W^Q) \cdot (H^w \cdot W^K)^T}{\sqrt{d_k}}\right)(H^w \cdot W^V) \quad (2)$$

$$H^h = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^m \quad (3)$$

$$H^{\text{sem}} = \text{MLP}(H^h) \quad (4)$$

式中: $H^w \in \mathbb{R}^{n \times h}$ 为词向量表征; $W^Q, W^K, W^V, W^m \in \mathbb{R}^{h \times h}$ 为可训练的权重矩阵; h 为多头注意力的头数; $H^h \in \mathbb{R}^{n \times h}$ 为分配注意力权重的特征向量; $H^{\text{sem}} \in \mathbb{R}^{n \times d}$ 为句子语义特征向量。

2.2 句法模块

句法模块用于学习句子的结构特征。首先,使用 BiAffine 解析器计算单词之间的依存关系,该工具由斯坦福大学研发的句法解析工具,能准确地预测算两个单词之间的依存关系标签,例如 nn、nsubj、cop 等是表示依存关系标签。然后,使用深度图库工具(deep graph library, DGL)将依存关系构建为句法关系图结构 $G = (N, E, R)$, 其中 N 表示图的节点; E 表示两个节点之间边; R 表示节点之间的依存关系,用于衡量边的权重。最后,使用 R-GAT 来捕获单词之间的句法依赖关系,其计算原理如图 2 所示。




图 2 R-GAT 计算原理

相比图注意力神经网络而言, R-GAT 在聚合邻居节点信息不仅考虑注意力权重,而且还考虑关系权重的影响,详细的计算为:

$$h_{att_i}^{l+1} = \left\| \sum_{j \in N_i}^K a_{ij}^{lk} \cdot W_k^l \cdot h_j^l \right\| \quad (5)$$

$$h_{rel_i}^{l+1} = \left\| \sum_{j \in N_i}^K \beta_{ij}^{lk} \cdot W_k^l \cdot h_j^l \right\| \quad (6)$$

$$x_i^{l+1} = h_{att_i}^{l+1} \left\| h_{rel_i}^{l+1} \right\| \quad (7)$$

$$h_i^{l+1} = \text{relu}(W_{l+1} \cdot x_i^{l+1} + b_{l+1}) \quad (8)$$

式中： K 表示多头注意力的头数； a_{ij}^{lk} 表示注意力权重， β_{ij}^{lk} 表示关系权重由关系标签表征向量计算而来； h_j^l 表示邻居节点特征向量； $\left\| \right\|_{k=1}^K$ 表示多头注意力的拼接操作。

给定输入句子 $X = \{w_1, w_2, \dots, w_n\}$ ，句法模块的详细计算过程为：

$$(w_i, \text{res}_i, w_j) = \text{BiAffine}(W) \quad (9)$$

$$G_{\text{syntax}} = \text{DGL}(w_i, \text{res}_i, w_j) \quad (10)$$

$$H^{\text{syntax}} = R - \text{GAT}(G_{\text{syntax}}, H^w) \quad (11)$$

式中： res_i 表示单词之间的依存关系； G 表示句法关系图结构；

$H^{\text{syntax}} \in \mathbf{R}^{n \times d}$ 表示输出的句法特征隐藏向量。

2.3 构成模块

构成模块的主要用于学习句子的层次结构并将句子划分为短语级别，其处理过程如图3所示。




图3 构成特征模块结构

首先，利用 Stanford CoreNLP 解析工具将句子解析为构成树，其中“S, NP, VP, ADJP”为句子的构成成分标签，S为包含主语和谓语的完整短语，NP为名词短语，VP为动词短语，ADJP为形容词短语。然后，使用 DGL 工具将构成树转化为图结构表示，并利用 HGNN 模型学习句子的层次信息。

依据构成树的解析结果还能进一步地将完整的句子划分为独立的短语。具体而言，采用广度优先算法遍历树节点，并获取当前 S 节点下面的所有叶子节点。当给定输入句子 $W = \{w_1, w_2, \dots, w_n\}$ 构成特征模块详细计算过程为：

$$T_{\text{const}} = \text{StanfordCoreNLP}(W) \quad (12)$$

$$G_{\text{const}} = \text{DGL}(T_{\text{const}}) \quad (13)$$

$$H^{\text{const}} = \text{HGNN}(G_{\text{const}}, H^w, H^T) \quad (14)$$

$$\{S_1, \dots, S_i\} = \text{GetNode}(\text{BFS}(T_{\text{const}}, S)) \quad (15)$$

$$H_i^S = \text{Get}(S_i, H^{\text{const}}) \quad (16)$$

式中： T_{const} 为 Stanford CoreNLP 计算得到的构成树结构， H^w 为单词向量表征； H^T 为构成标签的向量表征；BFS为广度优先搜索算法；GetNode为获取当前节点的叶子节点； $S_i = \{w_k, \dots, w_l\}$ ， $k, l \in [1, n]$ 为句子划分的多个短语，其中 i 为段落数量； $H_i^S \in \mathbf{R}^{(l-k) \times d}$ 为最终的段落特征向量。

2.4 情感查询模块

首先，将语义向量句法向量进行拼接融合，并使用一维最大池化处理，以保留关键特征信息和降低维度。然后，在情感查询模块利用交叉注意力（Cross Attention）实现方面词短语对全局特征的情感查询。然后，使用全连接层来计算隐藏特征向量的情感极性概率分布。详细的计算过程为：

$$H^f = \text{MaxPooling}(H^{\text{sem}}, H^{\text{syntax}}) \quad (17)$$

$$\tilde{H} = \text{CrossAttention}(H_i^S, H^f, H^f) \quad (18)$$

$$H^O = \text{LayerNorm}(\tilde{H} + H_i^S) \quad (19)$$

$$y' = \text{Softmax}(\text{FC}(H^O)) \quad (20)$$

式中：MaxPooling为窗口大小为2的最大池化计算； $H^f \in \mathbf{R}^{n \times d}$ 为融合语义和句法的特征向量； $H_i^S \in \mathbf{R}^{(l-k) \times d}$ 为方面词对应段落的向量； y' 为情感极性的概率分布。

模型训练过程中采用交叉熵损失函数计算最终的损失值，其计算为：

$$\ell = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(y'_{i,c}) \quad (21)$$

式中： N 为训练批量大小； $C = \{\text{Positive}, \text{Neutral}, \text{Negative}\}$ 为类别数量； $y_{i,c}$ 为第 i 个样本中第 c 个类别的真实标签； $y'_{i,c}$ 为第 i 个样本预测为第 c 类的概率。

3 实验

3.1 数据集与实验环境

为了验证 Phrase-ABSA 框架的有效性，实验采用 SemEval 2014 task 提供的官方数据集，其中包括 Lap14 和 Rest14 分别来自笔记本和餐厅两个领域。此外，还在 Twitter 和 MAMS 两个数据集上验证模型的鲁棒性。Twitter 数据集来自网络在线评论，而 MAMS 数据由多个方面词的长句子组成。实验数据集的详细信息如表1所示。

表 1 实验数据集

Datasets		Positive	Neutral	Negative
Lap14	Train	994	464	870
	Test	341	169	128
Rest14	Train	2 164	637	807
	Test	728	196	196
Twitter	Train	1 507	1 528	3 016
	Test	172	169	336
MAMS	Train	3 380	5 042	2 764
	Test	400	607	329

实验采用的硬件环境为显卡为 RTX 4060ti 与 16 GB 显存, Intel i9 处理器。软件环境为 Win10 操作系统, pyTorch 版本 1.0.2, Transformers 版本为 4.30.2 和 3.8 的 Python 环境。

模型参数设置, BERT 模型输出的隐藏层维度为 768, 多头注意力机制采用 12 头, 通过参数实验来寻找 R-GAT 和 HGNN 的最优层数。模型训练设置为迭代次数为 50 次, 批次大小设置为 64, 学习率为 $1e-5$, 优化器为 Adam。

实验的评估指标为机器学习任务中常用的准确率 (Accuracy) 和 F_1 值 (F_1 -score)。

3.2 基线模型

实验采用的基线详细描述如下:

(1) R-GAT: 对 GAT 模型进行扩展, 并提出关系图注意力网络, 使用注意力权重和依存关系权重来聚合节点邻居特征。

(2) SSEGCN^[12]: 设计了一种方面级感知注意力机制来增强图节点表征, 并利用 GCN 学习句法依赖关系。

(3) dotGCN^[13]: 将依存关系转化为方面词作为更节点的离散意见归纳树结构, 并利用 GCN 和奖励机制来捕获方面词的情感极性。

(4) TF-BERT^[14]: 提出了一种跨度级别表征, 表格填充方法能有效考虑多词术语情感表达一致性。

3.3 主要实验结果

表 2 展示 Phrase-ABSA 与基线模型在四种数据集上取得的准确率和 F_1 值。通过观测对比实验, 得到以下结果:

表 2 主要实验结果

Models	Lap14		Rest14		Twitter		MAMS	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
R-GAT	78.21	74.07	86.60	81.35	76.15	74.88	82.93	82.75
SSEGCN	81.01	77.96	<u>87.31</u>	81.09	77.40	76.02	—	—
dotGCN	81.03	78.10	86.16	80.49	<u>78.11</u>	<u>77.00</u>	<u>84.95</u>	<u>84.44</u>
TF-BERT	<u>81.80</u>	<u>78.46</u>	87.09	81.45	77.84	76.23	—	—
Phrase-ABSA	82.12	78.85	87.34	<u>80.86</u>	78.45	77.36	85.24	84.82

(1) 基于 BERT 预训练的 BERT-SPC 要明显优于基于注意力机制的 RAM。这表明 BERT 具有更准确的语义表征能力, 进而提升模型整体性能。

(2) 融合句法知识与 GCN 模型能有效提升模型的性能表现。R-GAT、DualGCN、T-GCN、SSEGCN 这些方法在 BERT 模型的基础之上探索依存句法关系, 并利用 GCN 学习句法特征。这表明结合语义与句法能有效地捕获单词的句法特征。

(3) Phrase-ABSA 模型在四种数据集上的性能明显优于基线模型, 特别是在 Twitter 和 MAMS 数据集上准确率分别提升了 0.61% 和 0.29%。这表明模型在处理网络在线评论和复杂长句子上有优势。Phrase-ABSA 不仅采用 R-GAT 网络来学习句法特征, 而且还利用构成树将句子划分为多个短语表征。长句子中蕴含多个方面词容易产生情感噪声的影响, 而模型能利用方面词所在短语来查询情感极性。

然而, 模型在 Rest14 数据集上准确率与基线模型的差距不太明显, 而 F_1 值略逊于基线模型。这可能是因为 Rest14 数据集包含较多的简短句子影响模型中构成树的短语划分, 进而错误地查询情感极性。

3.4 消融实验

为验证 Phrase-ABSA 中各模块对模型整体性能的影响, 在四种数据集上设计消融实验。其中“w/o 构成模块”表示移除构成模块, 并使用自注意力实现情感查询。“w/o 句法模块”表示移除句法模块仅使用语义模块特征信息。“w/o R-GAT”使用 GCN 来替换 R-GAT 模型。

实验结果如表 3 所示, 通过观测对比分析可以发现这些组件均能提升模型的整体性能。句法模块对模型的整体性能影响最大, 其次是构成模块。

表 3 消融实验结果

Models	Lap14		Rest14		Twitter		MAMS	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
Phrase-ABSA	82.12	78.85	87.34	80.86	78.45	77.36	85.24	84.82
w/o 构成模块	80.42	77.39	85.50	78.22	75.42	74.57	82.71	81.23
w/o 句法模块	79.85	75.34	84.10	77.66	75.51	74.23	82.42	80.76
w/o R-GAT	81.88	77.27	86.32	80.18	77.37	76.54	84.60	83.75

值得注意的是移除构成模块, 模型在 Twitter 和 MAMS 两种数据集上性能下降比较明显。此外, R-GAT 和 MHA 也对模型有提升作用, 这表明 R-GAT 相比 GCN 更能有效地捕获图中的重要节点和边的关系。

4 结论

针对当前方面级情感分析容易受到句子中情感噪

声的影响,提出一种结合短语与句法特征的方面级情感分析方法 Phrase-ABSA。首先,在语义模块中采用 BERT 和多头注意力捕获语义信息,并在句法模块中采用依存图结构和 GCN 模型学习句子的句法特征。其次,设计构成模块解析句子的层次,并利用 HGNN 学习单词之间层次关系。最后,在情感查询模块中利用 Cross Attention 来捕获方面词短语情感极性。实验结果表明,在四种基准数据集上模型的整体性能要明显优于基线模型,基于构成树的方面词短语划分能有效避免情感噪声影响。

参考文献:

- [1] 陈壮,钱铁云,李万理,等.低资源方面级情感分析研究综述[J].计算机学报,2023,46(7):1445-1472.
- [2] WANG K, SHEN W Z, YANG Y Y, et al. Relational graph attention network for aspect-based sentiment analysis[EB/OL].(2024-04-26)[2025-04-15].<https://doi.org/10.48550/arXiv.2004.12362>.
- [3] ZHANG C X, SONG D J, HUANG C, et al. Heterogeneous graph neural network[C]/KDD'19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:ACM,2019: 793-803.
- [4] TANG D Y, QIN B, LIU T. Aspect level sentiment classification with deep memory network[C]/Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Brussels:ACL,2016: 214-224.
- [5] FAN F F, FENG Y S, ZHAO D Y. Multi-grained attention network for aspect-level sentiment classification[C]/Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018: 3433-3442.
- [6] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding[C]/Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, volume 1. Brussels: ACL, 2019: 4171-4186.
- [7] SUN C, HUANG L Y, QIU X P. Utilizing BERT for aspect-based sentiment analysis via constructing auxiliary sentence[C]/Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Brussels: ACL, 2019: 380-385.
- [8] WU Z X, ONG D C. Context-guided bert for targeted aspect-based sentiment analysis[J].Proceedings of the AAAI conference on artificial intelligence,2021, 35(16): 14094-14102.
- [9] LI R F, CHEN H, FENG F X, et al. Dual graph convolutional networks for 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. Brussels: ACL, 2021: 6319-6329.
- [10] TIAN Y H, CHEN G M, SONG Y. Aspect-based sentiment analysis with type-aware graph convolutional networks and layer ensemble[C]/ Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Brussels: ACL, 2021: 2910-2922.
- [11] TSAI Y H H, BAI S J, LIANG P P, et al. Multimodal transformer for unaligned multimodal language sequences[C]/ Proceedings of the conference. Association for computational linguistics. Brussels: ACL, 2019:6558-6569.
- [12] ZHANG Z, ZHOU Z L, WANG Y N. SSEGCN: syntactic and semantic enhanced graph convolutional network for aspect-based sentiment analysis[C]/Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Brussels: ACL, 2022: 4916-4925.
- [13] CHEN C H, TENG Z Y, WANG Z Q, et al. Discrete opinion tree induction for aspect-based sentiment analysis[C]/Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Brussels: ACL, 2022: 2051-2064.
- [14] ZHANG M, ZHU Y X, LIU Z, et al. Span-level aspect-based sentiment analysis via table filling[C]/Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics . Brussels: ACL, 2023: 9273-9284.

【作者简介】

孙涛(1974—),通信作者(email:tc_st@petrochina.com.cn),男,陕西乾县人,本科,工程师,研究方向:智能信息处理、文本数据挖掘。

(收稿日期:2025-03-25 修回日期:2025-09-03)