

文本情感与情绪分析综述

3.1 概述

文本情感与情绪分析的主要任务是识别人们谈论的话题中所表达的观点,主要包括情感信息抽取、立场挖掘、情绪诱因识别、情绪分类等。随着文本分析与挖掘技术的深入,很多领域都出现了与情感、情绪分析有关的产品和应用:从电商评论到 QA 服务,从信息检索到舆情分析、票房预测等,都能从中看到文本情感、情绪分析起到的作用。从认知科学的角度看,情绪表现不稳定,带有情境性,反映了人们的心理状态,是细粒度类别的情感表达,能够更加全面准确地表达人类真实的内心世界(Parrott^[1]不仅给出了基本情绪,如生气、伤心、惊喜等,还给出了二级情绪(如厌恶、失望、同情等)和三级情绪(如鄙视、沮丧、有罪等更细致的情绪类别)。情感较本质,有稳定性等特点。较稳定的情感在情绪的基础上形成并通过情绪表达,而情绪变化则反映了情感的深度。从研究的理论意义上看,文本情感与情绪分析对认知科学中情感与情绪的研究从感性认知上升为可计算模型,也是面向和谐的人机交互研究领域不可或缺的重要研究内容,对提高人机交互、自然语言理解的能力具有重要意义;从应用角度看,微博、微信等社交网络开放域文本已成为人们重要的信息来源之一,同时也是社会重要的信息传播渠道,这些可能富含情绪的碎片化信息在大数据环境下被整合,具有潜在舆情价值,而通过情感分析或情绪识别,了解大规模人群的情绪特点,可使之成为决策中的重要参考和依据。例如,在商业决策领域,通过对海量用户评论的观点挖掘,能够获取可靠的用户反馈信息,了解产品的优缺点,这样也有助于深刻理解用户的真实需求,实现精准营销。可见,研究成果对相关部门了解社情民意、分析网络舆情、实现精准营销、完成知识发现等提供帮助,具有一定的应用价值。

3.2 文本情感分析

文本情感分析的主要任务是通过一些方法分析给定的一段带有主观描述的文本中可能带有的情感倾向,主要任务包括文本情感信息抽取、文本情感分类、立场分析等,其中信息抽

取的质量将直接影响后续的情感分类和意图挖掘。限于篇幅,本节对文本中的情感信息抽取、情感分类、立场分析方法进行综述。

3.2.1 情感信息抽取

情感信息抽取是情感分析的基础,主要包括情感词抽取、评价对象抽取、评价搭配抽取等。其中,情感词是指带有情感倾向性的单词或短语,评价对象是评论文本中评价词所修饰的对象,评价搭配抽取是在识别出评价对象后对被评价对象和评价修饰短语进行的匹配,如例句“这款相机性价比高”中的“<性价比,高>”为一个评价搭配的二元对。

在情感词抽取方面,一般可将情感词的极性分为正向、负向、无偏向等类型。在基于词典和规则的方法中,一般会基于已构建好的情感词典,结合用户预先定义的规则进行情感词抽取。相关工作中,文献[2]将预处理的评论语料映射到特征词、意见词和否定副词的情感词表中,再根据上下文和情感词表寻找特征意见对,利用定义好的规则过滤出正确的特征意见对。基于机器学习的抽取方法一般是利用机器学习中的序列标注模型进行情感词抽取。Wang 等提出了一种基于规则的 Bootstrapping 方法^[3],利用程度副词并以其为重要的上下文完成对情感词实例的抽取。基于深度学习的方法一般在尽可能少的人工标注下利用深度神经网络将情感词抽取任务构建为序列标注模型,通过神经网络自动提取有效短语特征表示。Tang 等从 Twitter 语料中建立大规模的情感词典^[4],将构建情感词典作为短语级的情感分类任务。Wang 等利用神经网络从词、句子、文档多级别学习情感词的向量化表示^[5],该方法融合了词汇和文档级别的有监督的情感分类方法,能够有效缓解单一文档级监督方法粒度过大的问题。

评价对象抽取旨在寻找评论文本中所讨论的对象是什么。相关工作中,Liu 等将评价对象的抽取转为一个序列标注任务^[6],将文本中的词语作为观测序列,基于 CRF 模型为观测序列找到最有可能的状态序列,其模型输入为从外部数据源获取的预训练的词的分布式表示,利用 RNN 自动提取有效特征,并将面向特定任务的特征向量作为附加特征应用于模型。除基于序列标注模型方法外,将无监督学习方法应用于评价对象抽取也是研究方向之一。相关工作中,Mukherjee 等提出一种基于 LDA 方法的无监督模型抽取评价对象和确定文本中的情感^[7],利用用户提供的少量种子词汇自动导出无监督的正面和负面种子集。

评价搭配抽取旨在识别评论中的被评价对象,然后对被评价对象和评价修饰短语进行搭配。相关工作中,Zhao 提出一种主要依靠句法特征识别目标词和评价修饰词间关系的方法^[8],它基于 CRF 的情感句子压缩模型作为其预处理改进评价对象和极性词之间的关系,删除情感分析中不必要的信息,在相关产品领域的中文数据集上的实验结果表明,句子压缩模型能够有效地提升准确率。

3.2.2 情感分类

文本情感分类(或倾向性分析)是从带有主观描述的文本中辨别出文本总体情感类别的技术,其中基于规则的方法是通过事先定义好的规则完成对文本的倾向性分析。相关工作中,文献[9]提出基于情感词典的情感分类方法,利用多种规则对非正式文本进行主题检测与情感分类。文献[10]提出基于概率生成模型的 Sentence-LDA(SLDA)模型,将 SLDA 扩展到主题和情感相统一的模型中去模拟不同类型的情感。但是,随着应用场景和句式变化的不断增多,基于规则的情感分类方法的弊端就显现出来。为进一步提高情感分类的准确率,基于机器学习的情感分析方法受到关注。文献[11]在电影评论数据集中进行文本情感分析研究,利用朴素贝叶斯、最大熵和支持向量机分类器对评论文本进行情感分类研究。文献[12]提出一种利用依赖树和带隐变量的基于 CRF 的情感分类方法,根据隐变量计算整个句子极性,利用 CRF 在英文和日文语料上训练分类器。针对文本情感分析,可将深度学习模型和词嵌入技术引入任务中。在词的分布式表示与应用中,文献[13]提出基于矩阵分布式表示的 word2vec 模型,该方法将语义相似度直接转换为两个向量空间距离。Glove^[14]模型能充分利用语料库的统计性信息,利用共现矩阵中的非零元素进行预训练,可比 word2vec 模型更加有效地利用语料信息。文献[15]提出的 ELMO 模型能学习到词汇用法的复杂性,并能根据不同的上下文学习到词汇的多义性,在多个任务上都取得了较好的效果。文献[16]提出基于预训练策略的双向迁移学习模型 BERT,该模型提出的遮蔽语言模型能利用语料库的双向上下文信息,且利用 Fine-Tuning 策略,在预训练的语言模型上增加了少量的可调参数,从而能够灵活地应用在多个任务领域中。文献[17]提出基于句法树的递归神经网络(RNN)的情感分析模型,将深度学习模型引入文本情感分析领域。文献[18]在句子级别的分类任务应用卷积神经网络(CNN),通过细粒度的调节参数学习特定任务的词向量,对文本向量做卷积操作。文献[19]提出一种基于树形结构的基于 LSTM 的情感分类方法,依赖句法分析树的树形结构构建段落级别的文本特征表示。文献[20]提出在 LSTM 基础上增加一个存储器单元,该存储器单元可以在递归过程中反映多个子单元或多个后代单元的历史记忆。

3.2.3 立场分析

立场分析是文本情感分析的子领域,目的是识别针对某话题的立场态度。由于立场分析任务面临着比普通情感分析更多的挑战,因此单纯利用传统方法可能会有更多局限。基于深度学习的方法能以自主的特征学习取代人工特征选择,同时可以循序渐进的方式对文本特征进行学习,而且利用深度学习进行集成的策略,比独立的深度学习分类模型更有优势。研究者也尝试使用双向 RNN 架构将文本和话题分别在两个同步的网络层计算(可搭

配注意力机制等)。相关工作中,文献[21]综述了 NLPCC 2016 技术评测任务中的立场分析任务,介绍了立场分析的主要内容和开源数据集,给出了评测任务中各个科研机构得出的最终评价指标。文献[22]提出一种基于启发式的半监督方法处理立场分类,在领域语料中识别关键词和具有极性的 N 元语法特征进行预处理和基于规则的自动标注,训练出预测模型,利用已选择的 N 元语法模型预测文本立场。文献[23]提出监督学习和半监督学习方法处理中文微博开源数据集的立场分析。文献[24]提出一种将多类语言特征结合的方式,在分类器中加入词汇、形态、语义和语法共 14 种语言特征完成立场分类。文献[25]提出一种将多种特征提取方法集成的方式处理立场分类的方法,在特征词、隐语义特征和词性特征中进行选择后,使用一个线性模型划分出一种加权求和方式的集成方法执行分类。文献[26]提出一种集双向门控循环单元(GRU)层与 CNN 层于一体的 AS-biGRU-CNN 模型,将话题向量单独生成嵌入向量,同时上下文词向量在双向 GRU 层进行计算,随时间步输出隐层状态,通过计算语义级注意力向量得到话题相关的隐层状态,经过 CNN 计算得到最终文本表示并预测。文献[27]提出一种用于立场分析的双向条件编码器,将话题和上下文分别送入两组双向条件编码器计算后得到结果。文献[28]提出一种新的深度立场分析模型,该模型强调话题与上下文之间的关系,将话题向量扩充到上下文向量中,同时对上下文向量单独输入双向 LSTM 计算,两者经注意力机制合并为最终文本表示,对数据集中的每个话题执行分类,将多个话题的预测结果合并。文献[29]提出分阶段的立场分类器,采用传统机器学习方法进行特征选择后,借助立场词典和句法特征训练分类器。文献[30]利用深度学习提出分阶段的立场分类模型,先将话题平均向量拼接到上下文向量中,经过线性 Softmax 算法计算出注意力权重向量,同时上下文向量输入双向 LSTM 层,其输出与权重向量相乘,再经线性 Softmax 计算实现分类。

近年来,越来越多的研究者致力于研究基于深度学习的集成策略。相关工作中,文献[31]提出基于多层感知器的集成学习模型,用于处理细粒度金融评论数据的情感分析,模型在词嵌入基础上分别使用 LSTM、CNN、GRU 3 种神经网络层次提取文本特征,同时使用一个支持向量回归(SVR)分类器同步执行特征提取,最后将 4 种子分类器模型的输出作为多层感知器的输入,以此进行集成学习。文献[32]提出一种深度集成学习方法增进社交应用中的情感分析性能,结合了经典的特征选择方法与词嵌入中自动提取的特征,以及从这些特征中进行学习的集成策略。

在利用深度学习方法对文本分类任务的灵活处理的基础上,如何通过已有模型扩展至其他领域的文本分析简化学习过程,以集成模型为基础,提取原有训练数据中的主要特征,并使用新话题训练,基于跨领域迁移的学习方式完成新话题及其评论的预测,也是近期的研究热点之一。相关工作中,文献[33]对当前用于执行异构迁移学习任务的方法进行了综述。文献[34]探讨了对语言进行 Aspect 级别跨语言情感分类的方法,将基于 Aspect 级别跨领

域情感分类(CLSC)的零样本学习、双语词嵌入、堆叠去噪自动编码器表示和机器翻译技术进行了对比,实验结果表明基于分布式语义的模型可以在 Aspect 级别的 CLSC 上实现与机器翻译相当的结果。文献[35]针对不平衡的商品评论数据,提出一种基于主题句的文本迁移学习方法。文献[36]结合迁移学习和极限学习机的优势,提出基于迁移学习的极限学习机(TL-ELM)模型和领域适应内核极限学习机模型(TL-DAKELM),使用少量的目标域标签数据和大量的源领域旧数据构建性能更佳的分分类模型。文献[37]提出了一个两阶段双向 LSTM 和参数传递框架的短文跨域情感分类模型,先利用双向 LSTM 网络在大量带标记源领域训练数据上进行预训练并调参,再使用目标域训练数据执行后续训练。文献[38]提出一种基于共享模型适应的个性化情感分类方法,在提出的 MT-LinAdapt 算法中,全局模型共享缓解了数据稀疏性问题,个性化模型适应性捕获了人类情绪的异质性,并实现了有效的在线模型学习。文献[39]提出一种基于迁移学习的有效和可复用的选举分类器,结合了迁移学习与不同的分类器,通过使用线性平移方法,将词向量从一种语言映射到另一种语言,概括用于跨语言分类的学习分类器模型。文献[40]研究半监督学习和迁移学习方法的应用,以提高带标记数据缺乏前提下的情绪分类性能,实验中通过提取密集特征表示,并通过预训练和正则化增强情感分类系统的性能。文献[41]提出了一种基于迁移学习的分层注意力神经网络模型,首先训练编码器以理解机器翻译任务中的上下文,接着通过将编码器生成的隐藏向量与相应的无监督向量连接,将编码器转移到情感分类任务,最后针对情感分类任务应用两级分层网络,在每个级别放置最小门单元(MGU)并使用注意力机制。文献[42]将不同任务中训练的两个模型的编码器部分迁移到情感分类,以证明迁移学习在自然语言处理中有效。文献[43]提出一种零样本学习方法,考虑句子的顺序结构以及不同领域的一般问题类型,实验结果表明该方法在两个完全不同的领域中获得了比基准方法更高的准确性。文献[44]提出一种用于文本分类的零样本学习方法,该方法在大型句子级数据集上训练模型,以学习句子与句子标签嵌入之间的关系,该模型通过学习预测给定句子是否与标签相关而非精准分类,实验结果表明模型很好地概括了测试数据的大致类别。

3.3 文本情绪分析

文本情绪分析是指通过文本挖掘与分析等方法检查和处理文本大数据,以便确定作者主观情绪(如对于特定主题的大众情绪或某一群体的意见)的过程。目前学术界在多项研究中被广泛采用的是一个更定性的情绪分类体系,如将情绪细分为多种类别。

3.3.1 传统的情绪分析方法

传统的情绪分析方法主要指基于词典和规则的情绪分析方法,以及基于统计机器学习

的情绪分析方法等。

1. 基于词典的情绪分析

基于词典的情绪分析是借助词典将文本的非结构化特征提取出来。它主要是通过构建一系列情绪词典并制定一定的规则,在对文本依次进行拆句、分析(如基于词性分析或句法依存分析)的基础上计算情绪值,以情绪值为评判标准,实现对文本大数据的情绪倾向分析。

情绪词典的建立是基础。情绪词典的构建往往需要结合人工标注、语义词典扩展或基于语料库抽取标注等方法。英语中的情绪词典资源是 WordNet-Affect,该词典的构建是从 WordNet 开始,通过选择和标注代表情绪概念的 WordNet 中的同义词集获得 6 种基本情绪相关的词语,然后继续利用 WordNet 中定义的关系、情绪标签和领域标签进行扩展,找到情绪同义词所在的同义词集,逐步扩展得到情绪词典^[45]。情绪词典中的情绪词往往在较大程度上有领域依赖性,同一词汇在不同领域可能会表达完全不同的情绪。相关工作中,文献^[46]提出了一种新的情绪感知 ELDA 模型,用于构建一个特定领域的包括愤怒、厌恶、恐惧、喜悦、悲伤、惊讶 6 种情绪的情绪词典,使用一组最小的与领域无关的种子词作为先验知识发现并学习特定领域的细粒度情绪词汇,从而使情绪词典更加丰富并能适应特定领域。自动构建情绪词典能很好地降低人工成本,并在一定程度上增强领域适应性。文献^[47]利用自动注释的推文构建 Twitter 意见词典,使用点互信息语义取向(PMI-SO)建模,并使用随机梯度下降语义取向(SGD-SO)学习词与情绪之间的线性关系。情绪词典中的情绪词对语言也有一定的依赖性。为解决语言依赖性问题,往往需要构建面向特定语言的情绪词典。然而,对于中文来说,情绪词汇仍然是不容易获得的,目前只有为数不多的中文情绪词典,如大连理工大学的中文情感词汇本题库(DU-TIR)^[48]。在汉语情绪词典的构建工作中,Quan 等^[49]构建了专门用于博客情绪分析的语料库,包含 8 种基本情绪(期望、喜悦、爱、惊讶、焦虑、悲伤、愤怒和仇恨)、情绪强度、情绪词、程度词、否定词等。Xu 等^[50]提出一种基于 WordNet 的汉语情绪词典自动生成方法,该方法主要由翻译、过滤和扩展构成:首先将所有英语单词翻译成中文单词,然后在此基础上利用汉语同义词词典为每个情绪范畴建立双语无向图(提出一种对翻译过程中引入的所有非情绪词进行过滤的图算法),最后通过扩展同义词表达相似情绪,从而获得汉语情绪词典。

表情符号是社交网络中表达情绪的重要线索,已成为情绪分析的重要资源。在表情符号词典构建中,Yang^[51]等利用雅虎微博数据挖掘词汇与情绪之间的关系,从博客文章中学习情绪词汇的搭配模型从而构建情绪词典,即分 3 个阶段构建和评估情绪词汇。Tang^[52]等借助表情符标注微博数据,并考虑到有些表情符号会在不同的情绪表达中出现,因此通过公式对表情符进行挑选,选择每一类中排名靠前的表情符号(即选择情绪表达较为一致且情绪强烈的表情符号),并利用选择的表情符号标记协助后续处理过程。

在有关基于词典的情绪分析方法的研究中,文献^[53]描述了一种基于情绪估计的聊天

系统,即在对文本情绪内容识别上基于关键字识别技术将文本划分为单词并对每个单词进行情绪估计,然后基于句子级处理技术检测主题间的关系(提取动词和宾语,以提高情绪估计能力)。在此基础上,Aman等^[54]在情绪标注任务中根据一种基于知识的方法对情绪句和非情绪句分类,并提出一种基于情绪强度知识的方法对包含情绪的句子进行分类。由于情绪词典中情感词对时间的依赖性,同一词汇在不同时间可能会表达出完全不同的情绪。文献^[55]采用基于词典的方法,利用情绪词典对数百万条公开 Twitter 语料进行了自动情绪分析。另外,根据情绪表达的线索,还有一种基于情绪词的句子情绪识别方法。Quan^[49]等为探讨情绪词在句子情绪识别中的作用,运用情绪语料库,对基于情绪词的句子情绪进行了分析。但是,仅使用基于词典的方法并不能处理文本中情绪词缺失和隐式情绪表达的情况,为此文献^[56]提出了一种将基于词汇和基于学习的句子识别方法相结合的两阶段算法并对微博文本的情绪进行分析:第一阶段使用情绪词典识别测试数据集中的情绪句子;第二阶段构建一个基于 SVM 的分类器识别数据集中没有明显情绪词的情绪句子。

可见,在词典情绪词覆盖率和标注率较高的情况下,基于词典的情绪分析方法对于短文本和特定领域的文本进行情绪分析的效果比较好。但由于构建的词典往往只针对某个特定领域,因此跨领域的分析效果不好。此外,这种方法通常还依赖时间、语言等方面的背景知识,难以捕捉新词、变形词,难以自动构造高质量的情绪词典。

2. 基于规则的情绪分析

基于规则的情绪方法往往是在词典和分析情绪语料的基础上,结合表情符号、情绪词、程度副词等情绪影响因素,设置情绪分类规则库,并依据规则库规则进行情绪分析的一种方法。

相关工作中,文献^[57]提出了一种基于语义规则的情绪分类方法,该方法利用隐式语义分析(LSA)算法计算通用语义词和情绪词的语义相似度,再根据语义相似度对新闻标题进行分类。文献^[58]利用博客领域的语料研究了基于规则的文本情绪标注方法,首先将采集的博客内容按照句子进行划分,然后依次进行符号性提示分析、句法结构分析、基于词的文本情绪分类和基于短语的文本情绪分类,最后是基于句子的文本情绪分类。

鉴于一种情绪往往是由诱因事件触发的,诱因事件是情绪分析的重要组成部分,因此情绪原因检测是情绪处理中的一个新的研究领域。文献^[59]提出一种基于文本驱动的基于规则的情绪诱因检测方法,通过对语料库数据的分析,识别了7种语言线索,并据此归纳出两组用于情绪诱因检测的语言规则,还利用这两组语言规则开发了一个基于规则的情绪诱因检测系统。文献^[60]提出了一种基于规则模型的中文微博情绪成因检测方法。为了解决文本情绪识别任务中的有关不规范文件带来的挑战,文献^[61]提出基于规则的文本情绪分析方法并构建了一个情感分析模型 AAM,即首先对网络文本中的非正式缩写、情绪图标以及语法错误等不规范文本进行预处理,然后利用所提出的基于规则的方法分阶段处理每个句

子(包括符号提示处理、缩略语的检测和转换、句子分析和单词/短语/句子级分析),每个被分析的句子都会被自动标注情感标签和情感强度,最终情感分析模型(AAM)将目标语料中的情绪分为9类(愤怒、厌恶、恐惧、内疚、兴趣、欢乐、悲伤、羞耻、惊讶)。文献[62]分别使用3个情绪词典(即 WordNet Affect Lexicon、Affective Norms for English Word 和 NRC Word-Emotion),使用基于规则的方法进行情绪分析,结果表明词语级的情绪词典比 N-Gram 更便于对不同领域的文本进行情感分析。文献[63]针对中文微博中的情绪进行分析,将微博情绪分为喜、怒、哀、惧四大类,选取外部资源 HowNet 和 C-LIWC,利用词典微博文本情绪自动分析,找到微博中包含的情绪词,而情绪词数量最多的那种情绪为该文本的主要情绪。文献[64]提出基于词典和规则的方法识别微博所表达的喜、哀、怒、惧、恶、惊6类情绪,借助互信息方法构建表情符号词典,采用词典与规则结合的方法针对微博进行情绪分析。文献[65]介绍了一种基于类序规则的微博文本情绪分类方法,首先利用传统的基于词汇和机器学习的方法对微博文本中的每个句子提取两个潜在的情感标签,并提取微博文本中相邻两个句子之间的连词(将每个微博文本视为数据序列),然后从数据集中挖掘类序列规则,并从挖掘出的微博文本情感分类规则中提取新的特征。

3. 基于统计机器学习的情绪分析

1) 基于有监督学习的情绪分类

基于有监督学习的情绪分类方法认为情绪分类是一个基于大量有标注数据的统计分类问题。它分析处理训练样本数据,通过某种数学模型产生一个推断功能,再利用训练后的模型映射新的样本数据。

相关工作中,Wawre 等使用了一种基于 Unigram 和 Bigrams 的特征框架^[66],从标记为积极或消极电影评论中训练模型,首先在文本中提取特征,再使用机器学习算法进行训练。文献[67]采用机器学习方法以及最小切割框架,表明将文本分类应用于文档的主观分析可有效提高情绪分析算法的性能。Mishne 在对博客中的情绪进行分类的实验^[68]中使用了各种特性(包括内容和非内容特性以及一些在线文本特有的特性)并侧重对博客中文本特征的抽取,通过构建词模型、使用语义取向特征等对语义态度进行评估,并使用 SVM 进行分类,实验结果表明其处理效果有一定程度提升。集中于特征抽取的方法同样适用于 Twitter、微博等社交媒体中的小众语言。Alsharif 等使用 AlKhalil 形态分析和 Khoja 词干提取方法^[69],再使用相互抵消的特性向量表示方法对文本中的情绪进行分类,使用标准词袋模型处理已提取特征。Go 等测试了一些适用于情绪分类的标准分类器^[70],这些分类器使用 Twitter 中的表情符号以及推文中不同类型的文本特性作为标签,实验结果表明一些学习算法(朴素贝叶斯、最大熵和支持向量机)在使用表情符号数据训练时的准确率在 80% 以上,这说明将表情符号作为训练数据的噪声标签是有效的。另外,标签本身可能是嘈杂的或与想要的分类没有直接对应。Tang 等^[71]认为目前的词嵌入方法主要是通过词的上下文语

义信息构建的,忽略了文本的情绪信息,通常会把有相似上下文的情绪倾向词映射成相似的向量表示,该方法将情绪信息引入到词嵌入的学习过程中,得到具有特定情绪倾向的词嵌入表示,在情绪分类任务上,模型性能有明显的提升。Read 提出了检验在独立标签上训练的分类器相似性模型的方法^[72],使用朴素贝叶斯分类器和 SVM(light)实现,并展示了模型是如何依赖于域的,通过时间段情绪被分类器所影响的程度来展现出模型是时间相关的。Purver 等用自动标记的数据训练有监督分类器^[73],通过对不同标签训练的模型进行交叉验证和对人工标记的数据进行测试,说明无论是表情符号还是话题标签,都能对个体情绪进行合理预测,对于某些情绪(如快乐、悲伤和愤怒)来说,该模型的跨标签测试效果较好。

2) 基于无监督学习的情绪分类

分类器的训练需要大量有标签的数据,但大量准确标记的数据往往不易获得。另外,文本的情绪解释是高度主观的,有些情绪很难被准确标注出来,且某种程度上情绪特征并不容易识别,自动标注方法可能会损失一些准确率。基于无监督学习的方法的应用面更广^[74]。

相关工作中,Strapparava 在 6 种基本情绪识别问题上使用一个监督学习的朴素贝叶斯分类器和一个 LSA 的无监督分类器^[75],并提出一种用于细粒度和粗粒度评估的方法,实现一个从大量文本中以无监督方式自动获取语义相似的模型,该模型允许对单词、词集、句子和文本进行同构表示,通过在具有很多基线数据集上的对比实验,找出更合适的方法。Turney 提出一种简单的无监督学习算法^[76],用短语与正例之间的互信息减去给定短语与负例的互信息表达一个短语,实验先进行词性标注,再使用 PMI-IR 估计每个短语的语义定位,然后根据平均语义方向给短语分配合适类别。Kim 等人提出了一种新的自动检测文本情绪方法^[77],评估了用来识别 4 种情绪状态(愤怒、恐惧、快乐和悲伤)的分类模型和维度模型,将 WordNet Affect 作为语言词汇源并评价了潜在语义分析(LSA)、概率潜语义分析(PLSA)和非负矩阵分解(NMF),实验结果表明 NMF 的分类模型对 SemEval-2007 和儿童童话的测试性能较好。另外,Fernández-Gavilanes 等提出了一种预测在线文本信息情绪的方法^[78],基于无监督句法分类方法并使用句法依存构建,模型使用以前创建句子的特殊结构和语言内容的情感词汇确定推文中所包含的情绪类别,使用了各种自然语言处理技术和来源于情绪词汇的情绪特征,并采用了一种半自动极性扩展算法,上述方法在康奈尔大学电影评论、奥巴马-麦凯恩辩论和 SemEval-2015 数据集中都证实了该系统的准确性和健壮性。

其他非监督学习的分类方法还有:Annett 等的基于 SVM 的分类方法^[79],以及 Zhou 等的研究^[80]等。Fernández-Gavilanes^[78]等还将算法集成到一个博客的可视化工具中,使用奥巴马-麦凯恩辩论的数据集^[81]对模型进行了评估,使用该系统与 Hu 等的非监督分类方法^[82]作了比较。

3) 基于半监督学习的情绪分类

传统监督学习的方法依赖于带标记的语料。文献[83]在基于词典的西班牙语 Twitter 消息的情绪分析中证明全局情绪值(Global Sentiment Value, GSV)受文本中可用词汇数量的影响较大,这说明了許多模型是基于手工标记语料的监督学习。Mintz 等人在没有标记数据的情况下使用长距离监督学习对关系进行提取^[84],提供了一种能够快速获得带标签数据的方法并研究了一种不需要标记语料库的替代范式,避免了 ACEstyle 算法对领域的依赖性,该算法结合了监督学习 IE(结合一个概率分类器中的 400 000 个噪声模式特征)和非监督学习 IE(从任意大型语料库中提取大量的关系)的优点,实验显示出句法分析特性对表达中存在歧义或词法距离较远的关系有帮助,通过这种方式可以快速获得标签数据的大量子集,从而缓解了传统监督学习缺乏大量有标注数据的问题。

3.3.2 基于深度学习的情绪分析

1. 概述

近年来,深度学习已成为机器学习中具有强大学习能力的一个分支。基于深度学习的词法分析、句子表示、文档表示以及知识表示等引起自然语言处理研究者的极大兴趣。基于 CNN 的文本表示模型擅长局部特征信息的学习工作,它对特征学习的方式与 N 元语言模型类似,通过调节卷积窗口的大小控制每次卷积模型处理局部特征的范围^[85]。长短期记忆(LSTM)网络模型是一种特殊的 RNN,它添加了单元状态用于保存序列信息并传送到下一个 LSTM 神经元,通过 3 个门(输入门、输出门、遗忘门)保护和控制神经元状态,对远距离结构特征的学习能力较为突出(LSTM 能够对过去的信息有记忆,是因为它能够保证误差向后传递时较少衰减,实现了对过去较长时间范围内的信息保持),能更好地从文本中学习长期依赖信息^[86]。基于注意力机制的主要思路是目标序列的每步额外增加是来自源序列的信号,而信号为源序列每步输出的加权处理^[87]。相关工作中,文献[88]提出一个结合目标向量的基于注意力机制的 LSTM 模型,说明注意力机制在基于实体方面的文本意见挖掘任务中能起到一定作用,这项结论同样被其他工作所证实^[89]。得益于词嵌入技术的发展,基于深度学习技术的模型能更好地模拟词语之间的联系,使模型具有局部特征抽象化以及记忆功能,在情绪分析任务中具有很大的优势。

2. 迁移学习与 BERT 模型

大规模标注数据集不易获得且成本昂贵。为克服这些困难,迁移学习是一个不错的选择。迁移学习为情绪分析研究提供了新的思路。

大多数已存在的迁移学习方法或假设源任务与目标任务共享相同的句子表示,或将每个句子的表示划分为共享特征空间和两个任务特定的特征空间。前一种方法可能导致学习句子表示时更多关注一些情感词,同时忽略其他模糊情感词,然而这些模糊词可能也是情绪

分类中不可或缺的一部分;后一种方法可捕捉特定情绪词。然而,一些情感词只出现在源情感分类任务中,这些词在特定源特征空间中往往会受到更多的关注,在共享特征空间中受到的关注较少,因此,在情绪分类任务中这些情感词可能被忽视。但在标准的情绪分类任务中,任何情感词都蕴含着情绪,它们不应该被情绪分析任务所忽略。因此,文献[90]提出一种基于 Shared-Private (SP)的迁移学习模型,使用一个共享的 LSTM 层抽取情感分类任务和情绪分类任务中共同的情感特征,使用一个特定的 LSTM 层抽取仅对情绪分类任务敏感的特定特征。然而这样一个简单的模型不能很好地区分两个特征空间,很难抽取所期望的共享特征和目标特定的特征。为了增强两个特征空间的交互性,SP 模型进一步引入了一个 Dual Attention 机制,它将一个特征空间中的 Attention 权重作为额外的输入计算另一个特征空间中的特征,并明确最小化两组注意力量之间的相似性,实验结果表明加入 Dual Attention 的 SP 模型可带来稳定的性能提升,在 SemEval 英语数据集和 Ren-CECps 中文数据集上达到了满意的效果。

另外,Devlin^[16]等提出基于迁移学习的双向编码器(Bidirectional Encoder Representation from Transformers,BERT)模型,该模型使用遮蔽语言模型(Masked LM)和下一句预测(Next Sentence Prediction)模型两种方法分别捕捉词语和句子级别的向量化表示。迁移学习遵从 Vaswani^[91]等提出的模型,该模型抛弃了之前传统的端到端模型的固有模式。对于遮蔽语言模型来说,为了使用预训练模型中一个词左右两边的信息,模型使用双向上下文预训练。在基于深度学习方法的情绪分类方法中,样本数据的向量化是至关重要的一步。只有将样本数据无损失或少损失地转换为向量形式,才能在后续特征提取以及特征映射环节将样本数据和情绪标签一一对应。遮蔽语言模型的出现解决了传统语言模型只能利用上文或者下文信息的窘境,在预训练阶段赋予模型不依赖句子中特别重要的情感词的情况下,还能正确地识别出句子的情绪倾向性。不同于 ELMO^[92]模型将从左到右的和从右到左的 LSTM 拼接到一起,BERT 随机将 15% 的 token 隐藏,最终的损失函数也只计算被隐藏的单词,实现了模型的双向训练。如何遮蔽也是有技巧的,已有一些相关处理的随机遮蔽策略,其最终目的就是尽可能地保证每个单词都能被模型关注到,这样的训练策略能够保证句子的情绪极性不以某个单词为转移,取而代之的是将这些重要的信息(如情感词、否定词等)蕴含在句子级别的向量化表示中,并且模型能够双向利用句子的上下文信息,更加准确地分析句子的情绪标签。对于预训练的第二个任务“下一句预测”,目的是让模型理解两个句子之间的联系。该策略使得模型有能力处理文档级别的情绪分类任务,综合文档中可能出现的多种复合情绪表达,结合上下句信息做出判断。BERT 模型基于迁移学习和 Fine-Tuning 机制,为进一步使用大规模预训练模型进行情绪分析提供了支持。

3. 联合学习

目前很多模型是基于单一数据集完成情绪分类任务的。当已训练好的模型应用于其他

数据集时,处理精度可能会出现下降,可见模型训练具有数据依赖性。相关工作中,文献[93]提出一种旨在提升模型的鲁棒性的多任务联合学习模型,该模型在多个文本情绪分析语料库上进行训练,每个数据集作为一个单独任务训练单个模型,最后在多个任务之间共享参数,以实现联合学习。实验结果表明,在相同的神经网络框架下,联合学习模型优于单任务学习模型。

传统情绪分析将情绪分类和情绪诱因分析分为两个独立的子任务。这种分离框架虽然能使每个子任务被灵活处理,但它忽略了两个子任务之间的相关性。文献[94]提出一种基于神经网络的情绪分类和情绪诱因分析的联合方法,使用统一框架提取情绪分类实例和情绪诱因分析实例的特征,在情绪分析的两个子任务中能达到相互促进的效果,在提出的联合方法中有基于神经网络的两个部分:一部分是提取情绪分类和情绪诱因分析的特征表示的联合编码器,这里有 LSTM 网络和 Attention 网络,其中每个网络由若干层 BiLSTM 层和 Attention 层组成,LSTM 网络使用 BiLSTM 层捕获每个输入词的序列特征,使用这些特征的平均值作为输入序列表示,Attention 网络包括两层(BiLSTM 层侧重于序列特征的提取,Attention 层侧重于单词的重要性,即权重的学习);另一部分是线性解码器,这里的每个分类网络都使用线性层构建概率分类模型,并为它们分配标签。

4. 多标签学习

一些情绪分类方法被视为单标签学习问题(即每个句子表达一种情绪),这种任务的性能要么取决于情绪词汇词典及相应标签^[95],要么需要利用现有的学习方法完成分类任务^[96]。然而,在实际中,一个句子可同时拥有多种情绪,因此基于多标签学习的方法应引起重视。一般地,需要选择分类器输出的阈值并且将高于阈值概率的多个情绪分配给句子^{[97][98]}。但是,上述单标签和多标签方法都是在处理一个句子包含哪些情绪标签的问题,无法解决与情绪相关的歧义问题。为此,文献[99]提出标签分布学习方法,该方法可以表示与每个标签相关联的强度解决文本中的歧义问题,并提出一种多任务卷积神经网络,用于在单个句子中预测不同程度的多种情绪,可同时学到分布预测和情绪分类任务。具体地,给定一个句子,CNN 模型首先将其表示为句子嵌入向量矩阵,然后使用多个不同宽度的过滤器和最大池化操作,由于大多数数据集仅为句子提供单个标签,因此提出了一种基于词典的转换策略,用于生成单标签数据集的主导标签情绪分布。

5. 其他方法

近年来,基于深度学习的模型也暴露出一些问题。为此,有学者提出解决方案,部分解决了相关问题。相关工作中,文献[100]提出一种基于语言动机的对抗学习方法,该方法在网络训练时攻击(采用了基于词法和基于句法的两种攻击策略)输入信息的向量化表示,从而提高模型的鲁棒性,摒弃或遮蔽部分输入信息的向量化表示(对输入信息添加小而持久的扰动),模型在一系列的情绪分析数据集上取得了优于传统卷积神经网络的实验结果。文献

[101]将情绪语料库表示为图形,可有效捕获文本信息中发现语言变化的全局相互作用,而图形表示方法的优点是仅需较少的领域知识和人力即可捕获重要的上下文和潜在信息,这对于消除情绪表达中的歧义是有用的。文献[102]利用了具有表情符号标记的 Twitter 数据集(收集了超过 50 万组与表情符号对话的 Twitter 内容),并假设用户选择的细粒度表情符号表达了发表的 Twitter 内容的情感,利用几种神经网络模型学习并训练了一个大规模的表情符号分类器。另外,文本可能以不同的强度表达多种情绪,通过它们表达的强度预测和排序多个相关情绪是至关重要的。由于情绪可能由隐藏的主题引起,不同主题可能包含不同的情绪,因此抽取相关主题信息可以了解情绪是如何被诱发的。文献[103]提出一种可解释性的用于相关情绪排序的神经网络方法,通过区分相关情绪和不相关情绪关注相关情绪的排序,并提出一种新的损失函数优化神经网络,在 Sina Social News (News)、Ren-CECps corpus (Blogs)和 SemEval 3 个语料库的实验结果表明,该方法优于其他的情绪检测方法 and 多标签学习方法。另外,文献[104]分析了在线健康社区中的信息,从健康相关的帖子中检测细粒度的情绪类型,并展示了如何从结合词典特征的深度神经网络中获得可用于情绪检测的高水平和抽象特征,提出了一个用于在线健康社区中的情绪检测的 ConvLexLSTM 模型。该模型基于 Biyani^[105]提出的特征(weak subjective words (numWeak), strong subjective words (numStrong), cancer drugs (numDrug), side-effects (numSide), therapeutic procedures (numProc)),以及 Strapparava^[106]等人提出的 EmoLex1 和 Mohammad^[107]提出的 EmoLex2 特征做词典特征融合,然后将高级特征与词典特征结合作为下一层 LSTM 的输入,最后通过 Softmax 层产生最终输出。

3.4 本章小结

情感、情绪以微妙的方式表达。这些表达可能因集体或个人的经历、知识和信仰而异。为了理解通过文本传达的情感和情绪,需要捕获不同语言之间的细微差别。

基于规则的情绪分析方法能在有限时空范围内达到较好的处理水平,加入事前起因等规则可提高分类效果,但基于规则的方法一般依赖于语言学约束,缺乏对未登录词或隐含情绪的处理。另外,数据量较大时,规则的维护比较复杂,难以扩展,且存在情绪词缺失和匹配情绪词有时并不能准确表达真实情绪等问题,很多时候的处理效果并不理想。

在有监督情感情绪分类中,通过建立分类器识别文本中包含的情绪。虽然一些有监督的情感情绪分类方法表现良好,但是数据标注是一种劳动密集的费时费力工作,且缺乏足够的大型标记训练数据仍是核心问题。

为解决有监督学习方法面临的部分问题,有学者提出无监督或半监督的情绪分类方法,其中半监督学习的情绪分类方法是基于少量有标记的样本数据对大量无标记的样本数据进

行分类训练。但无论是监督、无监督,还是半监督的学习方法,训练数据和测试数据都要在主题上匹配。

基于深度学习方法中的“端到端”思想部分避免了人工提取特征工作,在分析中起到越来越重要的作用。借助词嵌入、注意力、记忆等机制,深度学习方法正在情绪分析中发挥着越来越重要的作用。迁移学习的目的在于重复利用具有相似结构的任务,在数据缺失和训练昂贵的情况下能够基于前人的工作构建出一个相对有效的模型,利用成熟领域预训练好的模型和基于任务相关的参数微调,将任务扩展至新的数据集,甚至是新的领域。

联合学习方法旨在学习两个任务之间的共性问题,使两个任务在训练的过程中相互促进,以获得更好的结果。

多标签学习方法旨在分析一段文本所蕴含的多种倾向性。多标签分析方法更贴切于人类的复杂表达,能够更好地分析出用户的真实情感和情绪。

参考文献

- [1] Parrott W G. Emotions in socialpsychology: essential reading [M]. Oxford, UK: Psychology Press, 2001.
- [2] Tan Y Z, Zhang Y F, Zhang M, et al. A unified framework for emotional elements extraction based on finite state matching machine [M]. Natural Language Processing and Chinese Computing. Springer, Berlin, Heidelberg, 2013.
- [3] Wang C H, Wang F. Extracting sentiment words using pattern based Bootstrapping method[J]. Computer Engineering and Applications, 2014, 50(1): 127-129.
- [4] Tang D Y, Wei F R, Qin B, et al. Building large-scale twitter-specific sentiment lexicon: a representation learning approach [C]. In Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics; Technical Papers, 2014: 172-182.
- [5] Wang L Y, Xia R. Sentiment lexicon construction with representation learning based on hierarchical sentiment supervision[C]. In Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2017: 502-510.
- [6] Liu P F, Joty S, Meng H. Fine-grained opinion mining with recurrent neural networks and word embeddings[C]. In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2015: 1433-1443.
- [7] Mukherjee A, Liu B. Aspect extraction through semi-supervised modeling[C]. In Proceedings of the 50th annual meeting of the association for computational linguistics: Long papers-volume 1. Association for Computational Linguistics, 2012: 339-348.
- [8] Zhao Y Y, Che W X, Guo H L, et al. Sentence compression for target-polarity word collocation extraction[C]. In Proceedings of COLING 2014, the 25th International Conference on Computational

- Linguistics: Technical Papers, 2014: 1360-1369.
- [9] Paltoglou G, Thelwall M. Twitter, MySpace, Digg: Unsupervised sentiment analysis in social media [J]. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2012, 3(4): 1-19.
- [10] Jo Y, Oh A H. Aspect and sentiment unification model for online review analysis [C]. In *Proceedings of the fourth ACM international conference on Web search and data mining*, 2011: 815-824.
- [11] Pang B, Lee L, Vaithyanathan S. Thumbs up? sentiment classification using machine learning techniques [C]. In *Proceedings of the conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2002: 79-86.
- [12] Nakagawa T, Inui K, Kurohashi Sadao. Dependency tree-based sentiment classification using crfs with hidden variables [C]. *Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics*, Association for Computational Linguistics, 2010: 786-794.
- [13] Mikolov T, Sutskever H, Chen K, et al. Distributed representations of words and phrases and their compositionality [C]. *Advances in neural information processing systems*, 2013: 3111-3119.
- [14] Pennington J, Socher R, Manning C D. Glove: global vectors for word representation [C]. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014: 1532-1543.
- [15] Peters M E, Neumann M, Iyyer M, et al. Deep contextualized word representations [C]. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2018: 2227-2237.
- [16] Devlin J, Chang M W, Lee K, et al. Bert: pre-training of deep bidirectional transformers for language understanding [J]. *arXiv preprint arXiv: 1810.04805*, 2018.
- [17] Sochard R, Perelygin A, Wu J Y, et al. Recursive deep models for semantic compositionality over a sentiment treebank [C]. In *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2013: 1631-1642.
- [18] Kim Y. Convolutional neural networks for sentence classification [C]. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014: 1746-1751.
- [19] Tai K S, Socher R, Manning C D. Improved semantic representations from tree-structured long short-term memory networks [C]. In *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*, 2015: 1556-1566.
- [20] Zhu X D, Sobhani P, Guo H Y. Long short-term memory over recursive structures [C]. *International Conference on Machine Learning*, 2015: 1604-1612.
- [21] Xu R F, Zhou Y, Wu D Y, et al. Overview of NLPCC shared task 4: stance detection in Chinese microblogs [C]. *Natural Language Understanding and Intelligent Applications*, Springer, Cham,

- 2016: 907-916.
- [22] Dias M, Becker K. An heuristics-based, weakly-supervised approach for classification of stance in tweets[C]. *Web Intelligence (WI), 2016 IEEE/WIC/ACM International Conference on IEEE*, 2016: 73-80.
- [23] Liu L, Feng S, Wang D L, et al. An empirical study on Chinese microblog stance detection using supervised and semi-supervised machine learning methods[C]. *Natural Language Understanding and Intelligent Applications*, 2016: 753-765.
- [24] Sun Q Y, Wang Z Q, Zhu Q M, et al. Exploring various linguistic features for stance detection[C]. *Natural Language Understanding and Intelligent Applications*, 2016: 840-847.
- [25] Xu J M, Zheng S C, Shi J, et al. Ensemble of feature sets and classification methods for stance detection[C]. *Natural Language Understanding and Intelligent Applications*, 2016: 679-688.
- [26] Zhou Y, Alexandra I, Shi L. Connecting targets to tweets: Semantic attention-based model for target-specific stance detection [C]. In *Proceeding of the International Conference on Web Information Systems Engineering*, 2017: 18-32.
- [27] Augenstein I, Rocktäschel T, Vlachos A, et al. Stance detection with bidirectional conditional encoding[C]. In *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing (EMNLP 2016)*, 2016: 876-885.
- [28] Du J, Xu R, He Y, et al. Stance classification with target-specific neural attention networks[C]. In *Proceedings of the International Joint Conferences on Artificial Intelligence (IJCAI 2017)*, 2017: 3988-3994.
- [29] Wojatzki M, Zesch T. Ltl.uni-due at SemEval-2016 task 6: stance detection in social media using stacked classifiers[C]. In *Proceedings of SemEval-2016*, 2016: 440-445.
- [30] Dey K, Shrivastava R, Kaushik S. Topicalstance detection for twitter: a two-phase LSTM model using attention[C]. In *Proceedings of the European Conference on Information Retrieval (ECIR 2018)*, 2018: 529-536.
- [31] Akhtar M, Kumar A, Ghosal D, et al. A multilayer perceptron based ensemble technique for fine-grained financial sentiment analysis [C]. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP 2017)*, 2017: 540-546.
- [32] Araque O, Corcuera I, Sanchez R, et al. Enhancing deep learning sentiment analysis with ensemble techniques in social applications[J]. *Expert Systems with Applications*, 2017, 77: 236-246.
- [33] Day O, Khoshgoftaar T. A survey on heterogeneous transfer learning[J]. *Journal of Big Data*, 2017, 4(1): 1-42.
- [34] Barnes J, Lambert P, Badia T. Exploring distributional representations and machine translation for aspect-based cross-lingual sentiment classification[C]. In *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*, 2016: 1613-1623.
- [35] Tian, F, Wu F, Chao K, et al. A topic sentence-based instance transfer method for imbalanced

- sentiment classification of Chinese product reviews [J]. *Electronic Commerce Research and Applications*, 2016, 16: 66-76.
- [36] Li X, Mao W, Jiang W. Extreme learning machine based transfer learning for data classification[J]. *Neurocomputing*, 2016, 174: 203-210.
- [37] Zhao C, Wang S, Li D. Deep transfer learning for social media cross-domain sentiment classification [C]. In *Proceedings of Chinese National Conference on Social Media Processing*, 2017: 232-243.
- [38] Gong L, Boni M, Wang H. Modeling social norms evolution for personalized sentiment classification [C]. In *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL 2016)*, 2016: 855-865.
- [39] Yang X, McCreddie R, Macdonald C, et al. Transfer learning for multi-language twitter election classification[C]. In *Proceedings of the 2017 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining 2017*, 2017: 341-348.
- [40] Gupta R, Sahu S, Wilson C E, et al. Semi-supervised and transfer learning approaches for low resource sentiment classification [C]. In *Proceedings of 2018 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP)*, 2018: 5109-5113.
- [41] Qu Z, Wang Y, Wang X, et al. A transfer learning based hierarchical attention neural network for sentiment classification[C]. In *Proceedings of the International Conference on Data Mining and Big Data*, 2018: 383-392.
- [42] Bai M, Han X, Jia H, et al. Transfer pretrained sentence encoder to sentiment classification[C]. In *Proceedings of 2018 IEEE Third International Conference on Data Science in Cyberspace*, 2018: 423-427.
- [43] Sadamitsu K, Homma Y, Higashinaka R, et al. Zero-shot learning for natural language understanding using domain-independent sequential structure and question types[C]. In *Proceedings of 2017 Interspeech*, 2017: 3306-3310.
- [44] Pushp P K, Srivastava M M. Train once, test anywhere; zero-shot learning for text classification [C]. In *Proceedings of International Conference on Learning Representations(ICLR)*, 2018.
- [45] Strapparava C, Valitutti A. WordNet affect: an affective extension of WordNet[C]. In *Proceedings of the Fourth International Conference on Language Resources and Evaluation*, 2004: 1083-1086.
- [46] Min Y, Zhu D, Chow K. A topic model for building fine-grained domain-specific emotion lexicon [C]. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (ACL 2014)*, 2014: 421-426.
- [47] Bravo M, Frank E, Pfahringer B. Building a twitter opinion lexicon from automatically-annotated tweets[J]. *Knowledge-Based Systems*, 2016, 108: 65-78.
- [48] 徐琳宏, 林鸿飞, 潘宇, 等. 情感词汇本体的构造[J], *情报学报*, 2008, 27(2): 180-185.
- [49] Quan C, Ren F. Sentence emotion analysis and recognition based on emotion words using Ren-CECps [J]. *International Journal of Advanced Intelligence*, 2010, 2(1): 105-117.

- [50] Xu G, Meng X, Wang H. Buildchinese emotion lexicons using a graph-based algorithm and multiple resources[C]. In Proceedings of the 23rd International Conference on Computational Linguistics, 2010: 1209-1217.
- [51] Yang C, Lin K H Y, Chen H H. Building emotion lexicon from weblog corpora[C]. In Proceedings of the 45th Annual Meeting of the ACL on Interactive Poster and Demonstration Sessions. Association for Computational Linguistics, 2007: 133-136.
- [52] Tang D, Qin B, Liu T, et al. Learning sentence representation for emotion classification on microblogs[M]. Natural Language Processing and Chinese Computing, 2013: 212-223.
- [53] Ma C, Prendinger H, Ishizuka M, et al. A chat system based on emotion estimation from text and embodied conversational messengers[C]. In Proceedings of the 2005 International Conference on IEEE, 2005: 546-548.
- [54] Aman S, Szpakowicz S. Identifying expressions of emotion in text[C]. In Proceedings of the 10th International Conference on Text, Speech and Dialogue, 2007: 196-205.
- [55] Golder S A, Macy M W. Diurnal and seasonal mood vary with work, sleep, and daylength across diverse cultures[J]. Science, 2011, 333(6051): 1878-1881.
- [56] Wang M, Liu M, Feng S, et al. A novel calibrated label ranking based method for multiple emotions detection in chinese microblogs[M]. Natural Language Processing and Chinese Computing, 2014: 238-250.
- [57] Strapparava C, Mihalcea R. Learning to identify emotions in text[C]. In Proceedings of the 2008 ACM symposium on Applied computing, 2008: 1556-1560.
- [58] Neviarouskaya A, Prendinger H, Ishizuka M. Recognition of affect, judgment, and appreciation in text[C]. In Proceedings of the 23rd international conference on computational linguistics, 2010: 806-814.
- [59] Lee S Y M, Chen Y, Huang C R. A text-driven rule-based system for emotion cause detection[C]. In Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text, 2010: 45-53.
- [60] Gao K, Xu H, Wang J. Emotion cause detection for chinese micro-blogs based on ECOCC model [C]. Pacific-Asia Conference on Knowledge Discovery and Data Mining. Springer, Cham, 2015: 3-14.
- [61] Neviarouskaya A, Prendinger H, Ishizuka M. Affect analysis model: novel rule-based approach to affect sensing from text[J]. Natural Language Engineering, 2011, 17(1): 95-135.
- [62] Mohammad S. Portable features for classifying emotional text[C]. In Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2012: 587-591.
- [63] 牛耘, 潘明慧, 魏欧, 等. 基于词典的中文微博情绪识别[J]. 计算机科学, 2014, 41(9): 253-258.
- [64] 潘明慧, 牛耘. 基于多线索混合词典的微博情绪识别[J]. 计算机技术与发展, 2014, 24(9): 28-32.

- [65] Wen S, Wan X. Emotion classification in microblog texts using class sequential rules[C]. In Proceedings of 2014 Association for the Advancement of Artificial Intelligence, AAAI, 2014: 187-193.
- [66] Wawre S V, Deshmukh S N. Sentiment classification using machine learning techniques[J]. International Journal of Science and Research (IJSR), 2016, 5(4): 819-821.
- [67] Pang B, Lee L. A sentimental education: Sentiment analysis using subjectivity summarization based on minimum cuts[C]. In Proceedings of the 42nd annual meeting on Association for Computational Linguistics, 2004: 271-278.
- [68] Mishne G. Experiments with mood classification in blog posts[C]. In Proceedings of ACM SIGIR 2005 workshop on stylistic analysis of text for information access, 2005: 321-327.
- [69] Alsharif O, Alshamaa D, Ghneim N. Emotion classification in arabic poetry using machine learning[J]. International Journal of Computer Applications, 2013, 65(16): 10-15.
- [70] Go A, Bhayani R, Huang L. Twitter sentiment classification using distant supervision[J]. CS224N Project Report, 2009: 1-12.
- [71] Tang D, Wei F, Yang N, et al. Learning Sentiment-Specific Word Embedding for Twitter Sentiment Classification[C]. In Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, 2014: 1555-1565.
- [72] Read J. Using emoticons to reduce dependency in machine learning techniques for sentiment classification[C]. In Proceedings of the ACL student research workshop, 2005: 43-48.
- [73] Purver M, Battersby S. Experimenting with distant supervision for emotion classification[C]. In Proceedings of the 13th Conference of the European Chapter of the ACL, 2012: 482-491.
- [74] Moreno-Ortiz A, Hernández C P. Lexicon-based sentiment analysis of Twitter messages in Spanish[J]. Procesamiento del lenguaje natural, 2013 (50): 93-100.
- [75] Strapparava C, Mihalcea R. Learning to identify emotions in text[C]. In Proceedings of the 2008 ACM symposium on Applied computing, 2008: 1556-1560.
- [76] Turney P D. Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews[C]. In Proceedings of the 40th annual meeting on association for computational linguistics, 2002: 417-424.
- [77] Kim S M, Valitutti A, Calvo R A. Evaluation of unsupervised emotion models to textual affect recognition[C]. In Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text, 2010: 62-70.
- [78] Fernández-Gavilanes M, Álvarez-López T, Juncal-Martínez J, et al. Unsupervised method for sentiment analysis in online texts[J]. Expert Systems with Applications, 2016, 58: 57-75.
- [79] Annett M, Kondrak G. A comparison of sentiment analysis techniques: Polarizing movie blogs[C]. In Proceedings of the 21st Conference of Canadian Society for Computational Studies of Intelligence, 2008: 25-35.

- [80] Zhou G, Zhao J, Zeng D. Sentiment classification with graph co-regularization[C]. In Proceedings of the 25th International Conference on Computational Linguistics, 2014: 1331-1340.
- [81] Shamma D A, Kennedy L, Churchill E F. Tweet the debates: understanding community annotation of uncollected sources[C]. In Proceedings of the first SIGMM workshop on Social media, 2009: 3-10.
- [82] Hu X, Tang J, Gao H, et al. Unsupervised sentiment analysis with emotional signals[C]. In Proceedings of the 22nd international conference on World Wide Web, 2013: 607-618.
- [83] Moreno-Ortiz A, Hernández C P. Lexicon-based sentiment analysis of twitter messages in Spanish [J]. *Procesamiento del lenguaje natural*, 2013 (50): 93-100.
- [84] Mintz M, Bills S, Snow R, et al. Distant supervision for relation extraction without labeled data [C]. In Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP, 2009: 1003-1011.
- [85] Shen Y, He X D, Gao J F, et al. Learning semantic representations using convolutional neural networks for web search[C]. In Proceedings of the 23th International Conference on World Wide Web, ACM, 2014: 373-374.
- [86] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436.
- [87] Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation[C]. In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2015: 1412-1421.
- [88] Wang Y Q, Huang M L, Zhao L, et al. Attention-based LSTM for aspect-level sentiment classification[C]. In Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016: 606-615.
- [89] Yang M, Tu W T, Wang J X, et al. Attention based LSTM for target dependent sentiment classification[C]. In Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI), 2017: 5013-5014.
- [90] Yu J, Marujo L, Jiang J, et al. Improving multi-label emotion classification via sentiment classification with dual attention transfer network[C]. In Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 1097-1102.
- [91] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]. *Advances in Neural Information Processing Systems*, 2017: 5998-6008.
- [92] Peters M E, Neumann M, Lyyer M, et al. Deep contextualized word representations[C]. In Proceedings of NAACL-HLT 2018, 2018: 2227-2237.
- [93] Tafreshi S, Diab M. Emotion detection and classification in a multigenre corpus with joint multi-task deep learning [C]. In: Proceedings of the 27th International Conference on Computational Linguistics, 2018: 2905-2913.
- [94] Chen Y, Hou W J, Cheng X Y, et al. Joint learning for emotion classification and emotion cause