

# 基于注意力机制的交互式神经网络模型在细粒度情感分类中的应用

杨鹏<sup>1</sup> 杨青<sup>1</sup> 李志斌<sup>2</sup> 王扬<sup>1</sup>

<sup>1</sup>(国网天津市电力公司信息通信公司 天津 300010)

<sup>2</sup>(国网天津市电力公司 天津 300010)

**摘要** 细粒度情感分类是情感分析领域中的一个重要的任务。给定意见句和方面词,该任务的目标是识别该意见句关于给定方面词的情感极性。情感极性不仅与上下文语义相关,而且与方面词的语义也有密不可分的联系。现有的研究工作通常仅利用方面词语义来生成特定的上下文表示,忽略了对方面词本身的语义建模。针对该问题,提出一个基于注意力机制的交互式神经网络模型,可以同步进行上下文语义和方面词语义的交互式建模,进而更好地生成上下文和方面词的表示,提升情感分类的效果。分别在两个公开数据集上进行实验,并与现有的方法进行比较。实验结果表明,该模型取得了最好的性能。

**关键词** 细粒度 情感分类 交互式 注意力机制

中图分类号 TP3 文献标志码 A DOI:10.3969/j.issn.1000-386x.2020.07.021

## APPLICATION OF INTERACTIVE NEURAL NETWORK MODEL BASED ON ATTENTION MECHANISM IN FINE-GRAINED SENTIMENT CLASSIFICATION

Yang Peng<sup>1</sup> Yang Qing<sup>1</sup> Li Zhibin<sup>2</sup> Wang Yang<sup>1</sup>

<sup>1</sup>(Information Communication Company, State Grid Tianjin Electric Power Company, Tianjin 300010, China)

<sup>2</sup>(State Grid Tianjin Electric Power Company, Tianjin 300010, China)

**Abstract** Fine-grained sentiment classification is an important task of sentiment analysis field. Given an opinion sentence and an aspect term, the goal is to identify the sentiment polarity of the given aspect term. Therefore, both of the semantics of context and aspect term are related to the sentiment polarity. The existing works usually only use aspect term to generate specific context representation, and ignore the semantic modeling of aspect terms themselves. To solve this problem, this paper proposes an interactive neural network model based on attention mechanism. It could be used for interactive modeling of context semantics and aspect terms simultaneously, so as to better generate the representation of context and aspect terms and improve the effect of sentiment classification. We experimented on two open datasets and compared them with the existing methods. The experimental results show that the model achieves the best performance.

**Keywords** Fine-grained Sentiment classification Interactive Attention mechanism

## 0 引言

细粒度情感分类是情感分析领域中的一个重要任务,其目标是在给定意见句与评价方面(即评价对象)的基础上,结合句子上下文,识别评价方面的情感极性<sup>[1]</sup>。例如:给定意见句“这家餐厅饭菜很好,但是环

境一般,服务很糟糕!”,以及句子中包含的三个评价方面“饭菜”、“环境”、“服务”,综合评价方面与上下文的语义可知,三个评价方面对应的情感极性分别为正向、中性、负向。

细粒度情感分类是自然语言处理领域中一项基础性的工作,近年来受到国内外学者的广泛关注<sup>[4-9]</sup>。该任务的研究成果可以进一步应用于自动问答<sup>[2]</sup>、推

荐系统<sup>[3]</sup>等。传统的方法通常会构建情感词典或情感特征,并在此基础上采用 SVM 等机器学习方法进行情感分类<sup>[7-8]</sup>。但是,人工构建情感特征或情感词典通常需要投入大量的人力,进而导致模型的灵活性与泛化性较差,限制模型的性能。近年来,随着深度学习的发展,许多研究工作开始设计并使用神经网络结构来自动学习评价方面与上下文的低维语义表示<sup>[9-11]</sup>,相关的研究工作已经在细粒度情感分类的任务中取得了可观的效果。

结合细粒度情感分类的任务目标可知,为了得到更好的分类性能,必须充分挖掘评价方面以及其上下文的语义信息。Jiang 等<sup>[7]</sup>指出:40%的细粒度情感分类的错误是由于没有考虑评价方面而造成的。因此,近年来的研究工作更多地关注于如何在进行上下文语义建模的同时考虑评价方面的影响。Vo 等<sup>[9]</sup>将整个意见句分成三个组成部分,即评价方面、上文和下文,然后利用情感词典和池化函数来生成与评价方面相关的上下文特征。Tang 等<sup>[11]</sup>以评价方面为中心将句子分成两个部分,并使用两个长短期记忆模型(LSTM)对两部分分别进行语义建模,然后将两部分的语义表示进行组合,并用于情感分类。Wang 等<sup>[10]</sup>对评价方面设计了特殊的词向量,并将其与原始的词向量进行拼接,利用 LSTM 网络和注意力机制生成最终的语义表示。

上述研究工作已经意识到评价方面的重要性,并在建模上下文语义表示的过程中融合评价方面的语义,但都忽略了如何在不同上下文语境下对评价方面的语义进行建模。本文认为,只有同时对评价方面和上下文进行语义建模并实现语义相互增强才能真正提升情感分类的效果。例如,给定意见句“这台显示器的分辨率很高,但是价格也很高。”当“高”形容“分辨率”时,情感极性是正向,但形容“价格”时,情感极性则是负向。由此,如何联合建模评价方面和上下文的语义是本文主要解决的问题。一方面,考虑到评价方面和上下文的语义表示具有较强的相关性,本文分别对评价方面和上下文单独地建模语义,并结合注意力机制对两部分的语义进行交互学习;另一方面,考虑到评价方面和上下文通常由多个词语组成,而不同词语对最终的语义表示具有不同的贡献度,本文利用注意力机制,分别计算评价方面与上下文中词语的注意力权重,捕获重要词语的语义信息。

基于以上两方面的分析,本文提出了一种基于 LSTM 和注意力机制的交互式神经网络结构(简称:基于注意力机制的交互式神经网络模型)。首先,模型使用 LSTM 网络分别对评价方面和上下文分别进行语

义建模;随后,利用两个注意力机制分别捕获上下文中与评价方面有关的语义,以及评价方面中与上文相关的语义;最后,模型将评价方面和上下文的语义表示进行拼接,用于判断情感极性。为了证明模型的效果,本文在 SemEval 2014 的数据集上进行了实验。实验结果表明,本文模型可以更准确地建模评价方面和上下文语义,并取得最优的性能。

## 1 相关工作

细粒度情感分类是情感分析中的一个重要分支,相关的研究方法主要可以分为两类:基于机器学习的方法和基于神经网络的方法。

在基于机器学习的方法中,细粒度情感分类通常被视为文本分类问题。因此,诸如 SVM<sup>[12]</sup>等的文本分类方法可以在不考虑评价方面的情况下,进行情感极性的判断。这些方法主要关注如何提取情感词典、情感特征等来训练情感分类器<sup>[8,13]</sup>。尽管这些方法取得了一定的效果,但其性能在很大程度上依赖于手工特征的有效性,这极大地限制了模型的灵活性与泛化性。

近年来,随着神经网络的发展,递归神经网络<sup>[14]</sup>、循环神经网络<sup>[15]</sup>、层次 LSTM<sup>[16]</sup>等结构在情感分析领域取得了可观的效果。然而,这些方法仅使用上下文语义进行情感分类,而没有考虑评价方面的语义对情感分类的直接影响。

针对这一问题,Jiang 等<sup>[7]</sup>首次强调了评价方面在情感分类中的重要性,其认为 40%的情感分类错误是由于没有考虑评价方面造成的。为考虑评价方面的语义,Tang 等<sup>[15]</sup>设计了两个依赖于评价方面的 LSTM 分别对评价方面的上文和下文进行语义建模,进而自动考虑评价方面的语义信息。此外,Tang 等<sup>[11]</sup>还设计了由多个计算层组成的深度记忆网络实现对评价方面语义信息的整合,每一层都是一个基于上下文和基于位置的注意力模型,它先学习每个上下文中词语的重要性权重,再利用这些信息计算上下文的语义表示。Wang 等<sup>[10]</sup>在细粒度情感分类中探讨了评价方面与情感极性之间的潜在相关性,并设计了一种基于注意力的 LSTM,在给定不同的评价方面时,捕捉上下文中最重要的语义信息。

虽然上述方法均在一定程度上考虑了评价方面对上下文语义的影响,但并未对评价方面的语义进行单独建模。因此,本文构建了一个基于注意力机制的交互式神经网络模型,同时对评价方面和上下文的语义信息进行学习。由此,本文模型可以得到更恰当的用于细粒度情感分类的语义表示。

## 2 基于注意力机制的交互式神经网络模型

### 2.1 问题介绍

给定一段长度为  $n$  的意见句  $C = \{c_1, c_2, \dots, c_n\}$ , 其中  $c_i$  表示意见句中的第  $i$  个词, 以及一个长度为  $k$  的评价方面  $T = \{t_1, t_2, \dots, t_k\}$ , 其中  $t_i$  表示评价方面中的第  $i$  个词。细粒度情感分析的目标为根据上下文判断给定的评价方面的情感极性  $s$ 。

### 2.2 模型结构

基于注意力机制的交互式神经网络模型的整体模型图如图 1 所示。

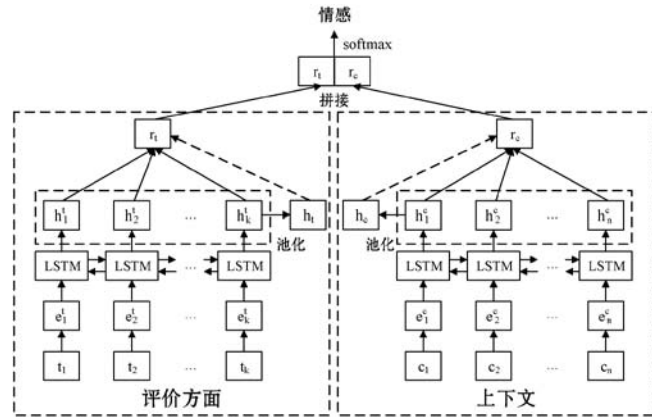


图 1 基于注意力机制的交互式神经网络模型

为了获取词语的语义表示, 本文首先将输入意见句和评价方面中的每个单词映射到一个低维稠密的词向量  $e$  中, 具体如下式所示:

$$e_i^t = t_i \cdot M \quad (1)$$

$$e_i^c = c_i \cdot M \quad (2)$$

式中:  $M \in \mathbf{R}^{v \times d}$  表示词向量的词典,  $v$  和  $d$  分别代表词典大小与词向量维数。

接着, 在词向量的基础上, 模型使用两个 LSTM 网络分别学习上下文和评价方面的隐藏词义表示。因为句子中的单词间通常具有较强的依赖关系与时序关系, 使用 LSTM 进行语义编码可以在捕获长期依赖的同时, 避免梯度消失的问题。以评价方面为例, 给定时刻的词向量  $e_j^t$ 、上一时刻的记忆单元状态  $u_{j-1}^t$  以及上一时刻的隐藏状态  $h_{j-1}^t$ , 则  $j$  时刻的记忆单元状态  $u_j^t$  和隐藏状态  $h_j^t$  可以由下式计算得到:

$$i_j^t = \sigma(\mathbf{W}_i^{te} \cdot e_j^t + \mathbf{W}_i^{th} \cdot h_{j-1}^t + \mathbf{b}_i^t) \quad (3)$$

$$f_j^t = \sigma(\mathbf{W}_f^{te} \cdot e_j^t + \mathbf{W}_f^{th} \cdot h_{j-1}^t + \mathbf{b}_f^t) \quad (4)$$

$$o_j^t = \sigma(\mathbf{W}_o^{te} \cdot e_j^t + \mathbf{W}_o^{th} \cdot h_{j-1}^t + \mathbf{b}_o^t) \quad (5)$$

$$\hat{u}_j^t = \tanh(\mathbf{W}_u^{te} \cdot e_j^t + \mathbf{W}_u^{th} \cdot h_{j-1}^t + \mathbf{b}_u^t) \quad (6)$$

$$u_j^t = f_j^t \odot u_{j-1}^t + i_j^t \odot \hat{u}_j^t \quad (7)$$

$$h_j^t = o_j^t \odot \tanh(u_j^t) \quad (8)$$

式中:  $i_j^t, f_j^t, o_j^t$  分别代表输入门、遗忘门、输出门, 用于控制信息的传递;  $\sigma$  为 Sigmoid 激活函数;  $\mathbf{W}$  和  $\mathbf{b}$  为网络参数, 分别代表权重矩阵和偏移量; “ $\cdot$ ” 代表矩阵乘法; “ $\odot$ ” 代表矩阵元素乘法。

由于 LSTM 是以序列的方式进行语义建模, 因此  $h_j^t$  中仅包含了  $j$  时刻之前的语义信息。为了同时得到前向和后向的上下文语义, 本文使用双向 LSTM 结构, 具体计算方法如下式所示:

$$\vec{h}_j^t = \mathcal{H}^t(e_j^t, \vec{e}_{j-1}^t) \quad \overleftarrow{h}_j^t = \mathcal{H}^t(e_j^t, \overleftarrow{e}_{j+1}^t) \quad (9)$$

$$h_j^t = [\vec{h}_j^t; \overleftarrow{h}_j^t] \quad (10)$$

由此, 通过上述计算可以得到评价方面的隐藏语义表示  $H^t = \{h_1^t, h_2^t, \dots, h_k^t\}$ 。同理, 根据上述方法可以得到上下文的隐藏语义表示  $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$ 。

为了交互式地学习上下文和评价方面表示, 并挖掘其中重要的信息, 本文在 LSTM 的基础上构建了两个注意力层:

$$c_{\text{avg}} = \sum_{i=1}^n h_i^c / n \quad (11)$$

$$t_{\text{avg}} = \sum_{i=1}^k h_i^t / k \quad (12)$$

首先, 对 LSTM 得到的隐藏状态进行平均池化, 得到上下文和评价方面的初始整体表示, 分别记为  $c_{\text{avg}}$  和  $t_{\text{avg}}$ 。

接着, 本文以上下文和评价方面的初始整体表示作为输入, 利用注意力机制选择有助于判断情感极性的重要信息。本文考虑了来自评价方面对上下文的影响以及来自上下文对评价方面的影响。以评价方面对上下文的注意力机制为例, 给定上下文的隐藏表示表示为  $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$  和评价方面的初始整体表示  $t_{\text{avg}}$ , 可通过下式生成注意力向量:

$$\alpha_i = \frac{\exp(\mathcal{F}(h_i^c, t_{\text{avg}}))}{\sum_{j=1}^n \exp(\mathcal{F}(h_j^c, t_{\text{avg}}))} \quad (13)$$

式中:  $\mathcal{F}$  是用于计算上下文向量重要程度的得分函数, 该函数的计算方法如下式所示:

$$\mathcal{F}(h_i^c, t_{\text{avg}}) = \tanh(h_i^c \cdot \mathbf{W}_c + t_{\text{avg}}^T + \mathbf{b}_c) \quad (14)$$

式中:  $\mathbf{W}_c$  和  $\mathbf{b}_c$  是待学习的参数,  $\tanh$  是非线性激活函数,  $t_{\text{avg}}^T$  表示向量  $t_{\text{avg}}$  的转置。同理, 由下式计算可以得到上下文对评价方面的注意力向量:

$$\beta_i = \frac{\exp(\mathcal{F}(h_i^t, c_{\text{avg}}))}{\sum_{j=1}^k \exp(\mathcal{F}(h_j^t, c_{\text{avg}}))} \quad (15)$$

在计算注意力权重的基础上, 利用下式可以得到上下文和评价方面的最终语义表示, 该表示包含了有

助于判断情感极性的信息。

$$\mathbf{r}_c = \sum_{i=1}^n \alpha_i h_i^c \quad (16)$$

$$\mathbf{r}_l = \sum_{i=1}^k \beta_i h_i^l \quad (17)$$

最后,将评价方面向量  $\mathbf{r}_l$  和上下文向量  $\mathbf{r}_c$  进行拼接,得到向量  $\mathbf{d}$ ,并将此向量输入到上层的分类器中,用于情感极性的判断。如下式所示,本文使用非线性层将  $\mathbf{d}$  投影到一个维度与情感极性种类数相同的向量空间中。

$$x = \tanh(\mathbf{W}_l \cdot \mathbf{d} + \mathbf{b}_l) \quad (18)$$

式中: $\mathbf{W}_l$  和  $\mathbf{b}_l$  分别代表权重矩阵和偏置向量。最后,通过下式计算情感极性的概率分布。

$$y_i = \frac{\exp(x_i)}{C} \quad (19)$$

式中: $C$  为情感极性的类别数。在测试过程中,模型将选取概率最大的标签作为最终的结果。

### 2.3 模型训练

在本文提出的基于注意力机制的交互式神经模型中,需要进行优化的参数  $\Theta$  包括:LSTM 网络中权重矩阵集合  $[\mathbf{W}_i^{te}, \mathbf{W}_i^{th}, \mathbf{W}_f^{te}, \mathbf{W}_f^{th}, \mathbf{W}_o^{te}, \mathbf{W}_o^{th}, \mathbf{W}_u^{te}, \mathbf{W}_u^{th}]$ 、偏移量集合  $[\mathbf{b}_i^t, \mathbf{b}_f^t, \mathbf{b}_o^t, \mathbf{b}_u^t]$ ,注意力层中的权重矩阵集合  $[\mathbf{W}_c, \mathbf{W}_l]$ 、偏移量集合  $[\mathbf{b}_c, \mathbf{b}_l]$ ,Softmax 层中的  $[\mathbf{W}_l, \mathbf{b}_l]$  以及需要进行微调的预训练词向量。

为进行模型参数优化,本文选取基于  $l_2$  范式的交叉熵作为损失函数,如下式所示。

$$J = - \sum_{i=1}^c y_i \log(\hat{y}_i) + \lambda_r \left( \sum_{\theta \in \Theta} \theta^2 \right) \quad (20)$$

式中: $y_i$  代表类别的真实值,是一个 one-hot 向量; $\hat{y}_i$  表示模型的预测概率,由式(19)计算得到。 $\lambda_r$  是  $l_2$  范式的正则化系数。本文采用反向传播的方法进行梯度的计算,通过下式更新所有的参数  $\Theta$ 。

$$\Theta = \Theta - \lambda_l \frac{\partial J(\Theta)}{\partial \Theta} \quad (21)$$

式中: $\lambda_l$  为学习率。为了避免过拟合,本文采用 dropout 策略。

## 3 实验

### 3.1 数据集

为了验证模型的有效性,本文使用 SemEval 2014 任务 4 中的数据集进行实验。该数据集包含两类评论数据,分别为:餐馆评论数据和笔记本评论数据。数据集中包含的情感极性分别为正向、负向和中性。数据

集的基本统计情况如表 1 所示。

表 1 数据集统计

种类	正向		中性		负向	
	训练	测试	训练	测试	训练	测试
餐馆	2 164	728	637	196	807	196
笔记本	994	341	464	169	870	128

### 3.2 实验设置

本文实验中,词向量由预训练的词向量 GloVe 初始化。模型中所有的权重矩阵通过对均匀  $U(-0.1, 0.1)$  分布采样进行初始化,所有的偏移量均设置为 0。词向量维度设置为 300, LSTM 隐藏层和注意力向量的维度都设置为 400。在训练过程中,本文使用 Momentum 方法训练参数,并将损失函数中  $l_2$  归一化系数设置为  $10^{-5}$ , dropout 比例设置为 0.3。

### 3.3 对比方法

为了全面评估模型的性能,本文将提出的模型与如下对比方法进行比较:

多数法:多数法是一种基本的对比方法,它简单地将训练集中出现次数最多的情感极性分配给测试集中的每个样本。

LSTM 模型<sup>[10]</sup>:模型仅使用一个 LSTM 网络对上下文进行建模,并获取每个单词的隐藏表示。然后将所有词隐藏状态的平均值作为最终表示,输入 Softmax 函数进行情感极性的分类。

TD-LSTM 模型<sup>[15]</sup>:模型采用两个 LSTM 网络分别对评价方面的上文和下文进行建模,并将两部分的隐藏表示进行拼接,输入 Softmax 函数进行情感极性的预测。

AE-LSTM 模型<sup>[10]</sup>:模型首先使用 LSTM 网络对上下文中的单词进行建模,并使用方面嵌入向量来表示评价方面。随后,模型将上下文的隐藏状态与方面嵌入向量相结合,并结合注意力机制生成面向方面的语义表示,最终将该表述输入 Softmax 层进行情感分类。

ATAE-LSTM 模型<sup>[10]</sup>:模型是在 AE-LSTM 模型的基础上进行构建的,其通过将方面嵌入附加到每个单词嵌入向量中表示上下文来进一步增强方面嵌入的效果。

### 3.4 评价指标

为了对情感分类的性能进行评估,本文采用准确度作为评价指标。准确度的公式定义如下:

$$Acc = \frac{T}{N} \quad (22)$$

式中: $T$  代表预测正确的样本的数量, $N$  代表样本的总

数。准确度衡量的是所有样本中预测正确样本的百分比。一般来说,准确度越高的模型,性能越好。

### 3.5 实验结果

表 2 展示了本文模型与其他对比方法的性能比较。可见,多数法的性能最差,但该方法的结果也侧面地反映了在餐馆和笔记本的测试集中,出现次数最多的极性分别占了 53.5% 和 65.0%。而其他方法均以 LSTM 模型为基础,并在性能上明显优于多数法,这说明 LSTM 可以自动学习句子中与情感相关的语义特征,进而为情感分类带来提升。

表 2 本文模型与对比方法的性能比较

方法	餐馆	笔记本
多数法	0.535	0.650
LSTM	0.743	0.665
TD-LSTM	0.756	0.681
AE-LSTM	0.762	0.689
ATAE-LSTM	0.772	0.687
本文方法	<b>0.799</b>	<b>0.716</b>

此外,LSTM 方法是所有基于神经网络的方法中性能最差的一种方法,因为它同等地对待上下文和方面词,而并没有充分地考虑方面信息。由于 TD-LSTM 是从标准的 LSTM 模型发展起来的,并使用评价方面来对左右上下文进行编码,因此在两个数据集上,TD-LSTM 模型的性能分别比 LSTM 高出 1% 以上。

进一步地,由于注意力机制的引入,AE-LSTM 模型和 ATAE-LSTM 模型的性能均超过了 TD-LSTM 模型。它们可以在评价方面的监督下更好地捕获上下文中的重要信息,为细粒度情感分类生成更合理的上下文表示。此外,AE-LSTM 和 ATAE-LSTM 通过引入方面嵌入进一步增强了对评价方面的建模,这也是性能提升的原因之一。与 AE-LSTM 相比,ATAE-LSTM 通过词向量拼接增强了上下文与方面词之间的交互作用,因此具有更好的性能。

本文模型通过交互式学习评价方面和上下文表示,进一步提升了评价方面的重要性。从表 2 可以看到,本文模型在所有对比方法中取得了最好的性能。与 ATAE-LSTM 模型相比,本文模型在两个数据集上的性能分别提高了 2.7% 和 2.9%。本文模型取得性能提升的主要原因是模型使用两个相互影响的注意力网络对评价方面和上下文进行建模,得到特定的语义表示,并将结果进行拼接用于情感分类。通过这种方法,模型可以更恰当地得到结合评价方面语义的上下文表示。

### 3.6 模型分析

为了进一步分析本文模型的性能,我们对 LSTM 隐藏层维度,以及评价方面和上下文的初步整体表示的生成方法进行分析。

表 3 展示了隐藏层维度对模型性能的影响。由表可见,模型的性能随着隐藏层维度的增加呈现出先上升后下降的趋势,这说明 LSTM 可以很好地学习句子的语义信息,并且随着隐藏层维度的增加,LSTM 可学习的特征也变得更加丰富,进而使得模型性能得到提升。但是当维度增加超过一定的范围,LSTM 捕获的特征会变得冗余,使得模型性能降低。

表 3 LSTM 维度对模型性能的影响

LSTM 维度	餐馆	笔记本
300	0.798	0.707
400	<b>0.799</b>	<b>0.716</b>
500	0.789	0.713

此外,也可以选取多种方法获取评价方面和上下文的初步整体表示。表 4 展示了平均池化和选取最后一个隐藏表示作为整体表示的结果。由表可见,两种方法的性能相差不多,但是平均池化的方法取得了更好的性能。总体来看,不论采用哪种方法,模型的性能总是优于对比方法。

表 4 初步整体表示的生成方法比较

整体表示结果	餐馆	笔记本
平均池化	<b>0.799</b>	<b>0.716</b>
最后的隐藏表示	0.794	0.708

综上,本文模型在一定程度上提升了细粒度情感分类的性能。

## 4 结 语

本文针对细粒度情感分类的任务开展相关研究,并提出基于注意力机制的交互式神经网络模型。该模型主要使用了两个注意力机制来交互式地学习评价方面和上下文的语义,并捕捉两部分中与情感分类有关的重要语义。为了验证模型性能,本文在两个数据集上进行了实验。实验表明,本文方法取得了最优的性能,这很好地说明了评价方面对细粒度情感分类任务中的重要性,以及交互式地生成融合方面信息的上下文语义和融合上下文的方面语义对提升情感分类性能的重要作用。

## 参 考 文 献

- [ 1 ] Liu B. Sentiment analysis and opinion mining[M]//Synthesis Lectures on Human Language Technologies. Morgan & Claypool, 2012.
- [ 2 ] Shen C L, Sun C L, Wang J J, et al. Sentiment classification towards question-answering with hierarchical matching network[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018:3654 – 3663.
- [ 3 ] Wang J Y, Bao B K, Xu C S. Sentiment-aware multi-modal recommendation on tourist attractions [ C ]//International Conference on Multimedia Modeling, 2019:3 – 16.
- [ 4 ] 陈自岩,黄宇,王洋,等.一种利用语义相似特征提升细粒度情感分析方法[J]. 计算机应用与软件,2017,34(3): 33 – 36,86.
- [ 5 ] 卿勇,刘梦娟,薛浩,等.OPEN:一个基于评论的商品特征抽取及情感分析框架[J]. 计算机应用与软件,2018,35(1):65 – 71.
- [ 6 ] 李佳丽,封化民,潘扬,等.基于卷积神经网络的情感分析算法[J]. 计算机应用与软件,2018,35(4):287 – 292.
- [ 7 ] Jiang L, Yu M, Zhou M, et al. Target-dependent twitter sentiment classification [ C ]//Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics; Human Language Technologies, 2011.
- [ 8 ] Pérez-Rosas V. Learning sentiment lexicons in Spanish [ C ]//Eighth International Conference on Language Resources and Evaluation (LREC-2012). 2012.
- [ 9 ] Vo D T, Zhang Y. Target-dependent twitter sentiment classification with rich automatic features [ C ]//Proceedings of the 24th International Conference on Artificial Intelligence. AAAI Press, 2015:1347 – 1353.
- [ 10 ] Wang Y Q, Huang M L, Zhu X Y, et al. Attention-based LSTM for aspect-level sentiment classification [ C ]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016.
- [ 11 ] 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.
- [ 12 ] Pang B, Lee L, Vaithyanathan S. Thumbs up?: sentiment classification using machine learning techniques [ C ]//Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing, 2002:79 – 86.
- [ 13 ] Mohammad S M, Kiritchenko S, Zhu X D. Nrc-canada: Building the state-of-the-art in sentiment analysis of tweets [ EB ]. arXiv preprint arXiv:1308.6242, 2013.
- [ 14 ] Qian Q, Tian B, Huang M, et al. Learning tag embeddings and tag-specific composition functions in recursive neural network [ C ]//Meeting of the Association for Computational Linguistics & International Joint Conference on Natural Language Processing. 2015.
- [ 15 ] Tang D Y, Qin B, Feng X C, et al. Effective lstms for target-dependent sentiment classification [ C ]//International Conference on Computational Linguistics, 2016:3298 – 3307.
- [ 16 ] Ruder S, Ghaffari P, Breslin J G. A hierarchical model of reviews for aspect-based sentiment analysis [ EB ]. arXiv preprint arXiv:1609.02745, 2016.
- ~~~~~
- (上接第129页)
- [ 8 ] Bai D D, Wang C Q, Zhang B, et al. CNN feature boosted SeqSLAM for real-time loop closure detection [ J ]. Chinese Journal of Electronics, 2018, 27(3):488 – 499.
- [ 9 ] Zhou B L, Lapedriza A, Xiao J X, et al. Learning deep features for scene recognition using places database [ C ]//Proceedings of the 27th International Conference on Neural Information Processing Systems—Volume 1, 2014:487 – 495.
- [ 10 ] 徐建鹏,卜凡亮.基于 Faster-RCNN 神经网络的回环检测优化算法 [ J ]. 计算机应用研究,2019,36(12):3628 – 3631.
- [ 11 ] Korrapati H, Mezouar Y. Multi-resolution map building and loop closure with omnidirectional images [ J ]. Autonomous Robots, 2016, 41(4):967 – 987.
- [ 12 ] Jégou H, Douze M, Schmid C, et al. Aggregating local descriptors into a compact image representation [ C ]//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE, 2010.
- [ 13 ] Angeli A, Filliat D, Doncieux S, et al. Fast and incremental method for loop-closure detection using bags of visual words [ J ]. IEEE Transactions on Robotics, 2008, 24(5): 1027 – 1037.
- [ 14 ] Zhou B, Khosla A, Lapedriza A, et al. Places: An image database for deep scene understanding [ J ]. Journal of Vision, 2017, 17(10):296.
- [ 15 ] The Norwegian Broadcasting Corporation: The NordlandsbanenDataset [ OL ]. <http://nrkbeta.no/2013/01/15/nordlandsbanen-minute-by-minute-season-by-season/>.
- [ 16 ] Schroff F, Kalenichenko D, Philbin J. FaceNet: A unified embedding for face recognition and clustering [ C ]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015:815 – 823.
- [ 17 ] Arandjelović R, Gronat P, Torii A, et al. NetVLAD: CNN architecture for weakly supervised place recognition [ J ]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018,40(6):1437 – 1451.
- [ 18 ] Shannon C E. A mathematical theory of communication [ J ]. Bell Labs Technical Journal, 1948, 27(4):379 – 423.