

分类号 TP391.1
U D C

密级
编号 10741



硕士学位论文

论文题目：融合外部知识的方面级情感分析研究

研究生姓名：赵金雨

指导教师姓名、职称：李强教授

学科、专业名称：管理科学与工程

研究方向：信息管理与信息系统

提交日期：2024年5月31日

独创性声明

本人声明所呈交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

学位论文作者签名： 赵金雨 签字日期： 2024年5月31日

导师签名： 李强 签字日期： 2024年5月31日

关于论文使用授权的说明

本人完全了解学校关于保留、使用学位论文的各项规定，同意（选择“同意”/“不同意”）以下事项：

1.学校有权保留本论文的复印件和磁盘，允许论文被查阅和借阅，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文；

2.学校有权将本人的学位论文提交至清华大学“中国学术期刊（光盘版）电子杂志社”用于出版和编入CNKI《中国知识资源总库》或其他同类数据库，传播本学位论文的全部或部分内容。

学位论文作者签名： 赵金雨 签字日期： 2024年5月31日

导师签名： 李强 签字日期： 2024年5月31日

A study of aspect-level sentiment analysis incorporating external knowledge

Candidate : Zhao JinYu

Supervisor: Li Qiang

摘 要

近年来,随着互联网的迅速发展和 5G 时代的到来,各大电商平台和社交 APP 拥有庞大用户群体,这导致大量的非结构化文本数据的出现,这些数据中包含了丰富的情感元素,具有极大的商业潜力。为了能够利用这些数据挖掘用户的情感倾向,快速地掌握对商业产品、社会制度、政治生活等方面的看法,文本情感分析变成一个备受关注的研究主题。当前已有很多机器学习技术实现了文本情感分析,但仍有许多问题亟待解决。文本情感分析主要包括方面级、句子级和篇章级情感分析。考虑到文本数据的独特性,方面级情感分析对于处理目前互联网上产生的文本情感数据更为合适。这种方法针对特定方面词进行情感分析,为个人、公司和相关部门实施某项措施时提供更加精准的数据支撑,在实际应用中非常有价值。目前大多数情感分析研究都集中在基于句子本身挖掘句法依存树的依赖关系,并且仅仅考虑是否存在依赖关系,将所有的依赖关系平等对待,同时没有使用太多与文本相关的外部知识,对外部知识的利用不充分。针对以上问题,本文开展的主要工作如下:

(1) 针对当前方面级情感分析研究中大部分模型未充分提取句法信息,且没有充分将文本位置信息融合的问题,本文提出了一种融合外部知识和位置信息增强的图卷积神经网络模型(A graph neural network model enhanced by fusion of external knowledge and location information, KL-GCN)。模型分为语义信息提取模块和句法信息提取模块,在句法信息提取部分中,我们对数据集词性进行统计,构建词性矩阵,充分考虑否定词、程度词等影响句子情感表达的词对情感分类的影响。然后,利用外部情感词典为句子中的每个词分配情感分数,构建情感分数矩阵来突出情感词的权重,通过该方法模型充分学习句子的依赖关系,得到包含丰富句法信息的特征向量,在语义信息提取模块,首先通过 BERT 模型对文本词和方面词进行编码,加入位置信息,获得位置信息词向量表示,然后通过 GRU-CNN 网络提取文本语义特征。最后构建基于注意力机制的特征融合模块,将两部分进行特征融合,增强特征向量表示的能力。

(2) 针对目前模型对外部知识利用不充分的问题,本文提出了一种融合外部知识的多通道图卷积神经网络模型(Fusion of External Knowledge Multi-Channel Graph Convolutional Networks, FEKM-GCN),将语法、语义和外部知识三种特征

向量融合。首先模型分别对句子中的语法信息和语义信息进行提取，在将外部知识信息嵌入模型中，利用自注意力机制得到外部知识的得分矩阵，输入图卷积中提取外部知识特征信息，将三种特征信息输入特征融合模块，使三个通道的特征能够互补学习。实验结果表明，模型可以更好地提取到文本的语义信息和语法信息，同时外部信息更加丰富了文本信息，提高了模型的准确率。

关键词：方面级情感分析 外部知识 图卷积网络 信息增强 多通道 特征融合

Abstract

In recent years, with the rapid development of the Internet and the arrival of the 5G era, major e-commerce platforms and social APPs have a huge user base, which leads to the emergence of a large amount of unstructured text data, which contains rich emotional elements and has a very high commercial potential. In order to be able to use these data to mine the emotional tendencies of users and quickly grasp the views on commercial products, social systems, political life and other aspects, text sentiment analysis has become a popular research direction in the field of natural language processing. It has become a much talked about research topic in the research field of natural language processing. There have been many Chinese sentiment analysis methods implemented based on machine learning techniques, but there are still many problems to be solved. Text sentiment analysis mainly includes aspect-level, sentence-level and chapter-level sentiment analysis. Considering the uniqueness of textual data, aspect-level sentiment analysis is more appropriate for textual sentiment data currently generated on the Internet. This approach provides sentiment analysis for specific aspectual words, which is valuable in practical applications as it provides more accurate data support for individuals, companies and related departments when implementing a measure. Most of the current sentiment analysis research focuses on mining dependency trees for context-word and aspect-word dependencies based on the sentence itself, and only considers whether there is a dependency or not, treats all dependencies equally, and does not use too much external sentiment knowledge related to the text, and at the same time, does not make sufficient use of external knowledge. To address the above problems, the main work carried out in this paper is as follows:

1. Aiming at the problem that most of the models in the current

research on aspect-level sentiment analysis do not sufficiently extract syntactic information and do not sufficiently fuse textual location information, this paper proposes a graphical convolutional neural network model (KL-GCN) fused with external knowledge and augmented with location information. The model is divided into a semantic information extraction module and a syntactic information extraction module. In the syntactic information extraction part, we count the lexical properties of the dataset, construct a lexical matrix, and take into full consideration the influence of words affecting the expression of the sentiment of the sentence such as negative words, degree words, and so on, on the sentiment classification. Then, the external sentiment dictionary is used to assign sentiment scores to each word in the sentence, and the sentiment score matrix is constructed to highlight the weight of the sentiment words, and the dependency relationship of the sentence is fully learnt through the method model to obtain the feature vector containing rich syntactic information. In the semantic information extraction module, firstly, the text words and aspect words are encoded through the BERT model, and the positional information is added to obtain the positional information word vector representation. In the semantic information extraction module, firstly, the text words and aspect words are encoded by BERT model, and the location information is added to obtain the location information word vector representation, and then the text semantic features are extracted by GRU-CNN network. Finally, the feature fusion module based on the attention mechanism is constructed to fuse the two parts to enhance the feature vector representation.

2. Aiming at the problem that the current models do not make sufficient use of external knowledge, this paper proposes a Fusion of External Knowledge Multi-Channel Graph Convolutional Networks

(FEKM-GCN) model that fuses syntactic, semantic and external knowledge three feature vectors are fused. Firstly, the model extracts the syntactic and semantic information in the sentence respectively, then embeds the external knowledge information into the model, uses the self-attention mechanism to get the score matrix of external knowledge, inputs the external knowledge feature information into the graph convolutional to extract the external knowledge feature information, and inputs the three kinds of feature information into the feature fusion module, so that the features of the three channels can be learnt in a complementary way. The experimental results show that the model can better extract the semantic and syntactic information of the text, while the external information enriches the text information more and improves the accuracy of the model.

Keywords: Aspect-level sentiment analysis; External knowledge; Graph convolutional networks; Information enhancement; Multichannel; Feature fusion

目 录

1 绪 论	1
1.1 研究背景及意义.....	1
1.1.1 研究背景.....	1
1.1.2 研究意义.....	2
1.2 国内外研究现状.....	2
1.2.1 基于规则和情感词典的方法.....	3
1.2.2 基于机器学习的方法.....	3
1.2.3 基于深度学习的方法.....	4
1.3 论文研究内容.....	7
1.4 论文组织结构.....	8
2 相关理论和技术	10
2.1 方面级情感分析.....	10
2.2 词向量表示技术.....	10
2.2.1 One-hot 编码.....	11
2.2.2 Word2Vec 模型.....	12
2.2.3 GloVe 模型.....	12
2.2.4 BERT 预训练语言模型.....	13
2.3 神经网络模型.....	16
2.3.1 循环神经网络及其变体.....	16
2.3.2 卷积神经网络及其变体.....	20
2.4 注意力机制.....	22
2.5 依存句法分析.....	23
2.6 本章小结.....	24
3 基于外部知识和位置信息增强的方面级情感分类模型	25
3.1 任务定义.....	25
3.2 KL-GCN 模型框架.....	25
3.2.1 输入层.....	26

3.2.2 语义提取层.....	27
3.2.3 外部知识嵌入模块.....	28
3.2.4 图卷积网络层.....	31
3.2.5 特征融合层.....	31
3.2.6 输出层.....	32
3.3 实验与分析.....	33
3.3.1 实验数据集与评价指标.....	33
3.3.2 实验环境与参数配置.....	34
3.3.3 对比实验.....	35
3.3.4 实验结果与分析.....	37
3.3.5 消融实验.....	39
3.3.6 GCN 层数对模型性能的影响.....	40
3.3.7 案例分析.....	41
3.4 本章小结.....	42
4 融合外部知识的多通道方面级情感分析模型.....	43
4.1 FEKM-GCN 模型框架.....	43
4.1.1 输入层.....	44
4.1.2 语法信息通道.....	45
4.1.3 语义信息通道.....	45
4.1.4 外部知识通道.....	46
4.1.5 特征融合模块.....	46
4.1.6 输出层.....	47
4.2 实验与分析.....	48
4.2.1 实验数据集与评价指标.....	48
4.2.2 实验环境与参数配置.....	49
4.2.3 对比试验.....	50
4.2.4 实验结果与分析.....	51
4.2.5 消融实验.....	53
4.2.6 GCN 层数对模型性能的影响.....	54

4.3 本章小结.....	56
5 总结与展望.....	57
5.1 总结.....	57
5.2 展望.....	58
参考文献.....	59
致 谢.....	66
攻读硕士学位期间发表的论文及科研情况.....	67

1 绪 论

1.1 研究背景及意义

1.1.1 研究背景

近年来,随着信息技术的发展,现实生活中人们的情感表达时刻渗透在网络中的方方面面,与人们生活密不可分。越来越多的人将自己的情感体现在文字中,通过微博、知乎、抖音等网络媒体表达在互联网上,网民习惯于在平台发表观点意见,以此来表达自己的看法情感,因此互联网成了文本最重要的载体,这极大得扩宽了情感数据的主要来源渠道。在 5G 时代到来的今天,文本信息也出现了更多新时代特点,文本信息的传播方式呈现多样化发展,如网络渠道、新媒体渠道以及其他渠道。文本信息的数量和蕴含的隐藏信息量已经不可同日而语,网络已经覆盖到人们生活的方方面面,使得不同的群体都能在网络中获取自身需要的信息。在大众生活中,不管是团体还是个人,想要做出精准的判断必须通过文本信息判断其情感态度,因此如何利用计算机工具进行文本处理和分析,并且精准挖掘出内在的情感信息就变得尤为重要,而蕴含在文本中的观点则是进行情感分析的关键途径。这种利用计算机工具进行文本信息挖掘,实现人与计算机之间的有效通信的方式称为自然语言处理(Natural Language Processing, NLP)^[1]。

根据中国互联网信息中心(China Internet Network Information Center, CNNIC)第 51 次《中国互联网络发展状况统计报告》显示^[2],到 2022 年 12 月为止,我国的互联网用户总数已经达到了 10.67 亿,与 2021 年 12 月相比有了 3549 万的增长,而互联网普及率更是高达 75.6%。因此我国的电子商务领域正面临新的发展机会,其中以快手和抖音为代表的直播电商业务呈现出全面的增长态势,每个短视频下面都有些各种各样表达人们情感的评论文本,同时每个电商产品也饱含着大量的文本情感信息,如果能在这上千万条评论中精准获取消费者对商品方方面面的评价,就可以从产品销售方的角度对潜在客户提供购买意见,同时根据评价调整产品的营销信息、产品开发等。

情感分析,又被称为观点挖掘(Opinion Mining, OM),是自然语言处理领域中的重要分支之一^[3]。它的任务是从带有主观感情色彩的文本信息中提取人们对某

些事物的情感态度。根据文本信息处理的粒度不同，情感分析可分为篇章级^[4]、句子级^[5]和方面级^[6]。方面级情感分析（Aspect Based Sentiment Analysis, ABSA）最早由 Thet^[7]等人于 2010 年提出的，方面级情感分析包括方面词抽取和方面级情感分类两大任务。2012 年，Liu^[1]给出了观点的定义，为方面级情感分析任务的研究奠定了基础。方面级情感分析任务的目标是预测文本信息中人们对某一事件、产品、服务等特定方面的情感极性，这些情感极性可被分为积极、中性、消极三种。

近几年，由于文本信息数据量的急剧增加和计算机性能的不断提升，基于深度学习的方面级情感模型在自然语言处理领域被快速应用以后，情感分析的研究成果也慢慢出现在人们的实际应用中。

1.1.2 研究意义

当前，情感分析的研究已经渗透到多个领域。随着人们生活方式逐步从线下向线上转变，网络社交平台上发布的评论文本信息量呈爆炸式增长。不论是在传统的电商平台，如拼多多、淘宝、京东，还是抖音、快手、小红书等社交化电商平台中，用户每日发布的评论规模都相当庞大。在电商平台中，情感分析研究可以帮助消费者在购买商品前提前了解商品的详情，通过读取商品评论，消费者可以对商品有一个全方位了解，进而得出对此商品的综合评价后决定是否购买，防止出现商品虚假宣传被骗的情况；另一方面，对于商家而言，挖掘评论中的情感信息能够帮助商家了解自己的产品在当前市场的核心竞争力与不足之处，从而做出正确的决策，完善产品营销信息和品牌定位等。对于政府而言，网络舆情一直是难以干预的挑战，相关部门可以通过挖掘网络舆论中的情感色彩，判别人们对整个事件的态度，从而提前采取措施干预舆情发展，避免网络舆论达到不可挽回的地步，确保网络社会安全良好的秩序。

在众多学者探索下，作为 NLP 领域的一个分支，方面级情感分析在各领域的实际应用中发挥着重要的作用，对用户个人决策、企业产品改进以及舆情监测等领域均有重要的现实意义。

1.2 国内外研究现状

文本情感分析作为自然语言处理领域的一个核心分支，其研究目标是使用多

种技术方法,让计算机能够从文本内容中准确地识别出人的情感。方面级情感分析主要分为基于情感词典的方法、基于机器学习方法和基于深度学习的方法,近年来,随着计算机性能的提高和深度学习技术的发展,基于深度学习的方面级情感分析方法得到了广泛的应用。

1.2.1 基于规则和情感词典的方法

最早用于情感分析的方法是基于规则和情感词典的方法,该方法利用情感词典中的情感词和规则来识别文本中的情感表达,并根据一定的规则或算法对情感进行分类。所以情感词典的质量是该方法预测结果正确与否的关键,目前研究人员常用的情感词典有 WordNet^[8]、MPQA^[9]以及中文情感词典 HowNet^[10]、国立台湾大学情感词典(NTUSD)^[11]。

基于规则和情感词典的情感分析方法在进行情感的判别时,首先需要对目标评论文本数据预处理,包括停用词、标点符号、数字、特殊字符的去除、分词、词性标注等,再将情感词典中的词与评论文本中的词相对应匹配,综合语义规则,最后按照设定好的情感得分规则计算最终的情感倾向。Ding 等人^[12]提出了一种基于情感词典的分析方法,并针对评论文本中的显式与隐式两个方面进行情感极性分析。吴杰胜等人^[13]通过构造程度副词和微博词典等方式对当前情感词典进行了补充,同时考虑了文本之间的语义规则关系,将这些规则关系与情感词典相结合,实现了对微博评论文本的情感分析。

基于规则和情感词典的方法进行情感极性的判断虽然实现起来相对简单,但是这种方法过度依赖情感词典,情感词典构建者的经验丰富程度直接决定了情感词典的好坏,同时该方法需要耗费大量人力去进行情感词典和规则的构建。随着时间的推移和网络信息的更新,各种新词的涌现导致模型准确率低的问题需要通过扩充情感词典和规则来解决,且由于领域、语言、时间的不同,情感词典和规则并不通用,这就导致在跨语言、跨领域环境下,模型泛化性差。这些缺点使得基于规则和情感词典的方法未得到广泛的应用。

1.2.2 基于机器学习的方法

随着信息量的增加和人们的需求的提高,基于规则和情感词典的情感分析方法不能满足人们的需求。情感分析的研究尝试使用机器学习的分析方法得到更精

确的情感分析结果。基于机器学习的方法是利用机器学习算法从文本数据中提取特征信息，训练情感分类模型，从而实现对文本中不同方面情感的识别和分类，解决实际问题。

最早常用的机器学习情感分析方法为朴素贝叶斯^[14](Native-Bayes, NB)和支持向量机^[15](Support Vector Machine, SVM)这类监督算法。Pang 等人^[16]将电影评论文本的情感分析简化为二分类问题，创新性地使用朴素贝叶斯算法解决问题。Sharma 等人^[17]将 SVM 和 Boosting 结合，将 SVM 作为基础分类器，利用 Boosting 算法提升效果，结果表明在文本评论数据集中，该方法比单独的 SVM 分类器的效果要好。Mohammad 等人^[18]使用机器学习算法通过捕捉上下文、情感特征等信息，提出了基于方面词的特征提取算法，结合 SVM 对评论文本进行方面级情感分类。

传统的机器学习方法进行实验时至关重要的一点是特征信息和提取和分类器的选择。特征信息提取的充分程度决定了最终算法的准确率，而分类器的组合选择会产生不同的情感分类结果。尽管这种方法在多次优化调整后已经取得了相当不错的效果，但是仍然存在一些不足之处，比如该方法对特征提取工程的需求高，需要耗费大量人力资源对特征进行标注。另外，基于机器学习的方法缺乏对数据集文本语义方面的理解，且模型泛化能力有待提高。

1.2.3 基于深度学习的方法

在信息爆炸的时代，随着计算机性能的提升和数据量提高，神经网络特征提取能力和文本表示能力的强大使得当前研究往深度学习模型上拓展，深度学习模型在处理复杂文本信息时具有较好的性能，可以更加准确高效地完成情感分析任务。本文主要介绍以下四种基于深度学习的方面级情感分析方法：基于预训练模型的方法、基于外部知识的方法、基于卷积神经网络的方法、基于图卷积网络的方法。

(1) 基于预训练模型的方法

深度学习模型首先需要将文本进行向量化，并且尽可能避免文本信息的丢失。词嵌入(Word Embeddings)被广泛应用于 NLP 领域。最早的文本向量化的方法是 One-hot 表示法，但是该方法处理大规模数据和语义理解任务时存在一些明显的不足，不能适用于所有深度学习模型。因此 Mikolov 等人^[19]提出了 Word2Vec 的

方法,该方法可以将文本转化为带有局部上下文特征的向量表示方法,提高了模型计算效率和准确性,有效地将词向量表示稀疏性的问题解决。由于 Word2Vec 方法没办法关注全局信息, GloVe (global vectors for word representation)算法^[20]被提出,该算法通过构建共现矩阵,既能关注全局信息,又能关注滑动窗口的局部上下文信息。虽然 GloVe 算法在一定程度上实现了词嵌入,但该方法属于静态的词嵌入技术,并不能有效地解决一词多义的问题,也不能准确地识别文本在不同领域中词义的差异。为解决这些问题,华盛顿大学于 2018 年提出了 ELMo (embedding from language models)方法^[21],该方法利用 LSTM 模型提取上下文的语义信息,通过学习大量的语料信息,最终得到一个动态的词嵌入预训练模型,从而能够对多义词进行建模。同年 6 月,OpenAI 将 Transformer 作为模型的特征提取器,提出了生成式预训练模型 GPT (generative pre-training) ^[22],该模型采用了有监督和无监督结合的二段式训练方法,提高了提取特征的能力,然而,该模型主要关注局部上下文信息,并未充分考虑整个文档和背景知识的影响。因此,同年 10 月谷歌提出了 BERT (Bidirectional Encoder Representations from Transformers)^[23]预训练模型。BERT 模型使用了双向的 Transformer 特征提取器,实现了对上下文的双向特征抽取。该模型一经提出,便被广泛应用到各种基线模型中,其实验效果得到了业界的充分肯定和一致认可。在接下来的时间出现了各种使用 BERT 模型改进后的优秀预训练模型,Liu 等人提出的 RoBERTa 模型^[24]通过使用更大的模型参数量和更多的训练数据使实验取到了更好的效果,但同时该模型训练时间相对较长。基于 RoBERTa 模型对电脑硬件要求较高,轻量级的 BERT 模型改进版 ALBERT^[25]被提出,该模型通过词嵌入因式分解和不同层参数共享方法减少训练参数,降低内存消耗,提高模型的训练速度。

(2) 融合外部知识的方法

近年来,基于外部知识的方法在自然语言处理任务中得到了广泛的应用,外部知识在方面级情感分析中通常发挥着增强情感特征的作用,Feng 等人^[26]将大量常识性情感知知识与评论文本句子融合,提出了一种新的异构图网络 (Heterogeneous Graph Network, DHGN)来指导对话摘要的生成。Feng 等人^[27]将 16 个外部关系引入到对话总结任务中,并提出了对话话语感知会议摘要生成器。若是能将卓越的情感词典提供的外部情感知识用于具体的方面级情感分析任务中,可以使我们的实验效果更好。在情感分析任务中,外部情感知识经常被用来增强

情绪特征的表达^[28]。Baccianella 等人^[29]设计了一个词汇资源 SentiWordNet, 用于支持情感分类和意见挖掘应用。Deng 等人^[9]将实体和事件目标概念引入数据库 MPQA(Multiple-Perspective QA), 用于实体-事件级情感分析任务。MPQA 是一个基于新闻文章的多跨度深度标注数据集, 包含了来自各种来源的新闻句子 10606 个。Cambria 等人^[30]融合了常识推理、心理学、语言学以及机器学习的方法, 开发出了一种情感分析工具: SenticNet, 作为公共资源用于情感分类和意见挖掘。Liang 等人^[31]在 SenticNet 的基础上创建了一个图卷积网络, 可以根据不同的方面词充分挖掘句子中词之间的情感依赖关系。为了解决训练数据不足的问题, Ayetiran 等人^[32]将学习到的篇章级情感分析的数据特征用于实现方面级情感分类, 提出了基于注意力的联合学习方法。另一方面, 词性作为句法的基础, 对理解整个句子至关重要, 且某些词性在情感分析任务中有显著贡献。因此, 在句法依赖树中加入词性信息, 可以增强句法依赖树的句法特征信息, 从而使方面级情感分析任务达到更好的效果。

(3) 基于卷积神经网络的方法

卷积神经网络 (Convolutional Neural Network, CNN) 主要通过卷积池化等操作提取数据的局部特征, 取得了较好的结果。2008 年 Collobert 等人^[33]首次将卷积神经网络和自然语言处理结合, 提出了一个可以根据输入文本数据来预测诸多语言的模型, 取得较为理想的效果。2014 年, Kim 等人^[34]将 CNN 的输入层进行调整, 使其更适用于文本方面的特征提取, 提出了 TextCNN 模型用于文本情感分析任务, TextCNN 通过构建矩阵的方式将文本信息表达, 进而使用卷积操作进行特征识别, 实验证明 CNN 在文本情感分析的可行性。虽然 TextCNN 模型实现效果不错, 且训练速度快, 但是它所关注的文本信息有限, 很难确定每个特征的重要程度, Lai 等人^[35]提出了 TextRCNN 模型, 模型在 TextCNN 的基础上加入了循环神经网络 (Recurrent Neural Network, RNN), 重点关注每个特征的重要程度, 该模型在情感分类任务中也取得了较好的效果。在基于卷积神经网络的情感分析模型的基础上, 研究人员相继提出了 DCNN (Dynamic Convolutional Neural Network)^[36]、GCNN (Graph Convolutional Neural Networks)^[37]、VDCNN (Very Deep Convolutional Networks)^[38]等模型, 皆在情感分析任务中取得了不错的成果。汪林等人^[39]提出 CNN-BiLSTM 模型通过多级特征融合的方式, 充分挖掘和利用情感特征信息, 文章的消融实验证明了与单极、单尺度特征相比, 多级特征

融合可以获取更多的情感信息。

(4) 基于图卷积网络的方法

由于方面词和情感词之间的关系蕴含丰富的特征信息,学者们尝试将图卷积网络(graph neural network, GNN)^[40]引入自然语言处理领域,利用图卷积网络建模句法结构获取句法信息。在基于方面的情感分析任务中,对于给定的文本评论,GCN 可以根据语法距离捕获与前一个方面词相对较远的词。Sun 等人^[41]在句法依赖树的基础上构建图卷积模型,利用上下文的句法信息和单词的关联信息提高情感分析的效果。Beck 等人^[42]将门控图神经网络与输入信息融合,考虑了节点和边上信息的重要性,有效地解决了模型参数过多的问题。Wang 等人^[43]针对句子结构的复杂性和一个词的多面性问题,对依存树进行重构和剪枝,建立了以方面词为根节点的依存树结构。阳影等人^[44]提出的双通道图卷积网络的情感分类模型将情感知识融入特征信息中,分别学习句法和语义信息,充分挖掘情感知识。李帅等人^[45]提出“敏感关系集合”的概念,将其用于构造辅助句增强文本中上下文和方面词的关联,改进图卷积网络的构建。由于图卷积网络通常无法关注有序词的上下文关系,谢珺等人^[46]在模型中加入双指导注意力网络模块加强上下文信息,并验证了实验的可行性。然而,现如今大部分学者往往只对神经网络模型进行改进来提高网络的效果,忽略了句法和语义信息的增强对模型的重要性,没有专注于依赖图的构造,且深度学习模型较复杂使得模型训练时间长,容易引发过拟合现象。

1.3 论文研究内容

现如今,对方面级情感分析的研究已经非常成熟,学者在该领域模型改进方面均有重大成果。但是现有模型仍然存在对外部知识利用不充分、句法语义信息提取不完整等问题,为了进一步提升方面级情感分析模型的效果,本文对句法依赖图的构造和语义提取模块的构建进行了改进,同时加入了外部知识以提高模型的性能。具体工作如下:

(1) 在对当前用户评论数据进行方面级情感分析任务时,目前主流的方法是利用图卷积网络的方法构建模型,学者们通常对图卷积网络本身进行改进,而忽略了句法依赖树信息的提取充分程度。因此,基于句法依赖树构建的图卷积网络模型在建模时可能会导致句法信息解析不准确,语义提取不充分。基于此,本

文提出了一种基于外部知识和位置信息增强的方面级情感分析模型。该模型同时考虑句法通道和语义通道，采用 SenticNet 情感词典加权依赖矩阵来构建句法依赖树来增强句法信息，采用 GRU-CNN 网络提取语义信息，同时加入位置信息，丰富了语义特征表示，最后引入注意力机制融合句法和语义特征用于情感分类。模型通过在三个数据集上进行实验，证明模型的可行性。

(2) 由于当前互联网中网络评论大多数都是短评论，所以在判别情感极性时往往因为背景信息不足导致模型在分析短文本时效果不佳的问题。针对以上问题，本文提出了一种融合外部知识的多通道图卷积网络模型用于方面级情感分析任务，该模型分别从语法、语义的角度提取特征信息进行融合来对文本进行情感分析，增强模型对文本的理解能力。同时利用外部知识源中的上下文语义关系作为补充信息参与训练，为了充分融合不同类型的信息，模型最终通过高速网络机制信息融合模块将三个通道中的特征信息融合，最终得到模型输出结果，完成方面级情感分析的情感极性判别。实验结果表明，融合外部知识作为补充信息的多通道图卷积网络模型能充分提取文本中的特征信息，提高了模型的表现力和泛化能力，解决了情感分析过程中先验知识不足的问题。

1.4 论文组织结构

本文分为五个章节，具体内容安排如下：

第一章：绪论。本章首先概述了方面级情感分析的研究背景及其研究意义，接着深入探讨了国内外在这一领域的研究进展及主要成果。分别阐述了近些年情感词典、机器学习和深度学习在该领域的应用发展。最后介绍了本文的主要研究内容和论文组织结构。

第二章：相关理论和技术。第二章首先介绍了方面级情感分析的概念定义。然后详细阐述完成本文情感分类研究内容相关的理论和技术。主要包括词向量技术、注意力机制、依存句法分析等相关知识，为本文后续章节奠定理论基础。

第三章：提出基于外部情感知识和位置增强的方面级情感分析模型。本章首先介绍了现有情感分析模型的不足之处和改进思路方法，之后详细介绍了所提出模型的各个部分。最终通过进行实验与分析，验证了模型的有效性。

第四章：提出融合外部知识的多通道图卷积网络模型。本章首先介绍了基于外部知识构建模型的一种方法，接着介绍所提出模型的各个部分的细节，包括模

型的语义提取通道、语法提取通道和外部知识特征提取通道三个模块，同时通过实验分析，证明了模型的有效性。

第五章：总结与展望。本章总结全文所作的研究工作，分析不足同时对下一步研究方向做简要介绍。

2 相关理论和技术

本章主要介绍了论文工作中用到的相关理论和技术,首先介绍了方面级情感分析的概念,其次阐述了词向量技术的基本方法,然后重点阐述本文构建模型用到的深度学习模型基本原理,最后引入注意力机制和依存句法分析并举例说明。

2.1 方面级情感分析

传统情感分析中,篇章级情感分析判断情感极性的最小单位是整个篇章,其最终的情感是整个文章的综合情感,而句子级情感分析是分析整个句子的情感极性,与传统情感分析只关注整体情感不同,方面级情感分析着重于识别文本中对特定方面或实体的情感表达。

方面级情感分析可以帮助了解用户对特定产品、服务或话题的看法,并进一步从多个方面挖掘情感信息。例如句子“The pizza is tasty while waiter is unfriendly.”这个句子包含两个方面词,而方面级情感分析任务目标就是识别句子中的目标对象“pizza”和“waiter”并判断其情感极性。在本句中,“pizza”对应的情感态度是“tasty”,表达了积极的情感,而方面词“waiter”对应的情感态度是“unfriendly”,表达的是消极的情感。方面级情感分析可以对含有多个方面词的文本进行细粒度的情感分析,识别出句子中的每个方面并对其一一进行情感判别。方面级情感分析可以帮助了解用户对特定产品、服务或话题的看法,并进一步从多个方面挖掘情感信息。该技术在社交媒体监测、产品评论分析和市场调研等领域具有广泛应用。

2.2 词向量表示技术

由于计算机无法识别现实中的语言文本,因此在模型训练之前需要先将输入的文本转化为计算机能识别的语言,即将文本转化为数值输入。在方面级情感分析任务中,许多模型都需要以词向量作为输入。词向量表示是一种自然语言处理中的技术,用于将文本中的词语映射到实数向量空间中。在传统的文本处理中,每个词语通常使用一个独立的离散标记来表示,这样的表示方式难以捕捉词语之间的语义关系和语义信息。相比之下,词向量表示通过将词语映射到一个连续的向量空间中,使得词语的语义和语法信息可以以向量形式呈现。这样的表示方式

允许计算机更好地理解词语之间的相似性、关联性和语义含义，从而改善了自然语言处理任务的性能，如文本分类、机器翻译、情感分析等。词向量表示的一种常见方法是使用词嵌入技术，通过在大规模文本数据上进行训练，将词语映射到低维度的实数向量表示。本文主要介绍常见的三种词嵌入技术：One-hot 编码、Word2Vec、Glove。

2.2.1 One-hot 编码

One-hot 编码是一种常见的特征编码方法，是最早采用的词嵌入技术，被用于将离散的分类特征转换成二进制向量表示。在 One-hot 编码中，每个可能的取值都用一个独特的二进制向量表示，其中只有一个元素为 1，其他元素为 0。这样的编码方式可以有效地表示不同的分类取值，使得机器学习算法可以更好地处理这些特征。

举例来说，假设文本数据为“今天天气很好。”，这个文本可以被划分为四个词元，分别是[“今天”，“天气”，“很好”，“。”]。通过 One-hot 编码，我们可以将这三个单词和一个标点符号转换成以下二进制向量表示：

$$w_{\text{今天}} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad w_{\text{天气}} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \quad w_{\text{很好}} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \quad w_{\text{。}} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}$$

那么文本数据“今天天气很好。”可以被表示为如下矩阵向量：

$$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

这样，每个字取值都被表示为一个唯一的二进制向量，使得它们在计算机中可以方便地被处理和比较。在进行机器学习任务时，可以将这些编码后的向量作为特征输入到模型中，从而对这个分类特征进行有效的处理。

从上面可以看出 One-hot 编码方式的优点是实现起来非常简单，但不足之处也很明显。一方面，当数据量很大的时候，该方法的维度将非常高并且较为离散，

另一方面，该方法仅能将文本转化为向量表示，并不能提取文本中的上下文之间的信息，无法更好地完成情感分析任务。

2.2.2 Word2Vec 模型

Word2Vec 由 Google 公司于 2013 年提出的，用于将词语映射到低维度的实数向量空间。与 One-hot 编码不同，Word2Vec 是通过训练大规模文本数据，使得具有相似语义的词语在向量空间中的距离也比较接近，从而捕捉词语之间的语义关系。具体来说，Word2Vec 可以分为连续词袋模型 (Continuous Bag Of Words, CBOW)和跳词模型(Skip-gram)两种类型。CBOW 和 Skip-gram 框架结构如图 2.1 所示。

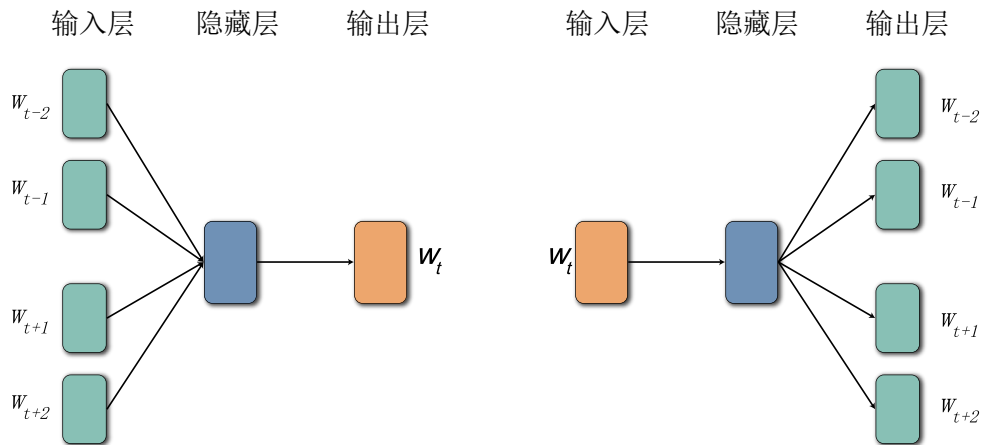


图 2.1 CBOW 模型和 Skip-gram 模型

2.2.3 GloVe 模型

GloVe 模型也是一种词嵌入技术，与 Word2Vec 类似，用于将词语映射到低维度的实数向量空间。GloVe 模型是由斯坦福大学的研究团队于 2014 年提出的，该模型通过统计全局词语的共现信息来学习词向量，捕捉了词语之间的全局语义关系。GloVe 模型实现步骤如图 2.2 所示。




图 2.2 GloVe 模型实现步骤

其步骤主要分三步，第一步，根据给定的语料库中使用滑动窗口将单词 i 和上下文 j 的出现的频率构建一个“词-上下文”共现矩阵 x 。矩阵中的元素 X_{ij} 表示在该给定的语料库中单词 i 和上下文 j 共同出现在一个滑动窗口的次数。

第二步，构建词向量和单词间共现矩阵的近似关系，计算公式如下：

$$w_i^T \bar{w}_j + b_i + \bar{b}_j = \log(X_{ij}) \quad (1-1)$$

其中 w_i^T 和 \bar{w}_j 分别最终词向量， b_i 和 \bar{b}_j 词向量的偏差。

最后，GloVe 模型在均方误差的基础上加入了权重函数构建损失函数，这个权重函数是基于词对出现的频率来定义大小的原则构造，计算公式如下：

$$J = \sum_{i,j=1}^V f(X_{ij}) (w_i^T \bar{w}_j + b_i + \bar{b}_j - \log(X_{ij}))^2 \quad (1-2)$$

$$f(x) = \begin{cases} (x/x_{\max})^{0.75} & \text{if } : x < x_{\max} \\ 1 & \text{otherwise} \end{cases} \quad (1-3)$$

GloVe 模型在学习词向量时，不仅考虑每个词语在上下文中的局部共现信息（类似于 Word2Vec 的 Skip-gram 模型），还通过全局共现矩阵统计所有词语的共现信息，进一步捕捉词语之间的全局语义关系。这使得 GloVe 在某些语义关系的表达上可能更为准确。和 Word2Vec 一样，GloVe 学习到的词向量可以用于改善自然语言处理任务的性能。GloVe 模型在训练过程中表现优秀，但是也有不足之处，模型最大的局限性就是生成的词向量是静态的，无法训练和学习文本词所在位置的信息，包含的语义特征不明显，特征信息表达不充分。基于此，研究人员发现预训练模型能很好地弥补 GloVe 模型的缺点，能够动态地训练和学习词向量语义信息。

2.2.4 BERT 预训练语言模型

广义的预训练模型是指经过大量数据训练过的模型，预训练模型包括 ELMo、BERT 等，随着 Transform 的发展，预训练模型往往特指以 Transform 为架构的预训练语言模型。该类模型同样也是经过海量数据训练后使用，包括 BERT、RoBERTa 和 ALBERT 等。在自然语言处理领域种，预训练模型的应用显著提升了许多深度学习模型的性能。本文以 BERT 为例，详细阐述预训练模型的功能和

建模方法。

BERT 是一种预训练深度双向 Transformer 模型,由 Google 在 2018 年提出,通过在大规模文本数据上进行预训练,学习到丰富的上下文相关的词向量表示。BERT 预训练模型在首次提出时,在十一项 NLP 任务中刷新了当时的记录。在此之后,尤其是方面级情感分析领域,涌现出了大量基于 BERT 的深度学习模型。因此,BERT 预训练模型被认为是一种革命性的自然语言处理技术。

BERT 模型在预训练时通过将这两个句子作为输入,并尝试预测其中一个词语的上下文,从而学习到词语在上下文中的深层表示。假设我们有一个文本数据集包含以下两个句子“猫喜欢吃鱼”和“狗喜欢跑步”。BERT 可以学习到“猫”在第一个句子中和“喜欢”、“吃”、“鱼”这些上下文词语的相关信息,以及“狗”在第二个句子中和“喜欢”、“跑步”这些上下文词语的相关信息。这样的预训练过程使得 BERT 模型学习到了丰富的句子级和词级的上下文表示,使得模型可以更好地理解和处理自然语言。如图 2.3 所示,BERT 模型主要分为输入层、编码层和输出层,其中编码层是 BERT 模型的核心,是基于 Transform 模型构建而成。

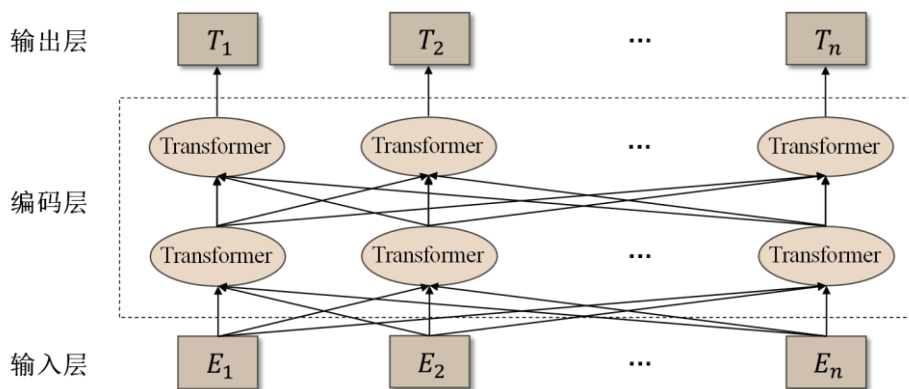


图 2.3 BERT 模型结构

1. 输入层

文本信息在输入 BERT 模型之前需进行数据预处理,即在经过词嵌入层时添加特殊标识符[CLS]和[SEP],[CLS]添加在文本序列开头,[SEP]添加在文本序列末尾,特殊标识符的添加用于在后面的分类任务中对向量信息结果进行分析,也可以为划分句子对提供依据。BERT 模型输入由三部分拼接组成,如图 2.4 所示。三部分分别为用于表示文本词位置信息的位置向量嵌入(Position Embeddings)、

判断两段文本先后顺序的段向量嵌入 (Segment Embeddings) 和用于表征每个文本词信息的词向量嵌入 (Token Embeddings)。

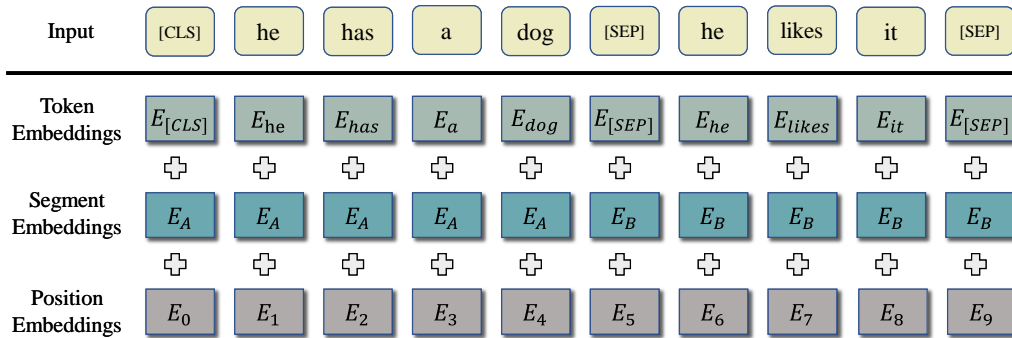


图 2.4 BERT 模型结构

2. 编码层

BERT 预训练语言模型的核心部分是基于 Transform 模型的编码层，Transform 模型由谷歌于 2017 年发布，模型的结构如图 2.5 所示。BERT 编码层是由 Transform 模型的编码器 (encoder) 构成，编码器在多头注意力机制上结合了残差连接 (Residual Connection)、层归一化 (Layer Normalization)、前向反馈传播 (Feed forward) 三种操作。其中，残差连接的主要功能是将模块的输入数据与输出数据结合起来，从而生成下个模块的输出结果。层归一化的作用是将网络节点标准化。残差连接和层归一化的目的是使网络简单化，降低训练难度，同时减少梯度消失的情况发生。前向反馈传播则是将本文特征向量做线性变换。

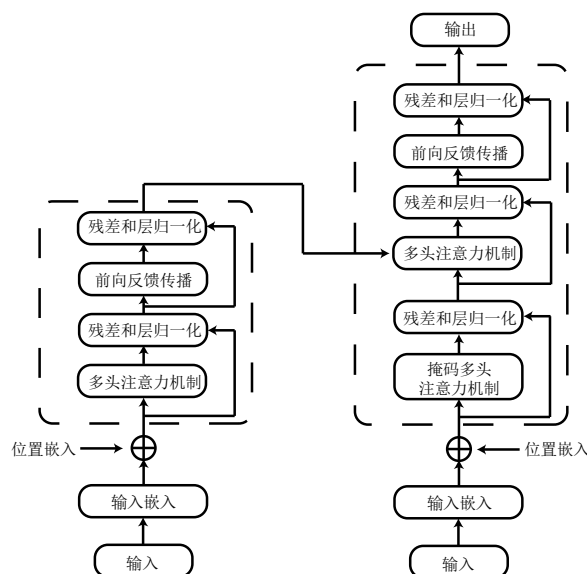


图 2.5 Transformer 模型结构

3. BERT 预训练过程

BERT 在预训练过程阶段中还包括两个任务，分别是掩码语言模型（Masked Language Model, MLM）和下一句预测（Next Sentence Prediction, NSP）。由于本文使用 BERT 模型只为获取富含更多信息的词向量表示，BERT 模型训练过程只需要完成掩码语言模型任务，因此本文只介绍掩码语言模型。

掩码语言模型的目标是对输入句子中的 15% 的单词使用掩码符号[MASK]进行遮蔽，然后使用 Transform 模型基于上下文信息对遮蔽的地方进行预测，将[MASK]遮蔽的单词还原，类似于完形填空。为了使模型效果更好，研究人员设计了遮蔽规则使模型学习到更丰富的知识，具体的遮蔽规则为：（1）遮蔽词的 80% 为[MASK]，（2）遮蔽词的 10% 用随机词替换，（3）最后 10% 保持不变。掩码语言模型能够使 BERT 不受单向语言模型所限制。

虽然 BERT 模型训练时硬件要求较高且耗费时间较长，但是在预训练完成后，BERT 模型可以直接在下游任务上进行微调，完成情感分析任务。通过微调，BERT 可以根据具体任务的特点进一步优化模型参数，使得在特定任务上表现更加优秀。由于 BERT 具有深层双向的 Transformer 结构，在自然语言处理任务中取得了令人瞩目的性能，自 BERT 模型提出以来，预训练模型成为了一个重要的研究方向，成为了自然语言处理领域的一个重要里程碑。

2.3 神经网络模型

2.3.1 循环神经网络及其变体

循环神经网络是一类具有短期记忆力的神经网络，最早是于 1982 年由 Saratha Sathasivam 提出的霍普菲尔德网络，但是由于当时的计算机性能的限制使得网络难以实现和发展，因此该网络当时没有得到广泛应用。后来更有效的循环神经网络被提出，可以处理文本的序列信息，因此该网络被大量应用在文本情感分析任务中。RNN 的具体结构如图 2.6。

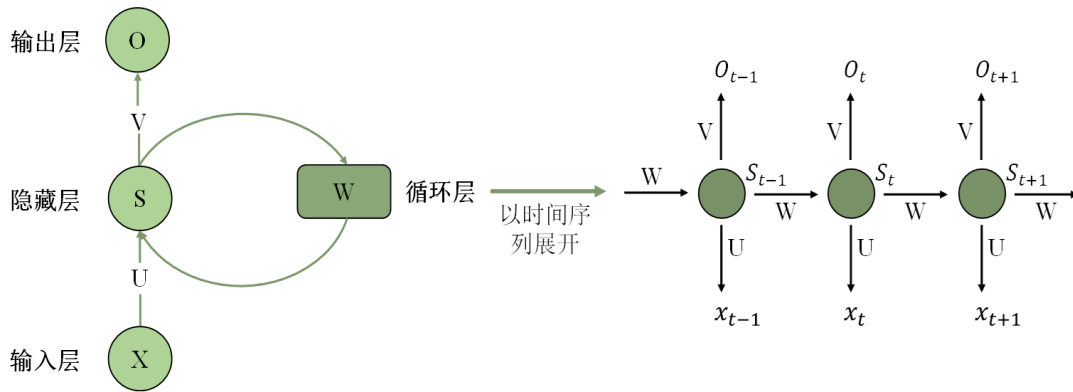


图 2.6 循环神经网络结构图

图中左侧为一个 RNN 的单元结构，右侧为 RNN 的按时间序列的整体展开图，其中 RNN 的单元结构包括输入层、隐藏层、输出层和循环层。途中 x 、 s 、 o 分别代表各层的向量表示，每个单元结构都可重复使用。在展开图中，中间隐藏层的向量表示 S_t 的值由自身输入的 x_t 和前一段保留的隐藏层信息 S_{t-1} 组成。隐藏层 S_t 的计算公式如下：

$$S_t = f(U(x_t) + W \cdot S_{t-1}) \tag{1-4}$$

$$O_t = g(VS_t) \tag{1-5}$$

在 t 时刻时， U 代表输入层 x_t 到隐藏层 s_t 的权重矩阵； w 是以上一时刻的值，为基础的权重矩阵， f 是激活函数。 O_t 为 t 时刻的输出值， v 代表权重矩阵， g 是激活函数。

然而，传统的 RNN 在处理长序列数据时常面临梯度消失和梯度爆炸等问题。这导致传统 RNN 难以捕捉长期依赖关系，限制了其在实际任务中的性能。针对上述问题，研究人员提出了多种改进算法来克服 RNN 的局限性。Hochreiter 等^[47]提出了长短时记忆网络 (Long Short-Term Memory, LSTM)。LSTM 作为 RNN 的变体，它在解决传统 RNN 中的梯度问题方面有重要意义，具有更强大的长期记忆能力。LSTM 引入了三个关键的门控单元：输入门 (Input Gate)、遗忘门 (Forget Gate) 和输出门 (Output Gate)。这些门控单元允许 LSTM 在每个时间步选择性地输入、遗忘和输出信息，从而有效地控制信息的流动。LSTM 结构如图 2.7 所示




图 2.7 LSTM 内部结构图

LSTM 的结构和循环神经网络很类似，在图中，方框代表神经网络的层，每个层由权重矩阵、偏置矩阵和激活函数组成。圆圈表示对矩阵的每个值进行加法或乘法运算，箭头表示数据在计算过程中的流动方向。LSTM 模块间的各个门计算公式如下：

$$i_t = \sigma(W_i[x_t \oplus h_{t-1}] + b_i) \tag{1-6}$$

$$f_t = \sigma(W_f[x_t \oplus h_{t-1}] + b_f) \tag{1-7}$$

$$o_t = \sigma(W_o[x_t \oplus h_{t-1}] + b_o) \tag{1-8}$$

$$\tilde{c}_t = \tanh(W_c[x_t \oplus h_{t-1}] + b_c) \tag{1-9}$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \tag{1-10}$$

$$h_t = o_t \otimes \tanh(c_t) \tag{1-11}$$

其中用 f 、 i 、 c 和 o 分别表示遗忘门、输入门、记忆单元、输出门， f 用于控制过去信息的遗忘， i 用于控制新信息的输入， o 用于控制输出的信息， \oplus 表示向量的拼接， \otimes 表示向量的点乘运算， w 表示权重， h 表示 LSTM 模型的隐藏状态， x 表示输入， b 表示偏置。 σ 为 sigmoid 函数， \tanh 为双曲正切函数。

LSTM 通过细胞状态的更新和选择性记忆，成功解决了梯度问题，并具备强大的长期记忆能力，使得它在处理序列数据时表现出色。但是 LSTM 每个模块的 4 个神经网络层的复杂结构可能导致计算成本较高。为了简化 LSTM 并减少参数数量。有研究人员提出了门控循环单元(Gated Recurrent Unit, GRU)。GRU 与 LSTM 类似，同样引入了门控机制，但将输入门和遗忘门合并为更新门 (Update Gate)，并采用重置门 (Reset Gate) 来控制历史信息的遗忘。这种结构的改变使

得 GRU 不仅具备了与 LSTM 相似的长期记忆能力，同时模型参数较少，计算成本更低。GRU 结构如图 2.8 所示




图 2.8 GRU 内部结构图

GRU 的输入输出结构可以拆解成三个关键部分：更新门（Update Gate）、重置门（Reset Gate）和候选隐藏状态（Candidate Hidden State）。具体 GRU 实现公式如（2-13）~（2-15）所示

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (1-12)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (1-13)$$

$$\hat{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (1-14)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \hat{h}_t \quad (1-15)$$

其中 r_t 和 z_t 分别是重置门和更新门的计算函数， σ 和 \tanh 为激活函数，作用是将输出取值范围控制在 $[0, 1]$ 之间， h_{t-1} 表示 $t-1$ 时刻的隐含信息， x_t 表示当前 t 时刻的输入信息， $1 - z_t$ 表示上一时刻保留的信息， W_z ， W_r ， W_h 表示权重矩阵， b_z ， b_r ， b_h 表示偏置参数。

GRU 在处理序列数据方面表现出色，被广泛应用于自然语言处理、时间序列分析、音频视频处理等领域，为 RNN 的发展带来了新的可能性。由于其高效和强大的性能，GRU 成为了 RNN 的重要变体之一。在一些资源受限的情况下，GRU 可能是一个更具吸引力的选择，但在某些特定任务上，LSTM 可能仍然是更好的选择。因此，选择 GRU 还是 LSTM 取决于具体问题和应用场景。

2.3.2 卷积神经网络及其变体

(1) 普通卷积神经网络

卷积神经网络是一种特殊的深度学习模型，最早用于从图像中自动提取有用的特征来实现高效的图像处理和识别。后来被成功地应用于文本处理领域，如文本分类和情感分析。在文本情感分析中，CNN 能够捕捉文本中的局部特征，从而有效地识别文本的情感倾向。CNN 基本结构如图 2.9 所示。

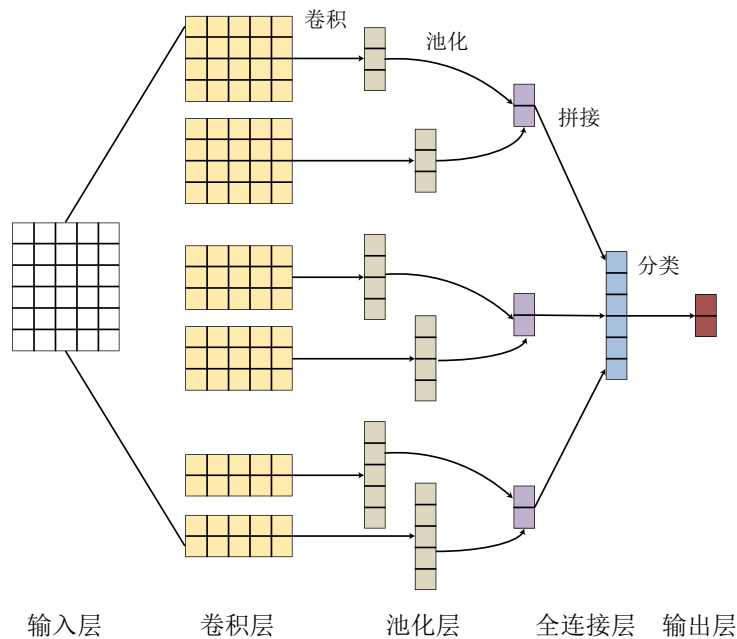


图 2.9 卷积神经网络结构图

卷积神经网络的主要组成部分包括卷积层、池化层、激活函数和全连接层。卷积层的主要作用是从输入数据中提取特征。池化层用于降低特征图的尺寸，减轻计算负担，同时保留主要特征。激活函数通常被应用在卷积层和全连接层之间，用于引入非线性特性，使得神经网络可以学习复杂的模式和关系。全连接层的主要作用是将高维的特征映射到低维的空间中，并通过学习特征之间的关系，实现最终的分类或回归任务。

由于卷积神经网络具有提取局部特征，从而有效地识别文本的情感倾向的作用，因此现今的许多方面级情感分析模型都有 CNN 的身影。在文本情感分析领域，CNN 扮演着不可或缺的角色，发挥着关键的作用和重要性。通过将 CNN 这一强大的神经网络模型应用于文本数据，我们能够突破传统方法在特征提取和

语义理解方面的限制，从而实现更精准、高效的情感分析。

(2) 图卷积神经网络

图卷积神经网络（Graph Convolutional Neural Networks, GCN）是卷积神经网络的一种变体，是专门用于处理图数据的深度学习模型。传统的卷积神经网络主要适用于处理规则的网格结构数据，而 GCN 则针对非规则的图形数据的结构和特性进行优化。GCN 能够在图上进行信息传播和特征聚合，考虑节点之间的关系，以适用于节点之间具有连接关系的图结构数据。近年来，在方面级情感分析领域中句子语法结构分析广泛应用，各种与图卷积神经网络相关的方面级情感分析模型涌现出来，尤其是与节点和图分类相关的模型，一般都是由图卷积神经网络进行构造学习。图 2.10 直观地展示了 GCN 的计算步骤。

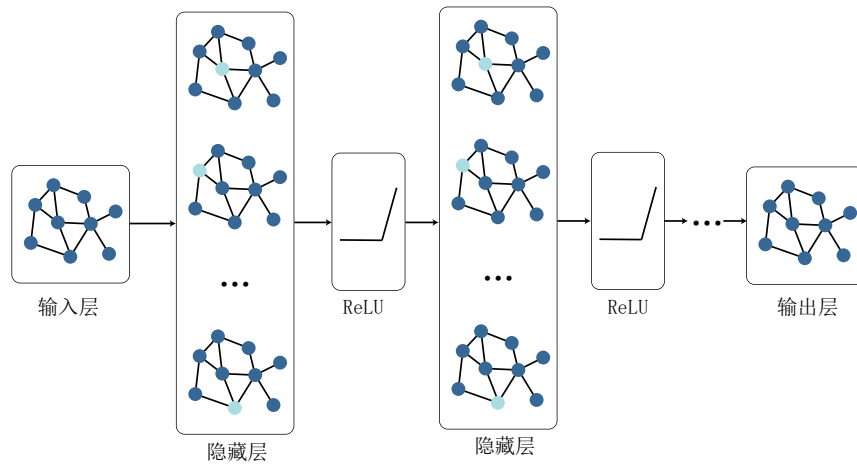


图 2.10 图卷积神经网络结构图

图卷积神经网络的主要思想是将节点及其邻居节点的特征进行聚合，从而获取更丰富的上下文信息，具有很强的学习特征能力。图卷积神经网络的核心是卷积操作，这种操作是在图的节点上进行的。其计算公式如下：

$$\mathbf{H}^{(L+1)} = \sigma\left(\mathbf{D}^{-0.5} \mathbf{A} \mathbf{D}^{-0.5} \mathbf{H}^{(L)} \mathbf{W}^{(L)}\right) \quad (1-16)$$

其中， \mathbf{D} 为对角度数矩阵， \mathbf{A} 为归一化的邻接矩阵， $\mathbf{H}^{(L+1)}$ 表示节点在第 $L+1$ 层经过卷积转换后的向量。 $\mathbf{W}^{(L)}$ 表示第 L 层的参数矩阵， σ 表示激活函数。

图卷积神经网络在 NLP 领域的应用主要集中在处理具有文本和语言关系的数据，如文本分类、命名实体识别、句法分析等。在文本情感分类任务中，GCN 可以将每个词或句子视为图中的一个节点，并考虑它们之间的语义关系。通过构

建一个基于语义关系的图，可以使用 GCN 来捕捉词汇之间的依赖关系，从而提升文本情感分类的性能。

2.4 注意力机制

注意力机制起源于神经科学领域，它是一种模仿人类视觉和认知系统的方法，通过对特定信息的选择性处理，使系统能够在处理大量信息时集中注意力于关键部分。然而，随着深度学习技术的进步，注意力机制在更多领域被广泛研究和应用。最初，注意力机制应用在计算机视觉任务领域中，尤其是在图像分类和目标检测任务上。其后，注意力机制被学者们引入到自然语言处理领域，取得了显著的成果。在自然语言处理中，注意力机制的主要目标是使模型能够在处理长文本时更加有效地关注关键信息，从而提升模型的性能和泛化能力。

注意力机制用于模型在处理序列数据时集中关注输入中的相关部分，首先，计算出每个输入位置的注意力权重。然后，使用计算得到的注意力权重对输入进行加权求和，以产生模型关注的加权输入，得到最终结果。注意力机制的计算公式表示如下：

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T)V \quad (1-17)$$

其中， Q 代表查询 (Query) 向量， K 、 V 分别代表键-值(Key-Value)向量集合，在计算时， Q 作为模型的输入，与每个向量 K 进行相关性计算，将计算得到的标量通过 softmax 函数归一化，得到注意力权重，最后通过注意力权重和 Value 相乘得到最终结果，其计算过程如图 2.11 所示。

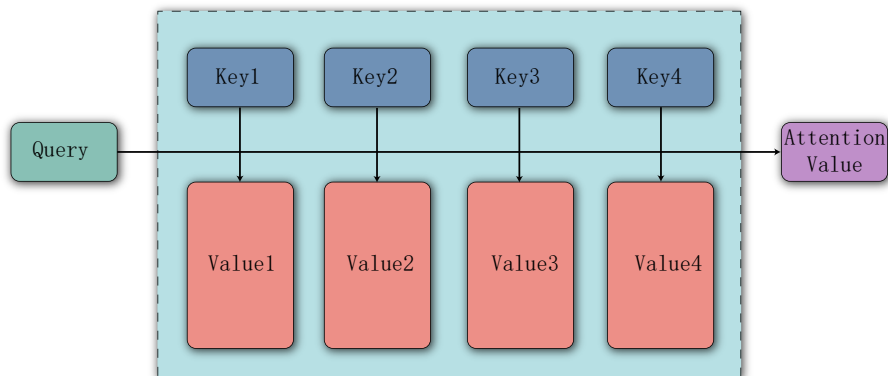



图 2.11 注意力机制计算流程

在方面级情感分析任务中，通过注意力机制，模型能更准确地识别出与某一特定方面相关联的情感信息，从而提升情感分类的准确率。同时，注意力机制能使模型能够关注不同部分的不同方面，解决信息冗余和多样性等问题，从而使模型更具有适应性和解释性。

2.5 依存句法分析

依存句法分析（Dependency parsing）也叫依存关系分析或依存结构分析，其目标是分析句子中单词之间的依存关系，并构建出句子的依存句法结构。依存句法分析起源于语言学和计算语言学领域，其背后有着深厚的理论基础。20 世纪初，语言学家开始探讨词语之间的依存关系，发展出了不同的句法理论，如依存语法、生成语法等。随着计算机技术的发展，依存句法分析逐渐成为自然语言处理的研究热点之一。近年来，随着神经网络等技术的兴起，依存句法分析取得了重要进展。

依存句法分析关注的是单词之间的从属关系，将句子中的每个单词视为一个节点，并通过有向边表示单词之间的依存关系，从而形成一个依存句法图。如图 2.12 所示，以句子“The food is delicious but the service is poor.”为例，图中带方向的弧线表示依存关系，关系的支配成分为有向弧的发出点，被支配成分为有向弧的指向点，而在有向弧上，标注的标签表示单词间的依存关系类型，例如单词“food”是单词“delicious”的名词性主语(nominal subject)，关系标注为“nsubj”，句法依存图中不仅表明了单词之间的关系，还将单词的词性、从句类型一一标注，例如“DT”、“NN”等。



2.12 依存句法图

文本中词语之间的依存关系是普遍存在的。在本文研究工作中涉及依存关系的构建，会使用一些分析工具。目前常用的获得依存关系工具有 Stanford CoreNLP^[48]、LTP^[49]、Python 文本预处理库 SpaCy^[50]等。

2.6 本章小结

本章主要梳理了方面级情感分析任务中涉及的理论和技术。首先介绍了方面级情感分析的基本概念，接着对词向量技术进行详细的阐述。随后在下一节介绍了相关神经网络模型的原理，其中包括循环神经网络及其变体、卷积神经网络及其变体等，在循环神经网络部分，主要讲述了 CNN、LSTM 和 GRU 的原理；而卷积神经网络部分则详细介绍卷积的原理和图卷积神经网络。最后简要阐述注意力机制、句法依存关系的原理，为下一步模型的构建奠定了基础。

3 基于外部知识和位置信息增强的方面级情感分类模型

本章以方面级情感分析中的分类任务为研究方向,旨在判别文本中特定方面的情感极性。由于图卷积网络模型可以结合句法依存关系处理文本数据,因此被广泛用于严谨语法结构文本的信息提取,并取得不错的实验效果。然而,现有的大多数研究都集中在基于句子本身挖掘依赖树的上下文词到方面词的依赖性,而没有使用太多与文本相关的外部知识。此外,图卷积网络提取特征时往往会忽略方面词和上下文之间的相对位置关系,使得模型对于上下文语义提取不充分。基于此,本文提出了一种基于外部知识和位置信息增强的方面级情感分析模型,模型在进行情感分类任务时,能有效地将语法特征信息、外部知识以及方面词和上下文的位置信息融合,提高了情感极性判别的准确率。

3.1 任务定义

方面级情感分析是一种文本分析任务,其目标是判别特定目标词的情感倾向。其可以被定义为:给定一个包含 n 个上下文单词和 m 个方面单词的句子,用 $S = \{w_1, w_2, \dots, w_{i+m}, \dots, w_{n-1}, w_n\}$ 表示句子,用 $Aspect = \{w_1, w_2, w_{i+1}, \dots, w_{i+m-1}\}$ 表示该文本中包含的目标方面词, $Aspect$ 是上下文词的子集序列,可以是单个单词或短语。方面级情感分析的目的就是将评论文本 s 中给定的目标方面词 $w_i \in Aspect$ 的情感极性 y_i 判别出来。情感极性的集合 $y_i \in \{\text{积极}, \text{消极}, \text{中立}\}$ 。例如在“这款笔记本价格昂贵,但功能强大。”中,包含“价格”和“功能”两个目标方面词,其中“价格”的观点词是“昂贵”;而“功能”对应的观点词是“强大”,两者包含相反的情感极性。对于包含多个方面词的文本,简单的句子级情感分析不能够准确地解释该文本包含的情感,因此需要更加细粒度的分类任务——方面级情感分析。

3.2 KL-GCN 模型框架

本节中将介绍 KL-GCN 模型的结构。该模型主要由两部分组成,一部分是基于 GRU-CNN 的语义信息提取部分,该部分通过加入位置权重公式将方面词和上下文之间的位置信息融入词向量,进而输入 GRU-CNN 网络中提取语义信息;另一部分是基于外部知识的句法信息提取部分,首先构建词性矩阵以充分考虑否定词、程度词和其他影响句子情感表达的词对情感分类的影响,然后,使用外部

情感词典构建情感得分矩阵来突出情感单词的权重，以句法依存图生成的邻接矩阵作为语法编码，将 Bi-LSTM 层的输出向量作为初始节点，最终获取丰富句法特征，最后通过基于注意力机制的特征融合层将两种特征信息进行融合，并得到注意力权值，最后输出情感极性。图 3.1 展示了 KL-GCN 的整体网络结构。




图 3.1 KL-GCN 整体网络结构图

3.2.1 输入层

首先要将其变成计算机可以理解的词向量表示形式，由于 BERT 模型在大规模文本语料上进行预训练，学习了大量的语言知识和语义表示，所以使用 BERT 模型可以获得准确的词向量表示。在基于外部知识的句法信息提取部分，对于给定的文本 $S = \{w_1, w_2, \dots, w_{i+m}, \dots, w_{n-1}, w_n\}$ ，使用 BERT 预训练模型获得词向量矩阵 $W^{n \times d_{bert}}$ ，矩阵中的每一行为一个单词低维向量表示，其中 n 为文本单词的个数， k

为目标方面词的单词个数, d_{bert} 为词嵌入向量的维度。

在方面级情感分析任务中, 与目标方面词的情感词往往在其附近, 为了使模型能够重点关注目标方面词附近的词语, 在基于 GRU-CNN 的语义信息提取部分的词嵌入模块添加一个位置函数, 使得离目标方面词越近的上下文被赋予的权重越大。位置权重公式如下所示:

$$p_i = \left(1 - \frac{|i - avg|}{n}\right)^t \quad 1 \leq i \leq n \quad (2-1)$$

$$avg = \left\lfloor \frac{s + e}{2} \right\rfloor \quad 1 \leq s \leq e \leq n \quad (2-2)$$

其中, 句子长度为 n , s 为句子中目标方面词开始的位置, 而 e 表示句子中方面词结束的位置。 t 为超参数, t 越大, 方面词附近语句的影响越大。位置信息增强词向量可表示为:

$$Y_i = p_i x_i \quad (2-3)$$

其中, x_i 表示输入句子表征 x 中第 i 个词的表示向量。

3.2.2 语义提取层

为使模型能够提取包含位置信息的语义信息, 在语义提取层中, 将位置增强词向量 Y_i 作为语义提取层的输入, 使用 GRU 提取序列语义信息, 然后通过 CNN 提取局部上下文信息。由于本文使用的数据集数据量较小, 首先使用参数数量较少的 GRU 网络来获取文本向量的序列语义信息。计算公式如下所示:

$$h_i = gru(h_{i-1}, Y_i) \quad (2-4)$$

$$z = [h_1, h_2, \dots, h_n] \quad (2-5)$$

其中, GRU 表示 GRU 网络, h_i 表示在 i 时刻的隐藏状态向量, z 为位置增强词向量输入 GRU 网络后得到的最终结果, n 为句子长度。

语义提取层部分使用 GRU 和 CNN 分别获取时序信息和局部上下文信息, 两者互为补充, 保证了语义信息的完整性。在 CNN 网络部分, 模型通过对文本使用一维卷积操作, 使用卷积核在句子的二维矩阵的整行上滑动, 获得句子局部上下文特征。CNN 的输入为文本序列表示 $z = [z_1, z_2, \dots, z_n]$, 卷积核矩阵 $u \in R^{d_{bert} \times k}$ 是可学习参数矩阵, 其中 k 为窗口大小, d_{bert} 为 BERT 词向量的维度, CNN 通

过卷积核与每个子序列分别进行卷积，得到句子局部特征。卷积操作公式如下所示。

$$c_i = f(u \cdot z_{i:i+k-1} + b) \tag{2-6}$$

其中， f 为激活函数， \cdot 代表内积运算， $z_{i:i+k-1}$ 表示句子中第 i 个词到第 $i+k-1$ 个词组成的局部特征矩阵。在 CNN 处理过程中，对整个句子序列进行该卷积操作，即可得到特征映射 $C_i = [c_1, c_2, \dots, c_n]^T$ ， $C_i \in R^n$ 。

3.2.3 外部知识嵌入模块

在传统的图卷积网络的依赖图构建过程中，对于单词之间的依赖关系都是同等处理，依赖关系的重要程度没有区分，并且没有使用太多与之相关的外部情感知识。为了能够将外部情感知识融合从而提高模型的句法提取能力，利用这些依赖信息，本文首先基于单词之间的依赖关系构建依赖矩阵，然后对矩阵添加词性信息和情感词典的外部知识来重构矩阵，进而在输入图卷积网络时能够提取到更丰富的特征信息。

(1) 依赖矩阵的构建

在构建句法依赖矩阵之前，首先需要提取文本的句法结构信息。本文使用斯坦福大学自然语言处理小组提出的 Stanford CoreNLP^[48]来进行依存句法图的构建，该句法分析器能够充分利用依赖关系和标签的信息，从而在依存句法图的构建上有较好的表现。依存句法图构建完成后，单词节点之间的依赖关系就能以邻接矩阵的形式储存。图 3.2 展示了评论文本“ The mouse buttons are hard to push. ”的句法依存图。




图 3.2 句法依存图

从图中可以看出，目标方面词“mouse buttons”对应的情感词是“hard”，两者

之间的依赖关系是“nsubj”。依存句法图定义为 $G=(V,E)$ ，其中 V 代表着文本中的每个单词的集合，在邻接矩阵中，这些单词代表着矩阵中的每一个节点。 E 代表依存句法图中的依赖关系边的集合，包括“det”、“compound”和“nsubj”等。最终我们依据依存句法图 G 来创建一个依赖矩阵 $A_{ij} \in \mathbb{R}^{n \times n}$ 。

$$A_{ij} = \begin{cases} 1, & \text{if } a_i \text{ and } a_j \text{ have dependences} \\ 0, & \text{other} \end{cases} \quad (2-7)$$

在矩阵中，行和列都是输入文本的每个单词，由公式(3-7)可以看出，矩阵中只有“1”或者“0”， a_i 和 a_j 代表着单个词，当 a_i 和 a_j 有依赖关系时，矩阵中代表两个节点的空填为“1”，反之则为“0”，另外由于单词和本身也存在关联，因此该邻接矩阵是对角线为1的稀疏矩阵。

(2) 创建情感得分矩阵

由于存在大量与文本相关的外部知识还未应用于当前的情感分析模型中，并且外部知识的使用有助于模型能更好的理解文本的句法结构信息。因此通过添加词性信息和情感词汇的外部知识重构句法依赖矩阵能够充分提高对句法依赖信息的利用率，提高情感判别的准确性。

SenticNet5 是一个知识库和情感分析工具的集合，结合了常识推理、心理学、语言学和机器学习。在 SenticNet5 中，在越是积极的概念词，情感值越接近 1，而越是消极的概念词，情感值则接近-1。SenticNet5 在增强情感表征学习方面表现出色，因此为了更好地捕捉单词之间的相关性，我们首先通过结合 SenticNet5 的情感评分来对句子中的每个词语 a_i 进行分析，为它们分配相应的情感分数 $Sentic_{a_i}$ 以创建情感得分矩阵 S_{ij} ，计算公式为：

$$S_{ij} = Sentic_{a_i} + Sentic_{a_j} \quad (2-8)$$

其中， a_i 和 a_j 表示文本中的单词，且 $i, j \in [1, n]$ 。 $Sentic_{a_i}$ 和 $Sentic_{a_j}$ 分别是情感词典赋予单词 a_i 和 a_j 的情感分数， $Sentic_{a_i} \in [-1, 1]$ ，并且当 $Sentic_{a_i} = 0$ 时，表示单词 a_i 是中性词或不存在。由公式 3-8 可知，两个依赖单词之间的情感信息是由他们的情感得分之和得出。在本章的实验中，我们从 SenticNet5 中提取了 39,891 个单词及其情感得分，其中，词典中部分文本词及其相应的情感得分如表 3.1 所

示。

表 3.1 部分文本词及其相应的情感得分

文本词	$Sentic_{a_i}$
Great	0.875
Romantic	0.928
Wonderful	0.805
Angry	-0.860
Terrible	-0.900
Abominable	-0.950

(3) 创建词性矩阵

考虑评论文本中否定词、程度词等对目标方面词情感表达的影响，以及情感词汇库中词的数量不足的问题，在创建情感得分矩阵的同时增加一个词性矩阵来帮助解决依赖关系构建不充分的问题。首先从实验使用的三个公开数据集中分别抽取了 100 条评论，并对每条评论中的意见词词性进行了统计分析。词性统计如图 3.3 所示。

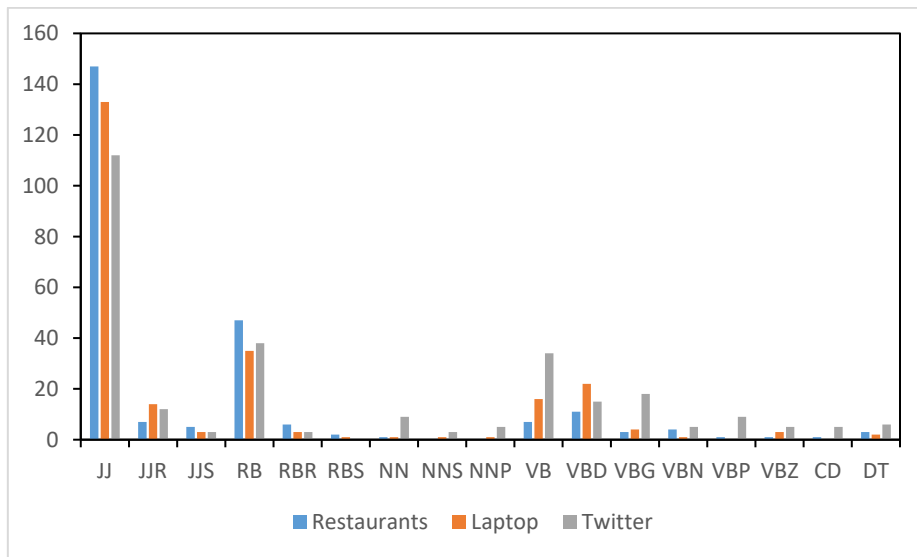


图 3.3 词汇统计图

基于图 3.3 中的词性统计，确定词性集 $P=[\text{adjectives (JJ, JJR, JJS), verbs (VB, VBD, VBG, VBN, VBP, VBZ), adverbs(RB, RBR, RBS)}]$ 。构建词性矩阵时，当单

词 a_i 或 a_j 的词性包含于词性集 P 且 $Sentic_{a_i}$ 和 $Sentic_{a_j}$ 均大于 0 时, 则两节点在词性矩阵 p_{ij} 中存在正向关系, 即 $P_{ij} = 1$, 当单词 a_i 或 a_j 的词性包含于词性集 P 且 $Sentic_{a_i}$ 和 $Sentic_{a_j}$ 均小于 0 时, 则 $P_{ij} = 0$, 其他情况下, P_{ij} 满足以下公式:

$$M = MAX \left(\left| S_{a_i} \right| \geq \left| S_{a_j} \right| \right) \quad (2-9)$$

$$P_{ij} = sign(M) \quad (2-10)$$

(4) 构建外部知识矩阵

在情感得分矩阵和词性信息矩阵的构建基础上, 将最初的依赖矩阵结合以获得更丰富的句法信息, 从而得到融合情感得分和词性信息的外部知识矩阵 D_{ij} , 公式如下:

$$D_{ij} = A_{ij} * (L_{ij} + P_{ij} + \Delta) \quad (2-11)$$

其中, $*$ 为矩阵相乘, Δ 为补充矩阵, 其目的是保证矩阵在相乘运算过程中避免得到 0 导致原始依赖矩阵结构的改变。

3.2.4 图卷积网络层

图卷积网络能够更好地学习单词依赖关系, 并处理数据的空间特征。在构建依存句法图后, 将其作为图卷积网络的输入, 有助于提取更丰富的句法特征信息。在本文模型的图卷积网络层计算过程中, 将外部知识矩阵作为语法编码, 并以 Bi-LSTM 层的输出向量 $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$ 为图卷积网络层的原始节点特征, 计算公式如下:

$$H^M = \sigma \left(\sum_{j=1}^n D_{ij} W^l h_i^{l-1} + b^l \right) \quad (2-12)$$

其中, 第 1 层的权重 W^l 和偏置 b^l 都是可以训练的参数, σ 为 ReLU 激活函数, D_{ij} 为上节构建好的外部知识矩阵。最终得到该图卷积网络层的输出记为 $H^M = \{h_1^M, h_1^M, \dots, h_n^M\}$ 。

3.2.5 特征融合层

本文中的语义提取层和图卷积网络层分别提取到的语义信息和句法信息并不相同，如何有效的将这两种特征进行融合是模型的关键部分。大多数方面级情感任务模型只是简单的拼接将特征信息堆叠，在特征融合过程中无法将前面提取到的语义信息和句法信息进行深层次的挖掘。与普通拼接不同，本文使用基于注意力机制的特征融合层对上下文语义特征和外部知识嵌入的句法信息进行提取，得到注意力权重后最终得到融合特征。

注意力机制能将文本中重要的词权重值提高，并忽略对情感判别没有帮助的信息。例如在句子“The laptop is great.”中，“laptop”为目标方面词，“great”为观点词，注意力机制就会将更多权重分配给“great”，同时编码“laptop”信息于向量中。在本文的特征融合层中， Q 为语义提取层提取到的语义信息向量， K 为GCN输出的句法信息向量， v 代表两者拼接的向量。具体的计算过程可分为以下几个阶段：

(1) 计算 Q 和 K 的相似度，公式如下所示：

$$s = F(Q, K) = \frac{Q \cdot K^T}{\sqrt{d_k}} \quad (2-13)$$

其中 s 为通过计算得出的相似度。

(2) 对上述公式得到的 s 进行数值转换，通过使用 softmax 函数突出关键元素的权重值。计算公式如下：

$$W = \text{softmax}(s) \quad (2-14)$$

(3) 依据(2-14)公式得到的权重系数 W 对关键字权重 V 进行矩阵乘法，计算公式如下：

$$\text{Attention}((K, Q), V) = W \cdot V \quad (2-15)$$

3.2.6 输出层

KL-GCN模型采用全连接层作为输出层进行情感判别。全连接的输入是带有融合特征的注意力层的输出向量 O ，采用 softmax 分类函数对全连接层的输出向量进行归一化处理，最终得到模型预测结果 \hat{y} 。计算公式如下：

$$\hat{y} = \text{softmax}(WO + b) \quad (2-16)$$

其中， w 代表权重矩阵， b 代表偏执参数。模型的输出向量 \hat{y} 是一个 1×3 的向

量，维度的值分别表示情感类别（积极、消极、中性）的概率，该任务最终的输出 Y 则选取数值最大的类别，公式如下：

$$Y = \arg \max(\hat{y}) \quad (2-17)$$

KL-GCN 使用 Adam 更新参数，选择最小化交叉熵损失函数来优化模型，损失函数的计算公式如下：

$$loss = -\sum_{i=1}^N \sum_{j=1}^C y_i^j \log \hat{y}_i^j + \lambda \|\theta\|^2 \quad (2-18)$$

其中， N 代表训练集总量， C 代表情感类别数量， y 为数据的真实标签， \hat{y} 为预测标签， $\lambda \|\theta\|^2$ 为交叉正则， λ 为正则系数， θ 为模型参数。

3.3 实验与分析

3.3.1 实验数据集与评价指标

为验证 KL-GCN 模型的有效性，本文使用了 SemEval2014 Task^[51]的餐馆评论（Restaurant）和笔记本评论（Laptop）以及 Acl-2014-short data 中的 Twitter^[52]短文本评论这三种最广泛使用的英文数据集进行实验分析。数据集中每条评论文本的情感极性都由积极、消极、中性组成，分别用 1, -1, 0 表示。Restaurant 评论数据集包含对餐馆食物品质、餐厅价格以及餐馆服务等目标方面的评论。Laptop 评论数据集包含了对笔记本电脑的性能、质量、价格、使用体验、售后服务等方面的评论。Twitter 数据集包含人们对公共事物发表的评论，共有六千多条，大部分评论的目标方面词的情感极性为中性且数量只有一个，因此情感分类难度要比 Restaurant 和 Laptop 数据集大。三种数据集的训练集和测试集的分布数量见表 3.2 所示。

表 3.2 数据集统计

数据集	积极		中性		消极	
	训练集	测试集	训练集	测试集	训练集	测试集
Laptop	976	337	455	167	851	128
Restaurant	2164	727	637	196	807	196
Twitter	1507	172	3016	336	1528	169

表 3.3 中展示了 Restaurant、Laptop 以及 Twitter 数据集的一部分样例，每条评论中包含评论文本、目标方面词和方面词对应的情感极性。

表 3.3 数据集样例

评论文本	方面词	情感极性
The driver updates don't fix the issue, very frustrating.	driver updates	N
The food is usually good but it certainly isn't a relaxing place to go.	food, it	(P, N)
A large is \$20, and toppings are about \$3 each.	toppings	O

为评估模型的性能，本文使用准确率 (Accuracy, Acc) 和宏观 F1 值 (Macro-F1) 作为评价指标来衡量模型的有效性。本章的方面级情感分析任务可以看成转化为分类问题，对应的混淆矩阵如表 3.4 所示。

表 3.4 混淆矩阵表

真实情况	预测结果	
	正例	反例
正例	TP	FN
反例	FP	TN

基于以上混淆矩阵的分类，精准率 (Precision)、召回率 (Recall)、准确率 (Accuracy) 以及 $F1$ 的值计算公式如下所示。

$$Precision = \frac{TP}{TP + FP} \quad (2-19)$$

$$Recall = \frac{TP}{TP + FN} \quad (2-20)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2-21)$$

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (2-22)$$

3.3.2 实验环境与参数配置

本文实验所用的开发环境及相关配置信息如表 3.5 所示。

表 3.5 实验环境配置

实验环境配置表	配置信息
操作系统	Ubuntu20.04
CPU	I9-10900X
显卡	NVIDIA GeForce 3080Ti 12G
编程语言	Python3.8
深度学习框架	Pytorch1.12
开发环境	PyCharm

本文采用 BERT 预训练模型对文本中的单词进行初始化, 实验中的具体超参数设置情况如表 3.6 所示。

表 3.6 参数设置

参数	设置值
词嵌入维度	768
隐藏层维度	300
Batch size	16
训练迭代次数 epoch	50
学习率 Learning rate	2×10^{-5}
Dropout	0.4
优化器	Adam
L2 正则化系数	0.01

3.3.3 对比实验

为全面评估 KL-GCN 模型的性能, 将其与一系列基线模型和目前效果较好的先进模型作对比, 对比实验选取的模型大致分为三类: 基于语义和注意力的模型、基于图卷积网络的模型、以 BERT 为主要框架的模型。

ATAE-LSTM^[53]: 该模型针对句子结构的复杂性, 在 LSTM 层对输入信息进行优化, 根据不同方面词的输入关注不同的句子语境信息。

IAN^[54]: 该模型将方面词与整个文本的表示结合起来, 通过应用注意力机制,

将重点放在与方面词相关的部分，以更好地理解方面与情感之间的关系。这样，模型可以有效地捕捉到文本中方面词和情感之间的交互作用，并生成最终的情感倾向预测结果。

RAM^[55]: 该模型使用 Bi-LSTM 网络来捕捉文本序列中的上下文信息，并在两个方向上进行序列建模，同时引入内存单元来存储文本序列中的重要信息，使用注意力机制来动态地调整模型对文本中不同部分的关注程度，以便更好地捕捉与特定方面相关的情感信息，充分考虑文本中方面词与情感词之间的复杂交互关系。

MAN^[56]: 该模型采用了层内和层间注意机制。首先，使用转换编码器进行编码，其次，全局和局部注意机制分别关注整个句子和词间的交互。

PBAN^[57]: 该模型采用 GRU 模块感知位置信息，采用双向注意机制对句子和方面词信息进行建模。

IPAN^[58]: 该模型以词性信息 POS 为指导，对不同词性赋予不同的权重比，使模型更加关注与情绪表达相关的词语。同时，还设计了面向词的突出机制，使面向词与语境充分互动。

CPA-SA^[59]: 该模型采用两种上下文加权机制，根据方面词在评论中的位置分配不同的位置权重。它可以有效地缓解方面词上下文中的词数对模型的干扰。此外，基于类不平衡问题，建立了一个全新的损失函数。

ASGCN^[60]: 该模型提出了一种基于句法依存关系的图卷积神经网络模型，将文本中的句法关系提取，结合语义信息和方面词表示，充分将文本的情感信息利用，提高了模型的准确率。

CDT^[61]: 该模型首次将图卷积神经网络应用于句子依赖树，将 Bi-LSTM 层输出的上下文信息作为初始点嵌入，然后利用图卷积网络对依赖树提取信息进行关系建模。

BiGCN^[62]: 该模型首先构建层次句法图和层次词汇图，通过双层图卷积有效的利用单词共现信息，并且更好地理解句法依存信息，提出了一种新的概念层次。

DGEDT^[63]: 该模型提出双向 Transformer 网络结构，并利用该结构学习 Bi-LSTM 提取到的隐藏向量，并将学习到的句子表示和通过依赖树迭代交互学习到的图表示结合，提高了模型的性能。

InterGCN^[64]: 该模型将文本数据建模为图形结构, 并在该图上执行图卷积操作以捕获单词之间的交互关系, 从而提高方面级情感分析的性能和准确性。

R-GAT^[65]: 该模型利用图注意力网络来有效地建模文本中单词之间的关系, 并引入关系感知机制以更准确地捕获单词之间的语义关联性, 从而提高方面级情感分析的性能和准确性。

R-GAT-BERT^[66]: 该模型是用 BERT 代替 Bi-LSTM 的 R-GAT 模型。

Sentic GCN-BERT^[67]: 该模型基于 SenticNet 创建了一个图卷积网络, 可以根据不同的方面词充分挖掘句子中词之间的情感依赖关系。

DualGCN-BERT^[68]: 该模型提出了一种新的双通道图卷积模型, 考虑了语法结构的互补性和语义相关性, 避免了评论的复杂性带来的问题。

DM-GCN^[69]: 该模型结合了图卷积网络和多头自注意力机制提取语义和语法, 并提出动态多通道图卷积来学习相关信息。

3.3.4 实验结果与分析

本文在三个数据集上进行了 KL-GCN 与其他三组模型的对比实验, 对比模型实验结果来自引用的出版物, 如表 3.7 所示。在三个数据集中, 不同类别的最优结果用粗体表示, 次优结果用下划线表示。“Sem+Att”表示语义与注意力相结合的模型, “Syn+GCN”表示基于句法依存关系的图卷积模型。“BERT”则表示结合 BERT 预训练的方面级情感模型。

表 3.7 模型实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	F1	Acc	F1	Acc	F1
ATAE-LSTM	77.20	-	68.70	-	-	-
IAN	78.60	-	72.10	-	-	-
RAM	80.23	70.80	74.49	71.35	69.36	67.30
MAN	84.29	71.36	78.21	72.98	76.70	72.41
PBAN	81.16	-	74.12	-	-	-
IPAN	82.80	73.80	77.20	73.50	74.30	72.50

续表 3.7 模型实验结果

模型	Restaurant		Laptop		Twitter		
	Acc	F1	Acc	F1	Acc	F1	
Syn+GCN	ASGCN	80.77	72.2	75.55	71.05	72.15	70.40
	CDT	82.30	74.02	77.19	72.99	74.66	73.66
	BiGCN	81.97	73.48	74.59	71.84	74.16	73.35
	DGEDT	83.90	75.10	76.80	72.30	74.80	73.40
	InterGCN	82.23	74.01	77.86	74.32	-	-
	R-GAT	83.30	76.08	77.42	73.46	75.57	73.82
BERT	R-GAT-BERT	86.60	81.35	78.21	74.07	76.15	74.88
	Sentic GCN-BERT	86.92	80.03	<u>82.32</u>	<u>79.55</u>	-	-
	DualGCN-BERT	87.13	81.16	81.80	78.10	77.40	76.02
	DM-GCN	87.66	82.79	80.22	77.28	78.06	77.36
本文模型	KL-GCN	<u>87.43</u>	<u>81.63</u>	82.36	79.65	<u>77.45</u>	<u>76.24</u>

由表可知，本章提出的 KL-GCN 模型在 Restaurant、Laptop 和 Twitter 三个数据集上均取得不错效果，从表中可以看出 KL-GCN 模型在 Laptop 数据集上的准确率和 F1 值都达到了最优，分别是 82.36、79.65。在 Restaurant 和 Twitter 数据集上的准确率和 F1 值均达到了次优，与最优模型的准确率相差 0.23 和 0.61，相较于其他对比模型，KL-GCN 模型效果比较号，说明模型在方面级情感分析中可以较好的捕捉文本特征信息。

通过对比实验，可以发现基于 GCN 的模型与基于语义和注意力机制相比效果更好，这是因为大部分文本数据具有严谨的语法结构，仅仅依靠注意力机制不能够充分的提取特征信息，不能有效地捕获方面词和情感词之间的关联。与引入注意力机制的经典模型相比，本章提出的 KL-GCN 模型融合了外部知识，更能关注图卷积网络获取的特征信息，并可以很好地捕捉词之间句法依赖关系。

与 ASGCN、CDT、BiGCN 等基于 GCN 的模型相比，KL-GCN 不在局限于

挖掘潜在的依赖树信息，而是结合外部知识，以帮助挖掘情感线索，同时结合上下文信息，将句法信息和语义信息整合，更好地完成方面级情感分析任务，提高了模型的准确率，也进一步证实了外部知识信息融合的可行性。

使用传统 GloVe 嵌入向量模型的性能普遍不如基于 BERT 的模型。传统词嵌入向量的缺点限制了复杂特征提取模块的性能。因此本文采用了以 BERT 为主要框架的 KL-GCN 模型。对于 R-GAT-BERT、Sentic GCN-BERT 和 DM-GCN 等基于 BERT 的模型，本章提出的 KL-GCN 模型在三个公开数据集上的性能显著优于其他模型。

本章提出的 KL-GCN 模型同时构建了以 CNN-GRU 模型为基础的语义提取模块和以融合外部知识信息模型为基础的句法信息提取模块，最后将两大模块学习到的输出向量在特征融合层进行融合，实现信息增强。实验证明，该模型在三个公开数据集上与其他模型相比具有更好的效果，有效地克服了信息提取不充分和信息丢失的问题，证实了 KL-GCN 模型的有效性。但是该模型在 Twitter 数据集上的表现不突出，这是因为该数据集中可能有太多其他字符，其中大多数是情感词典之外的单词。因此，情感词典无法确定这些词的情感得分，使得情感词矩阵相对稀疏，模型不能充分利用外部知识提供的指示。

3.3.5 消融实验

本节在三个公开数据集上完成了消融实验来验证模块的有效性。消融实验结果如表 3.8 所示。每组消融实验的具体描述如下，其中“w/o”表示无。

KL-GCN w/o Sentiment score matrix: 消除情感得分矩阵

KL-GCN w/o Part of speech matrix: 消除了词性矩阵。

KL-GCN w/o Position: 消除位置向量。

表 3.8 消融实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	F1	Acc	F1	Acc	F1
KL-GCN w/o Sentiment score matrix	84.76	78.12	80.57	77.46	76.22	75.74
KL-GCN w/o Part of speech matrix	85.58	78.86	81.23	77.83	76.86	75.65

续表 3.8 消融实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	F1	Acc	F1	Acc	F1
KL-GCN w/o Position	87.04	80.33	81.56	78.25	77.19	75.71
KL-GCN	87.43	81.63	82.36	79.65	77.45	76.24

从以上消融实验结果得知，特别是在消除情感得分矩阵（KL-GCN w/o Sentiment score matrix）后，模型的准确率和 F1 值明显下降，模型在三个数据集上的准确率分别下降了 2.67、1.79、1.23 个百分点，模型下降幅度大。可见依赖树的重构对 GCN 特征提取的效果产生着积极影响，情感得分矩阵部分对模型句法特征提取的贡献较大。

在消除了词性矩阵（KL-GCN w/o Part of speech matrix）之后，模型的准确率也有明显的下降趋势，以上消融实验也表明词性矩阵和情感得分矩阵是重要的部分，可以解决复杂的边缘标签捕获问题，增强否定词和程度词等影响情感极性的词的权重，生成更准确的句子表示。

当消除位置向量公式（KL-GCN w/o Position）之后，模型在三个数据集上的准确率略有下降，但没有对模型产生巨大的影响。位置向量公式能够帮助模型更好的提取上下文之间的信息，在消除它之后，模型并没有产生大幅下降，这表明语义信息的贡献度不如语法信息的贡献度大。

总体看，本节的消融实验模型的准确率都在原有模型基础上有不同幅度的降低，这表明在 KL-GCN 模型中的各个模块都有其存在的合理性。

3.3.6 GCN 层数对模型性能的影响

为进一步分析 GCN 层数对实验结果的影响，将模型中 GCN 的层数设置在 {1,2,3,4,5,6,7,8} 层的范围内，模型在三个数据集上的准确率和 F1 值如图 3.4、图 3.5 所示。从以下两幅图可以看出，当 KL-GCN 模型的 GCN 层数为 2 时性能达到最高值。当模型的 GCN 层数过浅时无法聚合远距离的关键特征信息。此外，当模型的层数大于 2 时。随着 GCN 层数的进一步增加，模型的准确率和 F1 值开始下降，可见模型层数过多时，每个节点聚合了许多不相关的节点，过多的噪

声信息导致模型的情感分类结果变差。




图 3.4 GCN 层数对模型准确率的影响

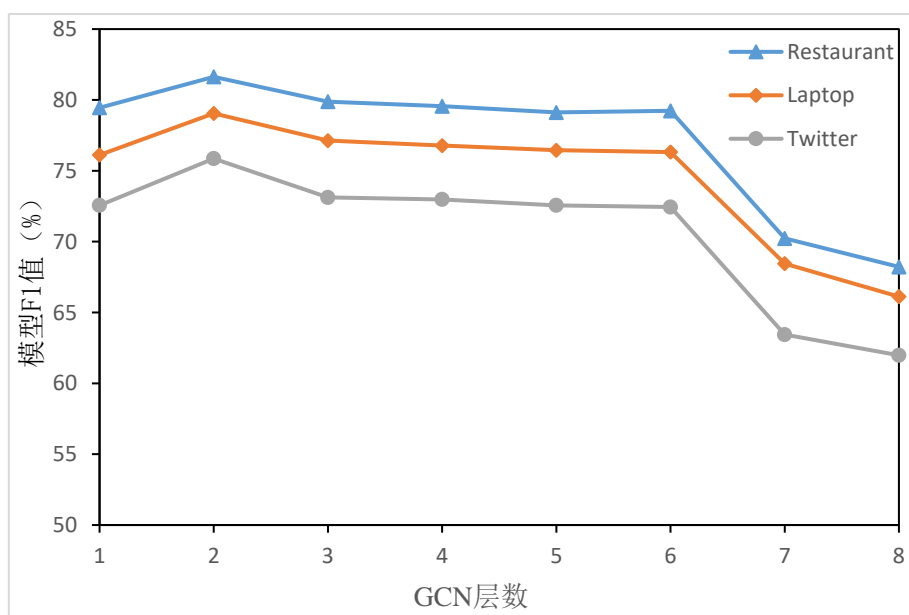


图 3.5 GCN 层数对模型 F1 值的影响

3.3.7 案例分析

为了能够更直观地展示本章提出的 KL-GCN 模型的情感分析性能比其他模型更优越,本节选择了有代表性的例句:“Great food but the service was dreadful!”

进行可视化。




图 3.6 实例可视化分析

如图 3.6 所示，例句包含“food”和“service”两个方面，并且两个方面词的情感极性也是不同的。图中颜色越深，代表所分配的权重越高，反之权重越低。从可视图中可以看出，KL-GCN 模型可以准确判别方面词的情感极性，在例句中“food”方面词的意见词是“great”，因此 KL-GCN 模型分配给“great”的注意力权重比较大，方面词的意见词是积极的，因此该方面词判别为积极；另一个方面词“service”的意见词是“dreadful”，因此模型根据句法结构将更多的注意权重分配给“dreadful”，最终该方面词判别为消极。虽然 KL-GCN 模型也将注意力权重分配给意见词之外的词，但是对于“food”和“service”两个词而言，分配给“great”和“dreadful”的权重最大，可视图中颜色最深。由此可见，面对包含多个方面词文本不同的情感极性时，KL-GCN 模型依旧可以将不同的情感极性的方面词进行分类，准确地判别特定方面词的情感极性。

3.4 本章小结

本章提出了一种融合外部知识的图卷积网络，以解决当前方面级情感分析模型没有特别关注外部知识的缺点和依赖树信息提取不充分的问题。本章中的 KL-GCN 模型重新构造了依赖树，在依赖矩阵中加入词性信息和情感得分信息，得到重构后的依赖矩阵，并用它来构造句法图卷积模块。并且在模型中还构建了 CNN-GRU 模型，以此作为本章模型的语义提取模块，来弥补仅从句法结构提取信息导致的上下文信息被忽略的缺点。另外，两个模块最终通过注意力机制进行特征融合，更好地完成方面级情感分析任务，进行正确的情感判别。三个公开数据集的实验表明了 KL-GCN 模型在情感极性的判别上优于大多数模型，证明了模型的有效性。

4 融合外部知识的多通道方面级情感分析模型

目前大部分情感分析模型都是基于单通道的语法或语义特征提取方式,部分模型是基于神经网络的语法提取和语义提取的双通道建模,在面对复杂的网络评论时,由于模型背景知识的不足,导致其不能很好地理解评论文本。另外,由于单词的排列顺序需要句法知识的支持,以构成一个完整的句子,所以要想让机器充分理解文本,不仅需要理解每个单词的语义,还需要句法结构的辅助。现有的模型大多依赖于文本内部结构为语法信息进行建模,未尝试利用外部知识引入的方式来处理这一任务。

本章提出一种融合外部知识的多通道图卷积网络模型框架,将语法、语义和外部知识三种特征向量融合。首先模型分别对句子中的语法信息和语义信息进行提取,再将外部知识信息嵌入模型中,利用自注意力机制得到外部知识的得分矩阵,输入图卷积中提取外部知识特征信息,将三种特征信息输入特征融合模块,使多通道的特征能够互补学习。本章中使用的外部知识来源于 WordNet, WordNet 主要对词与词之间的语义关系进行定义。实验结果表明,模型可以更好地提取到文本的语义信息和语法信息,同时外部信息更加丰富了文本信息,提高了模型的准确率。

4.1 FEKM-GCN 模型框架

本章提出的融合外部知识的多通道图卷积网络模型主要由语法信息提取模块、语义信息提取模块和外部知识信息提取模块三部分构成。利用依存句法树学习语法信息,同时使用自注意力机制学习语义信息和外部知识信息,在外部知识信息提取模块,该框架采用 WordNet 外部知识库来扩展方面类别的语义,建立知识库中方面类别与句子中的相关词语之间的关系,并通过图卷积网络进行更新节点表示,最终利用高速网络机制将特征信息融合,可以解决解长句中噪声问题以及短句中句子缺乏句法结构的问题,以及当前对数据集情感分析时缺乏先验知识的问题。图 4.1 展示了模型的整体网络结构。

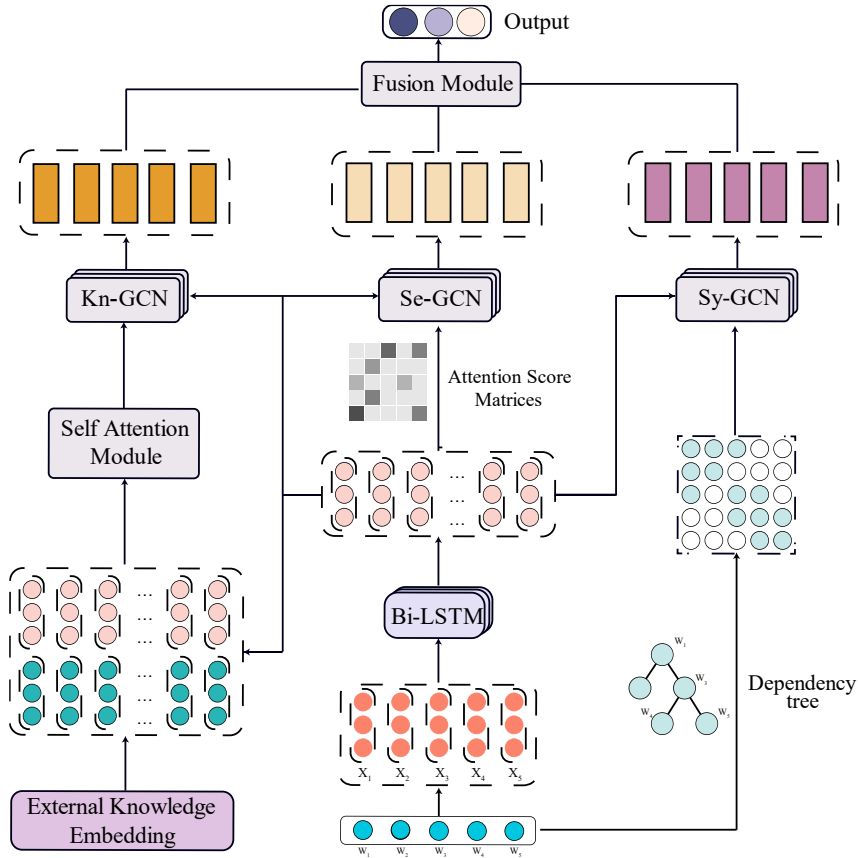


图 4.1 FEKM-GCN 整体网络结构图

4.1.1 输入层

输入层的作用是将文本变成计算机可以理解的词向量表示形式,对于给定的文本 $S = \{w_1, w_2, \dots, w_{i+m}, \dots, w_{n-1}, w_n\}$, 首先采用 GloVe 模型将文本中的单词映射为一个 d_w 维度的分布式词向量 x_t 。然后使用 Bi-LSTM 对每个词向量 x_t 进行编码, 得到每个词向量 x_t 的隐藏状态表示。具体来说, 输入单词 x_t 通过前向网络得到的 \vec{h}_t , 通过后向网络得到 \overleftarrow{h}_t , 将两者进行拼接, 拼接后最终得到输出结果 H^c , 如公式所示:

$$\vec{h}_t = \overrightarrow{LSTM}(x_t, \vec{h}_{t-1}) \tag{3-1}$$

$$\overleftarrow{h}_t = \overleftarrow{LSTM}(x_t, \overleftarrow{h}_{t-1}) \tag{3-2}$$

$$H^c = [\vec{h}_t; \overleftarrow{h}_t] \tag{3-3}$$

4.1.2 语法信息通道

单纯的注意力机制往往会将文本中的所有词都进行关注，产生噪声。特别是在文本情感分析中，不相关的情感表达词也会被聚合到当前的词语表示中。因此，本文使用依存句法树分析句子结构捕捉文本语法信息，依存句法分析关注的是单词之间的从属关系，将句子中的每个单词视为一个节点，并通过有向边表示单词之间的依存关系，从而形成一个依存句法图。

依存句法图定义为 $G=(V,E)$ ，其中 V 代表着文本中的每个单词的集合，在邻接矩阵中，这些单词代表着矩阵中的每一个节点； E 代表依存句法图中的依赖关系边的集合。最终我们依据依存句法图来创建如下依赖矩阵：

$$A_{ij} = \begin{cases} 1, & \text{if } a_i \text{ and } a_j \text{ have dependences} \\ 0, & \text{other} \end{cases} \quad (3-4)$$

在矩阵中，行和列都是输入文本的每个单词，由公式（4-4）可以看出，矩阵中只有“1”或者“0”， a_i 和 a_j 代表着单个词，当 a_i 和 a_j 有依赖关系时，矩阵中代表两个节点的空填为“1”，反之则为“0”，另外由于单词和本身也存在关联，因此该邻接矩阵是对角线为1的稀疏矩阵。

本文以图卷积神经网络为编码器，将上述依赖矩阵 A_{ij} 作为图结构，将经过 Bi-LSTM 得到隐藏状态向量 $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$ 作为图中节点的初始化表示。通过图卷积神经网络对图中的节点进行更新和特征聚合，最终语法通道模块得到含有语法信息的特征向量 H^{sy} ，特征向量表示如下：

$$H^{sy} = \{h_1^{sy}, h_2^{sy}, \dots, h_n^{sy}\} \quad (3-5)$$

4.1.3 语义信息通道

在语法提取通道模块中，依存句法图发挥了重要的作用，可以很好地提取符合严谨句法结构的文本信息。然而，由于数据集中含有无严谨语法结构的部分短文本，所以在语义提取通道中，解析不含严谨语法结构的短文本时，依存句法图不能达到很好的效果，从而影响了后续情感分析的结果。

为了解决上述问题，使得模型能充分捕获文本中的语义信息，模型使用基于自注意力机制的语义提取模块提取语义特征。如果词与词之间的相似度高，则通

过自注意力机制得到的分数更高。反之，则分数更低。表达公式如下：

$$A_{ij}^{se} = \text{softmax} \left(\frac{QW^Q \times (KW^K)^T}{\sqrt{d_k}} \right) \quad (3-6)$$

$$d_k = \frac{d}{h} \quad (3-7)$$

在公式（4-6）中， A_{ij}^{se} 为在训练过程中得到的注意力得分矩阵，矩阵中的元素代表单词之间的相关度， Q 和 K 是输入， W^Q 和 W^K 为参数权重矩阵，公式（4-7）中 d 为输入节点的维度， h 是注意力头的数量。

将 Bi-LSTM 输出的隐藏状态向量 $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$ 作为图中节点的初始化表示。注意力得分矩阵 A_{ij}^{se} 为图结构，通过图卷积网络进行节点特征值更新，最终语义通道模块得到含有上下文语义信息的特征向量 H^{se} ，公式表示如下：

$$H^{se} = \{h_1^{se}, h_2^{se}, \dots, h_n^{se}\} \quad (3-8)$$

4.1.4 外部知识通道

为了利用外部知识补充先验信息，精准评论文本你上下文语义，模型引入 WordNet 知识库作为知识源。与直接将情感知识融入句法依存关系建模不同，本文将预训练外部知识图谱嵌入作为先验知识引入模型。首先，使用语义匹配方法将 WordNet 中的语义关系建模为分布式表示。其次，将每个词汇的知识嵌入和 Bi-LSTM 输出的隐藏状态拼接，最后利用自注意力机制计算蕴含知识的上下文中词之间的相似度，将得到的注意力得分矩阵输入图卷积网络中得到特征向量 H^{kn} ，计算与语义提取通道类似，过程如下：

$$A_{ij}^{kn} = \text{softmax} \left(\frac{QW^Q \times (KW^K)^T}{\sqrt{d_k}} \right) \quad (3-9)$$

$$d_k = \frac{d}{h} \quad (3-10)$$

$$H^{kn} = \{h_1^{kn}, h_2^{kn}, \dots, h_n^{kn}\} \quad (3-11)$$

4.1.5 特征融合模块

语法信息提取通道通过句法依存关系提取包含语法信息的特征向量，语义信息提取通道通过注意力机制提取包含语义信息的特征向量，外部知识通道将融合先验知识的特征信息提取，来自三个通道的特征最终输入到多特征融合模块中进行特征融合。

首先在语法信息、语义信息和外部知识信息上执行池化操作得到：

$$H_{sy}^p = Pooling(H^{sy}) \quad (3-12)$$

$$H_{se}^p = Pooling(H^{se}) \quad (3-13)$$

$$H_{kn}^p = Pooling(H^{kn}) \quad (3-14)$$

模型采用高速网络机制进行三通道特征融合，与简单拼接，高速网络机制是通过门控机制选择比较重要的特征信息，将输入的语法信息、语义信息和外部知识信息通过网络调节，使得信息可以跨通道传输，从而将比较重要的特征信息融合。最终得到情感特征输出 O ：

$$O = H_{kn}^p \otimes [1 - \sigma(H_{se}^p)] + H_{sy}^p \otimes \sigma(H_{se}^p) \quad (3-15)$$

4.1.6 输出层

模型采用全连接层作为输出层进行情感判别。全连接的输入为带有融合特征的注意力层的输出向量 O ，采用 softmax 分类函数对全连接层的输出向量进行归一化处理，最终得到模型预测结果 \hat{y} 。计算公式如下：

$$\hat{y} = \text{softmax}(WO + b) \quad (3-16)$$

其中， w 代表权重矩阵， b 代表偏执参数。模型的输出向量 \hat{y} 是一个 $1*3$ 的向量，维度的值分别表示情感类别（积极、消极、中性）的概率，该任务最终的输出 Y 则选取数值最大的类别，公式如下：

$$Y = \arg \max(\hat{y}) \quad (3-17)$$

模型使用 Adam 更新参数，选择最小化交叉熵损失函数来优化模型，损失函数的计算公式如下：

$$\text{loss} = - \sum_{i=1}^N \sum_{j=1}^C y_i^j \log \hat{y}_i^j + \lambda \|\theta\|^2 \quad (3-18)$$

其中， N 代表训练集总量， C 代表情感类别数量， y 为数据的真实标签， \hat{y} 为

预测标签, $\lambda \|\theta\|^2$ 为交叉正则, λ 为正则系数, θ 为模型参数。

4.2 实验与分析

4.2.1 实验数据集与评价指标

为验证 FEKM-GCN 模型的有效性, 本文使用了 SemEval2014 Task^[51] 的 Restaurant 评论和 Laptop 评论以及 Acl-2014-short data 中的 Twitter^[52]。短文本评论这三种最广泛使用的英文数据集进行实验分析。数据集中每条评论文本的情感极性都由积极、消极、中性组成, 分别用 1, -1, 0 表示。Restaurant 评论数据集包含对餐馆食物品质、餐厅价格以及餐馆服务等目标方面的评论, Laptop 评论数据集包含了对笔记本电脑的性能、质量、价格、使用体验、售后服务等方面的评论, Twitter 数据集包含人们对公共事物发表的评论, 共有六千多条, 三种数据集的训练集和测试集的分布数量见表 4.1 所示。

表 4.1 数据集统计

数据集	Positive		Neutral		Negative	
	Train	Test	Train	Test	Train	Test
Laptop	976	337	455	167	851	128
Restaurant	2164	727	637	196	807	196
Twitter	1507	172	3016	336	1528	169

表 4.2 中展示了 Restaurant、Laptop 以及 Twitter 数据集的一部分样例, 每条评论中包含评论文本、目标方面词和方面词对应的情感极性, 三个样例中分别包含了三种不同的情感极性。

表 4.2 数据集样例

评论文本	方面词	情感极性
The driver updates don't fix the issue, very frustrating.	driver updates	N
The food is usually good but it certainly isn't a relaxing place to go.	food, it	(P, N)
A large is \$20, and toppings are about \$3 each.	toppings	O

为评估模型的性能，本文使用准确率和 F1 值作为评价指标来衡量模型的有效性。计算公式如下所示。

$$Precision = \frac{TP}{TP + FP} \quad (3-19)$$

$$Recall = \frac{TP}{TP + FN} \quad (3-20)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3-21)$$

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (3-22)$$

4.2.2 实验环境与参数配置

本文实验所用的开发环境及相关配置信息如表 4.3 所示。

表 4.3 实验环境配置

实验环境配置表	配置信息
操作系统	Ubuntu20.04
CPU	I9-10900X
显卡	NVIDIA GeForce 3080Ti 12G
编程语言	Python3.8
深度学习框架	Pytorch1.12
开发环境	PyCharm

本文采用 BERT 预训练模型对文本中的单词进行初始化，具体超参数设置情况如表 4.4 所示。

表 4.4 参数设置

参数	设置值
词嵌入维度	768
隐藏层维度	300
Batch size	16
训练迭代次数 epoch	50
学习率 Learning rate	2×10^{-5}
Dropout	0.4

续表 4.4 参数设置

参数	设置值
优化器	Adam
L2 正则化系数	0.01

4.2.3 对比试验

为全面评估模型的性能, 将其与一系列基线模型和目前效果较好的先进模型作对比, 对比实验选取的模型大致分为三类: 基于语义和注意力的模型、基于图卷积网络的模型、基于外部知识的网络模型。

ATAE-LSTM^[53]: 该模型针对句子结构的复杂性, 在 LSTM 层对输入信息进行优化, 根据不同方面词的输入关注不同的句子语境信息。

IAN^[54]: 该模型将方面词与整个文本的表示结合起来, 通过应用注意力机制, 将重点放在与方面词相关的部分, 以更好地理解方面与情感之间的关系。这样, 模型可以有效地捕捉到文本中方面词和情感之间的交互作用, 并生成最终的情感倾向预测结果。

RAM^[55]: 该模型使用 Bi-LSTM 网络来捕捉文本序列中的上下文信息, 并在两个方向上进行序列建模, 同时引入内存单元来存储文本序列中的重要信息, 使用注意力机制来动态地调整模型对文本中不同部分的关注程度, 以便更好地捕捉与特定方面相关的情感信息, 充分考虑文本中方面词与情感词之间的复杂交互关系。

MAN^[56]: 该模型采用了层内和层间注意机制。首先, 使用转换编码器进行编码, 其次, 全局和局部注意机制分别关注整个句子和词间的交互。

PBAN^[57]: 该模型采用 GRU 模块感知位置信息, 采用双向注意机制对句子和方面词信息进行建模。

IPAN^[58]: 该模型以词性信息 POS 为指导, 对不同词性赋予不同的权重比, 使模型更加关注与情绪表达相关的词语。同时, 还设计了面向词的突出机制, 使面向词与语境充分互动。

CPA-SA^[59]: 该模型采用两种上下文加权机制, 根据方面词在评论中的位置分配不同的位置权重。它可以有效地缓解方面词上下文中的词数对模型的干扰。

此外，基于类不平衡问题，建立了一个全新的损失函数。

ASGCN^[60]：该模型提出了一种基于句法依存关系的图卷积神经网络模型，将文本中的句法关系提取，结合语义信息和方面词表示，充分将文本的情感信息利用，提高了模型的准确率。

CDT^[61]：该模型首次将图卷积神经网络应用于句子依赖树，将 Bi-LSTM 层输出的上下文信息作为初始点嵌入，然后利用图卷积网络对依赖树提取信息进行关系建模。

BiGCN^[62]：该模型首先构建层次句法图和层次词汇图，通过双层图卷积有效的利用单词共现信息，并且更好地理解句法依存信息，提出一种新的概念层次。

DGEDT^[63]：该模型提出双向 Transformer 网络结构，并利用该结构学习 Bi-LSTM 提取到的隐藏向量，并将学习到的句子表示和通过依赖树迭代交互学习到的图表示结合，提高了模型的性能。

InterGCN^[64]：该模型将文本数据建模为图形结构，并在该图上执行图卷积操作以捕获单词之间的交互关系，从而提高方面级情感分析的性能和准确性。

R-GAT^[65]：该模型利用图注意力网络来有效地建模文本中单词之间的关系，并引入关系感知机制以更准确地捕获单词之间的语义关联性，从而提高方面级情感分析的性能和准确性。

SK-GCN^[70]：该模型以 GCN 作为模型基础，用图结构类型数据向文本融合外部知识并构建句法依赖树，融合句法和外部知识，提高了模型的准确率。

KD-GAT^[71]：该模型以外部知识为基础构建文本知识图，进而利用图注意力网络提取特征表示。

Sentic GCN-BERT^[67]：该模型基于 SenticNet 创建了一个图卷积网络，可以根据不同的方面词充分挖掘句子中词之间的情感依赖关系。

4.2.4 实验结果与分析

本文在三个数据集上进行了 FEKM-GCN 与其他三种类型模型的对比实验，对比模型实验结果来自引用的出版物，如表 4.5 所示。在三个数据集中，不同类别的最优结果用粗体表示，次优结果用下划线表示。“Sem+Att”表示语义与注意力相结合的模型，“Syn+GCN”表示基于句法依存关系的图卷积模型。“BERT”则表示结合 BERT 预训练的方面级情感模型。

表 4.5 模型实验结果

模型	Restaurant		Laptop		Twitter		
	Acc	F1	Acc	F1	Acc	F1	
Sem+Att	ATAE-LSTM	77.20	-	68.70	-	-	-
	IAN	78.60	-	72.10	-	-	-
	RAM	80.23	70.80	74.39	71.35	69.36	67.30
	MAN	83.29	71.36	76.21	72.98	74.70	72.41
	PBAN	81.16	-	74.12	-	-	-
	IPAN	82.80	73.80	77.20	73.50	74.30	72.50
Syn+GCN	ASGCN	80.77	72.20	75.55	71.05	72.15	70.40
	CDT	82.30	74.02	77.19	72.99	74.66	73.66
	BiGCN	81.97	73.48	74.59	71.84	74.16	73.35
	DGEDT	83.90	75.10	76.80	72.30	74.80	73.40
	InterGCN	82.23	74.01	77.26	74.32	-	-
	R-GAT	83.30	<u>76.08</u>	77.42	73.46	<u>75.57</u>	<u>73.82</u>
Kno	SK-GCN	82.48	75.19	73.20	69.80	71.97	70.22
	KD-GAT	82.50	74.97	75.96	72.16	73.32	71.92
	Sentic GCN	<u>84.03</u>	75.38	77.90	74.71	-	-
本文模型	FEKM-GCN	84.12	76.18	<u>77.46</u>	<u>74.45</u>	76.24	74.56

由表可知，本章提出的 FEKM-GCN 模型在 Restaurant、Laptop 和 Twitter 三个数据集上均取得不错效果。从表中可以看出 FEKM-GCN 模型在 Restaurant 和 Twitter 数据集上的准确率都达到了最优，分别是 84.12、76.24。在 Laptop 数据集上准确率和 F1 值均达到了次优，与最优模型的准确率和 F1 值分别相差 0.54 和 0.26，相较于其他对比模型，FEKM-GCN 模型性能比较优越，说明模型在方面级情感分析中可以较好地捕捉文本特征信息。

根据实验结果可以看出,基于语义和注意力的模型与基于句法和图卷积网络的模型相比效果较差,这是因为当方面词与意见词相距较远时,模型无法完成距离较长的依赖关系的建模,文本越长提取的无关信息则可能越多。而基于句法和图卷积网络的模型可以利用句法依存图建模句法信息,句法信息可以使得在文本中距离较远的方面词和意见词关联起来,有效地识别句法关系密切但是文本距离远的两个词,这样模型就可以在识别出对情感分析有贡献的上下文词汇。

FEKM-GCN 模型的实验表现效果明显优于 SK-GCN 和 KD-GAT 模型,在 Restaurant 和 Twitter 两个数据集上要比 Sentic-GCN 模型的效果要好,这是因为这三个模型都是在构建句法关系信息时加入外部知识以充分捕获语法信息,没有考虑到节点之间的关系信息。而在 Laptop 数据集上,由于外部知识的引入导致 FEKM-GCN 的语义信息捕获不充分,导致准确率低于 Sentic-GCN,基于此可以看出将预训练的外部知识信息输入模型可以获得更充分的先验知识信息。

4.2.5 消融实验

为了进一步证明本章提出的模型每个模块组成的有效性,本节在三个公开数据集上进行了以下消融实验来验证模块的有效性。每组消融实验的具体描述如下,其中“w/o”表示无:

FEKM-GCN w/o Sy: 表示模型去掉语法信息提取模块。

FEKM-GCN w/o Se: 表示模型去掉语义信息提取模块。

FEKM-GCN w/o Kn: 表示模型去掉外部知识模块。

消融实验结果如表 4.6 所示,实验表明,模型的所有模块都有助于 KL-GCN 模型性能的提高。

表 4.6 消融实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	F1	Acc	F1	Acc	F1
FEKM-GCN w/o Sy	82.76	75.12	74.57	70.46	74.22	72.74
FEKM-GCN w/o Se	83.58	75.86	76.23	71.83	75.86	73.65

续表 4.6 消融实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	F1	Acc	F1	Acc	F1
FEKM-GCN w/o Kn	83.04	75.33	75.56	71.25	74.88	73.41
FEKM-GCN	84.12	76.18	77.46	74.45	76.24	74.56

从以上消融实验结果可以看出，FEKM-GCN 模型在去掉语法信息提取模块，在三个数据集上的准确率分别下降了 1.36、2.89、2.02 个百分点，模型下降幅度非常大，可见语法信息的提取有利于模型情感极性的判别，语法信息模块贡献度大。

FEKM-GCN 模型在去掉语义信息提取模块后，模型在三个数据集上的准确率下降幅度相对较小，这说明语义信息能帮助模型有效地理解文本信息，但是句法关系对于模型性能的提升比语义信息对模型性能提升的帮助更大。

FEKM-GCN 模型在去掉外部知识模块后，模型性能显著下降，特别是在 Twitter 数据集上准确率和 F1 分别下降了 1.36% 和 1.15%，说明了外部知识的嵌入有助于模型分析文本性能的提高，补充先验知识能有效地提高模型情感分析的准确率。总体看，本节的消融实验模型的准确率都在原有模型基础上有不同幅度的降低，这表明在 FEKM-GCN 模型中的各个模块都有其存在的合理性。

4.2.6 GCN 层数对模型性能的影响

为进一步分析 FEKM-GCN 模型中 GCN 层数对模型性能的影响，将模型中 GCN 的层数设置在 {1,2,3,4,5,6,7,8} 层的范围内，模型在三个数据集上的准确率如图 4.2、图 4.3、图 4.4 所示。




图 4.2 Sy-GCN 层数对模型的准确率的影响




图 4.3 Se-GCN 层数对模型的准确率的影响




图 4.4 Kn-GCN 层数对模型的准确率的影响

根据上述三幅图可以看出,语法通道中的 GCN 层数设置为 2,语义通道的 GCN 层数设置为 2,外部知识通道的层数设置为 1 时为模型最佳的参数组合。实验结果显示,层数过多和过少的 GCN 网络都不能获得关键的情感特征信息,进而不能使得模型达到最优效果。

当 GCN 层数太少时,模型只能捕获周围邻居节点的信息,无法聚合远距离节点的信息,导致信息提取不充分。当 GCN 层数过深时,往往会使每个节点能够聚合大多数节点,这会导致节点聚合过多的噪声信息。而对于外部知识通道的 GCN 层数而言,单层的 GCN 效果更好,随着层数的进一步增加,模型的性能开始下降,因为在该通道中已经包含了先验知识,层数过深不仅不能提高模型性能,反而会引入噪声。

4.3 本章小结

本章提出了一种融合外部知识的多通道图卷积网络模型,解决了当前大多数单通道和双通道模型在处理较短评论文本时由于背景信息不足导致的信息特征提取不充分问题,模型为方面级情感分析任务补充了先验知识信息,实验结果证明了模型的有效性。

FEKM-GCN 模型由输入层、基于句法依存树的语法信息通道、基于自注意力机制的语义信息通道、外部知识通道和输入层组成。其中,基于句法依存树的语法信息通道将句法依存图生成的依赖矩阵作为图结构,输入到图卷积网络,以 Bi-LSTM 得到的隐藏状态向量作为初始节点,进而对网络节点进行特征聚合和更新,最终得到包含语法信息的特征向量。基于自注意力机制的语义信息通道经过图卷积网络得到包含上下文语义信息的特征向量。外部知识通道为情感分析补充了外部先验知识。最终通过多通道融合模块进行特征融合,实现不同特征信息的相互补充。对此,通过进行对比试验和消融实验证明了本章提出的 FEKM-GCN 模型在方面级情感分析任务中的有效性。

5 总结与展望

5.1 总结

随着互联网技术的持续发展，互联网已经融入到人们的日常生活中，成为人们表达观点的主要途径。通过筛选和分析成千上万条意见中的有效信息，不仅能够企业依据客户的反馈对产品进行优化，也能使政府根据民众对公共事件或政策的观点来调整其策略。面对这类精细化的需求，细粒度的情感分析被广泛应用。因此，本文以语法信息和语义信息的特征融合为基础，以外部知识作为辅助信息，以增强模型在信息提取中的效果。本文的主要工作如下：

(1) 为了更准确地识别不同上下文词对目标方面的作用，并加强目标方面词与上下文特征之间的联系，以减少情感信息的丢失，本文提出了一种融合外部知识和位置信息增强的方面级情感分析模型，文中简称 KL-GCN。KL-GCN 主要包括两大部分，第一部分是基于外部情感词典的句法信息提取模块，第二部分是基于 CNN-GRU 的语义提取模块。在第一部分中，本文的重点是对数据集词性进行统计，构建词性矩阵，充分考虑否定词、程度词等影响句子情感表达的词对情感分类的影响。然后，利用情感词典为句子中的每个词分配情感分数，构建情感分数矩阵来突出情感词的权重，通过该方法模型充分学习句子的依赖关系，得到包含丰富句法信息的特征向量。在第二部分中，首先通过 BERT 模型对文本词和方面词进行编码，加入位置信息，获得位置信息词向量表示，然后通过 GRU-CNN 网络提取文本语义特征。最后构建基于注意力机制的特征融合模块，将两部分进行特征融合，增强特征向量表示的能力。通过消融实验可知，模型中情感词典的加入和位置向量的融合对提升方面级情感分类准确率有帮助。

(2) 为更好地判别网络断评论信息的情感极性，解决由于背景信息不足导致模型在分析短文本时的效果不佳的问题，提出了一种融合外部知识的多通道图卷积网络模型用于方面级情感分析任务，文中简称 FEKM-GCN，模型将外部知识融合以提高模型对文本的理解能力。模型从基于句法依存图的语法信息通道提取包含语法信息的特征向量，从语义通道中得到包含上下文语义信息的特征向量，从外部知识通道提取外部知识信息，最终通过特征融合模块将三个通道中的信息协同融合，互相补充，用于最终的方面级情感分析任务。实验结果表明，融合外

部知识作为补充信息的多通道图卷积网络模型能充分地提取文本中的特征信息，有效地提高模型的表现力和性能，证明了 FEKM-GCN 模型的有效性。

5.2 展望

本文提出的 KL-GCN 模型和 FEKM-GCN 模型在三个公开数据集上的准确率和 F1 值较其他模型有所提高，证明了本文提出的两个模型的性能。但是仍存在进一步完善和改进的空间。具体如下：

(1) 由于本文提出的两个模型都是融合了外部知识，而过多的外部知识可能会带来部分噪声，导致模型对文本的特征信息过度理解。因此下一步工作中，应该考虑如何精确地从外部知识中获取情感分析需要的知识，从而进一步提升模型的预测性能。

(2) 由于当前时代节奏性和网络年轻化的发展，当前网络中的评论中加入了大量表情、颜文字、视频等内容，这些内容又往往代表着网民的真实情感，能够更直观地反应人们的情感，所以如何处理这样的多模态情感信息并且提取特征融入到模型中是一个对提升模型预测准确率非常有帮助的研究方向。

参考文献

- [1] Liu B. Sentiment analysis and opinion mining [J]. Synthesis lectures on human language technologies, 2012, 5(1): 154-167.
- [2] 中国互联网络信息中心发布第 51 次《中国互联网络发展状况统计报告》[J]. 国家图书馆学刊, 2023, 31(5): 12.
- [3] Medhat W, Hassan A, Korashy H. Sentiment analysis algorithms and applications: A survey [J]. Ain shams engineering journal, 2014, 5(4): 1093-1113.
- [4] Behdenna S, Barigou F, Belalem G. Document level sentiment analysis: a survey[J]. EAI endorsed transactions on context-aware systems and applications, 2018, 4(13): 2-8
- [5] Meena A, Prabhakar T V. Sentence level sentiment analysis in the presence of conjuncts using linguistic analysis[C]//Advances in Information Retrieval: 29th European Conference on IR Research, ECIR 2007, Rome, Italy, April 2-5, 2007. Proceedings 29. Springer Berlin Heidelberg, 2007: 573-580.
- [6] Zhang W, Li X, Deng Y, et al. A survey on aspect-based sentiment analysis: Tasks, methods, and challenges[J]. IEEE Transactions on Knowledge and Data Engineering, 2022.
- [7] Thet T T, Na J C, Khoo C S G. Aspect-based sentiment analysis of movie reviews on discussion boards[J]. Journal of Information Science. 2010, 36(6):823-848.
- [8] Miller G A. WordNet: a lexical database for English[J]. Communications of the ACM, 1995, 38(11): 39-41.
- [9] Deng L, Wiebe J. Mpqa 3.0: An entity/event-level sentiment corpus [C] //Proceedings of the 2015 conference of the North American chapter of the association for computational linguistics: human language technologies. 2015: 1323-1328.
- [10] Fu X, Liu W, Xu Y, et al. Combine HowNet lexicon to train phrase recursive autoencoder for sentence-level sentiment analysis[J]. Neurocomputing, 2017, 241: 18-27.
- [11] Chen W T, Lin S C, Huang S L, et al. E-HowNet and automatic construction of a lexical ontology[C]//Coling 2010: Demonstrations. 2010: 45-48.
- [12] Ding X, Liu B, Yu P S. A holistic lexicon-based approach to opinion mining[C] //Proceedings of the 2008 international conference on web search and data mining. 2008: 231-240.

- [13] 吴杰胜,陆奎.基于多部情感词典和规则集的中文微博情感分析研究[J].计算机应用与软件,2019,36(09):93-99.
- [14] Bayes T. An essay towards solving a problem in the doctrine of chances[J]. *Biometrika*, 1958, 45(3-4): 296-315. Cortes C , Vapnik V . Support-Vector Networks[J]. *Machine Learning*, 1995, 20(3):273-297.
- [15] Vapnik V N. The Nature of Statistical Learning Theory[M]. The nature of statistical learning theory, 1995
- [16] Pang B, Lee L, Vaithyanathan S. Thumbs up? Sentiment Classification using Machine Learning Techniques[C]. *Empirical Methods in Natural Language Processing (EMNLP)*, 2002: 79-86.
- [17] Sharma A, Dey S. A boosted svm based ensemble classifier for sentiment analysis of online reviews[J]. *ACM SIGAPP Applied Computing Review*, 2013, 13(4): 43-52.
- [18] Mohammad S, Kiritchenko S, Zhu X. NRC-Canada: Building the State-of-the-Art in Sentiment Analysis of Tweets[C]. *Proceedings of the Seventh International Workshop on Semantic Evaluation (SemEval 2013)*. 2013: 321-327.
- [19] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality[C]//*Advances in Neural Information Processing Systems*. 2013:3111-3119.
- [20] Pennington J, Socher R, Manning C D. Glove: Global vectors for word representation[C]//*Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2014: 1532-1543.
- [21] Peters M, Neumann M, Iyyer M, et al. Deep contextualized word representations[C]// *Conference of the North American Chapter of the Association for Computational Linguistics*. 2018:2227-2237.
- [22] Radford A, Narasimhan K, Salimans T, et al. Improving language understanding by generative pre-training[J]. 2018.
- [23] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[C]//*Proceedings of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Minneapolis, May 24. USA: the NAACL-HLT press*, 2019: 4171-4186.

- [24] Liu Z, Lin W, Shi Y, et al. A Robustly Optimized BERT Pre-training Approach with Post-training[C]//China National Conference on Chinese Computational Linguistics. Springer, Cham, 2021: 471-484.
- [25] Lan Z, Chen M, Goodman S, et al. ALBERT: A lite BERT for self-supervised learning of language representations[C]//In 8th International Conference on Learning Representations, ICLR 2020, Addis Ababa, Ethiopia, April 26-30, 2020. OpenReview.net.
- [26] Feng X, Feng X, Qin B, Incorporating commonsense knowledge into abstractive dialogue summarization via heterogeneous graph networks[J]. China National Conference on Chinese Computational Linguistics, Springer, Cham, 2021:127–142.
- [27] Feng X, Feng X, Qin B, et al. Dialogue discourse-aware graph model and data augmentation for meeting summarization[J]. Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence, 2021: 3808–3814.
- [28] Ma Y, Peng H, Khan T, et al. Sentic LSTM: a hybrid network for targeted aspect-based sentiment analysis[J]. Cognitive Computation, 2018, 10 (4): 639–650.
- [29] Baccianella S, Esuli A, Sebastiani F, SentiWordNet3.0: an enhanced lexical resource for sentiment analysis and opinion mining[C] //Language Resources and Evaluation. European Language Resources Association, 2011, pp. 2200–2204.
- [30] Cambria E, Li Y, Xing F X, et al. SenticNet 6: Ensemble application of symbolic and subsymbolic ai for sentiment analysis [C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management, 2020: 105–114.
- [31] B. Liang, H. Su, L. Gui, et al. Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks [J]. Knowledge-based systems, 2022: 107243
- [32] Ayetiran E F. Attention-based aspect sentiment classification using enhanced learning through CNN-BiLSTM networks[J]. Knowledge-Based Systems, 2022, 252: 109409.
- [33] Collobert R, Weston J. A unified architecture for natural language processing: Deep neural networks with multitask learning[C]//Proceedings of the 25th international conference on machine learning. 2008: 160-167

- [34] Kim Y. Convolutional neural networks for sentence classification[C] //Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg. 2014: 1746-1751.
- [35] Lai S, Xu L, Liu K, et al. Recurrent convolutional neural networks for text classification[C]//Proceedings of the 29th AAAI Conference on Artificial Intelligence. 2015: 2267–2273.
- [36] Kalchbrenner N, Grefenstette E, Blunsom P. A Convolutional Neural Network for Modelling Sentences[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2014: 655-665.
- [37] Dauphin Y N, Fan A, Auli M, et al. Language modeling with gated convolutional networks[C]//International conference on machine learning. PMLR, 2017: 933-941.
- [38] Conneau A, Schwenk H, Le Cun Y, et al. Very deep convolutional networks for text classification[C]//15th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2017. Association for Computational Linguistics (ACL), 2017: 1107-1116.
- [39] 汪林,蒙祖强,杨丽娜.基于多级多尺度特征提取的 CNN-BiLSTM 模型的中文情感分析[J].计算机科学,2023,50(05):248-254.
- [40] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80.
- [41] Sun K, Zhang R, Mensah S, et al. Aspect-Level Sentiment Analysis Via Convolution over Dependency Tree[C] //Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). 2019: 5679-5688.
- [42] Beck D, Haffari G, Cohn T, Graph-to-sequence learning using gated graph neural networks[J]. Proceedings of ACL, 2018:273–283.
- [43] Wang K, Shen W, Yang Y, et al. Relational graph attention network for aspect-based sentiment analysis[J]. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics Association for Computational Linguistics, 2020: 3229–3238.

- [44] 阳影,张凡,李天瑞.基于情感知识的双通道图卷积网络的方面级情感分析[J].计算机科学,2023,50(05):230-237.
- [45] 李帅,徐彬,韩祎珂等.SS-GCN:情感增强和句法增强的方面级情感分析模型[J].计算机科学,2023,50(03):3-11.
- [46] 谢珺,王雨竹,陈波,张泽华,刘琴.基于双指导注意力网络的属性情感分析模型[J].计算机研究与发展,2022,59(12):2831-2843.
- [47] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [48] Manning C D, Surdeanu M, Bauer J, et al. The Stanford CoreNLP natural language processing toolkit[C]//Proceedings of 52nd annual meeting of the association for computational linguistics: system demonstrations. 2014: 55-60.
- [49] 刘挺,车万翔,李正华. 语言技术平台[J]. 中文信息学报, 2011, 25(6):53-63.
- [50] Schmitt X, Kubler S, Robert J, et al. A replicable comparison study of NER software: StanfordNLP, NLTK, OpenNLP, SpaCy, Gate[C]//2019 Sixth International Conference on Social Networks Analysis, Management and Security (SNAMS). IEEE, 2019: 338-343.
- [51] Pontiki M, Galanis D, Pavlopoulos J, et al. Semeval-2014 Task 4: Aspect Based Sentiment Analysis[C]// The 8th International Workshop on Semantic Evaluation, 2014: 27-35.
- [52] Dong L, Wei F, Tan C, et al. Adaptive Recursive Neural Network for Target-dependent Twitter Sentiment Classification[C]// Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, 2014: 49-54
- [53] Wang Y, Huang M, Zhu X, Zhao L, Attention-based LSTM for aspect level sentiment classification, in: Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016:606-615.
- [54] Ma D, Li S, Zhang X, et al. Interactive attention networks for aspect-level sentiment classification [J]. Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, 2017, Melbourne, Australia, August 19-25, 2017: 4068-4074.
- [55] Chen P, Sun Z, Bing L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing EMNLP, Association for Computational Linguistics, 2017:452-461.

- [56] Xu Q, Zhu L, Dai T, et al. Aspect-based sentiment classification with multi-attention network[J]. *Neurocomputing*, 2020, 388: 135–143.
- [57] Gu S, Zhang L, Hou Y, et al. A position-aware bidirectional attention network for aspect-level sentiment analysis [C]// *Proceedings of the 27th International Conference on Computational Linguistics*, 2018: 774–784.
- [58] Shuang K, Gu M, Li R, et al. Interactive POS-aware network for aspect-level sentiment classification [J]. *Neurocomputing*, 2021, 420: 181–196.
- [59] Huang B, Guo R, Zhu Y, et al. Aspect-level sentiment analysis with aspect-specific context position information [J]. *Knowledge-Based Systems*, 2022, 243: 108473.
- [60] Zhang C, Li Q, Song D. Aspect-based sentiment classification with aspect-specific graph convolutional networks [J]. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, 2019:4567–4577.
- [61] Sun K, Zhang R, Mensah S, et al. Aspect-level sentiment analysis via convolution over dependency tree [C]//*Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, 2019: 5679–5688.
- [62] Zhang M, Qian T. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]//*Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2020: 3540-3549.
- [63] Tang H, Ji D, Li C, et al. Dependency Graph Enhanced Dual-transformer Structure for Aspect-based Sentiment Classification[C]// *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020: 6578-6588.
- [64] Liang B, Yin R, Gui L, et al. Jointly learning aspect-focused and inter-aspect relations with graph convolutional networks for aspect sentiment analysis[C]//*Proceedings of the 28th International Conference on Computational Linguistics*. 2020: 150-161.
- [65] Wang K, Shen W, Yang Y, et al. Relational Graph Attention Network for Aspect-based Sentiment Analysis[C]// *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020: 3229-3238.

- [66] Wang K, Shen W, Yang Y, et al. Relational graph attention network for aspect-based sentiment analysis [J]. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics Association for Computational Linguistics, 2020: 3229–3238.
- [67] Liang B, Su H, Gui L, et al. Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks[J]. Knowledge-based systems., 2022, 235: 107643.
- [68] Li R, Chen H, Feng F, et al. Dual graph convolutional networks for aspect based sentiment analysis [J]. Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers), 2021: 6319–6329.
- [69] Pang S, Xue Y, Yan Z, et al. Dynamic and multi-channel graph convolutional networks for aspect-based sentiment analysis[C]//Findings of the Association for Computational Linguistics: ACL-IJCNLP. 2021: 2627-2636.
- [70] Zhou J, Huang J X, Hu Q V, et al. SK-GCN: Modeling syntax and knowledge via graph convolutional network for aspect-level sentiment classification[J]. Knowledge-Based Systems, 2020, 205(3): 1-10.
- [71] Li Y, Sun X, Wang M. Embedding extra knowledge and A dependency tree based on A graph attention network for aspect-based sentiment analysis[C]//2021 international joint conference on neural networks. Shenzhen: IJCNN, 2021: 1-8.

致 谢

行文至此，思绪翻涌。研究生三年时光如白驹过隙，转瞬即逝。听闻这路遥马急的人世间只有硕士三年最值得怀念。时光抬眼，岁月低头，回顾三年生活，有不舍，有遗憾，但更多的是收获良师益友，我想“告别”不是再见，而是新的开始。

桃李不言，下自成蹊。首先，我要向我的导师李强教授致以最诚挚的感谢和深深的敬意。李强教授在整个研究过程中给予了我悉心的指导和无私的支持。他丰富的学术知识和深厚的研究经验为我的研究提供了宝贵的指导和启发。除了学术上的指导外，李强教授还关心我的个人成长和生活情况。我将终身受益于他的指导和教诲，在今后的学术道路上不断努力，以回报他的关怀和期望。最后，我要衷心感谢李强教授对我的信任和支持。

春晖寸草，山高海深。感谢父母的关心与无私奉献让我顺利完成三年学业。养育之恩无以为报，只愿在以后的日子里成为父母的依靠与骄傲。感谢您一路支持我走到现在，养育之恩，无以回报，只有不断努力，在未来为你遮风挡雨，只愿您身体健康、欢欣长久。

山水一程，有幸相遇。我还要感谢实验室的所有成员，师兄黄建民，师姐王雪绒，同门李聪聪，师弟何博文、张永富，师妹张昭云、张艺华。在整个研究过程中，他们给予了我无私的帮助和支持，让我感受到了团队的温暖和互助。在学习和生活的道路上，我要衷心感谢我的同学吴义稳、陈贵富、孙梦泽、韩运龙、李士伟、段会雨、宋思良、孙宏进，是你们的陪伴和支持让我的研究生生活更加丰富多彩。

在我人生的旅途中，我要特别感谢女朋友杨雅如，前路漫漫、幸有你伴，你是我生活中最重要的人之一，你的存在给予了我巨大的力量和支持。感谢我们没有彼此错过。感谢你带给我的快乐，感谢你的每一个笑脸，感谢你对我的包容，落日归山海，烟火向星辰，愿我们携手共进，朝朝暮暮。

最后，我要感谢百忙之中抽出时间来评审我的论文的各位专家教授以及答辩委员会的老师，感谢你们对本文的指导与宝贵意见！

攻读硕士学位期间发表的论文及科研情况

已发表论文:

[1] Zhao J Y, Li Q, Li C C, et al. A fused syntactic information tree model for aspect-level sentiment analysis[C]//Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series. 2023, 12717: 127172V.

专利:

[1]赵金雨, 李强等, 一种块茎作物收获机, 专利号: ZL 2023 20157791.3。