

基于字句动态特征和自注意力的情感分析方法

刘 强^{1,2}, 朱金森¹, 赵龙龙¹, 沙宇晨¹, 刘尚东^{1,2}, 季一木^{1,2}

(1. 南京邮电大学计算机学院, 南京 210023; 2. 南京邮电大学高性能计算与大数据处理研究所, 南京 210023)

摘要: 针对评论情感分析任务中文本长度失衡引起的特征稀疏、特征缺失和提取信息不全等问题, 提出了一种基于字句动态特征和自注意力的情感分析方法。首先基于预训练模型对评论进行动态特征编码, 使用句向量对不足固定长度的部分进行补充, 并表征超出的截断部分, 以缓解批训练下文本尺寸失衡引起的特征稀疏和特征缺失问题。然后使用基于自注意力机制的特征重组方法动态整合字句融合特征, 并优化权重参数以降低计算和训练时间复杂度。最后在开源数据集上分别进行了消融实验和对比实验。测试结果表明, 本文方法在准确率上有较优的改进效果。

关键词: 情感分析; 特征编码; 预训练模型; 自注意力机制; 权重参数

中图分类号: TP391 文献标志码: A

Emotional Analysis Approach Based on Dynamic Word-Sentence Features and Self-attention

LIU Qiang^{1,2}, ZHU Jinsen¹, ZHAO Longlong¹, SHA Yuchen¹, LIU Shangdong^{1,2}, JI Yimu^{1,2}

(1. School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. Institute of High Performance Computing and Big Data Processing, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Traditional models suffer from feature sparsity, feature loss and incomplete comment feature extraction problems due to the imbalance of comment length. This paper proposes an emotional analysis approach based on dynamic word-sentence features and self-attention (DWSF-SA), to alleviate the incomplete extraction problem caused by the imbalance of text size under batch training. DWSF-SA first follows pre-training on dynamic feature embedding, then employs sentence vectors to complete the less parts and represents the truncated parts by fixed length. Moreover, DWSF-SA also introduces a self-attention mechanism to dynamically integrate the word-sentence fusion features, and makes optimization on the weight parameters to accelerate the computation and training. The ablation and comparison experiments on publicly available datasets demonstrate that the proposed DWSF-SA outperforms traditional approaches in accuracy metrics.

Key words: emotional analysis; feature embedding; pre-training model; self-attention mechanism; weight parameters

基金项目: 国家重点研发计划专项 (2018AAA0103300, 2018AAA0103302); 江苏省自然科学基金及高校自然科学基金重大项目 (BK20170900, 20KJA520001); 江苏省创新创业人才项目及江苏博士后基金 (2019K024); 江苏省六大大人才高峰项目 (JY02); 江苏省博士后研究实践创新项目 (KYCX19_0921, KYCX19_0906); 之江实验室开放项目 (2021KF0AB05); 教育部人文社会科学基金青年项目 (20YJC880104); 南京邮电大学人才启动基金 (NY219132)。

收稿日期: 2023-01-31; **修订日期:** 2023-07-13

引言

随着互联网的快速普及,人们通过论坛、博客和电商平台等各种渠道表达观点,发表评论。对这些评论文本信息的挖掘也有许多应用,比如个性化广告服务、推荐系统和公共事件下的公众意见监控^[1]等。对于电商产品评论,商家通过分析来深入了解产品的客户满意度,分析产品改良的必要性和方向。其中,评论情感倾向的判断能够最直观地反映这个产品质量的好坏和产品的受欢迎程度。对于评论情感任务,基于深度学习模型的方法在性能、准确率方面表现较好,成为业界主流的研究热点之一^[2],但在编码方面仍然存在着一些问题。传统的情感文本分析任务通常基于静态词向量模型进行文本编码,如 Word2Vec 和 Glove。尽管静态词向量模型有着广泛的应用,但也存在语义提取信息不全、缺乏上下文语境等问题。首先,静态词向量在编码前需要对文本进行分词,而中文由于语义表达的复杂性,往往在切分时出现切分歧义^[3]或未登录词识别等问题,导致分词前后的文本语义表达不一致;另一方面,文本的情感表达需要结合上下文语境进行分析,而静态词向量模型则缺乏这方面因素考虑,对同样的词分配同一个向量表示,难以解决“一词多义”等问题。此外,面向分词进行编码使得模型依赖显式的情感信息进行判断,如情感词汇、否定词以及程度副词等,在情感信息稀疏的情况下效果欠佳。文本编码中的另一个突出问题就是文本长度不均衡问题。为了满足批处理中的统一长度需求,一般会设置一个固定的文本长度,不足固定长度的部分用零向量填充^[4],超出固定长度部分则截断^[5]。然而,评论文本的长度具有不规范性,一般情况下评论的长度小于 200 字,但在长度分布上依然存在不均匀性。特别是对于那些远小于固定长度的评论文本,本身特征较为稀疏^[6],而过多的零向量填充不仅引入了与文本特征无关的编码,还加剧了特征的相对稀疏性。对于那些远大于固定长度的评论文本,截断^[7]大部分的内容会造成整条评论编码特征缺失^[8],最终导致文本误判。针对上述文本编码存在特征稀疏和特征缺失,导致提取信息不全等问题,本文引入预训练模型进行动态编码,提出了一种字句融合编码方式,并针对新编码方式缺乏字句特征交互等问题,构建了基于自注意力机制的特征处理模型。

1 相关工作

本节主要从预训练模型、文本编码优化方法和特征模型优化等方面,对情感分析领域的研究现状进行总结。针对传统编码模型无法处理文本歧义、一词多义等问题,预训练模型在各种自然语言处理(Natural language processing, NLP)任务上取得了显著效果^[9]。预训练模型通过大规模开放领域语料库进行训练,从而嵌入丰富的语义和句法信息。BERT^[10]在预训练模型中具有代表性,是一种基于双向编码器的预训练模型,通过堆叠 Transformers 子结构来构建模型。在情感分类等下游任务,微调 BERT 进行上下文编码显著提高了分类准确性^[11]。随后,多种基于 BERT 的优化预训练模型被陆续提出,如 ALBERT 和 Roberta 等^[12]。这些预训练模型可以达到较高的分类准确率,但也存在模型参数多、计算代价大等问题。针对该问题,一些研究者们提出了基于知识蒸馏技术的轻量化预训练模型,如 TinyBERT 等,有效降低了模型的参数和计算代价。

针对特征稀疏和特征缺失等问题,常见做法是结合外部语言知识或内部语义关联性来调整特征信息^[13]。李卫疆等^[2]依托已有语言知识和情感资源,构建融合词性特征、位置特征和依存句法特征的多通道评论编码。文献[14]在短文本分类任务中,使用知识库等外部资源来丰富和获取更高级的文本表示,以克服短文本的特征稀疏性和模糊性。在内部特征编码的处理上,短文本可以通过模型实现特征扩张,避免填充向量造成的相对特征稀疏问题;而长文本常见的处理方式则是压缩^[15]和池化^[16]等,相对于直接截断,该方法在一定程度上缓解了特征缺失问题。此外,在对长文本进行拆分处理时,短句子编码会采用下一句的部分编码来进行填充。

除了特征编码,一部分学者将关注点放在了模型的特征处理方面,采用了多种深度学习模型和注意力机制相结合的思路。由于简单模型对文本特征的提取和保留能力不足^[17],学者们通过将不同模型进行合理组合并针对具体场景进行调整优化,从而弱化特征编码的不足。Huan等^[18]将卷积神经网络(Convolutional neural network, CNN)和长短时记忆神经网络(Long short term memory, LSTM)并联构造混合模型来进行文本的情感分类。注意力机制^[19]源于人体生理上的选择性注意力机制,因此具有显著的可解释性,被广泛应用于许多NLP模型中。在情感分析领域,注意力机制可以增强情感元素之间的依赖性^[20],独立计算每一对不同位置单词的相互作用,增强不同信息之间的交互,还兼顾了上下文相关性,有效提高了情感分类的准确性。研究者们将注意力机制、循环神经网络和卷积神经网络等相结合,构建了多元化的特征处理模型,更全面地提取情感特征^[21]。苏锦铄等^[22]融合依存关系信息,构建基于双向GRU(Gate recurrent unit)和距离注意力的句子属性情感分析方法。程艳等^[23]将连接注意力机制的多通道CNN和双向GRU并联,构建文本情感极性分类模型。

综上所述,现有文本编码优化方法大多是引入外部知识库,没有直接解决编码中存在的特征稀疏等问题,且引入外部知识库对指标的提升严重依赖于知识库自身的质量,具有较大的不确定性。在对特征处理模型的优化上,一方面是构建并联处理模型对不同角度的特征进行广度学习,另一方面是组合多种基础模型对文本特征进行深度学习,而并联处理的广度学习模型或者组合多种模型的深度学习模型尽管在准确率上有所提升,但模型复杂度和训练成本较高。

2 本文方法

2.1 评论长度的不平衡性及情感表达的复杂性

为了说明问题,本文采用公开数据集online_shopping_10_cats^①对文本长度进行了统计分析,如图1所示。该数据集包含26 413条评论,其中平均评论长度为58.4个字。定义长度不足平均长度一半的为短评论,长度超出平均长度1倍的为长评论。由图1可知,在所有评论中,短评论占比42.08%,长评论占比11.23%。可见该数据集中超过一半的数据存在序列长度不平衡问题,进而影响批训练时的信息抽取质量,导致特征稀疏和特征缺失。

从情感的角度,评论可能兼具显式和隐式情感的表达。显式情感文本指含有情感特征明显的词语文本,而隐式情感文本指情感特征不明显的文本,一般为事实叙述型文本。静态词向量模型无论评论的上下文和含义如何,同样的词只能分配相同的单词表示,无法表征上下文的语义信息,这导致了其在隐式情感表征时的局限性。本文从数据集中抽取相关评论作为例子,如表1中两条评论都包含价格,但在前一句中表达价格便宜是正向情感,后一句表达价格降价却是负向情感,体现出正负两种相反的极

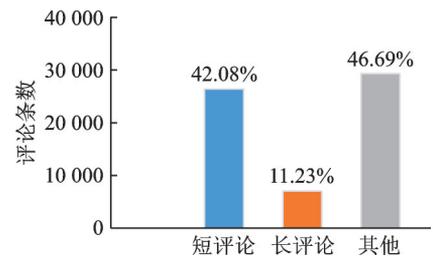


图1 评论长度分布统计

Fig.1 Comment length distribution statistics

表1 数据集样例

Table 1 Samples of dataset

评论	情感	备注
产品不错哦,这个洗发水价格非常便宜,而且非常实惠,洗完过后,头发非常柔顺,而且不打结,味道也非常香,什么也不说了,看图吧	正	显式情感
这么快就降价了? 怎么回事? 价格100	负	隐式情感

①https://github.com/SophonPlus/ChineseNlpCorpus/blob/master/datasets/online_shopping_10_cats

性。因此,文本可能存在多义和歧义等现象,在情感表达上有复杂性,需要结合上下文和语境进行分析。

2.2 基于字句动态特征和自注意力的评论情感分析方法

针对前述问题,本文提出了基于字句动态特征和自注意力(Dynamic word-sentence features and self-attention, DWSF-SA)的情感分析方法,主要包含字句动态特征融合和基于自注意力机制的特征重组,并基于这两部分构建了评论情感分析模型。

2.2.1 字句动态特征融合

针对传统词向量模型无法基于上下文进行动态编码的问题,兼顾计算成本与实验变量控制,本文采用轻量级预训练模型 TinyAlbert 进行动态语义编码。该模型与一般传统词向量编码维度更相近,是对 Albert 模型使用知识蒸馏技术得到的轻量级预训练模型。

本方法通过一种字句特征融合的编码方法来进行优化,如图2所示,首先利用句子级特征编码代替零向量编码进行填充,缓解特征稀疏问题;其次利用包含截断编码特征的句子级特征编码连接在截断处,缓解截断造成的特征缺失问题。

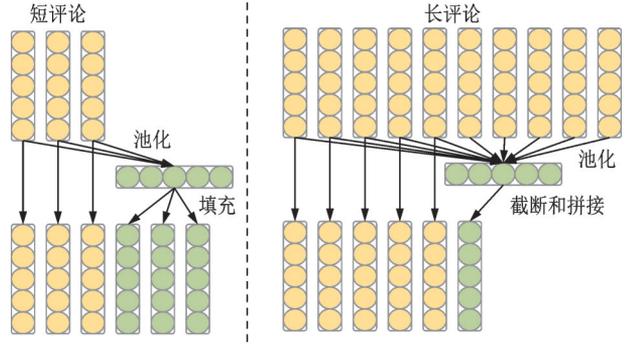


图2 字句融合特征编码

Fig.2 Word-sentence fusion features embedding

假设某条评论为 R ,其长度为 D ,设置编码长度为 d ,特征维度为 f ,则评论的编码为

$$\mathbf{X}_R = \text{concat}(\mathbf{C}_R, \mathbf{t} * \mathbf{S}_R) \quad D \leq d - 1 \quad (1)$$

$$\mathbf{X}_R = \text{concat}(\mathbf{C}_R[:d-1], \mathbf{S}_R) \quad D > d - 1 \quad (2)$$

式中: \mathbf{X}_R 表示评论 R 的特征嵌入; \mathbf{C}_R 表示评论 R 的字编码,形状为 $D \times f$; \mathbf{t} 为元素为1的常数向量,形状分别为 $(d-D) \times 1$; \mathbf{S}_R 表示评论 R 的句编码,形状为 $1 \times f$;concat表示两个矩阵的连接操作。

2.2.2 基于自注意力机制的特征重组

本文通过句子级特征进行填充和连接来缓解特征稀疏和特征稀疏问题,为了更好地实现内部特征交互以及整合字句融合特征,引入自注意力机制,并对其做出调整,实现特征重组。

自注意力机制可以单独计算每一对不同位置特征之间的相互作用,基于特征表示来计算它们之间的交互,有利于捕获句子中的多个依赖关系。特征间自注意力公式^[19]为

$$\text{Att}(\mathbf{x}_i, \mathbf{x}_j) = \frac{(\mathbf{x}_i \mathbf{W}^Q + \mathbf{b}^Q)(\mathbf{x}_j \mathbf{W}^K + \mathbf{b}^K)^T}{\sqrt{d_z}} \quad (3)$$

式中: $\mathbf{x}_i, \mathbf{x}_j$ 表示两个不同的特征编码,形状为 $1 \times f_{\text{att}}$, f_{att} 为注意力机制的输入特征维度大小; $\mathbf{W}^Q, \mathbf{W}^K$ 表示自注意力机制中计算query和key的变化矩阵,形状为 $f_{\text{att}} \times h$, h 表示隐藏层特征维度大小; $\mathbf{b}^Q, \mathbf{b}^K$ 为偏置,形状为 $1 \times h$; d_z 为文本编码长度。

整个自注意力层的公式^[24]为

$$\text{Att}(\mathbf{X}) = \text{softmax}\left(\frac{\mathbf{X}^Q (\mathbf{X}^K)^T}{\sqrt{d_z}}\right) \mathbf{X}^V \quad (4)$$

$$\mathbf{X}^Q = \mathbf{X} \mathbf{W}^Q + \mathbf{B}^Q \quad (5)$$

$$X^K = XW^K + B^K \tag{6}$$

$$X^V = XW^V + B^V \tag{7}$$

式中: X 为输入; X^Q 、 X^K 、 X^V 分别为 query、key、value,形状为 $d \times h$; B^Q 、 B^K 、 B^V 为对应偏置。将式(5~7)代入式(4),可得

$$\text{Att}(X) = \text{softmax} \left(\frac{XW^Q(W^K)^T X^T + XW^Q(B^K)^T + B^Q X^T(W^K)^T + B^Q(B^K)^T}{\sqrt{d_z}} \right) (XW^V + B^V) \tag{8}$$

式(8)中起特征交互作用的主要是 $XW^Q(W^K)^T X^T$,而 $XW^Q(B^K)^T + B^Q X^T(W^K)^T + B^Q(B^K)^T$ 为特征本身的线性变换,并不涉及特征交互,因此删除自注意力机制中的偏置计算,并对 W^Q 、 W^K 进行合并,可得

$$\text{Att}(X) = \text{softmax} \left(\frac{XW^{QK} X^T}{\sqrt{d_z}} \right) XW^V \tag{9}$$

式中 W^{QK} 为合并后的权重矩阵,形状为 $f_{\text{att}} \times f_{\text{att}}$ 。优化后的自注意力机制减少了1个权重矩阵和3个偏置。假设自注意力机制的输入特征维度与输出特征维度相等,即 $f_{\text{att}}=h$,式(5~7)的计算复杂度均为 dh^2 ,式(4)中 $X^Q(X^K)^T$ 、后乘 X^V 的计算复杂度均为 d^2h ,所以原自注意力机制的计算复杂度为 $O(dh(2d+3h))$ 。基于自注意力的特征重组机制中, $XW^{QK} X^T$ 的计算复杂度为 d^2h+dh^2 ,后乘 X 以及后乘 W^V 复杂度分别为 d^2h 、 dh^2 ,因此计算复杂度为 $O(dh(2d+2h))$,相比原自注意力机制有所降低。

原自注意力机制基于评论的字粒度级别进行重要性权重分配,但进行字句融合编码后,评论编码包括两个不同层次特征,不同层次特征不具有可比性,因此更改归一化维度,将字句特征拆分重组,从而实现字句特征交互。相比原自注意力机制对矩阵的第二个维度做归一化,基于自注意力的特征重组机制对矩阵的第一个维度进行归一化,即对每个时间步的输入向量来说,其对所有输出向量的贡献权重之和为1,如图3所示,其中 $\alpha_i(i=1,2,3,\dots)$ 表示输入向量对应不同输出向量的权重。

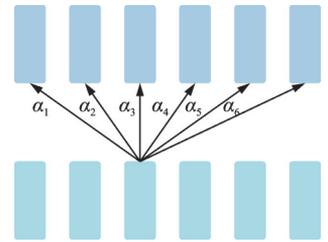


图3 改进自注意力机制
Fig.3 Improved self-attention mechanism

2.2.3 评论情感分析模型

基于前述思路,本文设计了基于字句动态特征融合的评论情感分析模型。如图4所示,模型主要包括编码层、GRU层、特征重组层、激活层、平均池化层和全连接层。(1)编码层:使用轻量级预训练模型 TinyAlbert 对评论进行动态特征编码,生成评论的特征矩阵,并使用池化句向量对特征矩阵进行调整;(2)GRU层:分析特征矩阵的序列信息,获得评论的内部关联特征;(3)特征重组层+激活层:特征重组机制是基于自注意力机制的调整,对特征序列进行重组,从而更好整合字句融合特征,然后通过 Tanh 激活层加强模型的非线性表征能力;(4)平均池化层:将特征序列通过平均池化进行压缩降维;(5)全连接层:通过全连接分类器得到情感极性类别数量的特征量,最大特征量所在位置对应的情感极性即为最终判断的情感极性。

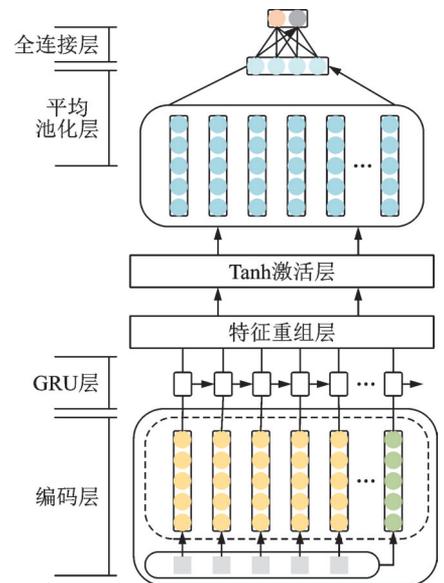


图4 整体模型设计
Fig.4 Overall model structure

3 实验与结果分析

3.1 实验设置

(1) 实验数据集

基于前述方法,本文实验采用公开数据集 online_shopping_10_cats 和谭松波酒店评论数据集^①进行测试。online_shopping_10_cats 数据集中包含衣服、平板、水果等 10 个种类的电商评论数据,总计 62 773 条,其中正向评论 31 727 条,负向评论 31 046 条。谭松波酒店评论数据集总计 10 000 条数据,其中正向评论 7 000 条,负向评论 3 000 条。

(2) 实验参数设置

本文模型参数设置如表 2 所示。

表 2 超参数设置

Table 2 Hyperparameter setting

超参数	含义	设置
word_vector_dimension	word_vector_dimension 编码的特征维度	312
sequence_length	sequence_length 固定文本长度	60
batch_size	batch_size 批大小	384
GRU_hidden_size	GRU_hidden_size GRU 网络的隐藏层大小	128
Attention_hidden_size	Attention_hidden_size 注意力机制的隐藏层大小	128

3.2 对比实验

为了证明模型的有效性,将本文模型与其他典型的情感分析模型进行比较,使用准确率(Accuracy)作为对比指标,计算公式为

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (10)$$

式中:TP(True positive)表示真正例数量;FP(False positive)表示假正例数量;FN(False negative)表示假反例数量;TN(True negative)表示真反例数量。

对比实验结果如表 3 所示。下文给出了对比模型及其简介。

(1)TextCNN^[25]:设置多个不同尺寸的卷积核,利用卷积神经网络提取文本局部特征,得到情感分类。

(2)GRU:使用 GRU 提取文本序列特征,得到情感分类。

(3)BERTTECNN^[26]:使用 bert_base 作为动态字向量模型,Transformer encoder 层对数据进行多头注意力计算,CNN 层利用不同大小的卷积核捕捉局部特征,最后应用 softmax 进行分类。

(4)ABLCNN+改进 TFIDF^[27]:使用改进 TFIDF 算法训练 Word2Vec 模型,使用 BiGRU 提取特征关联信息,并用自注意力机制调整情感依赖,然后使用多尺寸卷积神经网络实现特征再提取和整合,最后经过 softmax 得到情感极性。

(5)MTACBG^[28]:使用自注意力机制和多卷积神经网络双通道分别提取关联信息和局部信息,并输入 BiGRU 学习序列特征,最后使用高速注意力机制获得句子级关联,得到情感分类。

(6)MCBiGRUCapsule^[29]:使用 CNN 和双向 GRU 提取文本信息,并针对情感类别构建对应的情感胶囊,最后根据胶囊属性判断情感类别。

①<https://github.com/maoxiong26/TanSongBoSet>

表 3 对比实验
Table 3 Comparison experiments

编号	模型	online_shopping_10_cats	谭松波酒店评论
1	TextCNN	90.27	87.92
2	GRU	90.34	89.08
3	BERTTECNN	91.00	—
4	ABLCNN+改进 TFIDF	91.33	—
5	MTACBG	—	91.66
6	MCBiGRUCapsule	—	91.80
7	Multhead+CNN	91.88	—
8	BGRUA+CNNA	92.94	92.75
9	DWSFSA(TinyAlbert)	93.02	92.90
10	DWSFSA(Bert)	94.58	94.55

(7)Multhead+CNN^[30]:使用多头自注意力机制筛选不同词语间的关联特征,然后导入卷积网络,最后通过全连接层实现情感分类。

(8)BGRUA+CNNA:使用Word2Vec作为字向量模型,使用BiGRU获取文本关联特征,用自注意力机制提取关联情感依赖,然后导入多卷积核的卷积网络,使用自注意力机制对局部特征动态赋权,最后经过softmax得到情感极性。

为了对比的公正性,防止复现时因为代码细节问题导致模型指标与原论文描述有所偏差,实验数据集与本论文相同的对比模型的实验数据来自相关引用论文^[26-30]。另外,分别使用轻量级预训练模型TinyAlbert和预训练模型Bert构建DWSFSA的整体模型,并测试准确率进行对比。TinyAlbert和Bert分别采用Huggingface^①网站上下载的albert_chinese_tiny和bert_base_chinese模型。

从表3可知,传统的单一模型,如实验1的TextCNN模型和实验2的GRU模型在数据集上的效果较差,这是因为简单模型处理信息时具有局限性,无法深度挖掘情感特征。相对于TextCNN,实验3的BERTTECNN引入BERT预训练模型根据上下文语境信息进行动态编码,并对数据进行多头注意力计算,体现出上下文不同词的重要性,因此在数据集上的效果有所提升。类似地,实验7借鉴Transformer模型进行编码,嵌入位置向量辅助学习单词语义,并使用多头注意力机制丰富词语之间的关联关系,因此提高了情感分析的准确率。实验4中ABLCNN+改进TFIDF模型、实验5中MTACBG模型以及实验8中BGRUA+CNNA模型通过合理组合更多的基础模型,如BiGRU、自注意力机制、多尺寸卷积神经网络等,来提升整体模型对复杂特征的处理能力。实验6中MCBiGRUCapsule模型基于注意力和概率构建情感胶囊,增强情感信息表示。

相比实验4、实验5和实验6,基于DWSFSA构建的模型复杂度相对较低,但在准确率指标上呈现较好的效果。原因主要包括两方面:一方面本文使用预训练模型代替传统的静态词向量模型,并基于数据集对预训练模型参数进行微调,实现基于上下文的动态编码,使得源域和目标域之间的映射更加合理;另一方面,本文方法采用字句特征融合技术有效地缓解了由于评论文本过短或过长导致的特征稀疏和特征缺失问题,并基于特征重组机制实现字句特征的交互与整合,使得模型在短评论和长评论数据上具有较好的效果。为了验证在方法在评论文本长度失衡场景下的效果,本文使用online_shopping_10_cats数据集进行了两组实验:

①<https://huggingface.co/models>

(1)从online_shopping_10_cats测试集中抽取出长评论和短评论进行指标测试,并与整个测试集的指标对比,结果如图5(a)所示。

(2)将online_shopping_10_cats数据集中长评论与短评论之外的长度适中的评论分别删除50%(半失衡),删除100%(全失衡),并重新划分训练集和测试集,测试不同文本长度失衡程度下模型的准确率指标,与原数据集的对比结果如图5(b)所示。

由图5(a)中测试结果可知,长短评论的测试指标优于整个测试集的效果,可见模型优化了对短评论和长评论的处理,使得长短评论指标提升带动模型在整体数据上指标的提升。由图5(b)可知,在长度适中的评论减少,失衡程度加剧的过程中,基于DWSFSA构建的模型能够有更好的表现,可见DWSFSA更加适用于评论文本长度失衡甚至两极分化的场景下。

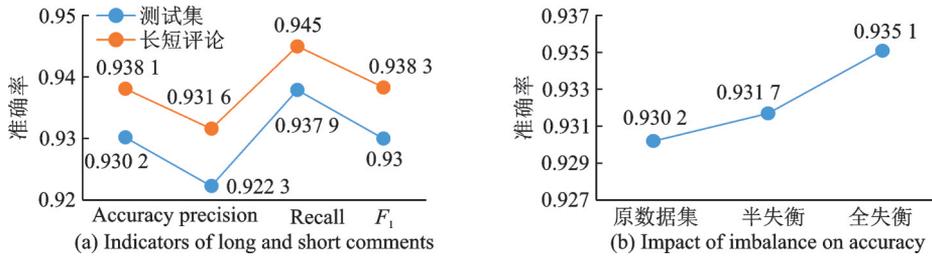


图5 模型有效性验证

Fig.5 Model validation

3.3 消融实验

本节在online_shopping_10_cats数据集上,通过消融实验对前述优化点分别进行验证,实验结果如表4所示。下文对消融实验模型中添加或修改的组件进行了说明。

表4 消融实验

Table 4 Ablation experiments

编号	模型	准确率/%
1	Word2Vec+GRU	90.34
2	TinyAlbert+GRU	92.29
3	TinyAlbert字句融合+GRU	92.42
4	TinyAlbert字句融合+GRU+selfatt	92.85
5	TinyAlbert字句融合+GRU+selfatt特征重组机制	93.02

(1)Word2Vec+GRU:基线模型。

(2)TinyAlbert+GRU:使用TinyAlbert预训练模型代替Word2Vec模型进行编码。

(3)TinyAlbert字句融合+GRU:在(2)的基础上,加入本文提出的字句融合编码方式,使用句子级编码对短评论进行填充,在长评论截断处进行拼接。

(4)TinyAlbert字句融合+GRU+selfatt:在(3)的基础上,加入自注意力机制。

(5)TinyAlbert字句融合+GRU+selfatt特征重组机制:使用本文提出的基于自注意力机制的特征重组机制代替(4)中的自注意力机制。

由实验1、实验2可知,TinyAlbert+GRU模型相比Word2Vec+GRU模型的情感分析准确率有明显提高,指标提升了1.95%。原因是预训练模型以字为编码单位,消除了静态词向量模型Word2Vec由于分词导致的歧义问题,同时预训练模型可以进行微调,实现了基于上下文语义的动态编码。

由实验2、实验3可知,在使用TinyAlbert+GRU模型的情况下,字句融合特征略优于常规编码,准确率指标提升0.13%。由结果可知,字句融合特征编码方式可以缓解特征稀疏和特征缺失问题,提升幅度有限的主要原因是GRU仅提取字编码关联特征,未能整合字句融合特征。此外,本实验中评论局部情感极性与整体情感极性一致率较高,因此由截断引起的特征缺失问题对结果影响有限。

实验4和实验5在实验3的基础上增加了特征交互组件。由结果可知,自注意力机制的添加使模型准确率提高了0.43%,selfatt特征重组机制的添加使模型准确率提高了0.60%。模型的参数量和平均前向计算时间如表5所示。其中,参数量是两种方法在本文环境下的训练参数量,平均前向计算时间是随机选取10个batch_size的数据进行注意力计算所需时间的平均值。由结果可知,selfatt特征重组机制减少了约33.9%的参数量和24.7%的计算时间,有效提高了计算性能,同时参数也更简洁。综上所述,随着组件的增加或改进,整体模型的指标呈上升趋势。

3.4 训练过程分析

对本文模型训练过程的参数进行分析,以DWSF-SA(TinyAlbert)模型在online_shopping_10_cats数据集上的结果为例,模型的损失值和准确率随训练步数的变化如图6所示。由图6可知,到第12个时间步为止,本文模型准确率呈稳步上升,损失值稳步下降,并且训练集和测试集的指标差值保持在较小的范围内。在第13个时间步开始时,指标出现拐点,是因为解除预训练模型参数冻结后,反向传播对预训练模型参数进行了微调。在微调的过程中,训练集和测试集的指标差值持续扩大。为了防止过拟合并保持模型的泛化能力,只对预训练模型微调了两个时间步。从第16个时间步开始,本文模型在训练集测试集上的损失值和准确率指标趋于收敛。从图中可以看出,本文构建的模型训练时能较快收敛,并达到一个稳定的状态。

4 结束语

本文针对评论长度导致的特征稀疏和特征缺失等问题,探讨在评论情感分析任务下模型优化的一些可行性方法,提出了一种基于字句动态特征融合的情感分析模型。首先使用预训练模型实现基于上下文的动态编码,并通过填充和连接池化句向量的方法进行特征融合,缓解批训练下文本编码的特征稀疏和缺失问题;在对特征的后续处理上,通过改进自注意力机制,实现字句融合特征的优化重组。在公开数据集上的测试结果表明,本文在准确率上有较优的改进效果。

参考文献:

- [1] ZHANG X, LI W, YING H, et al. Emotion detection in online social networks: A multilabel learning approach[J]. IEEE Internet of Things Journal, 2020, 7(9): 8133-8143.

表5 注意力层参数和计算性能对比

Table 5 Comparison of parameters and computational performance on the attention layers

机制	参数量	平均前向计算时间/s
自注意力机制	32 768	0.075 8
selfatt特征重组机制	49 536	0.100 6

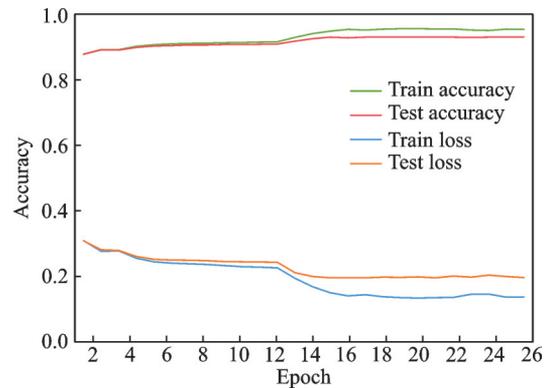


图6 损失值和准确率变化

Fig.6 Trend of loss and accuracy

- [2] 李卫疆,漆芳,余正涛.基于多通道特征和自注意力的情感分类方法[J].软件学报,2021,32(9): 2783-2800.
LI Weijiang, QI Fang, YU Zhengtao. Sentiment classification method based on multi-channel features and self-attention[J]. Journal of Software, 2021, 32(9): 2783-2800.
- [3] LI W, LI L. Combining knowledge with attention neural networks for short text classification[C]//Proceedings of International Conference on Knowledge Science, Engineering and Management. Switzerland: Springer, 2021: 240-251.
- [4] HASHEMI M. Web page classification: A survey of perspectives, gaps, and future directions[J]. Multimedia Tools and Applications, 2020, 79(17): 11921-11945.
- [5] LI A H, SETHY A. Semi-supervised learning for text classification by layer partitioning[C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona, Spain: Institute of Electrical and Electronics Engineers, 2020: 6164-6168.
- [6] GUAN R, ZHANG H, LIANG Y, et al. Deep feature-based text clustering and its explanation[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(8): 3669-3680.
- [7] KOCON J, GRUZA M, BIELANIEWICZ J, et al. Learning personal human biases and representations for subjective tasks in natural language processing[C]//Proceedings of 2021 IEEE International Conference on Data Mining. Piscataway, NJ: Institute of Electrical and Electronics Engineers, 2021: 1168-1173.
- [8] CUI P, HU L. Sliding selector network with dynamic memory for extractive summarization of long documents[C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: Association for Computational Linguistics, 2021: 5881-5891.
- [9] XIAO L, WANG L, HE H, et al. Modeling content importance for summarization with pre-trained language models[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: Association for Computational Linguistics, 2020: 3606-3611.
- [10] 刘栋梁,张嵩,张宁康,等.基于BERT的航天术语标准化[J].南京航空航天大学学报,2022,54(S1): 109-114.
LIU Dongliang, ZHANG Song, ZHANG Ningkan, et al. Standardization of aerospace terms based on BERT[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2022, 54(S1): 109-114.
- [11] 谢润忠,李焯.基于BERT和双通道注意力的文本情感分类模型[J].数据采集与处理,2020,35(4): 642-652.
XIE Runzhong, LI Ye. Text sentiment classification model based on BERT and dual channel attention[J]. Journal of Data Acquisition and Processing, 2020, 35(4): 642-652.
- [12] 赵京胜,宋梦雪,高祥,等.自然语言处理中的文本表示研究[J].软件学报,2022,33(1): 102-128.
ZHAO Jingsheng, SONG Mengxue, GAO Xiang, et al. Research on text representation in natural language processing[J]. Journal of Software, 2022, 33(1): 102-128.
- [13] CHEN H, YIN H, CHEN T, et al. Social boosted recommendation with folded bipartite network embedding[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(2): 914-926.
- [14] TÜRKER R, ZHANG L, ALAM M, et al. Weakly supervised short text categorization using world knowledge[C]//Proceedings of International Semantic Web Conference. Switzerland: Springer, 2020: 584-600.
- [15] ZHONG Y, JIANG C, XU W, et al. Discourse level factors for sentence deletion in text simplification[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park, CA: Association for the Advancement of Artificial Intelligence, 2020: 9709-9716.
- [16] ZHANG H, GONG Y, SHEN Y, et al. Poolingformer: Long document modeling with pooling attention[C]//Proceedings of International Conference on Machine Learning. San Diego, CA: Proceedings of Machine Learning Research, 2021: 12437-12446.
- [17] 胡艳丽,童谭骞,张啸宇,等.融入自注意力机制的深度学习情感分析方法[J].计算机科学,2022,49(1): 252-258.
HU Yanli, TONG Tanqian, ZHANG Xiaoyu, et al. Self-attention-based BGRU and CNN for sentiment analysis[J]. Computer Science, 2022, 49(1): 252-258.
- [18] HUAN H, GUO Z, CAI T, et al. A text classification method based on a convolutional and bidirectional long short-term memory model[J]. Connection Science, 2022, 34(1): 2108-2124.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing

- Systems, 2017, 30: 5998-6008.
- [20] ZHANG S, YU H, ZHU G. An emotional classification method of Chinese short comment text based on ELECTRA[J]. Connection Science, 2022, 34(1): 254-273.
- [21] KUMAR A. Contextual semantics using hierarchical attention network for sentiment classification in social internet-of-things[J]. Multimedia Tools and Applications, 2022, 81(26): 36967-36982.
- [22] 苏锦钿, 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.
SU Jindian, OUYANG Zhifan, YU Shanshan. Aspect-level sentiment classification for sentences based on dependency tree and distance attention[J]. Journal of Computer Research and Development, 2019, 56(8): 1731-1745.
- [23] 程艳, 尧磊波, 张光河, 等. 基于注意力机制的多通道CNN和BiGRU的文本情感倾向性分析[J]. 计算机研究与发展, 2020, 57(12): 2583-2595.
CHENG Yan, YAO Leibo, ZHANG Guanghe, et al. Text sentiment orientation analysis of multi-channels CNN and BiGRU based on attention mechanism[J]. Journal of Computer Research and Development, 2020, 57(12): 2583-2595.
- [24] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks[C]//Proceedings of International conference on machine learning. California, USA: Proceedings of Machine Learning Research, 2019: 7354-7363.
- [25] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of EMNLP 2014 Conference on Empirical Methods in Natural Language Proceeding. Toronto, Canada: Association for Computational Linguistics, 2014: 1746-1751.
- [26] 李铁飞, 生龙, 吴迪. BERT-TECNN模型的文本分类方法研究[J]. 计算机工程与应用, 2021, 57(18): 186-193.
LI Tiefei, SHENG Long, WU Di. Study on text classification method of BERT-TECNN model[J]. Computer Engineering and Application, 2021, 57(18): 186-193.
- [27] 景丽, 何婷婷. 基于改进TF-IDF和ABL CNN的中文文本分类模型[J]. 计算机科学, 2021, 48(S2): 170-175, 190.
JING Li, HE Tingting. Chinese text classification model based on improved TF-IDF and ABL CNN[J]. Computer Science, 2021, 48(S2): 170-175, 190.
- [28] 王勇, 张索宇, 吕心怡. 多重注意力特征融合网络对中文评价情感分析[J]. 小型微型计算机系统, 2021, 42(8): 1633-1638.
WANG Yong, ZHANG Suoyu, LV Xinyi. Sentiment analysis of chinese evaluate text based on multiple attention and feature fusion network model[J]. Journal of Chinese Computer Systems, 2021, 42(8): 1633-1638.
- [29] 程艳, 孙欢, 陈豪迈, 等. 融合卷积神经网络与双向GRU的文本情感分析胶囊模型[J]. 中文信息学报, 2021, 35(5): 118-129.
CHENG Yan, SUN Huan, CHEN Haomai, et al. Text sentiment analysis capsule model combining convolutional neural network and bidirectional GRU[J]. Journal of Chinese Information Processing, 2021, 35(5): 118-129.
- [30] 杜朋, 卢益清, 韩长风. 基于Transformer模型的商品评论情感分析[J]. 中文信息学报, 2021, 35(2): 125-132.
DU Peng, LU Yiqing, HAN Changfeng. Sentiment analysis of commodity reviews based on transformer model[J]. Journal of Chinese Information Processing, 2021, 35(2): 125-132.

作者简介:



刘强(1985-),男,博士,硕士生导师,研究方向:图计算、知识图谱和大数据处理, E-mail: liuqiang@njupt.edu.cn.



朱金森(1999-),男,硕士研究生,研究方向:自然语言处理和情感分析, E-mail: 1021041402@njupt.edu.cn.



赵龙龙(2000-),男,硕士研究生,研究方向:动态图摘要。



沙宇晨(1996-),女,博士研究生,研究方向:自然语言处理。



刘尚东(1978-),男,硕士生导师,研究方向:大数据及云计算、网络空间安全、人工智能。



季一木(1978-),通信作者,男,博士,教授,研究方向:高性能计算与大数据处理、物联网与车联网安全与人工智能, E-mail: jiyim@njupt.edu.cn.