

文章编号: 2095-2163(2023)08-0150-06

中图分类号: TP391.1

文献标志码: A

# 基于 Self-Attention 的方面级情感分析方法研究

蔡 阳

(浙江理工大学 计算机科学与技术学院(人工智能学院), 杭州 310018)

**摘要:** 针对传统模型在细粒度的方面级情感分析上的不足,如 RNN 会遇到长距离依赖的问题,且模型不能并行计算;CNN 的输出通常包含池化层,特征向量经过池化层的运算后会丢失相对位置信息和一些重要特征,且 CNN 没有考虑到文本的上下文信息。本文提出了一种 Light-Transformer-ALSC 模型,基于 Self-Attention 机制,且运用了交互注意力的思想,对方面词和上下文使用不同的注意力模块提取特征,细粒度地对文本进行情感分析,在 SemEval2014 Task 4 数据集上的实验结果表明本文模型的效果优于大部分仅基于 LSTM 的模型。除基于 BERT 的模型外,在 Laptop 数据集上准确率提高了 1.3%~5.3%、在 Restaurant 数据集上准确率提高了 2.5%~5.5%;对比基于 BERT 的模型,在准确率接近的情况下模型参数量大大减少。

**关键词:** 方面级情感分析; Self-Attention; Transformer; SemEval-2014 Task 4; BERT

## Research on aspect-level sentiment analysis method based on Self-Attention

CAI Yang

(School of Computer Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

**[Abstract]** To address the shortcomings of RNN and CNN-based models for fine-grained aspect-level sentiment analysis, which are RNNs encounter the problem of long-distance dependency and the models cannot be computed in parallel; meanwhile, there exist the following problems that the output of CNNs usually contains pooling layers, and the feature vectors lose relative position information and some important features after the operation of pooling layers, and CNNs do not take into account the contextual information of the text. This paper proposes a Light-Transformer-ALSC model, based on the Self-Attention mechanism, and uses the idea of interactive attention to extract features using different attention modules for aspect words and contexts to fine-grained sentiment analysis of the text. The model in the paper outperforms most of the LSTM-only based models. In addition to the BERT-based model, the accuracy is improved by 1.3%~5.3% on the Laptop dataset and 2.5%~5.5% on the Restaurant dataset; compared with the BERT-based model, the number of model parameters is greatly reduced with a similar accuracy.

**[Key words]** aspect-level sentiment analysis; Self-Attention; Transformer; SemEval-2014 Task 4; BERT

## 0 引言

互联网的迅速发展使各家电商和社交平台拥有了庞大的用户量,不同用户在平台中活动的同时产生了大量的评论信息。在这些评论信息中,蕴含着巨大的社会和商用价值,对其进行情感分析以把握用户的情感倾向,可以有助于舆情处理,让商业公司快速分析产品质量并做出改进,也能辅助其进行商业决策。传统的情感分析方法中,循环神经网络(Recurrent Neural Network, RNN)有着时序性的特点,无法并行计算,且不能直接提取句子的上下文语义特征;卷积神经网络(Convolutional Neural Network, CNN),在句子的全局特征表达上表现效果

欠佳;而自注意力机制(Self-Attention)能很好地解决上述问题,不仅能够做并行计算,在提取句子上下文特征上也展现出了强大的能力,因此本文将基于注意力机制搭建模型来展开研究,用来解决方面级文本评论情感分析问题。

方面级情感分析是判断文本对于给定方面表现出的情感极性,2016年,Wang等学者<sup>[1]</sup>提出一种用于方面级情感分析的模型,通过将方面词向量和输入词向量及 LSTM 隐层向量拼接的方式加入方面词的影响,当不同的方面被输入时,该机制能集中在句子的不同部分,在 SemEval 2014 数据集上的实验结果达到当时最先进的性能。2018年,Huang等学者<sup>[2]</sup>提出一种 AOA(Attention-Over-Attention)网

作者简介:蔡 阳(1996-),男,硕士研究生,主要研究方向:自然语言处理。

通讯作者:蔡 阳 Email:caiyang\_cy@qq.com

收稿日期:2022-09-21

哈尔滨工业大学主办 ◆ 专题设计与应用

络,对方面和句子进行联合建模,并明确地捕捉方面和上下文句子之间的交互信息,在 laptop 和 restaurant 数据集上的实验结果证明该网络性能优于之前的基于 LSTM 的模型。2019 年, Liu 等学者<sup>[3]</sup>提出门控交替神经网络(Gated Alternate Neural Network, GANN),该模型中有一个特殊模块 GTR (Gate Truncation RNN)被设计用于学习情感线索表示。2019 年,Zhang 等学者<sup>[4]</sup>针对 LSTM 网络在一定程度上忽略了方面词在句子中的句法依赖性问题,提出了一种邻近加权卷积网络,在 SemEval 2014 数据集上的实验结果证明了该方法的有效性。2020 年,Xu 等学者<sup>[5]</sup>提出一种多注意力网络(Multi-Attention Network, MAN),MAN 使用级内和级间注意机制来解决方面术语包含若干词的问题,实验证明 MAN 性能优于基准模型。2020 年,Liu 等学者<sup>[6]</sup>提出了一种新型记忆网络 ReMemNN (Recurrent Memory Neural Network),针对注意机制中弱交互的问题,设计了一种多元素注意机制,以产生强大的注意权重和更精确的方面依赖的情感表示,实验结果表明 ReMemNN 的优秀性能与语言无关,与数据集类型无关。2020 年,Xu 等学者<sup>[7]</sup>提出了 DomBERT (Domain-oriented BERT)模型,在方面情感分析任务中取得了较好的效果。2020 年,冉祥映<sup>[8]</sup>将语义注意力机制和基于注意力机制的方面融合,提出了 HAN (Hierarchical Attention Network)模型。2020 年,Cai 等学者<sup>[9]</sup>为了捕获显式和隐式方面术语的情感极性,提出了一种分层图卷积模型 Hier-GCN (Hierarchical Graph Convolutional Network),该模型在 4 个基准测试中取得了当时的最佳结果。2020 年,Gan 等学者<sup>[10]</sup>提出 SA-SDCCN (Sparse Attention based Separable Dilated Convolutional Neural Network)模型用于目标情感分析,在 3 个基准数据集上进行实验,结果表明其并行性更高的同时降低了计算成本,取得了较先进的性能。2020 年,Zhou 等学者<sup>[11]</sup>提出一种基于句法和知识的图卷积网络 SK-GCN (Syntax- and Knowledge-based Graph Convolutional Network),通过 GCN (Graph Convolutional Network)利用句法依赖树和常识知识。2021 年,Tian 等学者<sup>[12]</sup>提出了一种通过类型感知图卷积网络 T-GCN (Type-aware Graph Convolutional Networks)来显式利用方面情感分析依赖类型的方法,在 6 个英语数据集上取得了当时最先进的性能。2021 年,Yadav 等学者<sup>[13]</sup>提出了一种基于注意力机制的无位置嵌入模型用于方面级情感

分析,在数据集 restaurant 14、laptop 14、restaurant 15 和 restaurant 16 上进行实验,最终准确率分别达到 81.37%、75.39%、80.88% 和 89.30%。2021 年,Dai 等学者<sup>[14]</sup>首先在方面情感分析任务的几种流行模型上比较了预训练模型的诱导树和依赖解析树,然后通过实验证明纯基于 RoBERTa (A Robustly Optimized BERT Pretraining Approach)的模型可以取得接近之前 SOTA (State-Of-The-Art)性能的结果。

本文提出了用于方面级情感分析 Light-Transformer-ALSC 模型,运用了交互注意力的思想,对方面词和上下文使用不同的注意力模块提取特征,细粒度地对文本进行情感分析,并在 SemEval-2014 Task 4 数据集上进行实验以证明其有效性。

## 1 网络结构

### 1.1 Light-Transformer-ALSC 网络结构

为了更好地捕获方面词对文本情感极性的影响,本文模型将方面词向量和文本上下文向量分别用不同的注意力模块建模,对建模后的特征向量求和平均作为计算下一轮注意力的查询向量(Query, Q),具体来说,对上下文特征向量的注意力计算使用方面词向量的 Query,反之亦同。经过此轮注意力计算后将 2 个向量作拼接,然后通过 Softmax 计算情感极性。为了加速模型的训练并缓解训练数据不足的问题,本文模型中使用 Glove 预训练词向量,预训练的词向量已经一定程度上学习到了单词之间的语义信息,可以加速模型的收敛过程,模型的整体结构如图 1 所示。

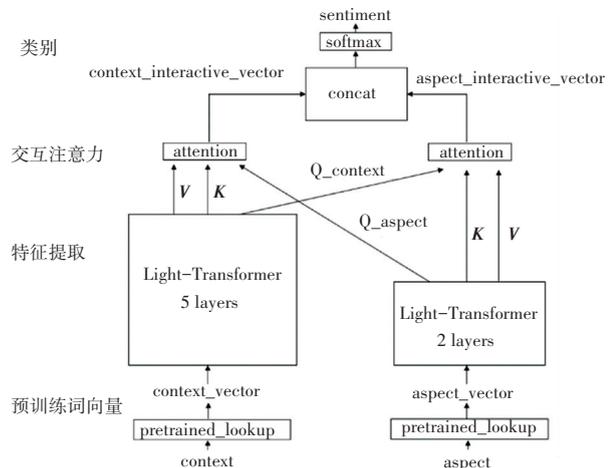


图 1 Light-Transformer-ALSC 网络结构图

Fig. 1 Structure of Light-Transformer-ALSC network

模型主要包括 Light-Transformer 特征提取器、交互注意力、以及特征拼接三大模块。

## 1.2 Light-Transformer 特征提取器

经过词嵌入处理的文本向量首先会经过特征提取模块初步提取特征,方面词向量和上下文向量由2个独立的 Light-Transformer 处理, Light-Transformer 基于 Transformer 模型并对其进行改造,取消 Decoder 模块,减少 Encoder 模块至5层,并对参数量做一定优化。其结构如图2所示。

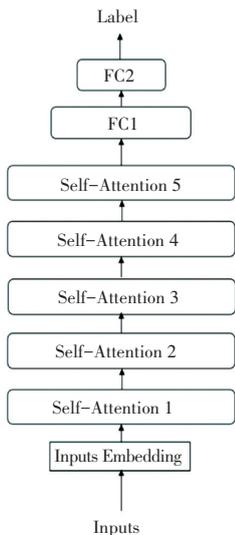


图2 Light-Transformer 结构

Fig. 2 The structure of Light-Transformer

模型的特征提取能力主要来自于自注意力模块,是由相同的5层堆叠在一起组成。每一层又包括一个多头自注意力子层和一个前馈神经网络子层,每一子层都用残差连接和层归一化增强网络的稳定性,自注意力子层由点积注意力机制(Scaled Dot-Product Attention)和多头注意力机制(Multi-Head Attention)组成。首先,初始化查询矩阵(Query,  $\mathbf{Q}$ )、键矩阵(Key,  $\mathbf{K}$ )和值矩阵(Value,  $\mathbf{V}$ )。每一组  $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$  被称为一个头(head),可以有多个,这也是多头注意力名称的来源。假设输入矩阵为  $\mathbf{X}$ , 则上述矩阵可由式(1)进行计算:

$$\begin{aligned} \mathbf{Q} &= \mathbf{X}\mathbf{W}^Q \\ \mathbf{K} &= \mathbf{X}\mathbf{W}^K \\ \mathbf{V} &= \mathbf{X}\mathbf{W}^V \end{aligned} \quad (1)$$

点积注意力机制计算见式(2):

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (2)$$

多头注意力机制计算见式(3):

$$\text{Mhead} = \text{Concat}(\text{head}_1, \dots, \text{head}_h)\mathbf{W}^O \quad (3)$$

其中,  $\text{head}_i$  的计算见式(4):

$$\text{head}_i = \text{Attention}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (4)$$

前馈神经网络子层由2层全连接神经网络组成,作用是将向量再投影到一个更高维度的空间,在高维空间里可以更方便地提取需要的信息,提取信息后再还原为原来的空间,计算公式具体如下:

$$\text{FFN}(x) = \max(0, x\mathbf{W}_1 + b_1)\mathbf{W}_2 + b_2 \quad (5)$$

经过注意力机制学习后的特征向量会再通过2个全连接层,以获取情感极性。这一步的目的是将注意力机制学习到的特征向量逐步降维,如式(6)所示:

$$\text{FFN}(x) = f(wx + b) \quad (6)$$

## 1.3 交互注意力

模型到目前为止,方面词和上下文向量都还是相互独立的,尚未对彼此产生影响。为了在建模上下文向量时考虑到方面词的作用,同时在建模方面词向量时引入上下文的作用,这里使用了一种交互注意力机制。上下文向量的交互注意力  $c_{att}$  和方面词向量的交互注意力  $a_{att}$  的计算分别见式(7)、式(8):

$$c_{att} = \sum_{i=1}^n \alpha_i h_c^i \quad (7)$$

$$a_{att} = \sum_{i=1}^m \beta_i h_a^i \quad (8)$$

其中,  $h_c^i$ 、 $h_a^i$  分别是上下文词向量和方面词向量经由2个 Light-Transformer 结构提取的中间向量,  $\alpha_i$ 、 $\beta_i$  是注意力权重,  $\alpha_i$  的计算公式可写为:

$$\alpha_i = \frac{\exp(\gamma(h_c^i, \mathbf{Q}_{aspect}))}{\sum_{j=1}^n \exp(\gamma(h_c^j, \mathbf{Q}_{aspect}))} \quad (9)$$

其中,  $\mathbf{Q}_{aspect}$  的计算可按式(10)来进行:

$$\mathbf{Q}_{aspect} = \sum_{i=1}^n h_a^i / n \quad (10)$$

研究推得的  $\gamma(h_c^i, \mathbf{Q}_{aspect})$  的计算公式如下:

$$\begin{aligned} \gamma(h_c^i, \mathbf{Q}_{aspect}) &= \\ \tanh(h_c^i \cdot \mathbf{w}_c \cdot \mathbf{Q}_{aspect}^T + b_c) \end{aligned} \quad (11)$$

这里,  $\beta_i$  的计算与  $\alpha_i$  相似。

## 1.4 特征拼接

将经过交互注意力计算后的上下文向量和方面词向量作拼接,然后通过  $\text{Softmax}$  函数计算情感极性,拼接示意如图3所示。

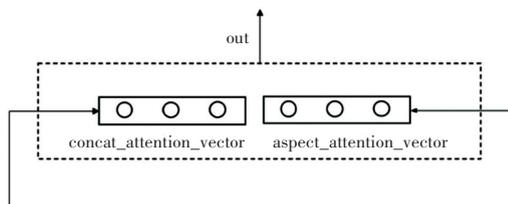


图3 特征拼接示意图

Fig. 3 Schematic diagram of feature splicing

## 2 实验数据

模型在 SemEval2014 Task4 数据集上做评估,该数据集是方面级情感分析领域最流行的数据集,其中包含 Laptop 和 Restaurant 两个不同类型的数据,数据集中共标注有 4 种情感类型,分别是:积极(positive)、消极(negative)、中立(neutral)以及冲突(conflict),对数据集中方面项的统计见表 1。

由表 1 可以看出,情感极性为“冲突”的样本占比很少,会导致样本失衡,因此不考虑情感极性为“冲突”的样本。接下来对数据集进行处理,处理完毕后的部分数据集如图 4 所示,其中 *polarity* 的值

为 1 表示积极,为 -1 表示消极,为 0 表示中立。

表 1 方面项统计信息

**Tab. 1 Statistical information on aspects**

统计信息	Restaurant 训练集	Restaurant 测试集	Laptop 训练集	Laptop 测试集
积极	2 164	728	994	341
中立	637	196	464	169
消极	807	196	870	128
冲突	91	14	45	18
总数	3 699	1 134	2 373	654
去除冲突	3 608	1 120	2 328	638

Id	text	category	polarity
0 3121	But the staff was so horrible to us.	service	-1
1 2777	To be completely fair, the only redeeming fact...	food	1
2 2777	To be completely fair, the only redeeming fact...	anecdotes/miscellaneous	-1
3 1634	The food is uniformly exceptional, with a very...	food	1
4 2534	Where Gabriela personally greets you and recomm...	service	1

图 4 部分 Restaurant 训练集

Fig. 4 Part of the Restaurant training set

## 3 实验与分析

### 3.1 实验环境

本文的实验环境见表 2。

表 2 实验环境

Tab. 2 Experimental environment

类型	具体信息
操作系统	CentOS Linux release 7.9.2009 (Core)
处理器	Intel(R) Core(TM) i9-7900X CPU @ 3.30 GHz
显卡	NVIDIA Corporation TU102 [ GeForce RTX 2080 Ti Rev. A ] (rev a1)
深度学习框架	TensorFlow-GPU (2.0.0)
代码编辑	PyCharm 2019.3.3 (Professional Edition)
编程语言	Python (3.6.12)
包管理工具	Anaconda (4.8.3)

### 3.2 评价指标

本文使用准确率指标对实验结果进行评估,首先给出三分类的混淆矩阵见表 3。

表 3 混淆矩阵

Tab. 3 Confusion matrix

	预测为正	预测中立	预测为负
实际为正	<i>TP</i>	<i>FUP</i>	<i>FNP</i>
实际中立	<i>FPU</i>	<i>TU</i>	<i>FNU</i>
实际为负	<i>FPN</i>	<i>FUN</i>	<i>TN</i>

由表 3 可以得出,准确率可由式(12)来计算求出:

$$acc = \frac{TP + TU + TN}{TOTAL} \quad (12)$$

其中, *TOTAL* 为表 3 中所有结果的累加。

### 3.3 实验结果分析

为了验证本文模型的有效性,将其在数据集上的实验结果与其他研究者提出的模型和基线模型进行比较,见表 4。本次研究中选择的对比模型详见如下。

表 4 模型对比

Tab. 4 Comparison of the models

模型	Accuracy	
	Restaurant	Laptop
TD-LSTM	0.756	0.681
AT-LSTM	0.762	0.689
ATAE-LSTM	0.772	0.687
IAN	0.786	0.721
BERT	0.815	0.753
HAN	0.802	0.756
BERT-LSTM	0.822	0.753
Light-Transformer-ALSC	0.811	0.734

(1)TD-LSTM 与 TC-LSTM 模型<sup>[15]</sup>:TD-LSTM 对目标词的上下文分别建模,具体来说,使用 2 个 LSTM,一个 LSTM 提取输入文本第一个词到目标词的特征信息,一个 LSTM 提取目标词到输入文本最后一个词的特征信息,将建模后的向量拼接再进

行分类。TC-LSTM 在 TD-LSTM 的基础上于输入端加入了方面词的信息,具体方式为将方面词向量做平均,拼接到输入文本中。

(2) AT-LSTM 模型<sup>[16]</sup>:将方面词向量和 LSTM 的隐藏层做拼接,再使用注意力机制提取特征信息,将经过注意力提取的向量用作最终分类。

(3) ATAE-LSTM 模型<sup>[9]</sup>:基于 LSTM 网络,将方面词向量和文本词向量及 LSTM 的隐藏层向量先后做拼接,然后通过注意力机制提取拼接后的向量信息,获得输出类别。

(4) BERT-LSTM 模型<sup>[17]</sup>:探索了 BERT 中间层信息的作用,使用 LSTM 连接 [CLS] 标识符的所有中间层标识,用最后一个 LSTM 单元的输出做分类。

(5) IAN 模型<sup>[18]</sup>:提出交互注意力网络,对目标词和上下文分别建模,最终得到的目标词向量和上下文向量融合了二者的交互信息,在此基础上将这 2 个向量用于分类输出类别。

从表 4 的对比结果可以看出,本文模型的效果优于大部分仅基于 LSTM 的模型。除基于 BERT 的模型外,在 Laptop 数据集上的准确率提高了 1.3%~5.3%、在 Restaurant 数据集上准确率提高了 2.5%~5.5%;对比基于 BERT 的模型,在准确率接近的情况下模型参数量大大减少,本文模型参数量约为 4M (这里,1M = 1 × 10<sup>6</sup>),而 BERT 约为 110M (这里,BERT-base, 12 层)。同时,实验结果也表明了 BERT 模型强大的特征提取能力,复杂模型如果能够有效处理过拟合问题会具有更好的效果。

## 4 结束语

本文基于 Self-Attention 机制搭建模型用于方面级情感分析任务,模型使用 2 个不同的注意力模块对方面词和上下文分别建模,接着用建模后得到的向量计算交互注意力,再把计算后的向量拼接用作最终分类。通过在 SemEval2014 Task4 数据集上做实验并同其他研究者提出的模型进行对比,验证了本文模型的有效性。

## 参考文献

- [1] WANG Yequan, HUANG Minlie, ZHU Xiaoyan, et al. Attention-based LSTM for aspect-level sentiment classification [C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin, TX, USA:dblp,2016: 606-615.
- [2] HUANG Binxuan, OU Yanglan, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks [C]//International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation. Cham: Springer, 2018: 197-206.
- [3] LIU Ning, SHEN Bo. Aspect-based sentiment analysis with gated alternate neural network [J]. Knowledge-Based Systems, 2019, 188:1-14.
- [4] ZHANG Chen, LI Qiuchi, SONG Dawei. Syntax-aware aspect-level sentiment classification with proximity-weighted convolution network [C]//Proceedings of the 42<sup>nd</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval. New York:ACM, 2019: 1145-1148.
- [5] XU Qiannan, ZHU Li, DAI Tao, et al. Aspect-based sentiment classification with multi-attention network [J]. Neurocomputing, 2020,388:135-143.
- [6] LIU Ning, SHEN Bo. ReMemNN: A novel memory neural network for powerful interaction in aspect-based sentiment analysis [J]. Neurocomputing, 2020,395:66-77.
- [7] XU Hu, LIU Bing, SHU Lei, et al. DomBERT: Domain-oriented language model for aspect-based sentiment analysis [C]//Findings of the Association for Computational Linguistics: EMNLP 2020. ACL,2020: 1725-1731.
- [8] 冉祥映. 基于深度神经网络的方面级情感分析研究 [D]. 南京: 南京大学,2020:22-27.
- [9] CAI Hongjie, TU Yaofeng, ZHOU Xiangsheng, et al. Aspect-category based sentiment analysis with hierarchical graph convolutional network [C]//Proceedings of the 28<sup>th</sup> International Conference on Computational Linguistics. Barcelona, Spain:dblp, 2020: 833-843.
- [10] GAN Chenquan, WANG Lu, ZHANG Zhufan, et al. Sparse attention based separable dilated convolutional neural network for targeted sentiment analysis [J]. Knowledge-Based Systems, 2020, 188: 1-10.
- [11] ZHOU Jie, HUANG J X, HU Q V, et al. SK-GCN: Modeling syntax and knowledge via graph convolutional network for aspect-level sentiment classification [J]. Knowledge-Based Systems, 2020,205:1-10.
- [12] TIAN Yuanhe, CHEN Guimin, SONG Yan. 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. Mexico:ACL,2021: 2910-2922.
- [13] YADAV R K, JIAO L, GOODWIN M, et al. Positionless aspect based sentiment analysis using attention mechanism [J]. Knowledge-Based Systems, 2021,226:1-10.
- [14] DAI Junqi, YAN Hang, SUN Tianxiang, et al. Does syntax matter? A strong baseline for aspect-based sentiment analysis with RoBERTa [C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Mexico:ACL,2021: 1816-1829.
- [15] TANG Duyu, QIN Bing, FENG Xiaocheng, et al. Effective LSTMs for target-dependent sentiment classification [C]//Proceedings of COLING 2016, the 26<sup>th</sup> International Conference on Computational Linguistics. Osaka, Japan:dblp, 2016: 3298-3307.