

基于多维扩展特征与深度学习的微博短文本情感分析

孙晓^{*①} 彭晓琪^① 胡敏^① 任福继^{①②}

^①(情感计算与先进智能机器安徽省重点实验室 合肥 230009)

^②(德岛大学工学部 德岛 770-8509)

摘要: 该文提出了一种基于深度信念网络(DBN)和多维扩展特征的模型,实现对中文微博短文本的情感分类。为降低传统文本分类方法在处理微博短文本时特征稀疏的影响,引入社交关系网络作为扩展特征,依据评论者和博主之间的社交关系,提取相关评论扩展原始微博,将扩展后的多维特征作为深度信念网络的输入。通过叠加多层玻尔兹曼机(RBM)构建DBN模型底层网络结构,多层玻尔兹曼机可以对原始输入抽象并获得数据的深层语义特征。在多个RBM层上叠加一层分类玻尔兹曼机(ClassRBM),实现最终情感分类。实验结果表明,通过调整模型参数和网络结构,构建的深度学习模型在情感分类中能够获得比SVM和NB等浅层分类系统更优的结果,另外,实验证明使用扩展多维特征方法可提高短文本情感分类的性能。

关键词: 社交网络; 深度信念网络; 扩展多维特征; 受限玻尔兹曼机; 分类受限玻尔兹曼机

中图分类号: TP393; TP391.43

文献标识码: A

文章编号: 1009-5896(2017)09-2048-08

DOI: 10.11999/JEIT160975

Extended Multi-modality Features and Deep Learning Based Microblog Short Text Sentiment Analysis

SUN Xiao^① PENG Xiaoqi^① HU Min^① REN Fuji^{①②}

^①(Anhui Province Key Laboratory of Affective Computing and Advanced Intelligent Machine, Hefei 230009, China)

^②(Faculty of Engineering, University of Tokushima, Tokushima 770-8509, Japan)

Abstract: This paper presents a Deep Belief Nets (DBN) model and a multi-modality feature extraction method to extend features' dimensionalities of short text for Chinese microblogging sentiment classification. Besides traditional features sets for document classification, comments for certain posts are also extracted as part of the microblogging features according to the relationship between commenters and posters through constructing microblogging social network as input information. Multi-modality features are combined and adopted as the input vector for DBN. A DBN model, which is stacked with several layers of Restricted Boltzmann Machine (RBM), is implemented to initialize the structure of neural network. The RBM layers can take probability distribution samples of input data to learn hidden syntactic structures for better feature representation. A Classification RBM (ClassRBM) layer, which is stacked on top of the former RBM layers, is adapted to achieve the final sentiment classification. The results demonstrate that, with proper structure and parameter, the performance of the proposed deep learning method on sentiment classification is better than the state of the art surface learning models such as SVM or NB, which proves that DBN is suitable for short-length document classification with the proposed feature dimensionality extension method.

Key words: Social network; Deep Belief Nets (DBN); Extended multi-modality features; Restricted Boltzmann Machine (RBM); Classification restricted Boltzmann machine

1 引言

近年来,随着微博等社交平台的普及,其

角色不仅仅是人与人之间的交流工具,还作为一种情绪宣泄途径。微博中蕴含的情感信息表征了博主的个性偏好甚至政治取向。对微博的情感极性判断主要包括文本特征提取和机器学习模型选择等。特征提取方法包括基于文本统计^[1]和基于知识词典^[2]。但这些方法大多考虑字符或者词之间词形上的联系,词义等内涵信息往往被忽略了,或未被全面考虑。

文本的情感分析需要考虑深层词义信息,已有研究采用深度学习算法^[3](如神经网络语言模型)来挖掘深度词义知识,或基于外部知识库^[4](词典)获得

收稿日期: 2016-09-28; 改回日期: 2017-05-17; 网络出版: 2017-06-14

*通信作者: 孙晓 sunx@hfut.edu.cn

基金项目: 国家自然科学基金(61432004), 模式识别国家重点实验室开放课题(NLPR)(201407345), 安徽省自然科学基金(1508085QF119), 中国博士后科学基金(2015M580532)

Foundation Items: The National Natural Science Foundation of China (61432004), The Open Project Program of the National Laboratory of Pattern Recognition (NLPR) (201407345), The Natural Science Foundation of Anhui Province (1508085QF119), The China Postdoctoral Science Foundation (2015M580532)

词义、语义和句法结构等等。文献[5]将原始领域情感词典转换为新领域的情感词典，可以直接表达新领域的情感特征，从而用于跨领域情感分析。文献[6]使用情感词作为附加特征并结合领域特征，实验表明使用语义特征处理文本，能够获得比词频特征更高的召回率和 F1 值。文献[7]，文献[8]和文献[9]等通过构建句子语法解析树来发掘词之间的从属关系，解析树包含整个句子的语义结构和单词的语法角色。面向情感计算的机器学习模型，从层次结构上，主要分为两类，浅层学习模型和深度学习模型。文献[10]比较了浅层机器学习算法(朴素贝叶斯和 N 元文法模型)在电影评论情感分类中的效果，得出以上方法均可达到 80%左右的准确率。浅层的学习模型需要大量的实验标注数据和人工设计的特征，并且这些模型的共同特点是函数计算复杂以及数据表征的层次有限。近年深度学习在图像和语音处理等热门研究中获得了广泛的关注，深度学习可以通过构建非线性多层网络结构来学习复杂函数。文献[11]提出了将深度学习用于文本分类，使用学习到的高层次抽象特征训练的线性分类器比传统分类器表现更好。文献[12]证实了深度学习在自然语言处理中的有效性，验证了它学习深度结构化知识(如文本的语义信息)的能力。深度学习相对浅层学习模型能够更好地解决分类中的特征提取和模型复杂度问题，但目前深度学习更多地用于长文本分类，因为微博句子短，无法利用深度学习模型进行很好地表征^[13,14]，效果较好的是基于卷积神经网络和基于递归神经网络模型的方法^[15-18]，例如，通过融合字和词特征来扩展特征的方法^[15]。但是在这些工作中，主要是对英文评论中的句子本身进行建模，虽然该方法可以对句子本身进行更好的向量表示，但是针对中文微博并不一定完全适用，中文微博文本长度更短，不规范与口语化表现得更明显。仅依赖与句子本身信息，不易获得其结构特征以及情感语义信息。

对于中文微博情感识别问题，存在以下的特点：中文微博长度短，句法结构不规范。另外，微博的短文本导致传统的特征提取方法存在比较严重的特征稀疏问题。本文针对中文微博情感分类中存在的问题，(1)提出了一种多维扩展特征提取方法。相比传统的特征提取方法，本文方法在提取微博文本特征的时候，引入微博的评论以及社交网络关系(包括评论和评论人与博主的关系)作为微博的扩展特征。(2)深度学习通过学习深层的非线性的网络结构能够实现任意复杂函数的逼近，同时深度学习强大的特征学习能力可以从少量的样本集中抓取到数据的本质特征，本文依据深度学习原理构建了面向短文本分

类的深度信念网络(DBN)模型，DBN 模型由分类受限玻尔兹曼机(ClassRBM)^[19-21]层和几层受限玻尔兹曼机(RBM)叠加构成。(3)通过实验选择适当的特征集和深度学习的网络结构，并在新浪微博语料和公开数据集上与现有模型进行了比较。

2 多维扩展特征提取

本文提出一种扩展多维特征提取方法来扩展中文微博情感分析问题中的短文本特征表示。扩展多维特征融合了基于文本的多粒度特征和基于微博社交关系网络的多维特征。

2.1 文本级特征提取

文本级的特征提取首先需要对句子进行分词，并对其中所有情感词的情感进行标记，其中每个词都有一个情感值(情感词典中获取)；然后进一步对已分词的微博进行语义结构分析，分析其中的情感词修饰词，如否定词、程度词等。否定词会改变情感词极性，程度词会增强或削弱句子情感强度。表 1 包含了实验中使用的部分程度词(57 个)和否定词(37 个)。

表 1 部分程度词和否定词

程度词	否定词
很，太，非常，十分，特别， 尤其，真，…	不，非，无，勿，莫，不用， 不够，没有，未曾，…

程度词的值称之为程度影响指数(DIV)，否定词的值称之为否定影响指数(NIV)，DIV 和 NIV 均可从情感词典中获取。通过遍历微博的语法结构树，标记出微博的程度词和否定词。情感词(w)的情感值将被改变。其最终的情感分数(FEMV)通过式(1)进行计算。

$$FEMV(w) = \prod_{i=1}^m DIV_i \prod_{j=1}^n NIV_j \cdot EMV(w) \quad (1)$$

其中， m 是修饰情感词 w 的程度词个数， n 是修饰情感词 w 的否定词个数， DIV_i 是第 i 个程度词的程度影响指数， NIV_j 是第 j 个否定词的否定影响指数， $EMV(w)$ 是情感词 w 的情感值。最后，情感词的最终情感值将用于抽取基于文本的多粒度特征。

2.2 社交关系网络特征提取

微博具有点对点关注和公开传播的特点。微博中相对稳定的关注者之间的互动往往持有同样观点与情感。微博社交网络关系反映了帖子和评论之间的连接，进而反映了帖子和评论之间的情感关联。社交网络将所有的微博置于一个图中，如图 1 所示，节点 P 代表用户，数字表示用户某段时间发布的微




图 1 社交网络的结构

博数目,带箭头的直线表示博主评论其他微博,边上面的数字表示过去某段时间内评论的次数,表征了两个用户之间联系的频度。箭尾表示发微博一方,箭头表示评论一方。

将博主和评论人之间关注关系数据作为微博的社交关系网络特征,附加到评论特征中,用于扩展原始微博特征。其中特征 $F(1), F(2), \dots, F(8)$ 描述如下: $F(1)$ 为某微博作者的粉丝对该微博的评论次数。 $F(2)$ 为该微博获得他人(非粉丝)评论的次数。 $F(3)$ 为微博作者已发布的所有帖子数量。 $F(4)$ 为基于博主的活跃指数和微博的流行指数(可通过接口直接获取,表征了博主在微博上的活跃程度,以及微博本身的传播程度),具体值为流行指数除以活跃指数。 $F(5)$ 为某微博获得的评论总数量。 $F(6)$ 为计算博主和评论者的互动程度。首先使用迪杰斯特拉最短路径算法获得图 1 中两个节点(对应博主和评论者)之间的最短路径,然后记录最短路径上的所有节点和边的数目(取该数字的倒数记为 CV),默认值为零(即在当前关系图中无关系)。 $F(7)$ 为对于图 1 中网络上的每一个节点,以该节点作为起点,对整个图进行广度遍历,记录下最长的路径并记录路径上的节点数。 $F(8)$ 为在获取了所有的博主和评论者之间的路径之后,间接关系分数就是这些路径的数目。

以上特征是用于测量博主和评论者之间的互动程度。因为微博中社交关系网络较大,往往难以搜索整个网络,因此遍历的范围仅限于一级关注。

2.3 多种形式特征的结合

在 2.1 节中,获取了微博及其评论的文本级别特征。在 2.2 节中,对于有评论的微博,获取了社交关系网络级别的特征。进一步,融合微博和评论文本级别特征和社交网络级别特征,构建扩展多维特征。

对于微博和评论文本级别的特征, tf_0 代表微博文本的特征, $(tf_1 \ tf_2 \ \dots \ tf_m)$ 表示评论的特征,即微博对应 m 个评论。获取 m 个评论对应的社交关系网络

特征向量 $(sv_1 \ sv_2 \ \dots \ sv_m)$,按照式(2)整合评论文本特征和评论的社交关系网络特征特征,首先,由两种特征向量组合获得 tsv , tsv 也是一个矩阵:

$$tsv = \sum_{i=1}^m tf_i \cdot sv_i \quad (2)$$

其中, tf_i 是第 i 条评论特征, sv_i 第 i 条评论对应的社交关系网络特征,利用矩阵 tsv 的范数 $norm$ 进行规范化。

$$\frac{1}{norm} \cdot tsv = (e_1 \ e_2 \ \dots \ e_k) \quad (3)$$

将微博文本特征与式(3)链接获得 $(tf_0 \ e_1 \ e_2 \ \dots \ e_k)$,形成最终的特征向量 e ,设 N 是社交网络特征的维度。通过式(4)进行规范化:

$$e(k) = \frac{e(k) - \frac{1}{N} \sum_{i=1}^N e(i)}{\sqrt{\frac{1}{N} \sum_{i=1}^N \left(e(i) - \frac{1}{N} \sum_{i=1}^N e(i) \right)^2}} \quad (4)$$

3 DBN 模型介绍

为实现中文微博的情感分类,构建一个多层深度信念网络(DBN),该深度学习模型结合了监督学习和非监督学习,使用了上文介绍的多维扩展特征。该 DBN 模型由 1 层 ClassRBM 和几层 RBM 组成。RBM 层实现对输入数据更好的表示。ClassRBM 是一个 3 层网络:输入层,隐藏层和输出层,用于最后的分类。RBM 和 ClassRBM 之间的结构类似,使得监督层和非监督层之间传递参数更容易。

3.1 RBM 和 ClassRBM

RBM 是典型的两层神经网络结构,隐含层 H 和可视层 V 。隐形层和可视层之间是全连接,而同一层的所有单元之间是相互独立的。多层 RBMs 的第 1 层采用 Gaussian-Bernoulli RBM,而后续层采用 Bernoulli-Bernoulli RBM。接下来是 RBM 自训练过程。首先,初始的输入特征向量分配至可视层,接着计算隐含层到可视层的条件概率分布,然后,同样计算从可视层到隐藏层的条件概率分布,然后重新分配可视层,根据预设阈值重复上述步骤。ClassRBM 的区别是加入了样本分类单元。ClassRBM 的输入数据由样本特征表示和样本标签 $(0,0, \dots, 1, \dots, 0)$ 组成。

3.2 DBN 的结构

多层深层结构可以解决复杂函数表示问题,增强模型表征能力;其学习的特征更能反映输入数据更高层的结构。本文训练 DBN 模型来完成微博的情感分类。DBN 模型由一个独立 ClassRBM 层和多层

RBM 组成。图 2 展示了 DBN 的结构。

首先多层 RBM 逐层训练连接权重和偏置，与传统的 RBM 训练过程相同。然后训练 ClassRBM。最上层 RBM 的输出特征和数据的分类标签都被设置为 ClassRBM 层的输入。分类层使用监督学习来训练。




图 2 DBN 结构

图 2 为级联 RBM 的深度学习。每一层 RBM 的任务是完成输入特征的抽象表示；顶层 ClassRBM 主要训练方法是加入不同的偏差分布参数和能量函数相应的贡献值。

本文中，DBN 中 RBM 通过一种叫做对比散度 CD 的方法快速地无监督的训练。初始化 RBM 的参数：RBM 中的权值是服从均值为 0，标准差为 1 的正态分布；偏置量和的初始值分别都是 0；学习率为 0.01；采用随机梯度法进行迭代，迭代次数设为 100。

4 实验结果与分析

实验的目的是验证(1)微博多维特征与(2)深度学习模型的效果。我们构建了两个语料。第 1 个使用的是最近第 5 届中文倾向性分析评测研讨会中的语料(D1)，在其评测任务④(微博情感分析)中包含了 7000 多个标注样本，情感标记为正面或负面。第 2 个数据集是 2014 年抓取并经过标注的新浪微博情感语料库(D2)，为了能够获取多维微博特征(需要获取微博的评论及其社交关系网络)，抽取了微博语料库 D2 中的部分数据(约 100 万样本)。表 2 是实验语料的组成。语料 D1 中 7415 个样本，语料 D2 包括评论和社交关系网络的微博样本集。

实验目的：(1)证明多维特征比单一的文本内容特征效果更好，尤其是在短文本分类时；(2)证明有多层 RBM 和 ClassRBM 组成的 DBN 能够提高分类精度，相对于传统浅度模型可以获得更好的分类表现。

表 2 实验语料

	数据集			
	D1		D2	
	训练	测试	训练	测试
正向	3069	445	2523	476
负向	3427	474	3108	513
中性	0	0	1769	378

针对目的(1)，第 1 步是选择适当的文本特征的维度，设计了 4 组实验来获取最优维度。

第 1 组文本特征作为初始特征，这些特征通过 SVM 训练。

第 2 组结合文本特征和社交关系网络特征作为初始特征，使用 SVM 训练。

第 3 组文本特征作为初始特征，训练模型使用有一个 RBM 层和 ClassRBM 层的 DBN。

第 4 组结合了文本特征和社交关系网络特征(提取方法见 2.2 节)，DBN 由一层 RBM 和一层 ClassRBM 层组成。

在这 4 组实验设置中，为了对比，为两种模型均设置最优参数。采用数据集 D2 作为实验数据。SVM 的最佳参数是($\gamma = 3$, $\text{coef}=1.5$)。有一个 RBM 层的 DBN 的隐含层单元数量设置为 1500。

图 3 中的 3 条曲线分别表示精度、召回率和 F1 值。从图 3 的 4 幅图中看出，准确率变化的大致趋势相同。特征维度小于 2500 时，准确率不断提高；当维度大于 2600 时，准确率上升变慢；当维度值小于 1500 时，所有的实验都表现较差，因为特征维度较小，特征向量难以很好地表征微博文本。只选一个 RBM 层是因为计算量会随着特征维度值的增加迅速增大。考虑到准确性和计算复杂度，本文选择 2600(系统词典维度)作为文本特征的维度。比较图 3 的 4 个子图，多维特征表示方法比单一特征的方法表现得更好。当维度值限于 1000 时，多维特征表示方法能够比单一特征的方法获取更多特征，进而可以获取更高的准确率。

表 3 展示了实验所采用的不同特征集合及其维度，表 4 展示了不同特征组合，以及不同模型在不同的数据集上的实验结果(只列出了其中最优的 6 种组合)，其中 f1, f2, f3 是基于 TFIDF 提取的一元词典、二元词典和情感词典。从特征组合 1 和特征组合 2 可以看出情感词特征 f3 的引进对结果无显著影响，也就是 f3 不能很好地表征句子情感信息。从特征组合 2 和特征组合 3 与特征组合 4 的对比可知，情感词特征和文本级特征的联合使用比单独使用某一种特种具有更好的效果，因为两种特征的联合使

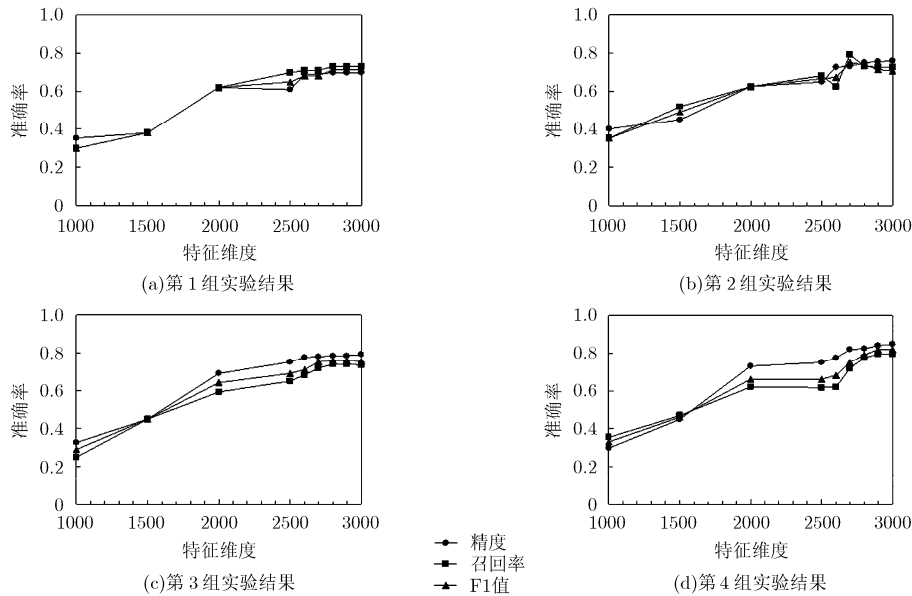


图 3 不同特征维度比较

表 3 不同特征介绍

特征标记	特征名称	特征描述	特征维度
f1	一元	单词特征	2200
f2	二元	双词特征	5000
f3	情感词	情感值情感词特征	3300
f4	文本级特征	微博和评论的语法语义特征	2600
f5	社交关系网络特征	发微博者和评论者社交关系网络特征	8

表 4 不同特征组合在数据集 D2 上的准确率(%)

组合序号	特征组合	SVM	DBN
1	f1+f2	66.9	67.1
2	f1+f2+f3	66.4	66.8
3	f1+f2+f4	70.8	71.8
4	f1+f2+f3+f4	72.1	73.2
5	f1+f2+f4+f5	76.9	77.3
6	f1+f2+f3+f4+f5	76.8	77.1

得特征的提取更加全面,更具有代表性。从特征组合 3 和特征组合 4 可知,加入 f3 是有提升的,但特征组合 5 和特征组合 6,加入 f3 反而没提升,这是因为社交关系网络特征和情感词特征之间具有一定的相关性,一般情况下,评论者与发微博者之间存在积极的关系,那么情感词也大多会是正向的,两者之间如果是消极的关系,那么情感词也大多会是负向的,所以在一定程度上,也验证了社交关系网络特征包含着情感词特征。社交关系网络特征有 8

种子特征组合而成,而实验设置的维度大致在 2000 以上,这使得关系网络特征稀疏性较大,然而从特征组合 3 和特征组合 5 比较得知,引入社交关系网络特征对实验结果仍有较大的提升,因为社交关系网络特征中包含了许多文本级特征所不具有的特征,而这些特征对实验结果有着较大的影响。而最佳的特征集组合是{f1,f2,f4,f5}。中文微博情感识别会存在特征稀疏的问题,因此本文提出使用评论扩展微博特征的方案。这个假设是两个频繁交流的好友的观点或者倾向性会趋同,该假设的关键在于同时考虑了评论、评论人、评论人和博主之间的交互频度,还有评论人和博主之间的好友关系。将这些社交网络关系作为评论的参数,而带参数的评论则作为原微博的特征扩展。在表 4 中,增加了社交网络关系的扩展特征后,情感识别的效果获得了提升。

为了进一步测试上述方法,同样使用第 5 届中文倾向性分析评测研讨会 COAE2014 中任务④^[22]的最佳方法进行对比。使用本文构建的深度模型在语料 D1 上进行实验。由于训练集和测试集仅仅含有帖子而没有评论,所以在本实验的深度学习中仅采用与帖子相关的特征集,即仅仅采用表 4 中的特征组合 3,然后采用第 3 组维度实验中取得最佳实验参数的 DBN 模型。对比结果如表 5 所示。

在不同数据集上的实验验证了模型的有效性,相比在 COAE2014 任务④中表现很好的模型在正向和负向的召回率上都表现出了更好的性能。同时,结果也表明了同最优算法相比,即使只采用微博帖子的特征,未采取扩展多维度特征,深度学习模型在正负面样本中均获得了比最佳算法更高的召回率和 F1 值。

表 5 COAE2014 的结果

	正向			负向		
	精度	召回率	F1 值	精度	召回率	F1 值
最优	0.977	0.603	0.715	0.971	0.766	0.778
中值	0.891	0.299	0.445	0.850	0.281	0.428
本文模型	0.862	0.730	0.791	0.727	0.890	0.800

第 2 个实验目标是确定 DBN 形状和深度。实验在数据集 D2 上进行，而 DBN 中每层 RBM 参数设置与 3.1 节所述相同。不同 DBN 形状的结果受到顶层 DBN 隐藏单元的影响，即 ClassRBM 层。结果如图 4 所示，分析得到 DBN 形状对其在在微博情感分类表现几乎没有影响。当隐藏单元超过 500 个的时候，准确率基本保持在 76%左右，所以后续实验中顶层隐藏单元定为 500 个。

进一步设置几组具有不同层数的 DBN 模型来证实深度网络模型对分类的有效性，并且获得最优的 DBN 层数。设置层数最大值为 7，自底向上的隐藏层单元的数量依次是 2000,1500,1000,1000,500,500,500。

从图 5 可以看出，F1 值随着层数的增加而稳步提升，在层数 4 处模型可能获得局部最小值而造成波动。当 RBM 层超过 6 时，F1 值下降。随着 DBN 模型的复杂度增加，模型所对应的函数的复杂程度越高，更容易出现过拟合问题。另外，特征信息在优化过程中也可能丢失，这都可能导致精度下降。

接着设计 4 组实验对比深度学习模型与其他浅层学习模型的效果，实验在 D2 上进行。DBN(i)(i 表示 RBM 的层数)，支持向量机和朴素贝叶斯均用于对比实验，模型参数均设置为最优。3 组实验均使用多维特征，对比不同情感分类效果。此外，为了与深度学习模型对比，构建了卷积神经网络模型 CNN 和 LSTM 模型，两个模型均将词向量作为模型输入，其中 LSTM 采用 <http://deeplearning.net/tutorial/lstm.html> 中的最优模型和参数，而卷积神经网络参考了文献[15]中的最优模型和参数，使用这

两个参考文献中的最优模型和参数，是因为两篇论文与本文有着相似的研究目标，如何用最优模型实现对文本情感的相关分析。为使用这两个模型，首先在 100 万已经分词的微博上训练相应的字和词向量，作为两个模型的输入。

表 6 展示了情感分类的结果。从分类的结果可以看出，DBN 的整体表现优于 SVM 和 NB，因为特征不稀疏，DBN 相对于 SVM 具有更好的特征提取和建模能力，并且 DBN 将特征经过多层抽象，能够获取深层语义知识。在 3 种情感分类中，中性情感的分类效果是最弱的，这主要是由于微博口语性表达中许多混淆和歧义导致的。通过对比，发现基于词的模型要优于基于字的模型，因此在最后的比较中，只列出了基于词的卷积神经网络和 LSTM 的实验结果。这可能是因为语料规模的原因，基于字的模型，不足以让深度学习模型训练得到更高层的语义特征，最终实验结果也不如本文提出的特征和模型。

5 结束语

本文面向中文微博情感分类，提出了使用扩展多维特征与深度学习模型(DBN)来解决由于中文微博内容过短所致的特征稀疏问题。结果表明扩展多维特征的特征比传统特征提取方法更有效，更有利于微博短文本分类问题，并且，针对微博情感分类问题，通过设置适当的结构和参数，深度学习模型比传统浅度学习模型(SVM 和 NB)效果更优。在以下几个方面可以考虑进一步改进，所有用户之间的




图 4 不同形状的 DBN 的实验结果




图 5 不同层数结构的 DBN 的实验结果

表 6 不同模型的情感分类结果

		SVM	DBN(5)	DBN(6)	NB	CNN	LSTM
正向	精度	0.802	0.812	0.831	0.792	0.798	0.801
	召回率	0.693	0.732	0.773	0.701	0.710	0.712
	F1 值	0.747	0.770	0.786	0.747	0.705	0.754
中性	精度	0.701	0.703	0.718	0.678	0.711	0.701
	召回率	0.682	0.673	0.645	0.632	0.672	0.667
	F1 值	0.691	0.715	0.705	0.654	0.691	0.684
负向	精度	0.793	0.827	0.834	0.754	0.801	0.841
	召回率	0.711	0.699	0.782	0.711	0.689	0.677
	F1 值	0.736	0.758	0.807	0.732	0.741	0.750

社交网络关系应该可以计算出来作为特征，然而这会增加计算复杂度，但可以通过剪枝筛选，避免漏掉重要特征；同时，训练过程中系统耗时会随着模型的层数的增加而增加，这可以通过采用一些更好的训练算法来优化性能。

参 考 文 献

- [1] 刘斌, 黄铁军, 程军, 等. 一种新的基于统计的自动文本分类方法[J]. 中文信息学报, 2002, 16(6): 18-24.
LIU Bin, HUANG Tiejun, CHENG Jun, *et al.* The automatic text classification method based on statistics[J]. *Journal of Chinese Information Processing*, 2002, 16(6): 18-24. doi: 10.3969/j.issn.1003-0077.2002.06.003.
- [2] 覃晓, 元昌安, 彭昱忠, 等. 基于词典和遗传算法的文本特征获取方法[J]. 计算机工程与设计, 2008, 29(21): 5651-5654.
QIN Xiao, YUAN Chang'an, PENG Yuzhong, *et al.* Based on the dictionary method and genetic algorithm for text feature extraction[J]. *Computer Engineering and Design*, 2008, 29(21): 5651-5654.
- [3] 胡侯立, 魏维, 胡蒙娜. 深度学习算法的原理及应用[J]. 信息技术, 2015(2): 175-177. doi: 10.13274/j.cnki.hdzj.2015.02.045.
HU Houli, WEI Wei, and HU Mengna. The principle and application of deep learning algorithm[J]. *Information Technology*, 2015(2): 175-177. doi: 10.13274/j.cnki.hdzj.2015.02.045.
- [4] 王荣波, 谌志群, 周建政, 等. 基于 Wikipedia 的短文本语义相关度计算方法[J]. 计算机应用与软件, 2015, 32(1): 82-85. doi: 10.3969/j.issn.1000-386x.2015.01.021.
WANG Rongbo, SHEN Zhiqun, ZHOU Jianzheng, *et al.* Short text semantic relatedness calculation method based on Wikipedia[J]. *Computer Applications and Software*, 2015, 32(1): 82-85. doi: 10.3969/j.issn.1000-386x.2015.01.021.
- [5] GLOROT X, BORDES A, and BENGIO Y. Domain adaptation for large-scale sentiment classification: A deep learning approach[C]. Proceedings of the 28 International Conference on Machine Learning, Bellevue, WA, USA, 2011: 513-520.
- [6] SAIF H, HE Y, ALANI H, *et al.* On stopwords, filtering and data sparsity for sentiment analysis of twitter[C]. The International Conference on Language Resources and Evaluation, Reykjavik, Iceland, 2014: 810-817.
- [7] XIA R, XU F, YU J, *et al.* Polarity shift detection, elimination and ensemble: A three-stage model for document-level sentiment analysis[J]. *Information Processing & Management*, 2015, 52(1): 36-45. doi: 10.1016/j.ipm.2015.04.003.
- [8] PEISENIEKS J, SKADINŠ R, and PEISENIEKS J. Uses of machine translation in the sentiment analysis of tweets[C]. Human Language Technologies-the Baltic Perspective, Kaunas, Lithuania, 2014: 126-131. doi: 10.3233/978-1-61499-442-8-126.
- [9] SUBRAHMANYAN and REFORGIATO D. AVA: Adjective-verb-adverb combinations for sentiment analysis[J]. *IEEE Intelligent Systems*, 2008, 23(4): 43-50. doi: 10.1109/MIS.2008.57.
- [10] NARENDRA B, SAI K U, RAJESH G, *et al.* Sentiment analysis on movie reviews: A comparative study of machine learning algorithms and open source technologies[J]. *International Journal of Intelligent Systems Technologies and Applications*, 2016, 8(8): 66-70. doi: 10.5815/ijisa.2016.08.08.
- [11] WU F and HUANG Y. Collaborative multi-domain sentiment classification[C]. IEEE International Conference on Data Mining, Atlantic City, NJ, USA, 2015: 459-468. doi: 10.1109/ICDM.2015.68.
- [12] ZHENG W L, ZHU J Y, PENG Y, *et al.* EEG-based emotion classification using deep belief networks[C]. IEEE International Conference on Multimedia and Expo, Chengdu, China, 2014: 1-6. doi: 10.1109/ICME.2014.6890166.
- [13] PSOMAKELIS E, TSERPES K, ANAGNOSTOPOULOS D,

- et al.* Comparing methods for twitter sentiment analysis[C]. International Conference on Knowledge Discovery and Information Retrieval. Rome, Italy, 2015: 225–232. doi: 10.5220/0005075302250232.
- [14] BRAVO-MARQUEZ F, MENDOZA M, and POBLETE B. Combining strengths, emotions and polarities for boosting twitter sentiment analysis[C]. Workshop on Issues of Sentiment Discovery and Opinion Mining, New York, NY, USA, 2013: 1–9. doi: 10.1145/2502069.2502071.
- [15] XU K, FENG Y, HUANG S, *et al.* Semantic relation classification via convolutional neural networks with simple negative sampling[J]. *Computer Science*, 2015, 71(7): 941–950. doi: 10.18653/v1/D15-1062.
- [16] SANTOS C N D and GATTIT M. Deep convolutional neural networks for sentiment analysis of short texts[C]. International Conference on Computational Linguistics, Dublin, Ireland, 2014: 69–78.
- [17] ZHAI S and ZHANG Z. Semisupervised autoencoder for sentiment analysis[J]. *Computer Science*, 2015, 64(8): 1570–1582. doi: 10.1080/03081087.2015.1107020.
- [18] SOCHER R, HUVAL B, MANNING D, *et al.* Semantic compositionality through recursive matrix-vector spaces[C]. Proceedings of the Conference on Empirical Methods in Natural Language Processing, Jeju Island, Korea, 2012: 1201–1211.
- [19] MIDHUN M E, NAIR S R, PRABHAKAR V T N, *et al.* Deep model for classification of hyperspectral image using restricted Boltzmann machine[C]. International Conference on Interdisciplinary Advances in Applied Computing, New York, NY, USA, 2014: 1–7. doi: 10.1145/2660859.2660946.
- [20] WANG Y, ZHAO S, QU D, *et al.* Using conditional restricted Boltzmann machines for spectral envelope modeling in speech bandwidth extension[C]. IEEE International Conference on Acoustics, Speech and Signal Processing, Shanghai, China, 2016: 5930–5934. doi: 10.1109/ICASSP.2016.7472815.
- [21] CHEN F, WU Y, BU Y, *et al.* Spectral classification using restricted Boltzmann machine[J]. *Publications of the Astronomical Society of Australia*, 2014, 31(31): 386–406. doi: 10.1017/pasa.2013.38.
- [22] TRIPATHY A, AGRAWAL A, and RATH S K. Classification of sentiment reviews using n-gram machine learning approach[J]. *Expert Systems with Applications*, 2016, 57: 117–126. doi: 10.1016/j.eswa.2016.03.028.
- 孙 晓： 男，1980年生，博士，副教授，硕士生导师，主要研究方向为自然语言处理、机器学习等。
- 彭晓琪： 女，1991年生，硕士生，研究方向为自然语言处理、情感计算等。
- 胡 敏： 女，1967年生，教授，硕士生导师，主要研究方向为多媒体信息处理、情感计算等。
- 任福继： 男，1959年生，教授，博士生导师，主要研究方向为人工智能、情感计算等。