

基于双向注意力机制的问答情感分类方法

沈忱林 张 璐 吴良庆 李寿山

(苏州大学计算机科学与技术学院 江苏 苏州 215006)

摘 要 情感分类是自然语言处理研究中的一项基本任务,旨在判别文本的情感极性。目前,情感分类相关研究主要针对句子、篇章和微博等文本形式。与以往研究不同的是,文中面向新颖的问答型评论展开情感分类。首先,收集并标注了大规模、高质量的问答型评论语料集;针对问答型评论的特点,提出了一种基于双向注意力机制的神经网络方法。具体而言,该方法首先通过双向 LSTM 对问题文本和答案文本分别编码,再通过双向注意力机制同时计算问题文本和答案文本的情感权重,最后通过情感权重计算得到问答型评论的情感匹配信息。实验结果表明,提出的方法在问答情感分类任务上达到了 75.5% 的准确率和 61.4% 的 F1 值,相较于其他基准方法有明显的提升。

关键词 情感分类,注意力机制,问答

中图分类号 TP391 文献标识码 A DOI 10.11896/j.issn.1002-137X.2019.07.024

Sentiment Classification Towards Question-Answering Based on Bidirectional Attention Mechanism

SHEN Chen-lin ZHANG Lu WU Liang-qing LI Shou-shan

(School of Computer Science & Technology, Soochow University, Suzhou, Jiangsu 215006, China)

Abstract Sentiment classification is a fundamental task in natural language processing, which aims at inferring the sentiment polarity of a given text. Previous studies for sentiment classification, mainly focus on sentence, document and tweet text styles. Different from these researches, this paper focused on a novel text style, i. e., question-answering (QA) review, for sentiment classification. Firstly, a large-scale and high-quality QA review corpus was collected and built. Then, a bidirectional attention neural network for QA sentiment classification was proposed. Specifically, the question and answer text with Bi-LSTM were encoded respectively. After that, sentiment weights in question and answer text were calculated synchronously by employing bidirectional attention mechanism. Finally, the sentiment matching representation for each QA review with sentiment weights can be obtained. Empirical studies show that the proposed approach achieves a great result (75.5% in Accuracy and 61.4% in Macro F1), and has remarkable improvement compared with other baselines.

Keywords Sentiment classification, Attention mechanism, Question-Answering

1 引言

情感分析又称意见挖掘,简单而言,是对带有情感色彩的主观性文本进行分析、处理、归纳和推理的过程^[1]。情感分析已经受到了来自工业界和学术界越来越多的关注,它有着广泛的应用,例如推荐系统^[2]和舆情监控^[3]。情感分类作为情感分析的一项基本任务,其主要目的是根据文本包含的情感倾向(如正面和负面)进行自动分类。在句子级^[4]和篇章级^[5]文本中,情感分类已经取得了非常好的性能。

近年来,随着互联网的快速普及和电子商务的飞速发展,网络购物已经成为大众主流的购物方式,随之而来的是用户在购物网站上发表了大量的产品评论。对这些评论文本进行情感分析对于研究用户反馈、进行商品推荐等具有十分重要的意义。

然而,在电商平台中,有大量的商家通过刷单的方式来提升自己店铺的信誉,这种方式带来了大量的虚假评论,对用户的购物体验以及平台的公平性有着非常大的负面影响。因此,最近一种新颖的面向用户的问答型评论方式出现在诸如淘宝、京东和亚马逊等各大电商平台上。这种面向用户的问答型评论方式由潜在的买家针对特定的商品提出关心的问题,平台根据用户的信誉值随机选出已购买此商品的高质量用户来回答相应的问题。相比于传统的评论方式,这种问答型的评论方式能很大程度上避免虚假评论,并且用户的回答更可信、更具体。但是,目前仍没有相关工作针对问答型评论展开情感分析研究。

例 1 问题:手机电池耐用不?玩游戏卡么?

答案:电池挺好的,很耐用。

收稿日期:2018-06-12 返修日期:2018-10-07 本文受国家自然科学基金(61331011,61375073)资助。

沈忱林(1993-),男,硕士生,CCF 学生会员,主要研究方向为自然语言处理、情感分析,E-mail:clshen@stu.suda.edu.cn;张璐(1994-),女,硕士生,主要研究方向为自然语言处理、情感分析;吴良庆(1995-),男,硕士生,主要研究方向为自然语言处理、情感分析;李寿山(1980-),男,教授,主要研究方向为自然语言处理、情感分析,E-mail:lishoushan@suda.edu.cn(通信作者)。

例2 问题:这款笔记本很耗电吗?

答案:不会啊。

处理问答情感分类任务的一种最直接的方式就是沿用传统的情感分类方法,但是传统的情感分类方法不能直接应用于问答情感分类任务,主要原因如下:

1)问答型评论中的问题文本和答案文本是两个独立的单元,而不是同一个词序列。在例1中,句子“电池挺好哒,很耐用。”与句子“玩游戏卡么?”没有直接的上下文联系,而与句子“手机电池耐用不?”有真正的上下文依赖关系。因此,如果直接将问题文本和答案文本拼接为一个序列,问题和答案之间的情感匹配关系将很难被捕捉到。

2)在问答情感分类任务中,尽管大部分的情感极性由答案文本表达,但是问题文本对于推断最终的情感极性也具有十分重要的作用。在例2中,仅仅通过答案文本“不会啊。”很难判断这条问答型评论的情感极性,但是加入问题文本中的信息“这款笔记本很耗电吗?”,我们就能轻易地推断出这条问答型评论的情感极性为正面。因此,在问答情感分类任务中,应同时考虑问题文本和答案文本中的信息以推断评论的情感极性。

为了解决问答情感分类任务的挑战,本文提出了一种基于双向注意力机制的神经网络方法来处理问答情感分类任务,通过注意力机制同时捕捉问题文本和答案文本中的情感匹配信息。本文主要的贡献为:1)首次提出问答情感分类任务,并构建了大规模的面向问答情感分类任务的语料库;2)提出了一种新颖的基于双向注意力机制的神经网络方法。

本文第2节介绍情感分类领域的一些相关工作;第3节介绍语料收集与标注工作;第4节详细介绍本文提出的基于双向注意力机制的问答情感分类方法;第5节详细介绍实验结果和分析;最后总结全文,并介绍下一步的工作。

2 相关工作

情感分类任务已取得不少成果,以往的情感分类相关工作主要可以划分为词语级、篇章级和属性级。

词语级情感分类的相关工作开展较早,早期的词语级情感分类任务主要预测词语的情感极性。Turney^[6]选取情感种子词,通过计算文本关键词与种子词的点互信息来判断词语的情感极性。由于深度学习的流行,近期的相关工作倾向于为每个词语学习合适的词向量,Tang等^[7]设计了一种神经网络模型,通过在损失函数中加入文本情感极性的信息为词语学习词向量。

篇章级情感分类的相关研究已经持续了相当长的时间。Matsumoto等^[8]通过文本挖掘技术提取篇章中的高频词序列和依存树信息,以进行情感分类。Zhou等^[9]提出了一种表示学习方法,在源语言和目标语言中同时学习文本的向量表示来进行情感分类。除了以上全监督学习的方法,一些半监督方法^[10-11]也被用于篇章级情感分类任务,并且取得了不错的效果。

属性级情感分类是一个细粒度的情感分类任务,其目的是给定一段评论文本和一个特定属性,针对这一特定属性,判断该评论文本包含的情感极性。传统的方法主要通过大量的

特征(如情感词典、POS特征等)进行情感分类^[12]。近期,基于注意力机制的神经网络方法^[13-14]在属性级情感分类任务上表现出了非常强大的性能。

不同于以上的所有研究,本文针对全新的问答型评论文本展开情感分类研究。据我们所知,本研究是情感分类任务在问答型评论文本上的首次尝试。

3 语料收集与标注

淘宝是中国最大的电商平台,我们从淘宝的“问大家”板块收集了10000条数码领域的问答型评论。我们通过多次的小规模标注,总结并制定了标注规范。标注规范中定义了4个情感类别:正面、负面、中性和冲突。中性是指问答型评论不包含正面情感或负面情感。冲突是指问答型评论同时包含正面情感和负面情感。

标注规范主要分为两部分,其中一部分是判断问答型评论的情感是否为中性,具体如下:

1)若问答型评论中的问题与答案不匹配,则该问答型评论的情感被视为中性。

例3 问题:这款手机屏幕清晰么?

答案:电池很耐用哦。

2)若问答型评论的答案中表现出不确定的表述,则该问答型评论的情感被视为中性。

例4 问题:手机的通话质量怎么样?

答案:我不清楚啊,给我爸买的。

3)若问答型评论的答案中只包含客观的陈述,则该问答型评论的情感被视为中性。

例5:问题:手机是什么系统?

答案:安卓。

4)若问答型评论中提及了多个产品,则该问答型评论的情感被视为中性。

例6 问题:这款手机和iPhone7哪个好?

答案:各有各的好吧。

另一部分的标注规范主要判别问答型评论的情感为正面还是负面,具体如下:

5)若问答型评论的答案中针对提出的问题表现出“很满意”“非常好”等积极的情感表述,则该问答型评论的情感被视为正面。

例7 问题:电脑性能怎么样?

答案:非常给力,打游戏很顺畅。

6)若问答型评论的答案中针对提出的问题表现出“太差了”“好失望”等消极的情感表述,则该问答型评论的情感被视为负面。

例8 问题:手机的像素OK么?

答案:太差了,拍出来都是模糊的!

7)当问答型评论的情感仅通过答案文本无法确定时,我们可以通过整个问答型评论(包括问题和答案)来最终确定该问答型评论的情感。例9的问答型评论包含正面情感,例10的问答型评论包含负面情感。

例9 问题:玩游戏的时候手机会发热么?

答案:不会的。

例 10 问题:这款电脑是不是玩网游很顺畅,一点也不卡?

答案:No!

对于每条问答型评论,我们安排了两位标注人员进行标注,一致性检验 kappa 值为 0.84。为了解决两位标注人员标注不一致的情况,我们安排了一位专家来对标注结果进行校对,以确保标注的一致性。标注好的数据集的情感类别分布如表 1 所列。

表 1 已标注语料中的情感类别分布

Table 1 Sentimental category distribution of annotated corpus

情感类别	数量
正面	3807
负面	1017
冲突	528
中性	4648

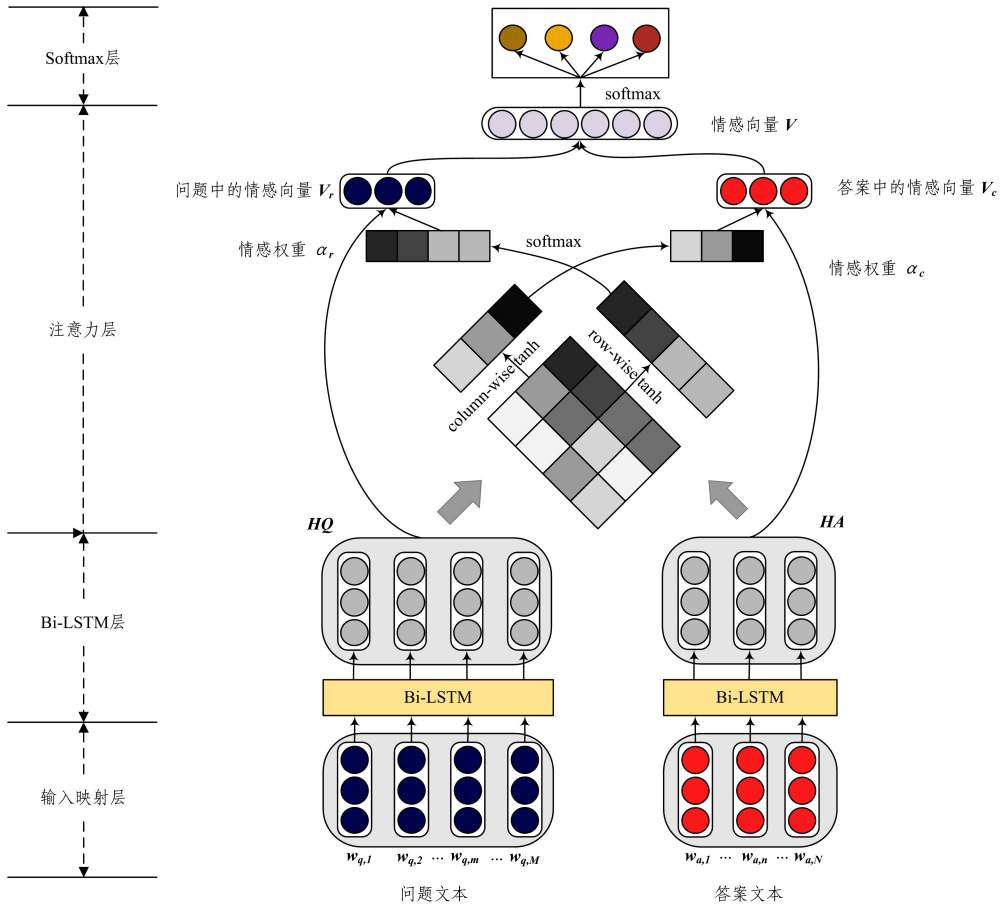


图 1 基于双向注意力机制的问答情感分类方法模型

Fig. 1 Model of bidirectional attention mechanism for QA sentiment classification

4.1 输入映射层

问答型评论的问题文本和答案文本可视为词语的 one-hot 表示序列,如下所示:

$$S_q = [\omega_{q,1}, \omega_{q,2}, \dots, \omega_{q,m}, \dots, \omega_{q,M}] \quad (1)$$

$$S_a = [\omega_{a,1}, \omega_{a,2}, \dots, \omega_{a,n}, \dots, \omega_{a,N}] \quad (2)$$

其中, $\omega_{q,m} \in \mathbb{R}^{|V|}$ 表示问题文本中第 m 个词基于词汇表的 one-hot 表示, M 是问题文本 S_q 的句子长度, $\omega_{a,n} \in \mathbb{R}^{|V|}$ 表示答案文本中第 n 个词基于词汇表的 one-hot 表示, N 是问题文本 S_a 的句子长度, $|V|$ 是词汇表 V 的大小。

4 基于双向注意力机制的问答情感分类方法

不同于传统的情感分类任务,面向问答文本的情感分类任务不能简单地将问题文本和答案文本拼接为一整个序列来处理,因此本文提出了基于双向注意力机制的神经网络方法来解决问答情感分类任务。模型结构如图 1 所示。

- 1)输入映射层:将问题文本和答案文本中的词语分别转化为词向量作为神经网络的输入。
- 2)Bi-LSTM层:分别采用双向 LSTM 得到问题文本和答案文本的高层语义信息。
- 3)注意力层:通过注意力机制分别从问题文本和答案文本中提取重要的情感匹配信息。
- 4)softmax层:通过 softmax 层对问答型评论的表示向量进行情感分类。

为了捕捉词语的语义信息,需要将问答型评论中的问题文本和答案文本包含的词语分别映射为词向量,公式如下:

$$\mathbf{x}_{q,m} = \mathbf{E}_w \cdot \omega_{q,m} \quad (3)$$

$$\mathbf{x}_{a,n} = \mathbf{E}_w \cdot \omega_{a,n} \quad (4)$$

其中, $\mathbf{E}_w \in \mathbb{R}^{d \times |V|}$ 为词向量矩阵, d 是词向量的维度, $\mathbf{x}_{q,m}$ 和 $\mathbf{x}_{a,n}$ 分别表示问题文本和答案文本中词语转化的词向量表示。

4.2 Bi-LSTM 层

LSTM 是 Hochreiter 等^[15]提出的改进的循环神经网络,包含输入门、遗忘门和输出门。为了得到文本序列中过去和

未来的上下文信息,本文采用双向 LSTM 分别得到问题文本和答案文本的高层语义表示。首先以问题文本为例,具体步骤如下:

$$\vec{h}_{q,m} = \overrightarrow{LSTM}(x_{q,m}) \quad (5)$$

$$\overleftarrow{h}_{q,m} = \overleftarrow{LSTM}(x_{q,m}) \quad (6)$$

$$\mathbf{h}_{q,m} = \vec{h}_{q,m} \oplus \overleftarrow{h}_{q,m} \quad (7)$$

其中, $\mathbf{h}_{q,m}$ 为问题文本中词语 $x_{q,m}$ 的高层语义表示, \oplus 表示向量的拼接操作。

同样地,通过双向 LSTM 得到答案文本中词语 $x_{a,n}$ 的高层语义表示 $\mathbf{h}_{a,n}$:

$$\vec{h}_{a,n} = \overrightarrow{LSTM}(x_{a,n}) \quad (8)$$

$$\overleftarrow{h}_{a,n} = \overleftarrow{LSTM}(x_{a,n}) \quad (9)$$

$$\mathbf{h}_{a,n} = \vec{h}_{a,n} \oplus \overleftarrow{h}_{a,n} \quad (10)$$

4.3 注意力层

基于注意力机制的神经网络在机器翻译^[16]和图像识别^[17]等一系列任务中取得了突破进展。本文也采取注意力机制^[18-19]分别学习问题文本和答案文本中各词语的情感权重。

通过 4.2 节,可分别得到问题文本和答案文本的高层语义表示:

$$\mathbf{H}_q = [\mathbf{h}_{q,1}, \mathbf{h}_{q,2}, \dots, \mathbf{h}_{q,m}, \dots, \mathbf{h}_{q,M}] \quad (11)$$

$$\mathbf{H}_a = [\mathbf{h}_{a,1}, \mathbf{h}_{a,2}, \dots, \mathbf{h}_{a,n}, \dots, \mathbf{h}_{a,N}] \quad (12)$$

其中, \mathbf{H}_q 和 \mathbf{H}_a 分别表示问题文本和答案文本的高层语义表示序列。

为了获得问题文本和答案文本之间的语义交互信息,我们通过式(13)计算问题文本和答案文本之间语义交互信息的双向匹配矩阵:

$$\mathbf{M} = (\mathbf{H}_q)^\top \cdot (\mathbf{H}_a) \quad (13)$$

其中, $\mathbf{M} \in \mathbb{R}^{N \times M}$ 是包含了语义交互信息的双向匹配矩阵。

为了得到问答型评论中具体的情感信息,如图 1 所示,我们分别通过答案-问题注意力机制(Answer-to-Question Attention)和问题-答案注意力机制(Question-to-Answer Attention)计算问题文本和答案文本中词语的情感权重和情感向量表示。

答案-问题注意力机制:如图 1 所示,通过以下行式(row-wise)计算步骤,我们得到了问题文本中各词语的情感权重:

$$U_r = \tanh(W_r \cdot \mathbf{M}^\top) \quad (14)$$

$$\boldsymbol{\alpha}_r = \text{softmax}(w_r^\top \cdot U_r) \quad (15)$$

其中, $\boldsymbol{\alpha}_r$ 为衡量问题文本中词语情感重要程度的权重, W_r 和 w_r 为注意力机制的参数。通过情感权重 $\boldsymbol{\alpha}_r$ 可以计算得到问题文本中的情感向量:

$$\mathbf{V}_r = (\mathbf{H}_q) \cdot \boldsymbol{\alpha}_r \quad (16)$$

其中, \mathbf{V}_r 为问题文本中的情感向量表示。

问题-答案注意力机制:如图 1 所示,通过以下列式(col-

umn-wise)计算步骤,我们得到了答案文本中的各词语的情感权重:

$$U_c = \tanh(W_c \cdot \mathbf{M}) \quad (17)$$

$$\boldsymbol{\alpha}_c = \text{softmax}(w_c^\top \cdot U_c) \quad (18)$$

其中, $\boldsymbol{\alpha}_c$ 为衡量答案文本中词语情感重要程度的权重, W_c 和 w_c 为注意力机制的参数。通过情感权重 $\boldsymbol{\alpha}_c$, 可以计算得到答案文本中的情感向量:

$$\mathbf{V}_c = (\mathbf{H}_a) \cdot \boldsymbol{\alpha}_c \quad (19)$$

其中, \mathbf{V}_c 为答案文本中的情感向量表示。

最后,拼接问题文本中的情感向量和答案文本中的情感向量作为这条问答型评论的情感向量:

$$\mathbf{V} = \mathbf{V}_r \oplus \mathbf{V}_c \quad (20)$$

其中, \mathbf{V} 表示问答型评论文本的情感向量表示。

4.4 softmax 层

通过 4.3 节得到了问题文本和答案文本中的情感信息的向量 \mathbf{V} , 下面通过 softmax 层输出情感类别的分类概率:

$$\mathbf{p} = \text{softmax}(W_s \cdot \mathbf{V} + b_s) \quad (21)$$

其中, \mathbf{p} 是问答型评论样本的类别输出概率, W_s 和 b_s 是 softmax 层的权重和偏置。

4.5 训练与优化策略

本文采用交叉熵函数作为目标函数,定义如下:

$$L(\theta) = - \sum_{k=1}^K \sum_{c=1}^C y_k^c \cdot \hat{y}_k^c + \lambda \|\theta\|_2^2 \quad (22)$$

其中, K 表示训练样本的数目, C 表示目标类别的数目, y_k 表示第 k 个样本的正确标签, \hat{y}_k 表示第 k 个样本的预测标签, λ 是正则化系数, θ 代表所有参数。我们采用 Adam 优化算法^[20]对参数进行更新。

5 实验

5.1 实验设置

根据第 3 节的介绍,我们标注的数据集包含 10 000 条问答型评论。实验中,将此数据集随机分为训练集(每个类别的 70% 样本)、验证集(每个类别的 10% 样本)和测试集(每个类别的 20% 样本)。

表 2 LSTM 神经网络中的参数设置

Table 2 Setting of parameters in LSTM neural network

参数	值
词向量维度	100
LSTM 层输出维度	128
批大小	32
Dropout rate	0.2
迭代次数	20

我们采用 FudanNLP¹⁾ 工具进行分词,并采用 word2vec²⁾ 训练词向量。用于训练词向量的数据来自数码领域,共计 200 000 条问答型评论。实验中的 SVM 算法使用 libsvm³⁾ 开源包。LSTM 神经网络模型通过 Keras⁴⁾ 来实现,具体参数如表 2 所列。我们采用准确率(Accuracy)和 F1 值作为衡量情

¹⁾ <https://github.com/FudanNLP/fnlp/>

²⁾ <https://github.com/dav/word2vec/>

³⁾ <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>

⁴⁾ <http://Keras.io/>

感分类性能的评价指标。

5.2 实验结果

为了验证基于双向注意力机制的神经网络方法对于问答情感分类任务的有效性,我们对比了以下几种情感分类方法。

1)SVM(BOW):将问题文本和答案文本拼接作为一个序列,使用词袋(bag-of-words)特征,将支持向量机作为分类器。

2)SVM(EM):将问题文本和答案文本拼接作为一个序列,将词向量作为特征,将支持向量机作为分类器。

3)LSTM:将问题文本和答案文本拼接作为一个序列,将词向量作为特征,将 LSTM 作为分类器。

4)Bi-LSTM:将问题文本和答案文本拼接作为一个序列,将词向量作为特征,将双向 LSTM 作为分类器。

5)Uni-ATT Q:本文提出的神经网络方法,注意力层仅使用答案-问题注意力机制。

6)Uni-ATT A:本文提出的神经网络方法,注意力层仅使用问题-答案注意力机制。

7)Bi-ATT:本文提出的基于双向注意力机制的神经网络方法,注意力层同时使用了问题-答案注意力机制和答案-问题注意力机制。

表 3 展现了上述几种方法在问答情感分类任务上的分类性能。

通过比较表 3 中的数据可以发现:

1)神经网络方法在性能上明显优于基于 SVM 分类器的方法,这说明了神经网络方法在处理问答情感分类任务上的优越性。

2)将问题文本与答案文本分别作为输入的方法(Uni-ATT Q,Uni-ATT A 和 Bi-ATT)在性能上明显优于将问题文本与答案文本拼接的方法,这表明问答型情感分类任务不适合将问题文本与答案文本进行拼接处理。

3)本文提出的基于双向注意力机制的神经网络模型(Bi-ATT)相较于基于单向注意力机制的方法(Uni-ATT Q 和 Uni-ATT A)在性能上有明显的提升,这表明基于双向注意力机制的神经网络方法能有效地捕捉问题文本与答案文本中的情感匹配信息。

表 3 各方法在问答情感分类任务上的性能

Table 3 Performance of all approaches to QA sentiment classification task

	准确率	F1 值
SVM(BOW)	0.560	0.300
SVM(EM)	0.691	0.435
LSTM	0.715	0.562
Bi-LSTM	0.723	0.574
Uni-ATT Q	0.734	0.578
Uni-ATT A	0.741	0.586
Bi-ATT	0.755	0.614

为了进一步验证本文提出的基于双向注意力机制的神经网络方法在问答情感分类任务上的有效性,我们选取了其他几种最新的处理传统情感分类任务的方法进行比较。

1)CNN-Tensor:此方法由 Lei 等^[21]提出,能在句子级情

感分类任务上达到目前最好的性能。

2)ATT-LSTM:此方法由 Wang 等^[13]提出,能在属性级情感分类任务上达到目前最好的性能。实验中,我们忽略了属性信息,直接通过 LSTM 的隐层输出得到注意力权重。

3)BiMPM:此方法由 Wang 等^[22]提出,能在问答匹配任务上达到目前最好的性能。实验中,我们将问答匹配向量直接输入 softmax 分类器进行情感分类。

表 4 展现了以上几种方法与本文提出的基于双向注意力机制的神经网络方法在问答情感分类任务上的性能比较,从中可以发现:

1)BiMPM 与本文提出的方法(Bi-ATT)在性能上明显优于其他方法,这表明问答匹配机制在问答情感分类任务中的重要性。

2)本文提出的方法(Bi-ATT)的性能明显优于其他方法,这表明所提方法能有效地捕捉问题文本和答案文本之间的情感匹配信息。

表 4 本文方法与其他方法的比较

Table 4 Comparison between proposed approach and other baseline approaches

	准确率	F1 值
CNN-Tensor	0.734	0.576
ATT-LSTM	0.721	0.576
BiMPM	0.746	0.584
Bi-ATT	0.755	0.614

结束语 本文提出了一个全新的面向问答型评论的情感分类任务,同时为此任务构建了大规模的语料库。针对问答情感分类任务的独特性,本文提出了一种基于双向注意力机制的问答情感分类方法,该方法能有效地捕捉问题和答案之间的情感匹配信息。实验结果表明,本文所提方法能够显著提升问答情感分类的性能。

在下一步工作中,我们将探索其他深度学习模型,进一步提升问答情感分类的性能。此外,我们也将测试本文提出的方法在其他领域上的效果。

参考文献

- [1] ZHAO Y Y, QIN B, LIU T. Sentiment Analysis [J]. Journal of Software, 2010, 21(8): 1834-1848. (in Chinese)
赵妍妍,秦兵,刘挺. 文本情感分析 [J]. 软件学报, 2010, 21(8): 1834-1848.
- [2] ZHANG Y F, LAI G K, ZHANG M, et al. Explicit Factor Models for Explainable Recommendation Based on phrase-level Sentiment Analysis[C]//Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval. 2014:83-92.
- [3] CHAMBERS N, BOWEN V, GENCO E, et al. Identifying Political Sentiment between Nation States with Social Media[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015:65-75.
- [4] WANG R H, CUI X M, ZHOU W, et al. Research of Text Sentiment Classification Based on Improved Semantic Comprehension [J]. Computer Science, 2017, 44(S2):92-97. (in Chinese)

- 王日宏,崔兴梅,周炜,等.改进的基于语义理解的文本情感分类方法研究[J].计算机科学,2017,44(S2):92-97.
- [5] XU J C, CHEN D L, QIU X P, et al. Cached Long Short-Term Memory Neural Networks for Document-level Sentiment Classification[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016:1660-1669.
- [6] TURKEY P D. Thumbs up or Thumbs down?: Semantic Orientation Applied to Unsupervised Classification of Reviews[C]//Proceedings of the 40th Annual Meeting on Association for Computational Linguistics, 2002:417-424.
- [7] TANG D Y, WEI F R, YANG N, et al. Learning Sentiment Specific Word Embedding for Twitter Sentiment Classification[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, 2014:1555-1565.
- [8] MATSUMOTO S, TAKAMURA H, OKUMURA M. Sentiment Classification Using Word Sub-sequence and Dependency Sub-trees[C]//Proceedings of Pacific-Asia Conference on Knowledge Discovery and Data Mining, 2005:301-311.
- [9] ZHOU X J, WAN X J, XIAO J G. Cross-lingual Sentiment Classification with Bilingual Document Representation Learning[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, 2016:1403-1412.
- [10] LI S S, HUANG C R, ZHOU G D, et al. Employing Personal/Impersonal Views in Supervised and Semi-supervised Sentiment Classification[C]//Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics, 2010:414-423.
- [11] XIA R, WANG C, DAI X Y, et al. Co-training for Semi-supervised Sentiment Classification Based on Dual-view Bags-of-words Representation[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, 2015:1054-1063.
- [12] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemEval-2014 Task 4: Aspect Based Sentiment Analysis[C]//Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016), 2016:19-30.
- [13] WANG Y Q, HUANG M L, ZHAO L, et al. Attention-based LSTM for Aspect-level Sentiment Classification[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016:606-615.
- [14] 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, 2016:214-224.
- [15] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [16] LUONG T, PHAM H, MANNING D. Effective Approaches to Attention-based Neural Machine Translation[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, 2015:1412-1421.
- [17] PENG Y, HE X, ZHAO J. Object-part Attention Model for Fine-grained Image Classification[J]. IEEE Transactions on Image Processing, 2018, 27(3):1487-1500.
- [18] YANG Z C, YANG D Y, DYER C, et al. Hierarchical Attention Networks for Document Classification[C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016:1480-1489.
- [19] CUI Y M, CHEN Z P, WEI S, et al. Attention-over-attention Neural Networks for Reading Comprehension[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, 2017:593-602.
- [20] KINGMA D, BA J. Adam: A Method for Stochastic Optimization[C]//Proceedings of the 3rd International Conference on Learning Representations, 2015:1-15.
- [21] LEI T, BARZILAY R, JAAKKOLA T. Molding CNNs for Text: Non-linear, Non-consecutive Convolutions[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, 2015:1565-1575.
- [22] WANG Z G, HAMZA W, FLORIAN R. Bilateral Multi-perspective Matching for Natural Language Sentences[C]//Proceedings of the 2017 International Joint Conferences on Artificial Intelligence, 2017:4144-4150.