

基于不同文本粒度的情感分析综述

wdevin@qq.com

摘要：近年来，随着互联网和社交网络的不断发展，网络上文本数据量迅速增长，情感分析成为自然语言处理领域的热点研究方向之一。本文采用文献调研方法，基于不同文本粒度层次的情感分析视角，对粗粒度情感分析到细粒度情感分析的演变过程进行阐述，重点梳理了各粒度层面情感分析的关键问题及主要方法，对各粒度层面的主流方法进行概括、分析和比较。最后对文本情感分析进行总结，并进一步探讨了情感分析在隐式、跨领域情感分析中的研究难点。

关键词：文本情感分析、情感词典、机器学习、深度学习

1 前言

情感是影响人类行为的重要因素之一，当我们需要做出决策的时候，我们希望能够根据他人的情感知道他人的观点或意见。当今社会，互联网已深入到人们日常生活和工作中的方方面面，用户可在博客、社交网站、论坛、购物网站中表达自己的意见或情感，互联网上蕴含人们丰富情感的文本资源呈指数级增长，通过人工方式进行处理难度越来越大，人们希望通过相应的计算机技术对这些情感文本进行自动化处理和分析，并从中提取出有价值的信息。在这样的应用需求背景下，出现了针对文本的情感分析技术。随着人工智能技术的不断发展，情感分析的应用已经深入到各个行业领域。

情感分析又称意见挖掘、倾向性分析等，是文本挖掘的一个细分研究领域。简单而言，是运用自然语言处理、文本挖掘和计算机语言学等方法对带有情感色彩的主观性文本进行抽取、处理、分析、归纳和推理的过程。情感分析的主要研究对象是互联网中海量存在的商品评论、博客和论坛帖子等文本。通过分析购物网站上的商品评论便于消费者详细了解商品信息，从而优化消费决策。企业可通过分析客户对产品的评价实时和快速地获取顾客反馈数据来提升产品竞争力，以更好地理解客户行为，为企业提供强大的决策支持。微博等社交媒体平台的兴起更是为基于网络数据的舆情分析、民意调查等活动提供了广泛的数据基础。

从分析的粒度层次来看，情感分析可分为粗粒度和细粒度层次分析，粗粒度层次分析有篇章级和句子级情感分析，细粒度层次情感分析则是基于评价对象及

其属性的分析。随着行业和个人对情感分析的要求越来越高，情感分析的粒度层次正逐步向细粒度分析层面发展。因此，本文从现阶段已有文献入手，以文本颗粒度为视角，对篇章级、句子级和方面级等三种不同粒度层次的情感分析概念和技术进行介绍，梳理并评述不同粒度层次情感分析的关键问题和方法。

2 篇章级情感分析

篇章级情感分析是情感分析中最浅层次的分析。篇章级情感分析的前提假设是整个文本只表达了一种情感，即积极的或者消极的情感。从篇章级情感分析的假设来看，该层次的情感分析的主要任务是将文本进行情感分类，即将带有观点的文本分类为积极的或消极的。从目前的研究来看，进行篇章级情感分析的主要方法是基于情感知识的情感词典方法和基于特征分类的机器学习方法。

2.1 情感词典方法

情感词典是文本情感分析的基础。利用构建的情感词典，并对情感词典进行极性和强度标注，能够有效地对文本进行情感分析。基于词典的文本情感分析，构建情感词典是关键。根据人工在情感词典构建过程中的参与程度不同，分为人工构建情感词典和自动构建情感词典。基于人工构建的情感词典虽然具备较好的通用性，但是在实际使用中，难以覆盖来自不同领域的情感词，领域适应性较差。同时，人工情感词典构建需要耗费大量的人力物力。因此，学术界更多地聚焦于情感词典的自动构建工作，这里主要介绍情感词典的几种主要的自动构建方法。

词关系扩展法：利用已知褒贬的种子词集，在语义知识库中寻找同义词、反义词等词间关系，进行扩展，去噪后得到一份通用情感词典。Strapparava 等^[1]在形容词的基础上，还加入了名词和一小部分动词和副词作为初始词典，使得到的情感词典更加全面。Neviarouskaya 等^[2]还引入情感得分和情感权重，使得篇章级文本情感值计算更加合理。

迭代路径法：由于语义知识库中，词间的网状关系任意两个词之间都可能存在着千丝万缕的联系。Kamp 等^[3]认为，意思越相似的两个词，它们通过同义词迭代所需的次数就越少。可以使用两个词相互迭代所需的次数衡量两者的相似性，并用于计算候选词的情感倾向。

连词关系法：通常，文本中转折词的出现会伴随着情感极性的改变，而一般的连词(如并列、承接词)则不会导致极性改变。该类方法利用连词信息，判断

文本片段的情感，从而判断片段中情感词的情感。

关系图半监督法：以词与词之间的相似关系构建词间关系图。利用已知极性的情感词，结合图算法如标签传播算法等推测其他情感词的极性。

深度表示法：Tang 等^[4]将情感词典的构建视为对词/短语的情感分类任务。他们使用 skip-gram 模型，依据大规模文本来训练词向量，使得语义相近的词在向量空间上距离较近，以此来判断词的情感极性。

2.2 有监督机器学习

B. Pang 等^[5]人首次将机器学习的方法应用于篇章级的情感分类任务中。他们尝试使用了 n-gram 词语特征和词性特征运用朴素贝叶斯、最大熵和支持向量机 3 种不同的有监督机器学习方法进行电影评论分类。实验结果显示基于 unigram 的支持向量机取得了最佳分类效果。

2.2.1 基于朴素贝叶斯的方法

朴素贝叶斯是概率模型，在许多领域都能令人满意地工作。贝叶斯分类提供了实用的学习算法和先验知识，观察到的数据可以相结合。在朴素贝叶斯技术中，基本思想是通过使用单词和类别的联合概率找出给定文本文档类别的概率。该算法被广泛用于文本情感分析。

$$P_{\text{NB}}(c | d) := \frac{P(c) \left(\prod_{i=1}^m P(f_i | c)^{n_i(d)} \right)}{P(d)}.$$

基于朴素贝叶斯的文本情感分析技术是通过计算概率对文本情感进行分类，适合增量式训练，而且算法比较简单，对小规模数据表现良好。但该方法对输入数据的表达形式很敏感，而且需要计算先验概率，因此会在分类决策方面存在错误率。

2.2.2 基于最大熵的方法

最大熵分类器属于指数模型类的概率分类器。基于最大熵原理，并且从适合训练数据的所有模型中，选择具有最大熵的模型。近年部分学者基于最大熵构建情感分析模型，对文本情感进行了分析。

$$P_{\text{ME}}(c | d) := \frac{1}{Z(d)} \exp \left(\sum_i \lambda_{i,c} F_{i,c}(d, c) \right)$$

基于最大熵的文本情感分析只要得到一些训练数据，然后进行迭代，就可以

得到所需模型，进行自收敛，方法简单。但是由于最大熵往往只能得到局部最佳解而非全局最优解，因此运用该方法进行情感分析准确率有待提高。

2.2.3 基于支持向量机的方法

支持向量机是一种相对较新的机器学习方法。它通过寻求结构化风险最小以提高学习机泛化能力，实现经验风险和置信范围的最小化，从而达到在统计样本量较少的情况下，亦能获得良好统计规律的目的。

$$\vec{w} := \sum_j \alpha_j c_j \vec{d}_j, \quad \alpha_j \geq 0,$$

基于 SVM 的文本情感分析方法被认为是最好的情感分析方法，该方法泛化错误率低，计算开销不大，而且对于训练样本较小的文本可以得到很好的情感分析效果，对高维数据的处理效果良好，能够得到较低的错误率，但该方法对参数调节和核函数的选择敏感。

2.3 无监督机器学习

P. Turney 等^[6]提出了一种基于无监督机器学习的篇章级情感分类方法。首先，他基于词性(Part of speech)将包含副词和形容词的短语抽取出来作为情感词。然后通过计算被抽取词与“excellent”的点互信息(point mutual information, PMI)值减被抽取词与“poor”的点互信息值的差值来计算情感倾向 (sentiment orientation, SO):

$$PMI(term_1, term_2) = \log_2 Y \frac{PrYterm_1 term_2 Y}{PrYterm_1 Y PrYterm_2 Y} Y$$

$$SO (phrase) = PMI (phrase, “excellent”) - PMI (phrase, “poor”)$$

其中， $Pr(term_1)$ 指词 $term_1$ 在文本中出现的概率， $PrYterm_1$ 指词 $term_1$ 和 $term_2$ 同时出现的概率。如果 $SO(phrase) > 0$ ，则该情感词的情感倾向为正，说明该词表达正向情感。如果 $SO(phrase) < 0$ ，则该情感词的情感倾向为负，说明该词表达负向情感。如果 $SO(phrase) = 0$ ，则该情感倾向为中性。

2.4 篇章级情感分析小结:

篇章级情感分析方法对比: 基于词典的文本情感分析技术由于构建的词典往往只针对某个领域，对于跨领域情感分析的效果不够好，而且词典中的情感词可

能不够丰富，对于短文本和特定领域文本进行情感分析的效果更好。基于机器学习的方法泛化错误率低，计算开销不大，而且对于训练样本较小的文本可以得到很好的情感分析效果，对高维数据的处理效果良好，能够得到较低的错误率。因此，对于篇章级情感分析来说，更好的解决方法是利用机器学习方法。

篇章级情感分析缺点：篇章级情感分析能提供一个情感文本总体层面上的情感倾向，但对于其他类型文本，例如博客、新闻和论坛讨论等文本，由于其具有情感表达丰富、评价对象多样化等特点，篇章级情感分析过于粗糙，并不能准确描述这类文章的情感倾向。因此，随着研究的深入，情感分析逐渐向句子级情感分析过渡。

3 句子级情感分析

相较于篇章级情感分析，句子级情感分析将整个文本以句子为单位进行分割，将单个句子作为情感表达的单元。句子级情感分析的前提假设是单个句子只表达一种情感，即积极的或消极的情感。从上述前提假设来看，句子级情感分析可以看作篇章级情感分析的延续，因为文本中的句子可以被视为一种短文本。句子级情感分析任务一般被分为两个步骤完成：①主客观分类，即将句子分类为主观句或者客观句。②是将主观句中的情感倾向进行划分，分类为正向或者负向情感。

3.1 主客观分类任务

J.M.Wiebe 等^[7]提出了基于二元特征运用朴素贝叶斯分类器的分类方法。H.Yu 和 V.Hatzivassiloglou^[8]运用句子相似性和朴素贝叶斯分类器进行主客观分类，句子相似性方法是基于以下假设：主观句与主观句之间的相似程度高于主观句与客观句之间的相似程度。对于朴素贝叶斯分类器，他们运用 unigram、bigram、trigram 和词性等不同特征进行分类。L.Barbosa 和 J.Feng^[9]运用传统特征和 Twitter 独有特征及 SVM 对推特文本进行主客观分类，他们指出进行句子主客观分类的关键在于抽取句子中的情感词或将其他特征值引入分类器对句子的主客观性进行分类。

3.2 主观句情感分类任务

主观句情感分类即判断主观句是积极的或消极的，除了传统的有监督机器学习方法，M.Q.H 和 B.Liu^[10]提出了基于词典的方法进行句子情感倾向分类。R.Mcdonald 等^[11]提出了分层序列学习模型进行句子级和篇章级情感分类，在训

练集中，每个句子和评论文档都标注了情感。实验结果表明，通过同时引入两个不同粒度层次的情感有效提升了分类结果。Kim 等^[12]人提出的 CNN 文本分类工作，成为句子级情感分类任务的重要 baseline 之一。其核心意义是将“词向量”与“深度学习”结合在一起，并且通过实验证明了“词的向量表示”是 NLP 领域的重要组成部分。

3.3 句子级情感分析小结

相比于篇章级情感分析，句子级情感分析在分析粒度上有了很大的提升。但是在实际应用当中，评论文本往往是复杂的，从句子层面看，一个句子表达的是积极的情感，但并不代表句子中评论对象的所有属性所对应的情感都是积极的。例如“河东食堂的饭菜非常有特色，味道很好，但是服务员服务意识不高，不过总体印象还是很不错的，我还会再来”。从句子级情感分析层面来看，评论者对食堂的评价是积极的，但是却不能识别出对于食堂服务这个属性的评价是负面的。所以篇章级和句子级情感分析无法满足更细粒度层次的情感分析，它们无法对评论对象属性所对应的情感进行识别和分类。在句子级情感分析的主客观分类中，客观句是对客观事实的描述，但客观句有时也反映出评论发布者的情感倾向。例如“丽娃澡堂的水管已经坏两天了”。这句话反映出了水管坏的这个事实，同时也反映出了同学们对丽娃澡堂的负向观点。基于篇章级和句子级情感分析的前提假设，这两个层次的情感分析粒度过粗，因此更细粒度的方面级情感分析需求成为当下情感分析研究的重要趋势。

4 方面级情感分析

基于方面级的情感分析作为更深层次的情感分析，可以针对不同的目标挖掘用户更细腻的情感表述。和普通情感分析不同，基于方面情感分析需要正确判断句子中不同方面的情感极性，这不仅依赖于文本的上下文信息，同时也要考虑不同方面的情感信息。例如在手机评论文本中，手机作为评论对象包含了电池、手机屏幕、照相功能和手机操作系统等属性。评论发布者往往会从评论对象属性层面对手机的各个功能部分做出评价，识别这些属性及其对应的情感倾向需要进行细粒度的情感分析，细粒度情感分析因此也被称为基于属性的观点挖掘。

4.1 方面级情感分析结构化定义

B.Liu^[13]基于产品评论文本将非结构化的情感进行了结构化的定义，他将产

品评论中的情感进行了五元组定义和抽取：

$$(e_i, a_{ij}, s_{ijkl}, h_k, t_l)$$

其中 e_i 指一个实体或目标的名称，也可以理解为情感表达对象； a_{ij} 指该实体的一个方面，可理解为表达对象的属性； s_{ijkl} 指实体某个方面的意见，可理解为对象属性所对应的情感； h_k 指情感的发布者； t_l 指情感的发布时间。

方面级情感分析关键任务主要由以下六种组成：①实体提取与分类 (entity extraction and categorization)；②方面(属性)提取与分类(aspect extraction and categorization)；③意见持有者(发布者)提取与分类 (opinion holder extraction and categorization)；④时间提取与分类 (time extraction and categorization)；⑤对属性情绪分类 (aspect sentiment classification)；⑥五元意见组的生成 (opinion quintuple generation)。其中的关键任务是方面提取(aspect extraction)和方面级情绪分类(aspect sentiment classification)。

4.2 方面提取

方面提取的主要任务是提取实体的所有方面表达式，并将这些方面表达式分类集中。实体 e_i 的每个方面表达式集表示唯一的方面 a_{ij} 。

传统机器学习方法：传统机器学习方法将方面提取看作是属性分类问题，将属性词提取视为序列标注问题。例如，Toh 等^[14]首先构造了一系列特征，包括词汇特征、语义特征、句法依赖特征、词聚类特征等，然后针对属性分类问题，采用 One-vs-all 策略，利用传统的神经网络算法训练多个二元分类器，识别句子中涉及的属性；而针对属性词提取问题，则采用条件随机场算法，训练识别句子中与属性关联的单词或词组。

深度学习方法：相较依赖于手动提取特征的传统机器学习方法，深度学习的优势在于可以自动抽取更抽象、更高层次的特征，因此通过深度学习算法抽取的特征可以更好地辅助属性分类或属性词提取。Toh 等^[15]在原来词汇特征、语义特征、句法依赖特征、词聚类特征的基础上，分别利用 CNN 和 RNN 提取更抽象、更高层次的特征，并将新抽取的深度学习特征增加到原来的神经网络算法和条件随机场中进行训练。实验结果表明，深度学习特征的加入显著增强了属性分类和属性词提取的效果。

4.3 方面级情绪分类

方面级情绪分类是指对于待分析文本，识别针对某一特定属性的情感极性。确定关于方面 a_{ij} 的意见是正面的，负面的还是中性的，或者将方面的数字情感评级分配。方面级情绪分类有两个子任务：①ATSA (aspect-term sentiment analysis): 预测文本中出现的目标实体相关的情感极性。②ACSA (aspect-category sentiment analysis): 预测给定方面的情感极性。目前方面级情绪分类的主流方法主要有以下三种：基于词典的方法、传统机器学习方法以及深度学习方法。

基于词典的方法: 基于词典的方法首先将句子涉及的属性和单词或词组关联起来，然后通过情感词典中每个单词或词组的情感极性来推理出属性的情感极性。Zhu 等^[16]人首先通过 MAB 自助算法 (Multi-aspect bootstrapping algorithm) 获取和每个属性相关的单词或词组集合；然后通过句子分割算法将句子重新划分，确保每个划分段只对应一个单独的属性；最后通过情感词典来判断每段文本的情感极性，进而确定句子中每个属性的情感极性。

传统机器学习方法: 传统的机器学习方法将属性的情感识别同样看作多分类问题，即将每个属性的情感极性归类为积极、消极或中立。Brun 等^[17]人提出一个基于反馈的分类框架，该方法首先构造语言学特征，包括 n-gram 特征、语义特征、句法依赖特征、属性类别特征等，然后通过奇异值分解进行特征降维，再采用 one-vs-all 策略的分类算法训练分类器；最后将模型的效果反馈到特征空间进一步优化特征。

深度学习方法: 深度学习方法也将属性的情感识别看作多分类问题。由于不需要人工构造特征，因此可以直接基于端到端来识别属性的情感极性。Tang 等^[18]提出顺序神经模型 LSTM，通过考虑上下文信息，解决目标词被忽略的问题，通过引入对目标词进行平均化处理后得到的向量，加强了目标词与句子的交互。Wang 等^[19]在 LSTM 的基础上引入属性向量和 attention 机制，提出 ATAE-LSTM 模型，试图利用目标词的向量学习文本不同位置的权重，以解决短语级情感分类问题；Tang 等^[20]针对 ACSA 任务借鉴自动问答中的深层记忆网络模型，结合记忆机制和注意力机制，解决了短期记忆问题；Ma 等^[21]创建了多层 attention 模型来分别明确计算目标词和整个句子，将外部知识引入传统 LSTM 网络，并将常识性情感知识融入深层神经网络，实现了方面级情感分析的最佳效果。Xue 等^[22]提

出一种基于门控机制的可并行训练的 CNN 模型对 ACSA 和 ATASA 任务分别进行了模型设计，解决了 LSTM 和注意层耗时且参数复杂的问题，基于门控机制的模型更易于并行化，训练时间更短，且具有更高的精度。

4.4 方面级情感分析小结

方法对比：基于词典的方法费时费力、难以保证一致性和准确性、有时需要领域知识。传统机器学习方法准确率相对较高、快速、来源于真实文本，但这类方法通常需要对输入文本进行大量的预处理和复杂的特征工程，以及如依存关系分析等外部知识，性能极大依赖于文本特征、情感词典等信息。深度学习方法自动抽取更抽象更高层次的特征，大大缓解了模型对特征工程的依赖，使模型用更低的代价取得更好的分类效果，但基于深度学习的方法一般参数较为复杂，黑盒训练具有不确定性，在深度学习中加入 Attention 机制或深度记忆网络等可显著增强方面属性提取和方面情绪分类的效果。方面级情感分析的技术尚在初步探索之中，结合深度学习的方面级情感分析是未来情感分析的重要趋势。

5 总结与展望：

本综述从文本粒度层面对情感分析相关研究进行了介绍，论述了情感分析由粗粒度到细粒度演变的过程，重点梳理了各粒度层面情感分析的关键问题及方法。通过对国内外现有研究进行梳理，发现情感分析作为文本挖掘研究的一个分支，受到了越来越多的关注及重视。在实际应用中，情感分析在组织与个人的决策过程中起到了越来越重要的作用。由于自然语言的丰富性及复杂性，特别是处于大数据高速发展的今天，如何提升情感分析的性能是情感分析研究面临的重要问题。笔者认为情感分析领域还有如下两个难点问题需要重点解决：

隐式情感分析：在情感表述中，除了用情感词表示情感外，对于客观事实的描述也能反映情感。现阶段对隐式情感分析的研究只集中在隐式评价对象抽取，但对于客观文本中隐藏的情感倾向识别研究较少。现阶段可使用人工标注并结合机器学习的方法来尝试解决隐式情感倾向识别问题。

跨领域情感分析：在不同的领域进行情感分析时，情感分析的性能会发生变化，特别是当领域差异过大时，情感分析的效率 and 性能会出现下降。由于语言的多样性与复杂性，不同领域间的情感表达差别较大。现阶段可采用迁移学习与情感分析相结合的方法来尝试解决跨领域情感分析问题。

参考文献:

- [1] Strapparava C, Valitutti A. WordNet-affect: an affective extension of wordNet. In: Proceedings of the 2004 International Conference on Language Resources and Evaluation. Lisbon: LREC, 2004. 1083–1086
- [2] Neviarouskaya A, Prendinger H, Ishizuka M. SentiFul: a lexicon for sentiment analysis. IEEE Transactions on Affective Computing, 2011, 2(1): 22–36
- [3] Kamps J, Marx M, Mokken R J, De Rijke M. Using word-net to measure semantic orientations of adjectives. In: Proceedings of the 4th International Conference on Language Resources and Evaluation. Paris: European Language Resources Association, 2004. 1115–1118
- [4] Tang D Y, Wei F R, Qin B, Zhou M, Liu T. Building large-scale twitter-specific sentiment lexicon: a representation learning approach. In: Proceedings of the 25th International Conference on Computational Linguistics. Dublin, Ireland: COLING, 2014. 172–182
- [5] Pang B, Lee L, Vaithyanathan S. Thumbs up? Sentiment classification using machine learning techniques. In: Isabelle P, ed. Proc. of the EMNLP 2002. Morristown: ACL, 2002. 79–86.
- [6] Turney P D. Thumbs up or thumbs down?: semantic orientation applied to unsupervised classification of reviews[C]//Proceedings of the 40th annual meeting on association for computational linguistics. Association for Computational Linguistics, 2002: 417-424.
- [7] Wiebe J M, Bruce R F, O’Hara T P. Development and use of a gold-standard data set for subjectivity classifications[C]//Proceedings of the 37th annual meeting of the Association for Computational Linguistics. 1999: 246-253.
- [8] Yu H, Hatzivassiloglou V. Towards answering opinion questions: separating facts from opinions and identifying the polarity of opinion sentences[C]//Proceedings of the conference on empirical methods in natural language processing. Sapporo:ACL,2003.
- [9] Barbosa L, Feng J. Robust sentiment detection on twitter from biased and noisy data[C]//Proceedings of the 23rd international conference on computational linguistics: posters. Association for Computational Linguistics, 2010: 36-44.
- [10] Hu M, Liu B. Mining and summarizing customer reviews[C]//Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2004: 168-177.
- [11] McDonald R, Hannan K, Neylon T, et al. Structured models for fine-to-coarse sentiment analysis[C]//Proceedings of the 45th annual meeting of the association of computational linguistics. 2007: 432-439.
- [12] Kim Y. Convolutional neural networks for sentence classification[J]. arXiv preprint arXiv:1408.5882, 2014.
- [13] Liu B. Sentiment analysis and opinion mining[M]. California:Morgan & Claypool Publishers,2012.
- [14] Toh Z, Su J. Nlangp: Supervised machine learning system for aspect category classification and opinion target extraction[C]//Proceedings of the 9th international workshop on semantic evaluation (SemEval-2015). 2015.

- [15] Toh Z, Su J. Nlangp at semeval-2016 task 5: Improving aspect based sentiment analysis using neural network features[C]//Proceedings of the 10th international workshop on semantic evaluation (SemEval-2016). 2016: 282-288.
- [16] Zhu J, Wang H, Tsou B K, et al. Multi-aspect opinion polling from textual reviews[C]//Proceedings of the 18th ACM conference on Information and knowledge management. ACM, 2009: 1799-1802.
- [17] Brun C, Perez J, Roux C. Xrce at semeval-2016 task 5: Feedbacked ensemble modeling on syntactico-semantic knowledge for aspect based sentiment analysis[C]//Proceedings of the 10th international workshop on semantic evaluation (SemEval-2016). 2016: 277-281.
- [18] Tang D, Qin B, Feng X, et al. Effective LSTMs for target-dependent sentiment classification[J]. Association for Computational Linguistics, 2015.
- [19] Wang Y, Huang M, Zhao L. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of the 2016 conference on empirical methods in natural language processing. 2016: 606-615.
- [20] Tang D, Qin B, Liu T. Aspect level sentiment classification with deep memory network[J]. Association for Computational Linguistics, 2016.
- [21] Ma Y, Peng H, Cambria E. Targeted aspect-based sentiment analysis via embedding commonsense knowledge into an attentive LSTM[C]//Thirty-Second AAAI Conference on Artificial Intelligence. 2018.
- [22] Xue W, Li T. Aspect based sentiment analysis with gated convolutional networks[J]. Association for Computational Linguistics, 2018.