

基于 Graph-LSTMs 的双重位置感知方面级情感分类

杨锐¹ 刘永坚¹ 解庆¹ 刘平峰²

¹(武汉理工大学计算机科学与技术学院 湖北 武汉 430070)

²(武汉理工大学经济学院 湖北 武汉 430070)

摘要 目前针对用户评论中方面词项情感分类任务的研究大多忽略了依存句法信息,或并未建立依存句法结构与单词之间的联系。为此,提出一种基于 Graph-LSTMs 的双重位置感知方面级情感分类方法。通过 Graph-LSTMs 学习词项的上下文语境特征;在双向 GRU 的输入中拼接具有双重位置信息的位置向量,优化句子情感编码;利用注意力机制捕获关键的情感特征,实现分类。在 SemEval2014 的两个数据集上的实验结果表明,该模型相比几种基线模型在准确率和 Macro-F1 这两个指标上提升明显。

关键词 方面级情感分析 Graph-LSTMs 依存句法 位置权重 注意力机制

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.04.025

ASPECT LEVEL SENTIMENT CLASSIFICATION WITH DUAL POSITION AWARENESS BASED ON GRAPH-LSTMS

Yang Rui¹ Liu Yongjian¹ Xie Qing¹ Liu Pingfeng²

¹(School of Computer Science and Technology, Wuhan University of Technology, Wuhan 430070, Hubei, China)

²(School of Economic, Wuhan University of Technology, Wuhan 430070, Hubei, China)

Abstract At present, most of the researches on the aspect term sentiment classification task in user reviews ignore the dependency syntactic information, or do not establish the relationship between dependency syntactic structure and words. Therefore, this paper proposes an aspect level sentiment classification method based on Graph-LSTMs. Graph-LSTMs was used to learn the context features of words. The position vector was spliced with dual position information in the input of bidirectional GRU to optimize the sentence sentiment coding. The attention mechanism was used to capture key sentiment features to achieve classification. The experimental results on two data sets of SemEval2014 show that the accuracy and Macro-F1 of this model are significantly improved compared with several baseline models.

Keywords Aspect level sentiment analysis Graph-LSTMs Dependency parsing Position weight Attention mechanism

0 引言

如今移动互联网发展迅猛,在各大网站上每天都有大量的评论出现,这些评论往往带有一定的情感倾向,在一定程度上能反映目标事物的特点或优缺点等客观信息。通过分析这些评论的情感倾向,企业可以针对性地优化产品和营销,个人也能基于此做出适合自己的选择。因此,不论是对企业还是个人,情感分析技术都具有巨大的应用价值。情感分析(Sentiment

Analysis)旨在挖掘出评论文本的情感倾向^[1],其利用文本分析、机器学习和深度学习等技术对带有情感倾向的文本进行分析、计算、推理和归纳^[2]。根据分类的粒度不同,情感分析主要有两个分类任务:篇章级和句子级的粗粒度任务与方面级的细粒度任务。其中,篇章级和句子级本质上基本相同,句子可看作是简短的文章^[1]。粗粒度分类任务针对评论的整体,文章或句子对应一个评论对象,分类的结果是全局的情感极性。然而,目前的评论所蕴含的情感倾向往往具有多样性,针对的评论对象也并非单一,粗粒度的情感分类任务

无法满足目前评论中复杂的情感极性的判断需求。因此,近些年,相关领域的研究主要集中在细粒度的方面级分类任务上,在应用方面也更有价值。

方面级情感分析旨在分析评论中一个或多个评论对象各自的情感极性,根据分类的对象不同,其又分为方面类别情感分析 ACSA (Aspect Category Sentiment Analysis) 和方面词项情感分析 ATSA (Aspect Term Sentiment Analysis) 这两个子任务,其中 ATSA 为本文研究的任务。对于 ACSA,分析对象为预先总结好的类别词,对于 ATSA,分析对象则是评论中出现的具体的目标词(本文用目标词代表方面词项分类任务的判断对象)。例如:“But the staff was so horrible to us.”类别词可以是“service”,而“staff”则是具体的目标词,两种分类任务分别对这两个对象进行情感极性的判断。目前的研究工作大多基于深度学习,同时考虑语言学等人工特征辅助分类,如依存句法、位置权重和情感词典等。其中:依存句法可根据句法结构将线性距离较远的两个单词联系起来;位置权重则是考虑句中单词与目标词之间相对距离对情感极性判断的影响,包括根据线性位置和句法位置得出的两种相对距离(下文分别用线性距离和句法距离表示)。现有的利用句法结构的研究都是将单词间的线性关系和句法关系分开处理,并未将两者有机结合在一起,尤其在位置权重的处理上,单一的位置权重存在局限性,并不能很好地表示对应单词的重要性。

受句法分析、图神经网络和位置权重等研究的启发,本文提出一种基于 Graph-LSTMs^[3] 的双重位置感知方面级情感分类方法 DPAGL (Dual Position Awareness based on Graph-LSTMs)。本文模型主要由两个编码层和一个注意力层组成,其中,编码层分为语境编码和情感编码;语境编码用来掌控目标词与其他单词之间的关联;情感编码则是学习句中的情感特征,用于最终的情感分类。在位置权重的处理上,本文利用两种相对距离和可学习的二维参数矩阵计算出对应的位置向量,以表示同时具有线性和句法距离的位置权重。

在 SemEval2014 的餐馆和笔记本领域的数据集上进行的实验表明,本文模型与目前一些优秀的方法相比,分类效果有一定的提升。

1 相关工作

1.1 神经网络

以往许多研究工作使用机器学习的方法进行情感分类,如朴素贝叶斯和支持向量机等^[4],这些方法分类

的效果依赖人工设计的特征和规则的质量,需要丰富的经验和大量的人力。而且,在不同领域,相应的特征也不同,不易移植推广,无法满足目前的应用需求。

近年来,基于神经网络的研究取得了不错的进展,如卷积神经网络(CNN)和循环神经网络(RNN)及其相应的变体——长短期记忆网络(LSTM)和门控循环单元(GRU)等,再结合注意力机制^[5]和记忆网络^[6]等,极大地提升了情感分类的效果。而且,神经网络能够自主地学习相应的特征,相较于传统的分类方法,不需要大量的人力和特征工程,简化了特征学习过程。CNN 擅于提取局部特征,最初应用于图像领域, Kim^[7]在此基础上提出了用于文本分类的模型。Tang 等^[8]提出了两种基于 LSTM 的模型:TD-LSTM 和 TC-LSTM, TD-LSTM 注重目标词的上下语境对其的影响, TC-LSTM 在 TD-LSTM 的基础上将目标词参与到 LSTM 的计算中,与简单的 LSTM 方法相比,两个模型都有不小的提升。刘全等^[9]提出结合区域 CNN 和分层 LSTM 的网络模型,结合两种网络的优点,学习出文本中中长距离的依赖关系和局部特征。Wang 等^[10]在 LSTM 的基础上引入注意力机制,将目标词向量参与到注意力权重的计算,实现分类效果的提升。Ma 等^[11]考虑到目标词自身对分类的影响,用 LSTM 分别对句子和目标词组合进行独立编码,再相互使用注意力机制,得到最终的情感表示。Tang 等^[12]通过深层记忆网络重复提取关键信息,较单一的注意力机制分类效果提升明显。Chen 等^[13]将多层注意力机制和 GRU 网络相结合,分类效果有所提升。

1.2 依存句法

句中单词之间除了依次相邻的关系外,还具有句法上的联系。依存句法分析(Dependency Parsing, DP)可通过分析句中单词之间的依存关系展示句子的句法结构。在句法结构上,线性距离较远的两个单词依旧有可能存在直接的联系,对其合理地利用能够提升情感分类效果。

如图 1 所示,目标词为 performance,决定其情感极性的单词为 disappointment,在线性距离上,两者相距较远,但在句法结构上,两者为相邻的。因此,在这种情况下,句法信息更能帮助目标词的情感极性判断。Wang 等^[14]提出了基于 Tree-LSTM 的分类模型,利用句法依赖树提升分类效果。Huang 等^[15]采用图注意力网络^[16](GAT)处理句法特征的提取,实现了不错的分类效果。Zhang 等^[17]使用图卷积神经网络^[18](GCN)提取句法特征,然后利用注意力机制实现分类。



图 1 依存句法

1.3 位置权重

许多研究考虑不同单词与目标词之间的位置信息以提升分类效果。一般认为,距离目标词越近的单词对其情感极性判断的影响越大。武婷等^[19]计算出线性距离的权重后与词嵌入相乘得到新的带有位置属性的词向量。Gu 等^[20]则是提出利用位置向量表示每个单词的位置权重,优化编码效果。但是,这种简单的线性位置关系存在弊端。例如:“Great food, but the service at the restaurant was dreadful.”对于目标词“service”而言,“Great”和它的距离与其对应的情感词“dreadful”相同,这会计算出错误的位置权重。因此,支淑婷等^[21]提出了一种基于标点符号的权重梯级衰减算法来计算句子中目标词与上下文之间的相对位置权重,在一定程度上避免错误的位置信息。

同样,句子的句法结构在位置权重方面也能提供有用的信息。就上面的例子而言,目标词“service”与情感词“dreadful”在句法结构上有直接的联系,计算位置权重时可获得较高的权重。Zhang 等^[22]将句法权重与编码层的隐藏状态向量相乘,得到新的特征表示。苏锦铨等^[23]同时考虑了线性距离和句法距离的作用,但在处理方式上有所差别。他们将线性距离映射成多维向量,与词嵌入相加取均值作为模型的输入。随后,他们将句法权重与编码层的隐藏状态相乘,最终得到具有两种位置权重加权的特征表示。

1.4 Graph-LSTMs

Graph-LSTMs 是一种基于 LSTM 的网络结构,最初应用在关系抽取领域。与 GCN、GAT 等图神经网络相似,其也可提取非欧氏关系结构的特征,因此可用于处理句法结构信息。GCN 和 GAT 同一时刻仅能处理一种非欧氏关系特征,因此,以往的研究大多将其用来单独处理句法关系。而 Graph-LSTMs 不局限于一种结构关系的特征提取,它能同时学习多种结构关系的特征,根据单词间不同的联系考虑一个或多个不同的上一时刻隐藏状态来计算当前时刻的隐藏状态。对于约定线性和句法这两种关系,其在提取单词线性特征的基础上可学习句法特征,不需要将线性和句法特征分别处理。基于单向句法依赖树的结构如图 2 和图 3 所示。




图 2 Graph-LSTMs 正向




图 3 Graph-LSTMs 反向

2 模型描述

本文提出基于 Graph-LSTMs 的双重位置感知方面级情感分类方法,在语境编码层采用 Graph-LSTMs 实现单词间线性和句法关系的上下文特征提取。在情感编码层中,本文将同时具有线性距离和句法距离信息的位置权重向量与词嵌入拼接,作为双向 GRU 的输入。在注意力层中,query 为语境编码层对应目标词的隐藏状态向量, key 和 value 皆为情感编码层的隐藏状态。最后将注意力结果输入到分类器,实现情感分类。模型整体架构如图 4 所示。

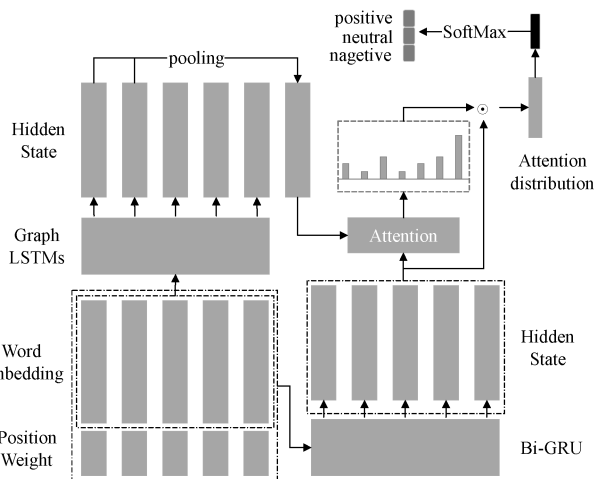


图 4 模型概括

2.1 输入层

在将句子输入到编码层前,需要预处理以下几个部分:将所有单词转换成小写;处理句法结构关系(若一个评论由多个句子组成,即评论中存在句号和感叹号等符号,整个句子的依赖会出现割裂,产生多个句法依赖树。因此,本文将当前单句的根节点指向上一个单句的根节点,以实现多个句子之间的联系。);通过句法依存树对句子进行分词处理(依存句法处理工具返回的句子和原本的句子可能存在差异,如将缩写分开等);标记目标词在句中的位置和长度(目标词可能由多个单词组成);计算出句子中每个单词与目标词之间的相对距离,包括线性距离和句法距离;将原始的单词序列转换为向量形式等。

本文使用预训练好的 300 维的 Glove 向量来处理单词序列的向量转换,转换后的句子表示为 $S = \{w_1, w_2, \dots, w_i, \dots, w_{n-1}, w_n\}$,其中: w_i 表示句子中第 i 个单词, n 为句子的长度。

相对距离有两种,分别为线性距离和句法距离,如图 5 和图 6 所示。这两个皆表明句子中其他单词对目标词情感极性的影响程度,除目标词外,距离越小,影

响越大。

The design and atmosphere is just as good.

(1) (0) (1) (2) (3) (4) (5) (6)

图5 线性距离




图6 句法距离

初始位置权重计算方式如下:

$$p_i = \begin{cases} 1 - \frac{d_{is}}{m_{ax} + 1} & d_{is} > 0 \\ 0 & d_{is} = 0 \end{cases} \quad (1)$$

式中: d_{is} 表示目标词与其他单词之间的相对距离; m_{ax} 为当前句子相对距离的最大值。对于目标词由多个单词组成的情况,其他单词与目标词的相对距离以离目标词成员的最小距离为准。

2.2 编码层

2.2.1 语境编码

语境编码层由 Graph-LSTMs 实现,计算公式如下:

$$i_t = \sigma(W_o x_t + \sum_{j \in P(t)} U_o^{m(t,j)} h_j + b_i) \quad (2)$$

$$o_t = \sigma(W_o x_t + \sum_{j \in P(t)} U_o^{m(t,j)} h_j + b_o) \quad (3)$$

$$\tilde{c}_t = \tanh(W_c x_t + \sum_{j \in P(t)} U_c^{m(t,j)} h_j + b_c) \quad (4)$$

$$f_{ij} = \sigma(W_f x_t + U_f^{m(t,j)} h_j + b_f) \quad (5)$$

$$c_t = i_t \times \tilde{c}_t + \sum_{j \in P(t)} f_{ij} \times c_j \quad (6)$$

$$h_t = o_t \times \tanh(c_t) \quad (7)$$

式中: j 表示与当前时刻有联系的隐藏状态下标, h_j 为隐藏状态; i_t 为输入门; o_t 为输出门; \tilde{c}_t 为候选的细胞状态; f_{ij} 表示遗忘门; c_t 为当前时刻的细胞状态; h_t 为输出状态; $U^{m(t,j)}$ 为不同类型关系的参数矩阵; $P(t)$ 表示与当前状态有联系的隐藏层状态下标集合; σ 表示 sigmoid 函数; \tanh 双曲正切函数。

Graph-LSTMs 为双向的网络,第 t 时刻的隐藏状态

向量表示为: $h_t = \begin{bmatrix} \vec{h} \\ \overleftarrow{h} \end{bmatrix}$, \vec{h} 表示正向的隐藏状态向量, \overleftarrow{h}

表示反向的隐藏状态向量。最终得到的隐藏层状态为: $H = [h_1, h_2, \dots, h_{a1}, \dots, h_{al}, \dots, h_{n-1}, h_n]$, h_{a1} 至 h_{al} 表示目标词组合对应的隐藏状态向量。若 $l > 1$, 则采用平均池化的方式得到最终的隐藏状态向量 h_a 。

此外,在句法依存树中,单词之间的联系是单向

的,存在目标词指向情感词的情况,如图 1 所示。在 Graph-LSTMs 中会错过相应特征的学习。因此,本文使用无向的依存树,即对称的依存矩阵来表示句中单词间的依存关系。

2.2.2 情感编码

情感编码层由双向 GRU 实现,计算公式如下:

$$r_t = \sigma(W_r [x_t, h_{(t-1)}] + b_r) \quad (8)$$

$$z_t = \sigma(W_z [x_t, h_{(t-1)}] + b_z) \quad (9)$$

$$n_t = \tanh(W_n [x_t, r_t \times h_{(t-1)}] + b_n) \quad (10)$$

$$h_t = (1 - z_t) \times n_t + z_t \times h_{(t-1)} \quad (11)$$

式中:下标 t 代表序列当前时刻, $t-1$ 代表上一时刻; r_t 为重置门; z_t 为更新门; n_t 为候选隐藏状态; h_t 为当前时刻的隐藏状态; W 为权重矩阵; b 为偏置向量。

在输入的词嵌入中,本文加入位置权重以优化编码效果。句子中每个单词都有一个初始的位置权重,由线性和句法相对距离经计算的结果组成,随后通过学习得出合适的位置向量以表示位置权重。具体的计算方式如下:

$$p_{vi} = W_p p_i \quad (12)$$

式中: p_{vi} 表示 i 位置的权重向量; $W_p \in \mathbf{R}^{(d_p, 2)}$ 是在训练中学习的参数矩阵, d_p 为位置权重向量的维度; $p_i \in p^{(2,1)}$ ($p \in [0, 1]$) 表示 i 位置单词的初始权重。最终的输入表示为: $\begin{bmatrix} w_i \\ p_{vi} \end{bmatrix}$ 。

编码得到的隐藏状态由正向和反向拼接组成,最终的矩阵表示为 H_s 。

2.3 注意力层

在情感分类任务中,一个句子中某一个目标词的情感极性往往由几个重要的单词决定。本文利用注意力机制,着重关注对目标词情感极性影响较大的单词,计算方式如下:

$$wh = h_a^T \cdot W_h \cdot H_s \quad (13)$$

$$\alpha = \text{softmax}\left(\frac{wh}{\sqrt{d_{hs}}}\right) \quad (14)$$

$$r = \alpha^T \cdot H_s \quad (15)$$

式中: h_a 表示语境编码层中目标词对应的隐藏状态向量; H_s 为情感编码层得到的情感矩阵; d_{hs} 表示情感编码层隐藏状态向量的维度; α 为注意力分布; r 为目标词最终的情感特征表示。

2.4 输出层

注意力层结果最终经全连接层,得到类别向量,接着通过 Softmax 归一化生成情感极性的概率分布。

本文使用交叉熵损失函数对模型进行训练,定义如下:

$$l_{oss} = - \sum_i \sum_j y_{ij} \log(y'_{ij}) + \lambda \|\theta\|^2 \quad (16)$$

式中: i 表示样本句子的索引; j 表示情感极性类别的索引; y_{ij} 表示预测的情感极性概率; y'_{ij} 表示正确的情感极性; λ 表示 L2 正则化的系数; θ 指需要正则化的参数。此外,本文也设置了 dropout 防止过拟合。

3 实验

3.1 数据集

本实验采用数据集为 SemEval 2014 的 Restaurant 和 Laptop 数据集。参考其他研究工作,将矛盾 (conflict) 标签的样本去除,保留积极 (positive)、中性 (neutral) 和消极 (negative) 三个标签的样本。句子的依存句法处理工具采用 Stanford NLP 工具包。数据集类别情况如表 1 所示。

表 1 数据集类别分布

数据集	positive		neutral		negative	
	train	test	train	test	train	test
Res	2 164	728	637	196	807	196
Lap	988	341	463	169	861	128

3.2 实验参数

本实验采用的词向量为预先训练好的 Glove 词向量,维度为 300,对于不在 Glove 词汇表中的单词,均采用 Glove 词汇表中的 ‘unk’ 替换,参数更新的优化器选用 Adam。位置向量的维度为 100,批处理大小为 32,隐藏状态向量维度为 300,初始的学习率为 0.001,L2 正则项系数为 10^{-5} ,dropout 为 50%。

3.3 实验结果分析

3.3.1 Graph-LSTMs 与双重位置权重的影响

本文分别测试了 Graph-LSTMs 和双重位置权重对模型的影响。实验结果见表 2,其中:NPAL 表示标准双向 LSTM 且不考虑位置权重;PAL-lin 表示标准双向 LSTM 加线性权重;PAL-dep 表示标准双向 LSTM 加句法权重;DPAL 表示标准双向 LSTM 加线性和句法的组合权重;NPAGL 表示 Graph-LSTMs 且不考虑位置权重;DPAGL 为本文模型。在两个数据集上实验表明,双重位置权重比单一的位置权重性能更佳,Graph-LSTMs 也比标准的 LSTM 更加精确地学习目标词的上下文语境。在 Restaurant 数据集上,双重权重较单一权重,准确率分别提升了 0.63 个百分点和 0.9 百分点,Macro-F1 分别提升了 0.71 个百分点和 0.6 百分点,Graph-LSTMs 比标准的 LSTM 在两个指标上分别提升

了 1.26 个百分点和 1.9 百分点;在 Laptop 数据集上,双重权重较单一权重,准确率分别提升了 0.82 个百分点和 0.35 百分点,Macro-F1 分别提升了 0.65 个百分点和 0.14 百分点,Graph-LSTMs 比标准的 LSTM 在两个指标上分别提升了 1.25 个百分点和 2.89 百分点。

表 2 Graph-LSTMs 和位置权重分别对模型的影响 (%)

方法	Restaurant		Laptop	
	Acc	Macro-F1	Acc	Macro-F1
NPAL	80.18	70.76	74.14	68.76
PAL-lin	81.25	72.41	75.08	70.78
PAL-dep	80.98	72.52	75.55	71.29
DPAL	81.88	73.12	75.90	71.43
NPAGL	81.44	72.66	75.39	71.65
DPAGL	82.18	73.64	76.33	72.36

3.3.2 样例分析

以下通过三个样例说明 Graph-LSTMs 和双重位置权重在分类上的表现。

1) “the food is just okay, and it is **almost not worth going unless youare getting pialla dish really good**.” 目标词为“pialla”,情感极性为“positive”,该句较长,仅展示关键词之间的依存结构,对应的单词在例句中用粗体表示。句法结构和相应的线性距离如图 7 所示。




图 7 样例 1 句法结构和线性距离

判断结果见表 3 样例 1 列。各方法的注意力分布见图 8 和图 9。NPAL 和 PAL-lin 无法根据上文反转的态度判断出正确的情感极性,做出了消极的情感判断,利用句法信息的方法借助“really”和“good”均判断正确。在使用双重位置权重的方法中,虽然“really”和“good”距目标词的线性距离相对较大,但句法距离较小,而“almost”和“not”两种距离都相对较大,相应的双重位置权重较小,最终在注意力权重上得分较低。

表 3 各方法的分类结果 (粗体表示分类正确)

方法	样例 1	样例 2	样例 3
NPAL	negative	positive	neutral
PAL-lin	negative	positive	neutral
PAL-dep	positive	neutral	neutral
DPAL	positive	positive	neutral
NPAGL	positive	negative	positive
DPAGL	positive	positive	positive




图 8 样例 1 PAL-lin、PAL-dep 和 DPAL 注意力分布




图 9 样例 1 NPAL、NPAGL 和 DPAGL 注意力分布

2) “I trust the people at go sushi, it never disappoints.” 目标词为“people”, 情感极性为“positive”, 该句的依存结构如图 10 所示。




图 10 样例 2 句法结构

判断结果见表 3 样例 2 列。各方法注意力分布见图 11 和图 12。NAPL 主要关注在“trust”“never”和“disappoints”上, 判断为积极。PAL-lin 对线性距离较近的“trust”关注最高, 分类正确。在仅利用句法权重的 PAL-dep 方法中, 虽然目标词在“trust”上赋予最高的句法距离权重, 但具有相反极性的“disappoints”同样有较高的权重, 导致 PAL-dep 在最终的分类中判断出中性的情感。在 DPAL 方法中, 虽然“trust”的句法距离与“disappoints”的句法距离接近, 但线性距离相对更小, 双重位置权重更高, 在随后的注意力计算中获得更高的权重。NPAGL 的注意力分布主要集中在“trust”和“never”, 最终判断为消极。DPAGL 经双重位置权重的影响, 注意力主要集中在“trust”和“go”上, 判断正确。




图 11 样例 2 PAL-lin、PAL-dep 和 DPAL 注意力分布




图 12 样例 2 NPAL、NPAGL 和 DPAGL 注意力分布

3) “Works well, and I am extremely happy to be back to an apple os.” 目标词为“apple os”, 情感极性为“positive”, 该句的依存结构如图 13 所示。




图 13 样例 3 句法结构

判断结果见表 3 样例 3 列。各方法注意力分布见图 14 和图 15。在该例中, 决定目标词情感极性的单词为“happy”, NPAGL 和 DPAGL 对其赋予了最高的注意力权重, 判断正确。NPAL 虽然关注到了“happy”, 但同样对“back”关注较多, 最终判断为中性。三种仅使用位置权重的方法均对“back”分配了最高的注意力权重, 判断中性。




图 14 样例 3 PAL-lin、PAL-dep 和 DPAL 注意力分布




图 15 样例 3 NPAL、NPAGL 和 DPAGL 注意力分布

3.3.3 与其他研究工作相比

为了进一步评估本文模型的性能, 本文与几种基线模型和两种考虑句法信息的模型进行比较。对比的模型如下:

1) TD-LSTM^[8]: 以目标词为中心, 分别从上下文

对目标词建模,然后将正向和反向 LSTM 最后时刻的隐藏状态拼接,最后实现情感判断。

2) IAN^[11]:利用 LSTM 分别对上下文和目标词进行编码,然后对隐藏层状态进行平均池化并互相使用注意力机制得到各自的表示,最终通过拼接来表示目标词情感,实现分类。

3) MemNet^[12]:将词嵌入矩阵作为外部记忆,利用目标词重复提取句子情感信息,并更新目标词特征表示。以最后的表示作为目标词的情感表示,实现分类。

4) RAM^[13]:用线性位置权重处理双向 LSTM 的隐藏状态,再利用 GRU 和注意力机制重复提取隐藏状态的关键信息。

5) PABN^[20]:分别对上下文和目标词通过双向 GRU 进行编码,其中上下文编码的输入为每个单词的词嵌入和其对应的位置向量拼接组成,最后利用双向的注意力机制得到相应的情感表示。

6) ASGCN-DT^[17]:使用双向的 LSTM 对句子进行编码,对隐藏状态的处理有两个方向:一是利用 GCN 根据有向的依存图提取句子的句法特征,并得到目标词的特征表示;二是与线性位置权重相乘得到新的隐藏状态。最后利用注意力机制提取情感信息。

7) ASGCN-DG^[17]:结构与 ASGCN-DT 基本一致,依存图为无向的。

8) PWCN-Pos^[22]:用线性位置权重加权双向 LSTM 的隐藏状态,再经卷积网络提取特征,最后通过最大池化实现分类。

9) PWCN-Dep^[22]:与 PWCN-Pos 结构一致,在位置权重上使用句法距离权重。

比较结果见表 4。可以看出,本文模型在两个不同主题的数据集上有着不错的分类效果。TD-LSTM 直接学习目标词的特征表示,分类效果一般。IAN 另外对目标词进行建模,再利用注意力机制,效果有所提升。RAM 利用注意力机制和 GRU 重复提取并筛选信息,相比 TD-LSTM 和 IAN 有不小的提升。PABN 以线性位置的权重向量优化双向 GRU 的编码效果,并结合双向的注意力机制,在 Restaurant 数据集上提升较大。利用句法信息的 ASGCN-DG 和 PWCN 在 Laptop 数据集上的分类效果出色,表明了依存句法对方面级情感分类任务有着积极的作用。本文方法在两个数据集上皆实现了最好的结果,其中在 Restaurant 数据集上有着比较明显的提升,相较对比模型中最好的结果,在两个指标上分别提升了 1.02 个百分点和 1.43 百分点,验证了本文方法的有效性。

表 4 各个方法在数据集上的准确率和 Macro-F1 (%)

方法	Restaurant		Laptop	
	Acc	Macro-F1	Acc	Macro-F1
TD-LSTM	78.00	66.73	71.83	68.43
IAN	78.60	—	72.10	—
MemNet	80.32	—	72.37	—
RAM	80.23	70.80	74.49	71.35
PABN	81.16	—	74.12	—
ASGCN-DT	80.86	72.19	74.14	69.24
ASGCN-DG	80.77	72.02	75.55	71.05
PWCN-Pos	81.12	71.81	75.23	70.71
PWCN-Dep	80.96	72.21	76.12	72.12
DPAGL	82.18	73.64	76.33	72.36

4 结 语

本文提出一种基于 Graph-LSTMs 的双重位置感知方面级情感分类方法 (DPAGL),充分考虑依存句法信息以提升情感分类效果。在语境编码阶段,根据线性句法结构学习到更加准确的目标词的语境表示。在情感编码阶段,将具有双重位置信息的权重向量参与到编码计算,得到更加倾向目标词的情感特征表示。最后通过注意力机制捕获目标词的情感特征。在 SemEval2014 的两个数据集上进行的实验表明,本文模型分类效果比几种基线模型有着大幅的提升,在 Restaurant 数据集上也明显好于目前较为优秀的方法。未来,将继续尝试发掘句子中图形结构信息,并结合图神经网络和其他方面的知识进一步提升情感极性判断效果。

参 考 文 献

- [1] Medhat W, Hassan A, Korashy H. Sentiment analysis algorithms and applications: A survey[J]. Ain Shams Engineering Journal, 2014, 5(4): 1093 - 1113.
- [2] 陈龙,管子玉,何金红,等. 情感分类研究进展[J]. 计算机研究与发展, 2017, 54(6): 1150 - 1170.
- [3] Peng N, Poon H, Quirk C, et al. Cross-Sentence N-ary relation extraction with graph LSTMs[J]. Transactions of the Association for Computational Linguistics, 2017(5): 101 - 115.
- [4] 谭炎,张进,夏立新. 社交媒体情境下的情感分析研究综述[J]. 数据分析与知识发现, 2020, 4(1): 1 - 11.
- [5] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//31st International Conference on Neural Informa-

- tion Processing Systems, 2017:6000 – 6010.
- [6] Sukhbaatar S, Szlam A, Weston J, et al. End-to-end memory networks [C] // 28th International Conference on Neural Information Processing Systems, 2015:2440 – 2448.
- [7] Kim Y. Convolutional neural networks for sentence classification [C] // 2014 Conference on Empirical Methods in Natural Language Processing, 2014:1746 – 1751.
- [8] Tang D, Qin B, Feng X, et al. Effective LSTMs for target-dependent sentiment classification [C] // 26th International Conference on Computational Linguistics: Technical Papers, 2016:3298 – 3307.
- [9] 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.
- [10] Wang Y, Huang M, Zhao L, et al. Attention-based LSTM for aspect-level sentiment classification [C] // 2016 Conference on Empirical Methods in Natural Language Processing, 2016:606 – 615.
- [11] Ma D, Li S, Zhang X, et al. Interactive attention networks for aspect-level sentiment classification [C] // 26th International Joint Conference on Artificial Intelligence, 2017:4068 – 4074.
- [12] Tang D, Qin B, Liu T. Aspect level sentiment classification with deep memory network [C] // 2016 Conference on Empirical Methods in Natural Language Processing, 2016:214 – 224.
- [13] Chen P, Sun Z, Bing L, et al. Recurrent attention network on memory for aspect sentiment analysis [C] // 2017 Conference on Empirical Methods in Natural Language Processing, 2017:452 – 461.
- [14] Wang J, Yu L, Lai K, et al. Investigating dynamic routing in tree-structured LSTM for sentiment analysis [C] // 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019:3432 – 3437.
- [15] Huang B, Carley K. Syntax-aware aspect level sentiment classification with graph attention networks [C] // 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019:5469 – 5477.
- [16] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks [C] // 6th International Conference on Learning Representations, 2017.
- [17] Zhang C, Li Q, Song D. Aspect-based sentiment classification with aspect-specific graph convolutional networks [C] // 2019 Conference on Empirical Methods in Natural Language Processing, 2019:4568 – 4578.
- [18] Kipf T, Welling M. Semi-supervised classification with graph convolutional networks [C] // 5th International Conference on Learning Representations, 2017.
- [19] 武婷, 曹春萍. 融合位置权重的基于注意力交叉注意力的长短期记忆方面情感分析模型 [J]. 计算机应用, 2019, 39 (8): 2198 – 2203.
- [20] Gu S, Zhang L, Hou Y, et al. A position-aware bidirectional attention network for aspect-level sentiment analysis [C] // 27th International Conference on Computational Linguistics, 2018:774 – 784.
- [21] 支淑婷, 李晓戈, 王京博, 等. 基于多注意力长时记忆的实体属性情感分析 [J]. 计算机应用, 2019, 39 (1): 160 – 167.
- [22] Zhang C, Li Q, Song D. Syntax-aware aspect-level sentiment classification with proximity-weighted convolution network [C] // 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019:1145 – 1148.
- [23] 苏锦钊, 欧阳志凡, 余珊珊. 基于依存树及距离注意力的句子属性情感分类 [J]. 计算机研究与发展, 2019, 56 (8): 1731 – 1745.
- ~~~~~
- (上接第 100 页)**
- 堆积显示, 影响操作人员关注重点目标。本文提出灵活编辑时间区间的态势显示方法, 态势显示系统根据时间区间参数只显示设定的最新时间段的目标数据, 并设计态势显示的 3 种运行状态切换实现实时态势和回放态势统一响应灵活编辑的时间区间, 有效解决不同使用场景下的态势堆积显示问题。
- 参 考 文 献**
- [1] 张明杰. 一种基于 B + 树航迹态势回放系统的设计与实验 [J]. 计算机应用与软件, 2018, 35 (8): 159 – 164.
- [2] 张明杰, 王静平. 态势实时显示与回放系统的设计与实现 [J]. 指挥控制与仿真, 2019, 41 (1): 112 – 119.
- [3] 雷祥, 黄安祥, 李劲松, 等. 基于 Skyline 的空战仿真数据三维可视化回放研究 [J]. 系统仿真学报, 2013, 25 (8): 1881 – 1885.
- [4] 汤建华. 多目标航迹显示数据的动态实时压缩处理 [J]. 光学精密工程, 1996, 4 (3): 58 – 61.
- [5] 胡勤友, 孟良. 一种提高电子海图上船舶航迹显示速度的方法 [J]. 中国航海, 2009, 32 (4): 13 – 16.
- [6] 宋姝婧, 焦健, 张兆永, 等. 基于 MapObjects 的无人机遥感航迹实时显示算法研究 [J]. 遥感信息, 2007 (6): 18 – 22.
- [7] 石书浩, 张洁, 吕品, 等. 模拟演练态势回放系统的设计与实现 [J]. 计算机工程与设计, 2012, 33 (3): 1079 – 1084.
- [8] Vaughn V. 实现领域驱动设计 [M]. 滕云, 译. 北京: 电子工业出版社, 2014:110 – 114.