

基于正交投影的 BiLSTM-CNN 情感特征抽取方法

魏苏波^{1,2}, 张顺香^{1,2}, 朱广丽^{1,2}, 孙争艳^{1,2}, 李 健^{1,2}

(1.安徽理工大学计算机科学与工程学院,安徽 淮南 232001)

(2.合肥综合性国家科学中心人工智能研究院,安徽 合肥 230000)

[摘要] 基于正交投影的 BiLSTM-CNN 的情感特征抽取方法旨在从文本中获取带权重的中性词向量,得到具有更高区分度的情感特征,为文本情感分类提供有力的技术支持. 传统的深度学习模型会忽略关键局部上下文信息中的特殊意义词,导致获取的情感特征不够丰富. 针对这一问题,本文提出一种基于正交投影的 BiLSTM-CNN 情感特征抽取方法. 首先,将中性词向量投影到情感极性词的正交空间中,得到加权中性词向量,同时通过 CNN 深度学习模型抽取文本关键语义;然后,利用 BiLSTM-Attention 模型和带权重的中性词向量,从提取出的关键语义中学习可增强句子情感的语义特征,使文本在情感分类时更具判别性. 实验结果表明本文所提出的情感特征抽取方法可以获得更完整的情感特征,从而显著提高文本情感分类的准确率.

[关键词] 文本情感分类,正交投影,BiLSTM,CNN

[中图分类号] TP391.1 **[文献标志码]** A **[文章编号]** 1001-4616(2023)01-0139-10

An Emotion Feature Extraction Method of BiLSTM-CNN based on Orthogonal Projection

Wei Subo^{1,2}, Zhang Shunxiang^{1,2}, Zhu Guangli^{1,2}, Sun Zhengyan^{1,2}, Li Jian^{1,2}

(1.School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, China)

(2.Artificial Intelligence Research Institute of Hefei Comprehensive National Science Center, Hefei 230000, China)

Abstract: The emotion feature extraction method of BiLSTM-CNN based on orthogonal projection aims to obtain the weighted neutral word vector from the text, obtain the emotion feature with higher discrimination, and provide strong technical support for text emotion classification. The traditional deep learning model ignores the special meaning of words in the key local context information, resulting in the insufficient acquisition of emotional features. To solve this problem, a BiLSTM-CNN emotion feature extraction method based on orthogonal projection has been proposed. Firstly, the neutral word vector is projected into the orthogonal space of emotional polarity words, and the weighted neutral word vector is obtained. At the same time, the CNN deep learning model is used to extract the key semantics of the text. Then, the BiLSTM-Attention model and weighted neutral word vector are used to learn the semantic features of sentence emotion from the extracted key semantics, which makes the text more discriminative in sentiment classification. The experimental results show that the proposed sentiment feature extraction method can obtain more complete sentiment features, thus significantly improving the accuracy of text sentiment classification.

Key words: emotional classification, orthogonal projection, BiLSTM, CNN

文本情感分类是利用机器模型对带有情感色彩的主观性文本进行处理、计算、归纳和分类的过程,同时也是人们对产品、服务、事件及其属性的观点、评价、态度和情绪等的计算研究,是文本分类的一个热门子任务^[1]. 不同于普通文本分类,文本情感分类要求更高层的语义抽取和高区分度的情感特征,这在技术

收稿日期:2022-08-08.

基金项目:国家自然科学基金面上项目(62076006)、安徽高校协同创新项目(GXXT-2021-008)、安徽省重点研发计划国际科技合作专项(202004b11020029)、安徽理工大学研究生创新基金项目(2021CX2110).

通讯作者:张顺香,博士,教授,博士生导师,研究方向:语义搜索、情感计算. E-mail: sxzhang@aust.edu.cn

上更具挑战性. 因此,如何利用自然语言处理(Natural Language Processing,NLP)技术对主观意见文本进行情感分类正被越来越多的研究人员关注^[2].

传统的 RNN 与 CNN 深度学习模型因其强大的表征学习能力在生成判别特征方面取得了重大进展^[3],但情感特征的完整性仍有待提高. 例如,RNN 与 CNN 学习模型都可以用来进行文本情感分类. 其中 RNN 模型可以对整个句子建模,捕获句子内的长期依赖关系. 然而,对整个序列进行建模可能会忽略一些对分类至关重要的关键局部上下文信息. CNN 模型可以通过不同大小的窗口提取更多的局部和位置不变特征,但无法对某些特殊的字符赋予适当的权重(例如“一般”“正常”“?”等这些特殊意义的词). 因此,在捕捉句子内的长期依赖关系的同时,对于某些特殊的字符赋予适当的权重,得到高区分度的完整情感特征是当前的研究热点之一.

为了解决该问题,一种有效的情感特征抽取方法应该考虑以下几个方面:(1)如何从文本中获取准确的情感极性词向量矩阵和具有特殊意义的字符;(2)特殊字符如何加权得到更高区分度的情感特征. 基于以上考虑,本文引入了中性词向量投影的方法,对一些含有特殊意义的词赋予适当的权重,得到高区分度的情感特征,从而提出一种基于正交投影的 BiLSTM+CNN 的情感特征抽取方法(CPD-NET+CBA). 如图 1 所示,该模型分为两部分,分别是正交投影模型(CPD-NET)和复杂神经网络模型(CNN+BiLSTM+Attention,CBA),模型核心任务是将中性词向量投影到正交空间中,赋予其适当的权重,再通过 CBA 模型学习具有更高区分度的情感特征,使文本在情感分类时更具判别性. 该模型主要任务如下:

(1)获取带权中性词向量. 通过词语关联度筛选出具有特殊意义的中性词,将中性词向量投影到情感极性词向量的正交空间中,计算出中性词向量的权值,得到加权中性词向量.

(2)获取具有更高区分度的情感特征. 首先,通过 BiLSTM、CNN、Attention 模型提取出文本的关键语义并进行强化学习,得到文本情感特征向量. 然后,将带权重的中性词向量和文本情感特征向量通过全连接层学得具有更高区分度的情感特征,从而使情感分类更具判别性.

- 本文研究工作的主要贡献如下:
- (1)提出了中性词向量投影的方法,对含有特殊意义的词赋予适当的权重,得到高区分度的情感特征.
 - (2)将高区分度的情感特征融入到 CNN、BiLSTM、Attention 深度学习模型中,该方法提高了模型的泛化性能和分类准确率.
 - (3)提出的框架应用于文本评论数据集上均取得良好效果,验证了其在文本情感分类领域的通用性.

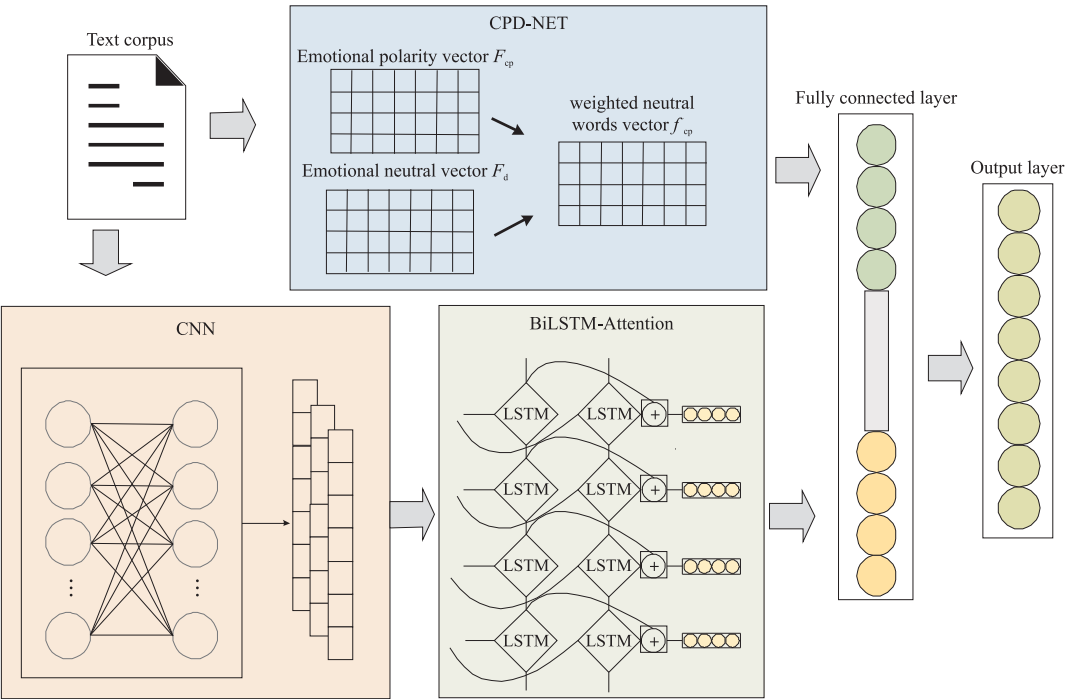


图 1 基于正交投影的 BiLSTM-CNN 的情感特征抽取框架

Fig. 1 BiLSTM-CNN's emotional characteristic extraction framework based on orthographic projection

1 研究方法

在情感分类的领域中,研究者们不断提出新的方法来更新技术,目前主流的情感分类方法分为两大类:基于传统的学习方法和基于深度学习的方法。

1.1 传统的学习方法

传统的学习方法主要包括基于词典的方法、基于机器学习的方法和基于词典与机器学习相混合的方法。Xu 等^[4-5]考虑句法分析中语义规则的影响,对短文本进行情感分析与研究。Mirtalaie 等^[6]使用语法依赖关系提取特征的极性强度,探究多种方法提取特征。陈铁明等^[7]提出使用一种凝聚式情感聚类方法进行显性特征和隐性特征的融合。Araque 等^[8]结合了表层和深层特征,使用多个领域的数据集与提出的基线模型比较,使 F_1 明显提高。谢丽星等^[9]引用外部的一些特征进行选择,同时考虑在有无主题情况下的分类效果,证明了多策略方法的有效性。李淑芝等^[10]从数据稀疏性问题出发,考虑到短文本深层次的隐含信息,并融合评论和评分实现精确推荐,同时采用弱监督的预训练策略训练模型,解决了监督学习需要人工标注的缺点,提高了短文本情感分类的准确率,模型整体的误差降低,进一步提高了推荐质量。车思琪等^[11]通过构建情感词典和机器学习的方法进行文本语义特征挖掘。景丽等^[12-13]面向酒店评论文本,扩充了领域情感词典,结合机器学习方法的监督训练,提高语料库质量的同时获得了更好的情感分类效果。

1.2 深度学习的方法

随着研究的深入,不少学者专家提出了深度学习的方法。深度学习方法可以从标记数据集中获得更优质全面的训练数据,有效提高数据的利用效率。目前语料库的来源繁杂、文本整体结构复杂、语义抽象,并且维度也越来越高,人工构建特征时间和人力耗费巨大。深度学习具有特征自学习能力,无需人工构造特征。Liao 等^[14-15]提出序列模型(如 LSTM、CNN 和 GRU 网络)用于处理文本,并使用不同大小的窗口来捕获局部相关性和位置不变信息。金志刚等^[16-17]则利用 CNN 进行特征集合与情感标签间关联的挖掘,突出局部特征的重要程度,进而提高文本的情感分析准确率。Gao 等^[18]通过使用 CNN 与多个不同窗口大小的过滤器,得到更新参数权重后的新模型。卷积和池化操作考虑到了不同数据集上的适应性,在跨领域方面的研究中起到了很大作用。Huang 等^[19]提出了一种新的参数化卷积神经网络,利用参数化的滤波器门控结构将方面词信息引入 CNN 中,再结合注意力机制捕捉特定方面的特征。而采用的卷积记忆网络(CMN)模型可以计算多个存储单元的权重,因此可以同时捕捉句子中的单词和多词表达。Fan 等^[20]提出了一种基于记忆网络的递归注意力机制(RAM),可以明确捕捉长距离上下文的重要信息,提取被长距离分隔的情感特征。为了解决相同情感类别的样本在表示空间的具有相似的向量,进一步提出了一种基于层次注意网络的文档分类方法,实验表明此方法在情感分类任务中有良好的效果。

众所周知,传统的文本情感分类构建规则或者特征耗费人力,而且评论文本数量的剧增导致语料库的质量参差不齐,因此探索高效率和高质量的分类效果迫在眉睫。通过预训练可将文本序列转化为含有语义的词向量(word vector)序列,而深度学习网络模型可通过自动进行特征抽取和优化模型提高文本情感分类的准确率。本文提出的模型结合正交投影模型和深度学习模型,有效改进了有监督分类的文本情感表示。

2 基于 CPD-NET 模型获取带权中性词特征向量

本文将对一些含有特殊意义的词赋予适当的权重,即通过计算出中性词上下文的相关度,将筛选出的中性词向量投影到情感极性词向量空间中,赋予中性词向量适当的权重。

CPD-NET 模型的框架如图 2 所示。整个模型由两部分组成,分别是特征投影网络(CP-NET)和情感极性特征学习网络(D-NET)。模型将学得文本完整信息向量投影到更有识别力的语义空间中,以增加特殊中性词向量对文本情感分类的影响。CP-NET 的目的是提取出共同的目标特征,即中性词特征向量,并赋予适当的权重;D-NET 的目的是获取情感极性词向量。CP-NET 由三部分构成:输入层 X 、特征提取器 F_{cp} 、正交投影层(OPL);D-NET 由输入层 X 、特征提取器 F_d (特征提取器 F_{cp} 和特征提取器 F_d 的参数独立)、梯度反向层(GRL)三部分构成。该模型的核心思想是:将特征提取器 F_{cp} 计算得到的特征向量 f_{cp} 投影到特征提取器 F_d 提取的特征向量 f_d 的正交方向上,即将 f_{cp} 投影到更有判别语义的空间中,使得一些特殊的中性词被赋予适当的权重,增加了情感特征提取的完整度。但是,为了执行正交投影操作,需要先进行两个操作,稍后会对此进

行阐释. 接下来, 本文将对所提出的正交投影模型的每个组成的部分进行详细描述.

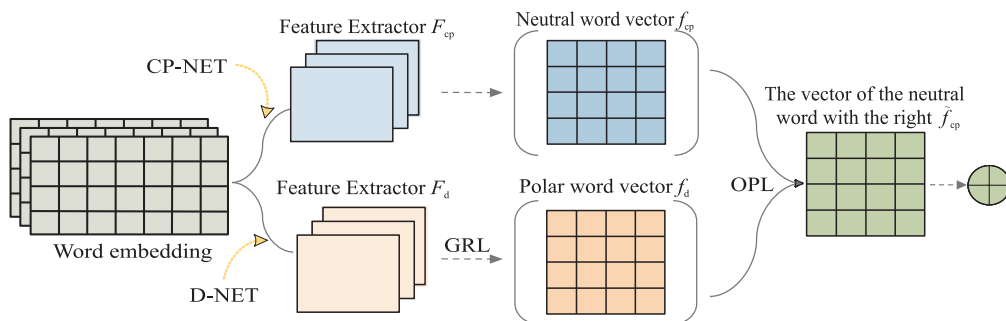


图 2 正交投影 (CPD-NET) 模型

Fig. 2 Orthogonal projection (CPD-NET) model

2.1 中性词向量

本文通过加权中性词向量表示某些特殊词的重要性, 即在对文本设置标签时, 一般会有情感特征表现较为明确的特征, 如 perfect 和 nice 代表的积极的情绪, bad 和 disgusting 代表的消极的情绪. 但是, 文本中还会存在除了特征表达明显之外的词, 称为中性词 (例如“一般”“正常”“?”等). 他们的情感特征是不明显的, 在分类上不存在歧义, 都属于中性词向量, 但是中性词向量在一定程度上会影响文本情感分类结果.

定义 1 词语间语义关联 (the degree of word correlation, DWC) 用于衡量情感极性词和上下文中中性词的关联度, 即从上下文中计算出中性词的情感极性强度, 借助词语间语义关联可以更准确的识别出具有特殊意义的词语或者字符, 从而提高特征抽取的完整度, 其计算公式如式 (1) 所示.

$$DWC_i = |C_i \times WC_i| \quad (1)$$

式中, C_i 表示中性词与极性词之间的关联度, 其计算公式如式 (2) 所示.

$$C_i = \frac{\sum (R_{u,i} - R_u)(R_{u,j} - R_u)}{\sqrt{\sum (R_{u,i} - R_u)^2} \sqrt{\sum (R_{u,j} - R_u)^2}} \times \left(\frac{R_i \times R_j}{R_u^2} \right) \quad (2)$$

式中, R_u 表示整个评论语料库中的平均值, $R_{u,i}$ 表示词 i 与平均值的关联度, $R_{u,j}$ 表示词 j 与平均值的关联度. WC_i 表示中性词的词性, WC_i 由 W_i 和 L_i 求得, 其计算公式如式 (3) 所示.

$$WC_i = W_i \times L_i \quad (3)$$

式中, W_i 表示中性词的初始权重, L_i 表示词的位置.

由于文本中的中性词较多, 而只有少部分的中性词具有特殊意义, 因此使用哈工大的 LTP 工具根据词性进行文本分词, 并计算词语间语义关联, 筛选出具有特殊意义的中性词或者符号. 如图 3 所示, “这个电脑真的很不一般!”, 其中“电脑”“一般”“!”都是中性词, 通过计算中性词与极性词的词语间语义关联, 筛选出具有特殊意义的中性词“一般”“!”. 选择大于阈值的词语作为筛选结果, 为后续的特征投影操作提供数据支持.

2.2 特征提取器 (VD-CNN)

给定一个数据集 $\{(x_i, y_j)\}_{i=1}^N$, 其中 x_i 是一个长度为 L 的输入文本 (已经预处理), y_j 对应于样本 x_i 签. 设 $V_{ij} \in R^k$ 为文本 x_i 的第 j 词对应的词向量, $X_i \in R^{L \times k}$ 是文本 x_i 的嵌入矩阵, 特征提取器采用非常深度卷积网络 (VD-CNN) 提取文本特征^[21]. 结合上文, 正交投影模型由两个子网络组成, 两个子网络 CP-NET 和 D-NET 具有相同的输入 x_i , 且两个子网络皆采用特征提取器 VD-CNN, 但是它们之间没有共享的参数.

当特征提取器 F_{cp} 从输入层接收 X_i 时, F_{cp} 以 n -gram 形式从 X_i 高级特征 f_{cp} 具体提取方式是:

$$f_{cp} = [c_1, c_2, \dots, c_{(l-n+1)}] = [c_j]_{j=1}^{l-n+1} \quad (4)$$

式中, c_j 表示 CNN 对 $X_i[j:j+n-1, :]$ 过滤产生的输出. 在数学上, 一个卷积运算由一个滤波器 $W \in R^{n \times k}$ 和一

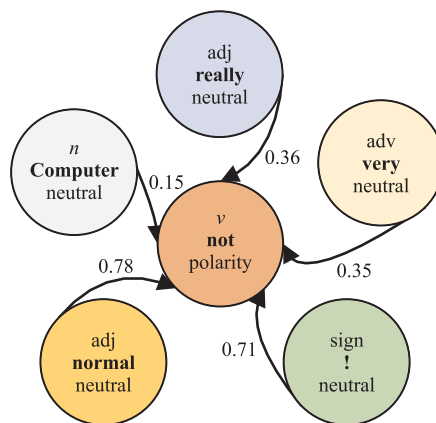


图 3 词语相关性描述样例

Fig. 3 Sample description of word relevance

个偏置 $b \in R$ 组成. 那么 c_j 可以表示为:

$$c_j = g(W \cdot X_i[j:j+n-1:] + b) \quad (5)$$

式中, g 为非线性激活函数, 如 Relu、Sigmoid、Tanh. 特征映射使用 Maxpooling 操作, 并取最大值 $f_{cp} = \max\{f_c\}$ 作为这个特定过滤器 v 对应的特征. 同样的特征提取器 F_d 也将从输入层获得高级特征 f_d .

$$f_{cp} = VD-CNN_{cp}(X) \quad (6)$$

$$f_d = VD-CNN_d(X) \quad (7)$$

2.3 特征投影网络(D-NET)

D-NET 的目标是提取情感极性特征向量, 即获取在文本情感分类任务中具有区分性的语义信息. 如前所述, 文本情感分类是利用机器模型对带有情感色彩的主观性文本进行处理、计算、归纳和分类的过程, 通过情感分类器将文本分为积极、中性、消极等类型. 而情感分类器使用情感极性词来区分不同的情感类别. 本文为了得到情感极性特征向量, 在特征提取器 F_d 之后添加了一个梯度反向层 (GRL) 来反转梯度的方向. 通过这个训练模块, 可以获取文本中具有较高区分度的情感极性特征向量. 在不失一般性的前提下, 可以把梯度反向层看作一个“伪函数”, 它由描述其正向和反向传播行为的两个不相容方程定义, 其计算公式如式(8)、式(9)所示.

$$GRL(x) = x \quad (8)$$

$$\frac{\partial GRL(x)}{\partial x} = -\lambda I \quad (9)$$

正交投影层 (Orthogonal Projection Layer, OPL) 如图 4 所示, 这里的示例是在二维空间中. f_d 代表情感极性词特征向量, f_{cp} 表示中性词特征向量, f_{cp*} 表示的是最终得到的带权重的中性词特征向量.

通过 GRL 将特征向量 \tilde{f}_d 设置为: $\tilde{f}_d = GRL(f_d)$, 其计算公式如式(10)、式(11)所示.

$$Y_{GRL} = \text{softmax}(\tilde{f}_d \cdot W_d + b_d) \quad (10)$$

$$Loss_d = \text{CrossEntropy}(Y_{truth}, Y_{GRL}) \quad (11)$$

2.4 情感极性特征学习网络(CP-NET)

CP-NET 的目标首先是提取出中性词特征向量, 即获取在文本情感分类任务中不具有区分性的语义信息, 然后将其投影到情感极性词的语义空间进行强化学习, 得到高区分度的情感特征, 即赋予中性词向量适当的权重. 本文为了获取中性词特征向量, 在特征提取器 F_{cp} 之后添加了一个 GRL 来反转梯度的方向. 通过这个训练模块, 可以获得文本中具有区分度较低的中性词特征向量. 为了获取高区分度的情感特征, 将特征向量 f_{cp} 投影到情感极性词向量 f_d 的正交方向上. 与情感极性词特征向量正交的特征空间应该包含对文本情感分类纯净且高效的特征 (如情感分类中的情感相关信息). 将中性词特征向量 f_{cp} 投影到这个正交的特征空间中, 不仅计算出中性词特征向量与极性词特征向量的相似度, 即情感分类的鉴别信息; 而且依据两者的正交距离, 将特殊的中性词特征向量赋予合适权重, 以获取高区分度的情感特征. OPL 可以帮助实现这一目标. 图 4 用一个二维空间的例子说明了 OPL 的思想. 在数学上, 首先将中性词特征向量 f_{cp} 投影到情感极性词特征向量 f_d 上, 计算公式如式(12)所示.

$$f_{cp*} = \text{Orj}(f_{cp}, f_d) \quad (12)$$

式中, Orj 是一个投影函数, 其计算公式如式(13)所示.

$$\text{Orj}(x, y) = \frac{x \cdot y}{|x| |y|} \quad (13)$$

式中, x, y 是向量. 然后在投影特征 f_{cp*} 的正交方向上进行投影, 得到高区分度的分类特征向量.

$$\tilde{f}_{cp} = \text{Orj}(f_{cp}, (f_{cp} - f_{cp*})) \quad (14)$$

由上得知, 式(14)得到的特征向量 \tilde{f}_{cp} 等同于 $f_{cp*} - f_{cp}$. 利用中性词特征向量 f_{cp} 投影得到特征向量 f_{cp*} , 可以构建一个平面 (在三维中). 这个平面和投影特征向量 f_{cp*} 的正交平面的相交就是高区分度的情感特征向量. 此外, 式(13)中的投影是对情感极性词特征向量的一个约束. 即情感极性词特征向量的模量受到

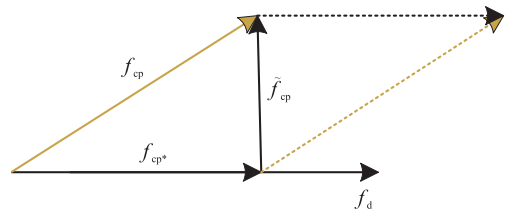


图 4 正交投影原理

Fig. 4 Orthogonal projection principle

将 f_{cp} 投影到 f_d 时的限制,所以由投影得到的情感极性词特征向量的语义信息就是投影特征 f_{cp}^* ,其只包含与中性词特征向量相关的情感极性语义信息.这使得最终得到的高区分度的情感特征向量 \tilde{f}_{cp} 来自于中性词特征向量 f_{cp} ,而不是与情感极性特征向量 f_d 正交的任何平面上的向量.最后,通过投影得到的特征向量 \tilde{f}_{cp} 对文本进行情感分类.

$$Y_{OPL} = \text{softmax}(\tilde{f}_{cp} \cdot W_{cp} + b_{cp}) \quad (15)$$

$$Loss_{cp} = \text{CrossEntropy}(Y_{truth}, Y_{OPL}) \quad (16)$$

这里 $Loss_{cp}$ 函数和 $Loss_d$ 函数是同时训练的,它们使用不同的优化器. $Loss_{cp}$ 损失函数使用 *Adam* 优化器. *D-NET* 中的损失函数 $Loss_d$ 使用的是 *SGD* 优化器^[22].当优化损失函数 $Loss_{cp}$ 时,梯度通过特性 f_d 传递回来.虽然这两种损失函数在特征提取器 F_d 的优化目标是相反的,但 $Loss_{cp}$ 对 F_d 的影响是在 f_d 的正交方向上.这样可以找到一个平衡点,使提取的特征更接近真实的情感极性特征.

3 基于 CBA 模型获取文本情感特征

我们将神经网络模型和注意力机制相结合,提出了 CBA 模型.该模型利用 CNN+BiLSTM 混合神经网络对输入文本进行情感特征提取,结合注意力机制以获取丰富的情感特征.首先,采用 Word2vec 模型将输入文本转换为词向量;其次,利用 CNN 模型优势对输入向量进行充分的挖掘,获取输入文本的主要特征. CNN 模型包含卷积层和最大池化层,卷积层的目的是获取输入数据的特征,两层的激活函数都是 Relu.在卷积层之后进行最大池化操作,对卷积层所提取的特征进行向下采样,达到精简模型参数的目的;然后,将 CNN 网络提取到的特征传入 BiLSTM 网络中,提取文本特征进行强化学习,以获取特征之间的内在联系来解决长时依赖问题;最后,引入 Attention 机制,计算每一时刻输出与整个特征向量的匹配得分.

3.1 词嵌入与处理

CBA 模型采用 word2vec 模型训练词向量.相较于独热编码方式,word2vec 模型通过训练得到维度较低的稠密词向量,可以更好的表示字符、词语之间及上下文信息. Word2vec 模型有 CBOW 和 Skip-gram 两种结构.从向量的训练速度方面来看,CBOW 模型训练向量速度较 Skip-gram 模型更快.但是在语义表达的准确性方面,Skip-gram 模型训练向量的最终效果较 CBOW 模型更优^[23-24].因此本文选择训练结果较好的 Skip-gram 结构训练输入文本的词向量.

假设输入到模型中的一条文本的词数为 K ,用向量 $[W_1, W_2, \dots, W_k]$ 来表示这条文本,在经过词嵌入层后文本表示转换成 $D = [x_1, x_2, \dots, x_k]$, $x_i \in R_d$,其中 d 为词向量维度.

3.2 Multi-head Attention 模块

Attention 机制的本质是一组权重值分布,在自然语言处理领域,权重越大的词在整个文本中越重要,在整个分类任务中发挥的作用也就越大.将注意力放在对文本分类结果影响较大的词可以有效提升分类的效果.

将向量矩阵输入多头自注意力(Multi-head Self-attention)模块,利用目标字特征向量 Q 、目标字上下文特征向量 K 和原始向量 V 计算并增强语义表达.其中,自注意力机制的计算思想为: Q 与 K 先进行相似性计算获取注意力权重,再基于注意力权重向量重构原始向量 V ,以区分 V 中目标词上下文对其不同的重要程度.其计算公式如式(17)、式(18)所示.

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (17)$$

$$\text{attention-output} = \text{Attention}(Q, K, V) \quad (18)$$

式中, d_k 为向量维度.将 Q 与 K 作用生成的注意力向量通过 Softmax 激活函数形成每一时刻输出与整个特征向量的匹配得分,然后对 V 中每个向量与其对应的注意力得分的点乘结果进行加权求和.

经过 BiLSTM-Attention 后得到的向量 O ,既包含了文本上下文信息,又将注意力放在了重要的词语上,更好的表示了语义信息. CBA 模型不仅可以得到丰富的情感特征向量,即先将待分类的文本输入到 Skip-gram 结构,对初试数据进行预处理,得到数据集 D ,然后通过卷积神经网络的卷积层和池化层得到局部关键信息特征向量,并将其传入到 BiLSTM 中提取文本特征进行强化学习,最后结合注意力机制得到一个新

的特征向量 O ,使得新的向量既包含了上下文语义信息又融合了关键局部信息,而且降低模型运算体量,提高情感特征提取效率。

4 实验及结果分析

通过在三个数据集上进行对比试验验证所提方法的有效性。

4.1 实验数据集

本实验的数据集由三部分构成,分别是 *AG_news* 数据集 20 000 条数据、搜狗实验室数据集 50 000 条数据,中山大学数据集 30 000 条数据。具体信息见表 1 所示。

表 1 数据集统计信息

Table 1 Data set statistics

Name	Training	Validation	Test	category	Total
Sogou Lab	20 000	20 000	10 000	4	50 000
Zhongshan	10 000	10 000	10 000	4	30 000
AG_news	10 000	5 000	5 000	4	20 000

4.2 参数设置

在 Word2vec 中训练的词向量表达语义信息准确性方面,由于 Skip-gram 要比 CBOW 效果好,因此本文采用 Skip-gram 结构进行词向量训练。同时我们选取了词频排列前 7 000 的单词进行训练以防止不常用词对实验结果造成影响。为防止 LSTM、CNN 及其混合模型在训练过程中出现过拟合现象,我们将 Drop-out 设为 0.5,随机失活 50%的隐藏层单元的激活值。此外实验采用的 Relu 激活函数可以加速模型的收敛速度,也可以进一步防止过拟合现象的发生。具体其他参数见表 2-4 所示。

表 2 Word2vec 网络参数

Table 2 Word2vec network parameters

parameter	value	parameter	value
Train algorithm	Skip-gram	Words number	6 000
Window size	5	Word vector dimension	200

表 3 CNN 网络参数

Table 3 CNN Network Parameters

parameter	value	parameter	value
Word vector dimension	200	Learning rate	0.001
Convolution size	2,3,4	Drop_out	0.5
Activate the function	Relu		

表 4 BiLSTM 网络参数

Table 4 BiLSTM network parameters

Parameter	value	Parameter	value
Word vector dimension	200	Earning rate	0.001
Hide layer size	256	Drop_out	0.5
Activate function	Relu		

4.3 评价标准

通过 Acc、Pre、Rec 和 F1 评价标准对模型进行评估。

4.4 实验方法

本文对文本情感分类的特征提取采用的是基于正交投影的多种抽取手段相结合的方法。为验证所提出的模型的性能,本文分别在三个数据集上展开实验,具体的实验步骤如下:

Step1:实验数据获取。实验的数据来源于中山大学中文新闻数据集、搜狗实验室中文新闻数据集以及 *AG_news* 英文新闻数据集,先获取有情感极性的评论数据,去噪后筛选出高质量的文本评论 10 000 条。

Step2:计算文本的嵌入矩阵。本文选择 Skip-gram 结构训练输入文本,得到词向量和嵌入矩阵,这样可以更好的表示字符、词语之间及上下文信息。

Step3:构造中性词特征向量词库。利用提出的基于正交投影的方法构建加权中性特征向量词库。

Step4:对评论文本进行情感分类。将加权中性词向量和由复杂神经网络得到的情感特征,通过全连接层,学习具有更高区分度的情感特征,使文本在情感分类时更具判别性。通过 Acc、Pre、Rec 和 F1 评价标准来计算文本情感分类的正确率,同时也与多个模型的文本情感分类结果进行对比。

4.5 实验分析

根据上述的实验步骤,本文采用不同模型分别在三个数据集上做了对比实验。对比模型分别是:

- (1)LSTM:对整个文档建模,进行序列化输出.将单方向隐藏状态的单词均值作为特征进行分类.
- (2)BiLSTM:相对于单向 LSTM,其是将两个方向隐藏状态的单词均值作为特征进行分类.
- (3)CNN:先通过 RNN 提取出文本上下文语义信息,再结合 CNN 从提取的上下文语义信息中获取局部关键信息进行分类.
- (4)CNN-LSTM:先通过 CNN 提取文本的局部特征信息,再结合 LSTM 在提取出的局部关键信息中获取上下文语音信息进行分类.
- (5)LSTM-CNN:先通过 BiLSTM 提取出文本上下文语义信息,再结合 CNN 从提取的上下文语义信息中获取局部关键信息,经过池化后分类.

CPD-CBA 模型和以上基准模型在三个公开数据集上的实验结果如图 5-7 所示,并由此得到以下结论:

(1)CPD-CBA 模型相较于传统的 CNN、LSTM 模型的 F1 值,在搜狗实验室数据集上分别提高了 7%和 6.8%,在中山大学数据集上提高了 4%和 8.5%,在 AG_news 数据集上提高了 3.7%和 2.4%.传统 CNN 在使用卷积核进行特征提取时只考虑到了局部特征,LSTM 模型在分析时认为各个词都对最后的结论起着同等意义,而忽略了上下文语义和带有特定含义的词.而 CPD-CBA 模式不但综合考察了其他影响词分类效率的因素,还在训练过程中把注意力放到了更关键的词上.

(2)CPD-CBA 模型相较于传统的 CNN-LSTM 和 LSTM-CNN 模型的 F1 值,在搜狗实验室数据集上分别提高了 5%和 7.5%,在中山大学数据集上提高了 3%和 2.5%,在 AG_news 数据集上提高了 3%和 2.5%.CNN、LSTM 混合模型相较于单个模型分类效果有所提升.但由于混合模型对影响较大的词缺少注意力,分类准确率有待提升.而 CPD-CBA 模型不仅可以有效提取局部关键特征,还将注意力更多放到对分类结果影响大的词语上,从而提升了文本情感分类的准确率.

(3)CPD-CBA 模型相较于传统的 CNN、LSTM 模型,处理的流程更为复杂,时间和空间的开销更大.filter 数量总数为 $H * W * I$,而每个又被映射到 64 个新的通道,加上每个 filter 的计算要有一个 Bias,所以总的参数数量为 $(H * W * I + 1) * O$.全连接层的前后为 n, m 维的输入输出,其参数规模为 $(n + 1) * m$.

为突出 CPD-CBA 模型在训练过程的优越性,本文在数据集上进行了更深入的研究,得出了数据集训练过程的校验集准确率,如图 8 所示.从图 8 可以看出本文模型的参数优化路线更加高效.在训练前期(前 10 轮),各个模型的准确率都较低,交叉熵损失较高,但本文模型处于领先位置;训练的中期(10 至 20 轮),各个模型的准确率逐渐提升.使用交叉熵损失函数计算得到损失值并进行模型的参数优化,但本文模型的准确率开始趋近平稳;训练的后期(20 至 50 轮),各个模型的准确率已经稳定.

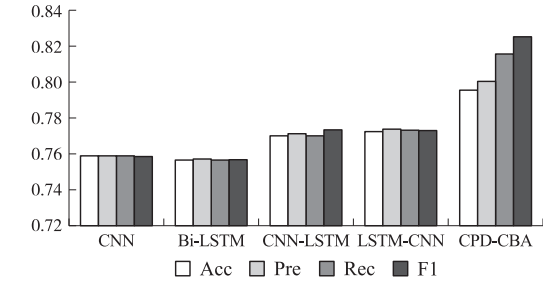


图 5 搜狗实验室的数据集实验结果对比
Fig. 5 Comparison of dataset results from sogou lab

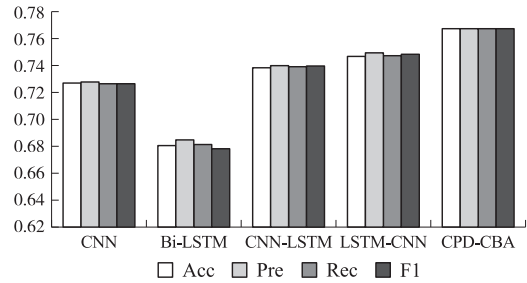


图 6 中山大学数据集实验结果对比
Fig. 6 Comparison of Zhongshan University

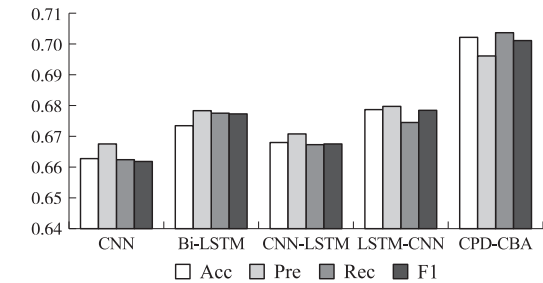


图 7 AG_news 数据集实验结果对比
Fig. 7 AG_news dataset experiment results

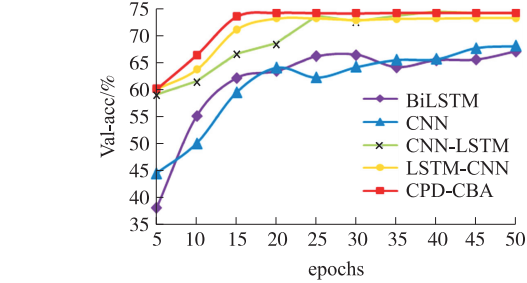


图 8 模型迭代训练
Fig. 8 Model iterative training

CPD-CBA 相较于传统的 CNN 和 LSTM 曲线波动较平缓, CNN 曲线波动较大并且在第 50 轮才趋于稳定. CNN-LSTM 和 LSTM-CNN 相对于 CNN 波动较小,效果更好. 本文提出的 CPD-CBA 模型由于是 CNN 和 LSTM 的混合模型,整体相对平缓收敛且速度更快,在训练过程中一直处于领先,更具优势.

5 结论

本文提出了一种基于正交投影的 BiLSTM-CNN 情感特征抽取方法,以提高文本情感分类的准确率. 本文通过更有语义判别能力的正交空间和深度学习,获取高区分度的情感特征,增加了情感特征提取的完整性,使文本在情感分类时更具判别性. 本文的贡献主要包括以下两个方面:

(1) 本文提出的基于正交投影情感特征抽取方法区别于传统的特征抽取方法,该模型可以筛选出含有特殊意义的词并赋予适当的权重,增加了情感特征提取的完整性. 同时由该方法所构建的情感词库可以为其他词库(例如,商品评论情感词库的构建、微博话题情感词库的构建等)的构建提供方法借鉴,以提高文本情感分类的准确率.

(2) 本文提出一种深层次的神经网络模型(CNN+BiLSTM+Attention). 该模型结合了深度学习网络进行强化学习,深层次的挖掘文本的情感特征,提高了模型的分类准确率和泛化性能,为文本情感分类提供技术支持.

本文提出的抽取方法目前仅针对传统的文本情感分类. 在未来的工作中,将充分考虑模型间的结合,同时改进深层次网络模型以学习出更具判别性的文本情感特征. 同时考虑将其扩展到情感分类和情感值计算等方面,以期获得更好的效果.

[参考文献]

- [1] 王汝言,陶中原,赵容剑,等. 多交互图卷积网络用于方面情感分析[J/OL]. 电子与信息学报,2021,43(0):1-8.
- [2] ZHANG S X,WEI Z L,WANG Y,et al. Sentiment analysis of Chinese micro-blog text based on extended sentiment dictionary[J]. Future generation computer systems,2018,81:395-403.
- [3] FANG Y,TAN H,ZHANG J. Multi-strategy sentiment analysis of consumer reviews based on semantic fuzziness[J]. IEEE access,2018,6:20625-20631.
- [4] XU Z,ZHANG S,CHOO K K R,et al. Hierarchy-cutting model based association semantic for analyzing domain topic on the web[J]. IEEE transactions on industrial informatics,2017,13(4):1941-1950.
- [5] ZHANG B,XU X,YANG M,et al. Cross-domain sentiment classification by capsule network with semantic rules[J]. IEEE access,2018,6:58284-58294.
- [6] MIRTALAIE M A,HUSSAIN O K,CHANG E,et al. Extracting sentiment knowledge from pros/cons product reviews:Discovering features along with the polarity strength of their associated opinions[J]. Expert systems with applications,2018,114:267-288.
- [7] 陈铁明,缪茹一,王小号. 融合显性和隐性特征的中文微博情感分析[J]. 中文信息学报,2016,30(4):184-192.
- [8] ARAQUE O,CORCUERA-PLATAS I,SÁNCHEZ-RADA J F,et al. Enhancing deep learning sentiment analysis with ensemble techniques in social applications[J]. Expert systems with applications,2017,77:236-246.
- [9] 谢丽星,周明,孙茂松. 基于层次结构的多策略中文微博情感分析和特征抽取[J]. 中文信息学报,2012,26(1):73-83.
- [10] 李淑芝,余乐陶,邓小鸿. 融合深度情感分析和评分矩阵的推荐模型[J]. 电子与信息学报,44(1):245-253.
- [11] 车思琪,李学沛. 评价系统视阈下中美企业致股东信情感话语对比分析——基于情感词典和机器学习的文本挖掘技术[J]. 外国语(上海外国语大学学报),2021,44(2):50-59.
- [12] 景丽,李曼曼,何婷婷. 结合扩充词典与自监督学习的网络评论情感分类[J]. 计算机科学,2020,47(11A):78-82,91.
- [13] DA'U A,SALIM N,RABIU I,et al. Recommendation system exploiting aspect-based opinion mining with deep learning method[J]. Information sciences,2020,512:1279-1292.
- [14] LIAO S,WANG J,YU R,et al. CNN for situations understanding based on sentiment analysis of twitter data[J]. Procedia computer science,2017,111:376-381.
- [15] 陈飞玥,朱玉莲,陈晓红. 多层特征融合的 PCANet 及其在人脸识别中的应用[J]. 南京师大学报(自然科学版),2021,166(44):127-133.
- [16] 金志刚,胡博宏,张瑞. 基于深度学习的多维特征微博情感分析[J]. 中南大学学报(自然科学版),2018,49(5):1135-1140.

-
- [17] CHEN T, XU R, HE Y, et al. Improving sentiment analysis via sentence type classification using BiLSTM-CRF and CNN[J]. Expert systems with applications, 2017, 72: 221–230.
- [18] GAO Z, WANG L, ZHOU L, et al. HEP-2 cell image classification with deep convolutional neural networks[J]. IEEE journal of biomedical and health informatics, 2016, 21(2): 416–428.
- [19] HUANG B X, CARLEY K. Parameterized convolutional neural networks for aspect level sentiment classification[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. New York, NY: ACM, 2018: 1091–1096.
- [20] FAN C, GAO Q, DU J, et al. Convolution-based memory network for aspect-based sentiment analysis[C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York, NY: ACM, 2018: 1161–1164.
- [21] QIN Q, HU W, LIU B. Feature projection for improved text classification[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2020: 8161–8171.
- [22] CONNEAU A, SCHWENK H, BARRAULT L, et al. Very Deep Convolutional Networks for Text Classification[C]//Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2017, 1: 1107–1116.
- [23] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//International Conference on Machine Learning. PMLR, 2015, 37: 1180–1189.
- [24] 张柯文, 李翔, 严云洋, 等. 基于多特征双向门控神经网络的领域专家实体抽取方法[J]. 南京师大学报(自然科学版), 2021, 165(44): 128–135.

[责任编辑: 杜忆忱]