

分类号 C93/80
U D C 0004971

密级 公开
编号 10741

兰州财经大学

LANZHOU UNIVERSITY OF FINANCE AND ECONOMICS

硕士学位论文

论文题目 基于深度学习的多通道餐饮评论
细粒度情感分析

研究生姓名: 秦精俏

指导教师姓名、职称: 王玉珍 教授

学科、专业名称: 管理科学与工程

研究方向: 电子商务

提交日期: 2023年6月6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： 秦精俏 签字日期： 2023年5月20日

导师签名： 王王 签字日期： 2023年5月20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內容。

学位论文作者签名： 秦精俏 签字日期： 2023年5月20日

导师签名： 王王 签字日期： 2023年5月20日

Fine-grained emotional analysis of multi-channel restaurant reviews based on in-depth learning

Candidate: Qin Jingqiao

Supervisor: Wang Yuzhen

摘要

情感分析作为自然语言处理的重要内容，在电子商务快速发展的今天有着广泛应用。然而，传统情感分析利用情感词典的方法，给予整条综合性评论单一情感极性，忽略了对多个不同角度情感的细化分析。因此，为进一步准确高效地分析综合性评论不同方面的情感，本文基于深度学习方法，构建了多通道餐饮评论细粒度情感分析模型，从优化细粒度情感分析模型和特征提取准确率两个角度展开研究。其中，情感分析模型的研究是粒度化餐饮评论情感极性，采用多通道方式提高各粒度情感分析的准确率，进而有针对性的挖掘综合性评论中的潜在价值；优化特征提取的研究是改进 Bert 预训练模型，构建餐饮评论词向量表，引入开源知识图谱，提高对隐式特征的抽取效果。本文主要工作：

(1) 构建了 Bert-BiSRU-Att 单通道餐饮评论细粒度情感分析模型。针对多粒度多极性的多维度情感分析问题，本文提出了 Bert-BiSRU-Att 模型，将 Bert 预训练模型获得的动态词向量输入到单通道 BiSRU-Att 中，从而获得丰富的语义信息。为下阶段优化情感分析模型创造基础。

(2) 构建了 Bert-BiSRU-Att-TextCNN 多通道餐饮评论细粒度情感分析模型。改变单通道模型输入方式，将词句向量以三通道形式分别输入到 BiSRU-Att、TextCNN 和句向量通道中，保留各通道提取到的特征信息、主题词与情感词之间的语义关系，最后输出 13 个粒度的情感极性。实验结果表明，本文所提出的多通道模型较其他模型在细粒度情感分析准确率方面有明显提升。

(3) 构建了 KW-Bert-BiSRU-Att-TextCNN 多通道餐饮评论细粒度情感分析模型。为进一步提高情感分析的准确率，首先优化了预训练模型，引入带有开源知识图谱的预训练模型 K-Bert，标注特殊词汇增加额外特征信息，再基于餐饮评论词向量表，借助 kd-tree 对词向量进行相似度检验，从而高效识别特殊领域的词汇，丰富下游情感分析模型的语义和语法信息；然后将改进后的预训练模型与多通道情感分析模型共同应用于餐饮评论数据集中，从而进一步提高情感分析的准确率；最后通过对比实验，验证本文提出的 KW-Bert-BiSRU-Att-TextCNN 模型的有效性。

关键词：深度学习 细粒度情感分析 局部特征提取 多通道情感分析模型

Abstract

As an important part of natural language processing, emotion analysis is widely used in today's rapid development of e-commerce. However, traditional sentiment analysis utilizes the method of sentiment dictionaries to provide a single emotional polarity for the entire comprehensive comment, neglecting the detailed analysis of multiple emotions from different perspectives. Therefore, in order to further accurately and efficiently analyze the emotions of different aspects of comprehensive reviews, this article constructs a multi-channel fine-grained sentiment analysis model for restaurant reviews based on deep learning methods, and conducts research from two perspectives: optimizing the fine-grained sentiment analysis model and feature extraction accuracy. Among them, the research on sentiment analysis models focuses on granular emotional polarity in food and beverage reviews, using a multi-channel approach to improve the accuracy of sentiment analysis at each granularity, and then targeted exploration of the potential value in comprehensive reviews; The research on optimizing feature extraction is to improve the Bert pre training model, construct a vector table of restaurant comment words, introduce open-source knowledge graph, and improve the extraction effect of implicit features. The main work of this article is:

- (1) A Bert-BiSRU-Att single-channel fine-grained emotional analysis model for restaurant reviews was constructed. In order to solve the problem of multi-dimensional emotion analysis with multi granularity and multi polarity, this paper proposes a Bert-BiSRU-Att model, which inputs the dynamic word vector obtained by Bert pre training model into a single channel BiSRU-Att to obtain rich semantic information. Create a foundation for optimizing the emotional analysis model in the next stage.

(2) A Bert-BiSRU-Att-TextCNN multi-channel fine-grained emotional analysis model for restaurant reviews was constructed. Change the input method of the single channel model, input the phrase and sentence vectors into the BiSRU-Att, TextCNN, and sentence vector channels in three channels, preserve the feature information extracted from each channel, and the semantic relationship between the subject word and the emotional word. Finally, output 13 granularity emotional polarity. The experimental results show that the multi-channel model proposed in this paper significantly improves the accuracy of fine-grained emotional analysis compared to other models.

(3) A KW-Bert-BiSRU-At-TextCNN multi-channel fine-grained emotional analysis model for restaurant reviews was constructed. In order to further improve the accuracy of emotion analysis, the pre training model was first optimized, and the pre training model K-Bert with an open source knowledge map was introduced. Special words were labeled to add additional feature information. Then, based on the food and beverage review word vector table, word vectors were tested for similarity using kd-tree, thereby efficiently identifying words in special areas and enriching the semantic and grammatical information of downstream emotion analysis models; Then, the improved pre training model and multi-channel emotional analysis model are applied to the food and beverage review data set to further improve the accuracy of emotional analysis; Finally, through comparative experiments, the validity of the KW-Bert-BiSRU-At-TextCNN model proposed in this paper is verified.

Keywords: Deep learning; Fine grained emotional analysis; Local feature extraction; Multi channel emotional analysis model;

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 主题词特征提取.....	2
1.2.2 细粒度情感分析.....	6
1.2.3 文献述评.....	8
1.3 研究内容与框架.....	9
1.3.1 研究内容.....	9
1.3.2 研究框架.....	10
1.4 论文创新点.....	11
1.5 本章小结.....	11
2 相关理论与技术	12
2.1 文本预处理.....	12
2.1.1 数据清洗.....	12
2.1.2 分词.....	12
2.1.3 去停用词.....	12
2.2 词向量预训练模型.....	13
2.2.1 静态词向量.....	13
2.2.2 动态词向量.....	16
2.3 相关深度学习模型.....	18
2.3.1 BiLSTM 基线模型.....	18
2.3.2 BiSRU 基线模型.....	19
2.3.3 多头自注意力机制.....	21
2.3.4 TextCNN 基线模型.....	23
2.4 本章小节.....	24
3 餐饮评论细粒度情感分析流程及数据预处理	25

3.1 餐饮评论细粒度情感分析流程	25
3.2 餐饮评论数据集及预处理	25
3.3 本章小结	29
4 Bert-BiSRU-Att 单通道细粒度情感分析模型	30
4.1 概述	30
4.1.1 当前方法的不足及面临的问题	30
4.1.2 本文采用方法	30
4.2 Bert-BiSRU-Att 的单通道模型构建	31
4.2.1 输入层	31
4.2.2 BiSRU-Att 层	32
4.2.3 输出层	32
4.3 实验对比与分析	34
4.3.1 实验环境	34
4.3.2 评价指标	34
4.3.3 参数设置	36
4.3.4 对比实验与结果分析	36
4.4 本章小结	38
5 Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型	39
5.1 概述	39
5.1.1 当前方法不足及面临的问题	39
5.1.2 本文采用的方法	39
5.2 Bert-BiSRU-Att-TextCNN 的多通道模型构建	39
5.2.1 输入层	40
5.2.2 三通道层	40
5.2.3 融合层	42
5.2.4 输出层	43
5.3 实验对比与分析	44
5.3.1 参数设置	44
5.3.2 对比试验及结果分析	44

5.4 本章小结	47
6 KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型	48
6.1 概述	48
6.1.1 当前方法不足及面临的问题	48
6.1.2 本文采用的方法	48
6.2 构建餐饮领域情感词向量表	49
6.3 KW-Bert 预训练模型构建	50
6.3.1 知识层	51
6.3.2 嵌入层	52
6.3.3 可视化层	53
6.3.4 词向量-知识图谱增强的 Transformer 层	53
6.3.5 词典适配器层	54
6.4 KW-Bert-BiSRU-Att-TextCNN 多通道模型构建	56
6.5 实验对比与分析	56
6.5.1 预训练模型参数设置	56
6.5.2 预训练模型对比实验及结果分析	57
6.5.3 KW-Bert-BiSRU-Att-TextCNN 对比实验及结果分析	57
6.6 本章小结	58
7 总结与展望	59
7.1 总结	59
7.2 展望	59
参考文献	61
致 谢	67
攻读硕士学位期间发表的论文及科研情况	68

1 绪 论

1.1 研究背景及意义

1.1.1 研究背景

随着移动互联网快速发展，餐饮业逐步实现网络化、平台化。餐饮业蓬勃发展，使得大量真实的网络评论涌现。网络评论对用户的决策和店铺的曝光率有较大影响，一方面用户在做决策时面对杂乱的信息，存在信息不全面、不对称等问题，因此渴望通过网络评论提前获取餐品和服务的相关信息，从而降低时间、资金及决策成本；另一方面，美团、饿了么、大众点评等 APP 集中了大量餐饮店铺，用户的综合性评论深刻揭示店铺存在的痛点、盲点问题，有助于店铺进一步改进餐品、优化管理。可见，餐饮评论蕴含着丰富的情感信息，具有一定研究意义。

情感分析作为自然语言处理的重要组成部分，是近年来的研究热点之一。大数据时代的到来，使得海量评论数据涌现，为了解决人工处理速度慢的问题，研究者以用户评论为研究对象，运用机器学习和深度学习的方法对评论文本进行情感极性判别。这类方法不同于静态词典方法，而是以更加灵活的动态词向量方式处理评论。相较于静态词典的分析方法，动态词向量可增强对综合性评论的语义及语法理解，实现对评论数据的情感极性判别。因此，基于深度学习的情感分析方法是处理海量评论数据的有效手段。

情感分析主要分为粗粒度情感分析和细粒度情感分析，粗粒度情感分析只能通过计算情感强度来判别综合性评论的积极或者消极情感。而现实生活中，用户往往更加关注多个不同方面的情感极性。因此，细粒度情感分析应运而生，其在数据预处理阶段通过信息提取、主题词共现得到综合性评论所含的粒度词，再利用预训练模型将评论数据转化为词句向量，然后利用深度学习模型训练，输出不同粒度词下所对应的情感极性。

因此，本文以餐饮评论细粒度情感分析为研究内容，通过优化特征提取的预训练模型和情感分析模型，以提高特征提取和情感分析的准确率，进一步丰富细粒度情感分析领域的研究成果。

1.1.2 研究意义

(1) 理论意义：传统粗粒度情感分析没有细分主题词，未能对每个主题词所涉及到的情感类别进行分析，会带来粒度划分单一问题。本文针对餐饮评论数据，划分4个一级粒度指标和13个二级粒度指标，细化评论的粒度词，构建情感分析模型，得到更加细化的情感极性。同时，建立起主题词与其情感词之间的联系，优化预训练模型特征提取，提高对隐式信息的提取能力。最终构建了KW-Bert-BiSRU-Att-TextCNN的多通道细粒度情感分析模型，从而提高情感分类的准确率。因此，通过本文的研究，可进一步优化餐饮评论细粒度情感分析模型，拓宽细粒度情感分析领域的研究范围。

(2) 现实意义：从实际应用来看，餐饮评论细粒度情感分析对用户、商家、外卖平台都具有重要意义。对用户而言，不必翻阅大量褒贬不一的评论信息，通过餐饮评论细粒度情感分析，可以得出不同餐品各属性的情感倾向，为选择质优物美的餐品提供决策支持；对商家而言，消费者评论中包含着大量有价值的信息，挖掘用户评论是改进餐品和提高服务质量的重要依据；对外卖平台而言，餐饮评论细粒度情感分析，可应用于平台的个性化推荐和食品安全方面。前者可以根据用户喜好推荐个性化餐品，从而精准满足用户需求；后者对于违反食品安全规则的商家或者餐品提出警告或做下架处理。综上所述，对餐饮评论进行细粒度情感分析具有非常重要的现实意义及应用价值。

1.2 国内外研究现状

细粒度情感分析涉及到主题词特征提取和细粒度情感分析两方面的工作，本节将分别从以上两个方面对研究现状进行阐述。

1.2.1 主题词特征提取

细粒度主题词特征提取可自动识别评论文本中的属性元素，是情感分析的关键步骤^[1]。根据细粒度主题词提取过程的表现方式，将其分为显式特征提取和隐式特征提取。其中，显式特征提取是指评论文本中可提取到明显的关键词；隐式特征提取则是提取到评论文本不明显的情感词或语义表达。

(1) 显式特征提取

根据提取对象不同，显式特征提取可以分为对评价对象的特征提取、评价情感词的特征提取及二者关系的特征提取^[2]。

评价对象特征提取是指提取评论中的主体对象，如在餐饮领域，主题词包括“服务”、“菜品”、“环境”等，在电子产品领域，主题词包括“续航”、“外观”、“内存”、“系统”等。准确提取评论对象的主题词，对提升细粒度情感极性准确率有着重要的意义。研究者通过优化各种网络模型，以提高特征提取的准确率，如 Irsoy 等人^[3]通过采用 RNNs 模型，对 MPQA1.2 中的评论句子进行对象提取，通过对比分析表明，RNNs 表现优于传统的浅层循环神经网络和半马尔可夫模型；Sang 等人^[4]摒弃原有话题模型和种子意见词作为先验知识的提取方式，采用词嵌入和无监督聚类的方法得到话题词，并以头部嵌入的方式提取到正确的评价对象；Peng 等人^[5]提出采用树形核的方法来提取方面特征，树形核不仅编码了句法结构信息，而且编码了情感相关信息，通过两树之间的相似度找到评价对象和方面级之间的联系；Lau^[6]等人基于 LDA 和 Gibbs 融合模型，提取了评论文本的显性信息，建立了包括显性和隐性的本体属性特征，并将提取的属性信息和情感词以本体的形式输出，实验结果表明，相较于 OpinionFinder 极性情感词典，准确率提高了 11.6%；Wang 等人^[7]将改进的 FL-LDA 和 UFL-LDA 两个半监督模型应用于商品属性提取中，通过计算属性间余弦相似度的方式来评估提取效果，实验结果表明，UFL-LDA 在 Hotel 数据集中熵值损失比 FL-LDA 降低了 13%，在 Camera 数据集中熵值损失比 FL-LDA 降低了 19%；Yan 等人^[8]建立了一种基于扩展的 PageRank 模型的新提取方法，该方法利用属性词和情感词之间的语法依赖关系扩展评价对象属性词，使用同义词词典对 PageRank 进行扩展，采用三种标准数据集进行验证，实验结果表明，改进的 PageRank 在提取产品属性的准确率方面有着明显提升。

评论文本情感词的特征是指修饰评价对象的词，通常这些情感词的词性可以是名词、动词、形容词等^[9]。在提取情感词的过程中，Fermín 等人^[10]采用基于随机森林的情感词典扩充方法，对情感词进行分类，同时定义了特定领域的词典对情感词进行提取，实验结果相较于仅通过情感词典提取情感词的方法有明显提升^[11]；Tan 等人^[12]对传统语料库存在的扩展性不足，冗余度高等问题进行分析后，提出一种基于有限状态匹配机的框架来提取情感元素，首先对情感元素进行列表匹配，然后将列表数据作为 FSM 进行情感元素提取，最后通过特定规则来过滤掉不合法的特征-观点对，实验结果表明所提出的框架解决了提取过程冗余度高的问题；陈炳丰等人^[13]首先采用 Linear-chain CRF 模型进行情感

实体识别和提取，然后对 Linearchain CRF 模型进行改进，解决识别和提取对应不准确的问题，并在汽车评论数据集上进行验证，实验结果表明，改进后的 CRF 有突出表现；Zhu 等人^[14]提出基于句子级别的特征分割模型，利用 bootstrapping 算法对未被标注的评论文本进行多特征的情感词提取，情感词的提取准确率达到 75.5%；Tang 等人^[15]基于 Twitter 语料库构建情感词典（TSlex），建立专门的神经网络架构作为情感分类器，对情感词的提取进行分类，采用分布式表示方法，获得一个由少量人工批注的训练数据集，经过对比实验发现该方法提取的情感词准确率较高；Lin 等人^[16]加入修正参数对联合情感-话题模型进行改进，在建模过程中将情感和话题的生成顺序颠倒，得到反向 JST，利用双向 JST 提取积极和消极情感主题，实验结果表明，提取的准确性为 76.6%。

将评价对象与所修饰的情感词进行一一对应，使之以二元对的形式搭配出现，考虑评论对象和情感词之间的关系，可以避免由于位置因素导致情感分析过程中，因不同粒度产生的歧义问题，从而提高分类过程中的准确性。彭云等人^[17]从句法、词义理解和语境等多个角度，提取评论文本的特征词和情感词之间的语义关系，并将其作为约束性知识嵌入主体模型，从而提高了 LDA 对语义理解和情感词对的识别效果；Liu K 等人^[18]提出一种基于部分监督的对齐模型，使用图的协作排序算法来估计每个候选人的可信度以此来提取意见词对，实验结果表明，该方法更精确地捕捉到了属性与情感词之间的关系，尤其是对长距离文本的二元对提取效果更优；Qiu 等人^[19]采用标准数据集，通过语法与词典搭配提取意见关系，实验结果表明，双重传播的提取方式优于现有的其他方法；Liu 等人^[20]提出以模糊领域的本体树为基础，构建一种新型特征级情感分析机制，有效提取特征词、情感词及两者之间的语义关系，实验结果表明，模糊本体树特征提取的准确率达 77.8%；Hai 等人^[21]利用关联度量来量化词语之间的依赖关系，提出基于关联词的自举方法，提取显著的情感对象和特征情感词，对评论文本中每一对关联词进行 LRTs 和 LSA 检验，实验结果表明，相比于基准方法，此方法在 Hotel 数据集中 F1 提高 3.43%，在 Phone 数据集中 F1 值提高 6.79%；肖璐等人^[22]以词性为基础，分别对产品特征、情感词进行成对提取，然后根据情感词的强度确定优势特征和劣势特征的各自的权重值，再通过相似度计算识别产品的主要竞争对手和次要竞争对手，但只对显式特征进行提取，并

未对隐式特征进行相关研究。

可见，在显式抽取主题的过程中，研究者分别采用监督、半监督以及无监督的方法结合特定领域的情感词典来提取不同属性，以提高评论文本显式特征提取的准确率。但中文文本评论中，往往会出现观点词和属性词数量不匹配的情况，这是因为在评论文本中存在着未被提取的隐含属性，这就需要进一步研究评论的隐式特征提取。

（2）隐式特征提取

为进一步挖掘评论的情感信息，弥补观点词和属性词数量不匹配的问题。Yang 等人^[23]为获得与核心词相互关联的隐式信息，利用相似度检验评估指示代词与方面名词之间的隐式关系，基于 ACE 数据，验证以上方法识别提取隐式信息方面有良好的效果；郎君等^[24]提出集成多种语义背景知识作为二元分类特征的方法，基于原有的浅层语义来消解词的上下文本特征，进一步挖掘深层语义信息；Amplayo 等人^[25]解决了 ABSA 模型中存在方面术语提取不规范、标签标注有误的问题，提出了买方情感模型（SA-ASM）和卖方情感模型（SA-PSM），在提取隐式特征过程中表现出更多微观情感；Zeng 等人^[26]提出基于规则的方法来提取隐式特征，首先提取显式“特征-情感”词对，然后对显式情感词对聚类，构建每个聚类的训练文档，最后将隐式文本识别转化为分类特征选择；Lazhar 等人^[27]针对现有隐式提取技术进行改进，建立“显式特征-意见”的关联规则并重新分组，在分组基础上建立分类模型，实验结果表明，纳入多种意见词的隐式特征提取效果比单一词准确率高；Sun 等人^[28]基于中文评论数据集，提出基于语境的隐性特征提取方法，构建关系矩阵表示意见词和产品特征之间的关系，通过关系矩阵相似性提取隐式特征，最后通过打分机制筛选隐式特征；Hua 等人^[29]构建 LDA 主题模型对显式评论进行特征提取，将关联性参数和约束性参数作为输入参数输入到 SVM 分类器中，对隐式句子进行特征分类，实验结果表明，包含先验知识的显式主题模型在很大程度上优于传统的特征选择方法和其他现有方法；唐晓波等人^[30]为解决隐式特征对情感分析准确率的影响，提出了一种基于特征本体的产品评论情感分析方法，通过计算情感词与特征之间的权重，构建相应字段信息，并计算评论的极性和情感强度，以有效识别隐性特征。

由此可见，国内外研究者在隐式属性提取方面虽有一定的研究成果，但是

由于隐式特征提取确实是情感分析研究的难点，其在文本评论中通常难以被准确提取，从而影响情感极性的判定。因此，本文尝试在将显式特征和观点词提取完成后，通过改进预训练模型对隐式特征进行进一步提取，获得更加丰富的语义及语法信息，提升下游情感分析模型的准确率。

1.2.2 细粒度情感分析

随着互联网在各领域的迅速渗透，出现了海量的评论数据，对评论数据进行情感分析，可高效且准确地识别评论文本的情感极性，具有重要的应用价值。细粒度情感分析是情感分析的重要分支，其目的是将不同的粒度特征词分别输入到情感分析模型中，得到不同方面的情感极性。常见的细粒度情感分析方法有基于情感词典和规则的方法、基于机器学习的方法和基于深度学习的方法。

(1) 基于情感词典和规则的方法

基于情感词典及规则的方法是使用国内外现有的庞大语料库，通过标注情感词句，计算情感得分，获得情感极性的方法。如 **Baccianella** 等人^[31]构建了 **WordNet** 词典，手动收集大量的种子情感词，形成了一个庞大且有效的情感极性库，但是由于 **WordNet** 词典固定不变，应用到不同领域存在词汇量不足、灵活度低、精度不高等问题，同时词典无法考虑到上下文的语义语法关系，因此，现阶段基于情感词典和规则的方法通常作为情感分析的一个补充。随着情感词典构建技术逐渐成熟与完善，研究者通常构建特定领域情感词典，来解决特定领域相关词句识别效率不高的问题。**Deng** 等人^[32]利用未注释过的语料库和词典更新现有的情感词典，实现特定领域的情感分类，实验结果证明，更新后的词典在特定领域情感分类中有着较好的效果；**Khan** 等人^[33]基于信息增益和余弦相似度的方法，优化了 **SentiWordNet** 中情感得分的计算公式，从而提高了情感分类的准确率；**Chihli** 等人^[34]考虑到情感词典无法联系上下文语义信息，建立了三个上下文语义关系词库，保持单词和其相关情感类别之间的对应关系，然后建立四个偏好向量分类器模型，专注于提升口碑质量的情感分类；**Nguyen** 等人^[35]提出基于树核的关系提取，通过成分树和依赖树的树核进行方面观点的提取和情感分析，实验结果表明，改进后的词典准确率提高了 5.8%；**Turney** 等人^[36]对词性进行分类研究，针对以往语义仅考虑了形容词，未考虑副词及短语的情况，首次提出了 **PMI-IR** 算法，对提取出来的短语计算其语义指向，以此来

提高单词之间的语义相关性；Gaikwad 等人^[37]发现文本中的词语对情感影响程度不同，因此采用注意力机制为词典中每一个词分配不同的权重，句中某个词权重越大，对整体的情感极性判别影响越大。在构建情感分类模型中，采用机器学习和情感词典相结合的方式训练和测试数据集，情感分类的准确率提升效果明显。

可见，在实际应用过程中，情感词典常用于辅助方式来增强情感分析的准确率。为进一步提高情感分析的准确率，利用机器学习的方法对评论数据进行情感分类。

（2）基于机器学习的方法

采用机器学习进行情感分类，需要在预训练过程中提取特征，Pang 等人^[38]利用朴素贝叶斯、SVM 和最大熵模型等机器学习分类方法和多特征（Unigram Bigram）模型在不同的参数条件下进行情感分类，实验结果表明 SVM 与 unigram 语言模型的词特征向量相结合，情感分类的准确率最高；Singh 等人^[39]利用 Naïve Bayes, J48, BFTree 和 OneR 四个机器学习分类器，用于情绪的分析判断，对比发现 Naïve Bayes 学习速度最快，OneR 准确率在测试数据集表现最好；Abbas 等人^[40]在贝叶斯、决策树、多层感知器和逻辑回归四个机器学习分类器的基础上，构建社交媒体情感词典，利用词典提取用户偏好，提高情感分类器的准确率；Zou 等人^[41]基于 Naive Bayes 和 SVM 两种机器学习模型，对电影评论进行情感判别，为解决词与词之间的句法特征，生成句法树，分析每个评论的句法特点，实验结果表明，综合多特征因素的情感分类效率和精度均有所提升。但是在机器学习过程中，训练数据集需要依赖人工标注，标注的质量越高，训练的模型越好，因此部分学者对数据标注问题进行了研究，如樊振等人^[42]提出的情感标注的方法，首先基于情感词典对评论文本进行评分，根据评分情况和情感词典进行自动标注，然后，使用机器学习算法对标记的数据进行分类。实验结果表明，改进后的标注方法对准确率的提升有一定效果。

（3）基于深度学习的方法

近年来，深度学习在细粒度情感分析方面有着广泛的应用，一方面深度学习不再依靠人工提取特征，而是通过预训练模型进一步提升评论的语义和语法信息，获得高价值的特征信息；另一方面，利用深度学习进行情感分析，将词语转化成词向量，应用神经网络构建情感分类器，有效解决评论无标签的问

题,从而提高了情感分析的效率。如 Wang 等人^[43]提出强化双向注意力机制的神经网络,结合高质量的语料库,对面向互动式问答的评论进行情感极性的检测,实验结果表明,所提出的 ASC-QA 模型与 LSTM、RAM、GCAE 等多个基线模型相比表现更优;张柳^[44]等人构建基于字词向量的多尺度卷积神经网络模型,通过多尺度的卷积核挖掘评论文本的上下文语义信息,实验结果表明,在微博热搜舆情分析方面表现良好,对提高舆情监管部门的工作效率有重要意义;Yang 等人^[45]提出一种基于卷积神经网络和门控机制的模型,采用 Tanh-ReLU 单元门控来选择性的输出情感极性特征,同时该网络模型结构简化了模型的复杂度,降低了对时间的依赖程度,在 SemEval 数据集上有良好的效果;Guo 等人^[46]为解决管道错误传播的问题,提出方面分类和情感分析联合处理的多向匹配深度神经网络,实验结果表明,相较于基线模型 DocRNNF1 和 EM 的准确率分别提高 3.8%和 0.88%;林哲^[47]等人为解决卷积神经网络稀疏连接和空间不变性的问题,提出一种基于注意力机制模块和 involution 的文本情感分析模型,并在公开数据集中验证模型准确率,实验结果表明,该情感分析模型比词向量卷积神经网络和循环神经网络的准确率分别高 6.74%和 1.07%;郭荣荣^[48]等人提出一种基于图卷积神经网络的细粒度情感分析模型,并在英文公开数据集中进行训练测试,实验结果表明,该模型效果最优。

1.2.3 文献述评

可见目前在细粒度情感分析领域已有不少研究成果,但仍有许多问题需要解决。(1)中文文本评论细粒度情感分析准确率低。世界语言种类繁多,现有的研究成果大多将研究重点放在英文细粒度情感分析中,利用公开的英文数据集,构建英文文本细粒度情感分析模型,由于英文情感词表达更加直接,其情感极性判断的准确率更高,而中文语法结构更复杂且预处理流程不同于英文,许多英文情感分析模型难以应用于中文数据集中。因此,中文文本细粒度情感分析模型若要获得高精度的情感极性难度更大^[49]。(2)应用领域需进一步拓宽。最初细粒度情感分析是应用于电商产品评论文本中,其后随着技术的不断成熟和研究视角的不断扩大,细粒度情感分析在汽车、酒店、教育等行业都有一定的应用,而针对餐饮评论进行细粒度情感分析的研究成果较少。因此,本文对餐饮评论细粒度情感分析进行了较为深入的研究与探索。(3)词典、语料库规范性、全面性不足。在细粒度情感分析的研究过程中,需要利用各领域的

语料资源进行预处理，词典、语料库不全面，格式不规范的问题会影响使用的效率和频率；此外中英文词典、语料库因为语法和句法规则不同，难以实现交互使用，因此构建特定领域、特定语言的词典、语料库是优化细粒度情感分析的必要手段。（4）隐式评论特征提取需进一步优化。由于不同领域的评论表述存在歧义，规范性差等问题，挖掘隐式特征是情感分析的难点。现有的研究成果对隐式特征的提取方式主要是从句子级和单词级两个方面进行静态提取，难以以动态方式提取歧义性语句的隐式特征信息。因此，本文基于 Bert 预训练模型对隐式特征提取进行优化。

基于以上分析，本文的主要工作为：第一，针对中文评论文本在细粒度情感分析准确率低、应用领域少的问题，首先，引入 Zeng^[50] 等人提出 BiSRU 模型，解决循环神经网络不能像卷积神经网络进行并行处理的问题；其次，利用注意力机制，赋予各主题词不同的权重，提高对重要特征的提取效率；再次，基于 TextCNN 模型加强对评论文本局部特征的提取；最后转变输入方式，以多通道输入方式，获取更加丰富句词向量特征信息。采用 BiSRU-Att-TextCNN 的多通道网络模型，对中文餐饮评论进行细粒度情感分析，从而获得各粒度的情感极性。第二，针对隐式特征难提取、缺乏特定领域情感词典的问题，构建了 KW-Bert 预训练模型，通过引入带有开源知识图谱的预训练模型 K-Bert 和构建餐饮词向量表，优化预训练模型特征提取效果，增加额外特征信息，增强了对特殊领域词汇的高效识别，丰富了下游情感分析模型的语义和语法信息。

1.3 研究内容与框架

1.3.1 研究内容

本文的研究内容主要有以下三个方面：

（1）Bert-BiSRU-Att 单通道细粒度情感分析模型的构建。为深入挖掘评论数据的相关特征，解决传统静态词向量一词多义的问题，从多角度挖掘文本的语义和语法信息。对 AI Challenge 餐饮评论数据集进行数据预处理后，首先，基于 Bert 预训练模型，提取评论文本的语义特征；然后，使用 BiSRU 快速理解上下文的语义信息，同时引入注意力机制赋予信息不同的权重，筛选出高价值的信息进行学习，得到 Bert-BiSRU-Att 单通道模型。为保证模型性能稳定，将交叉熵损失函数进一步优化，引入 LSR 损失函数，对不同粒度的标签进行平滑

处理，进而避免了模型的过拟合现象。

(2) Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型的构建。为进一步提高 BiSRU-Att 模型的准确率，引入 TextCNN 模型，以提高模型局部特征提取效果。利用 BiSRU、TextCNN 和多头自注意力机制，首先，采用多通道特征向量融合方式，获得评论文本和粒度词之间全局和局部的语义关系；然后，对三通道的所有特征信息进行合并，生成多特征向量，从而获得对同一条餐饮评论的多层次语义理解，提高餐饮评论细粒度情感分析的准确率；最后，经过与基线模型对比，验证了该模型的有效性。

(3) KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型的构建。首先，对预训练模型的特征提取方式进行优化，为进一步提高细粒度情感分析的效果，将带有[实体，关系，实体]的预训练模型 K-Bert 与自建的餐饮领域情感词向量表相结合，以 HowNet 开源知识图谱为辅助，通过在 K-Bert 网络结构层中加入词典适配器，从而提高对特定领域隐式特征信息的提取效果。并通过 KW-Bert 与 Bert、Albert、K-Bert 三个预训练模型对比实验，验证了 KW-Bert 模型在隐式特征提取方面的有效性；然后将 KW-Bert 预训练模型与 BiSRU-Att-TextCNN 多通道情感分析模型融合，并在餐饮评论数据上进行了对比实验，验证了本文所提出的细粒度情感分析模型的优越性。

1.3.2 研究框架

文章共分为七章，结构及各章节内容简介如下：

第一章：绪论。本章首先介绍了餐饮评论细粒度情感分析的研究背景及意义；其次对现阶段细粒度特征提取和情感分析两方面的研究现状进行分析和总结；最后阐述了文章的主要研究内容、框架及创新点。

第二章：相关理论和技术。本章主要介绍了文本预处理方法、细粒度情感分析常用的预训练模型和基于深度学习的情感分类模型，为本文的研究奠定了理论基础。

第三章：餐饮评论细粒度情感分析流程及数据预处理。本章首先总体介绍了餐饮评论细粒度情感分析的流程；然后介绍了本文使用的中文餐饮评论数据集；最后对数据集进行预处理，获得适用于情感分析模型的序列文本。

第四章：Bert-BiSRU-Att 的单通道细粒度情感分析模型。本章阐述了单通道细粒度情感分析模型的构建思路及过程，并通过对比实验，分析了该模型进

一步优化的可能性。

第五章：**Bert-BiSRU-Att-TextCNN** 多通道细粒度情感分析模型。本章引入 TextCNN 模型增加对局部特征的提取，进一步提高模型情感分类效果。改变词句向量输入方式，按照不同的通道提取中文餐饮评论文本中的特征，并通过对比实验，验证该模型的有效性。

第六章：**KW-Bert-BiSRU-Att-TextCNN** 多通道细粒度情感分析模型。本章首先对预训练模型的特征提取方式进行优化，引入带有知识图谱的预训练模型 K-Bert，并与自建的餐饮领域情感词向量表相结合，构建了 KW-Bert 特征提取优化模型，并通过与 Bert、Albert、K-Bert 三个预训练模型进行对比，验证了该模型的有效性；然后将 KW-Bert 与 BiSRU-Att-TextCNN 多通道情感分类模型进行融合，构建了 KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型，并通过对比实验，验证该模型的有效性。

第七章：总结和展望。对本文所做的工作进行总结，分析目前研究的不足，并针对不足之处展望下一阶段的工作。

1.4 论文创新点

本文的创新点主要包括以下两个方面：

第一，构建了 Bert-BiSRU-Att-TextCNN 多通道餐饮评论细粒度情感分析模型。为了提高情感分析的准确性，本文以深度学习模型为基础，改变词句向量输入方式，引入卷积神经网络，以三通道方式将 BiSRU-Att,TextCNN 和 Bert 句向量融合，在保证不影响整体语义语法的情况下，获得更加丰富的局部特征信息，从而提高情感分析的准确率。

第二，对预训练模型的特征提取方式进行优化。为改善隐式信息难提取的问题，在预训练模型中引入开源知识图谱，增加隐式特征实体与关系之间的识别；同时构建餐饮领域情感词向量表，提高特定领域隐式特征信息的提取效果，从而提高词句向量的特征提取准确率。

1.5 本章小结

本章主要介绍了论文的研究背景及研究意义，系统分析了特征提取和情感极性判断两方面的国内外研究现状，并在此基础上，介绍了本文的研究内容、研究框架以及创新点。

2 相关理论与技术

情感分析作为自然语言处理过程中的热点问题，因可识别评论中的情感倾向，对用户和商家有重要的现实意义。本章针对文章所研究的相关内容，分析了研究过程中需要的相关理论和技术。

2.1 文本预处理

中文文本评论信息作为机器不能识别的“自然语言”，在对其进行情感分析时，应当把评论文本转化为机器能理解的“符号语言”，即需将文本进行序列化处理，主要流程为：数据清洗、分词、去停用词三部分。通过数据清洗使得数据更加规范；采用分词技术将句子转化为词；利用停用词表，去除无用的停用词，最终转化为机器可以识别的序列形式。

2.1.1 数据清洗

首先，通过“繁化简”将评论中出现的繁体字转化为简体字，对特殊符号进行正则化处理，保留特殊符号中包含的情感倾向；其次，删除空白及多余符号，节约内存空间；最后是处理缺失值的问题，在数据清洗过程中遇到缺失值问题有多种解决方式，针对数据的实际情况，可采用删除相应样本或插补缺失数据值两种方法，尽最大可能避免信息的丢失。

2.1.2 分词

中文文本评论信息是由字和词组成的连续性字符串，为充分理解语义，需要将句子划分为词，构成词序列。中文语句并不会出现英文语句的空格间隔，因此中文不能通过简单的标点和空格进行分词。如在英文中“The food is delicious”，它的中文意思是“食物很好吃”，单词“food”、“is”和“delicious”都有实际含义，但是在中文语义表达过程中，计算机将“食物”分开，该句的意思将无法完整表达，故本文使用jieba分词，其方便快捷且最大限度的保留原有的句法关系和语法关系，并且jieba分词支持自定义添加词典，能够满足特定领域词句划分的需求。

2.1.3 去停用词

停用词通常在文本中起连接、补充的作用，一般无实际意义，所以在整条评论中对情感极性的判别无明显导向性作用，因此可以去掉。中文文本评论中容易出现大量的“了”，“呢”，“的”等语气助词，这些词偏口语化，并不

能对下游分析产生作用，如果保留并将所有文字转化成“语言符号”反而浪费了算力和内存，因此为凸显情感词的内容，将一些不重要的语气助词进行删除。同时，在处理评论文本时发现，表情符、错别字、繁体字等数据相较于语言文本不同，可能会对实际情感极性产生副作用，因此采用正则化方式处理表情符，用繁化简字典对繁体字进行一一映射，使得繁体字得以转化为简体字，进一步降低文本的“噪声”，提高情感分析的准确率。

2.2 词向量预训练模型

在细粒度情感分析中，首先考虑的是将粒度最细的字、词、句进行符号化表示，使其成为可被机器识别的数值形式。本节分别从静态词向量和动态词向量展开介绍。

2.2.1 静态词向量

静态词向量是指不会因上下文语义信息的变化而改变向量表示，只有唯一的词向量表示。常见的静态词向量预训练模型包括 Word2vec 和 Glove。

(1) Word2vec 词向量表示

Word2vec 是一种基于神经网络的静态词向量预训练模型。它通过计算单词之间的关系来确定词的向量化表示。常见的两种结构为 CBOW 和 Skip-gram。

CBOW 使用目标词的几个上下文词汇作为输入，预测目标词的词向量。设长度为 t 的固定窗口， w_t 为预测的目标词，窗口内其他的词 $[w_{t-n}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+n}]$ 是与之相邻的上下文词汇，模型结构如图 2.1 所示。处理过程为：首先，根据式 (2.1) 计算每个单词出现的概率；然后，通过映射层对多个输入的词向量之和进行共享矩阵的乘积操作；最后，确定维度后通过输出层归一化输出。

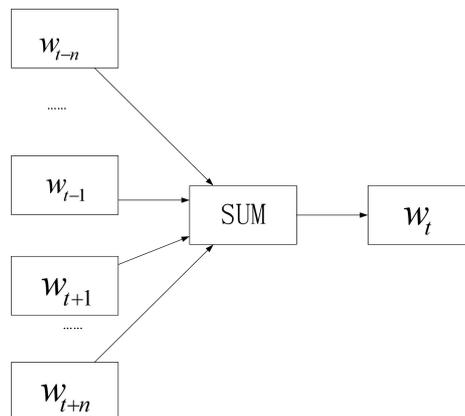


图 2.1 CBOW 模型图

$$y = \text{soft max}(p_i) = \frac{\exp(p_i)}{\sum_{k=1}^K \exp(p_i)}$$

$$h = E(w_{t-n} + \dots + w_{t-1} + w_{t+1} + \dots + w_{t+n}) \quad (2.1)$$

$$y = \text{soft max}(h_k) = \frac{\exp(V_k^T h_k)}{\sum_{k=1}^K \exp(V_k^T h_k)}$$

其中， p_i 为目标词第 i 个类别的概率， E 代表输入层到隐藏层的共享权值矩阵， V 代表隐藏层到输出层的共享权值矩阵。

而 Skip-gram 的模型结构则与 CBOW 相反，如图 2.2 所示，其输入向量是序列中任意的 w_t ，首先，将该目标向量通过线性变化得到词向量；然后，计算目标向量与上下文词语间的概率；最后，输出文本序列。Skip-gram 的模型结构为三层，其计算过程如式 (2.2) 所示，参数所表示的含义与上文一致。

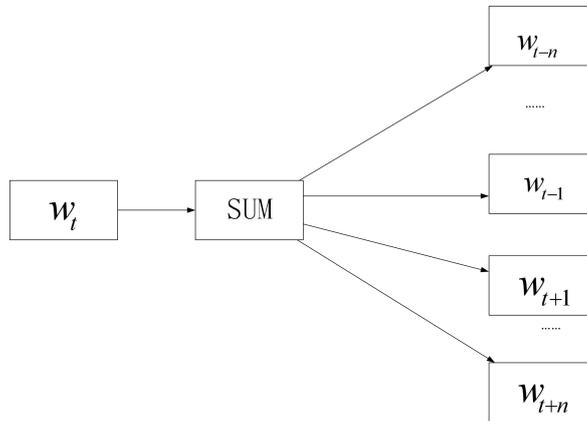


图 2.2 Skip-gram 模型图

$$h = Ew_t$$

$$y = \text{soft max}(h_k) = \frac{\exp(V_k^T h_k)}{\sum_{k=1}^K \exp(V_k^T h_k)} \quad (2.2)$$

基于以上分析，Word2vec 使用二者所表征的词向量，通过上下文的语义信息进行预测，以较低的维度预测目标词，但是其所表征的词向量是固定不变的，其词向量无法针对多义词进行动态调整，因此，可考虑采用动态词向量的表示方法来增强语义的表征。

(2) Glove 词向量表示

虽然在词向量表征过程中，Word2dvec 取得良好效果，但是在针对上下文的语义理解方面，只能利用固定窗口的局部信息来分析上下文，无法利用全局的语义信息，而 Glove 的出现弥补了这一缺点。Glove 是对全文的词频信息进行

统计，其本质是采用无监督的方式对共线矩阵进行降维。Glove 实现词向量语义表达需经过以下三步：

Step 1: 计算词与词之间的共线概率。首先，根据文本序列语料中的词进行词向量表征，确定滑动窗口的大小 m ，从文本序列第零个位置开始，滑动窗口的步长为 1，确定词 i 到达中心词的距离；然后，统计窗口内单词 j 出现的频率并且不断累加，得到以 i 为中心词，计算任意词出现在 i 周围的次数；最后得到词 j 在词 i 的环境中出现的概率，如式 (2.3) 所示，得到词 i 与 j 的共线概率。

$$X_i = \sum_k x_{ik}$$

$$P_{ij} = \frac{x_{ij}}{x_i} \quad (2.3)$$

其中， X 是文本序列共线矩阵， X_{ij} 是语料库中第 i 个单词遍历上下文出现的次数 j ， X_i 是所有词在文本中出现的次数。

Step 2: 添加偏置向量保持共线概率函数的线性结构。将共线矩阵 X 与对应的词向量 v_i, v_j, v_k 进行共线概率比的点积计算，加入偏置向量保持函数的对称性。计算结果如式 (2.4) 所示，

$$v_i^T \tilde{v}_j + b_i + b_j = \log(x_{ij}) \quad (2.4)$$

其中 v_i^T 和 \tilde{v}_j 是上下文对应的词向量， b_i 和 b_j 是两个对应词向量的偏置向量。

Step 3: 构建带权重的最小二乘法回归模型 J 。为解决文本序列共现矩阵稀疏问题，根据 Glove 模型的学习策略，将式 (2.4) 改写成目标函数为最小二乘法的形式，如式 (2.5) 所示。同时，为避其计算过程中出现点乘为零的情况，对共线频率低的词语赋较小的权重，并且控制共线频率高的词语，避免其权重无限大，权重赋值过程如式 (2.6) 所示：

$$J = \sum_{i=1}^N \sum_{j=1}^N f(x_{ij}) (v_i^T \tilde{v}_j + b_i + b_j - \log(x_{ij}))^2 \quad (2.5)$$

$$f(x_{ij}) = \begin{cases} \left(\frac{x_{ij}}{x_{\max}}\right)^\alpha, & \text{如果 } x_{ij} < x_{\max} \\ 1, & \text{其他情况} \end{cases} \quad (2.6)$$

其中, $f(x_j)$ 为权重函数系, $\alpha = 0.75, x_{\max} = 100$ 。

2.2.2 动态词向量

采用 Bert 预训练模型对评论文本进行特征提取时, 可根据输入句子的上下文不同, 在网络模型中实时计算, 从而动态生成词向量。因此, Bert 预训练模型的特征提取有利于充分理解上下文语义信息, 区分不同语境下的多义词。为了动态获取餐饮评论的特征信息, 本文分别利用 Bert、Albert、K-Bert 和 KW-Bert 进行预训练过程的特征提取。其中, K-Bert、KW-Bert 将在第五章详细叙述, 本小节重点介绍 Bert、Albert 两个预训练模型。

(1) Bert 预训练模型

Bert 的核心是利用双向的 Transformers 进行训练, 作为一种动态预训练模型应用到下游情感分类任务中。它与传统的特征提取过程不同, 不再使用静态方式提取文本特征, 而是利用大规模无标注的语料, 通过学习海量数据中的特征信息, 获得包含丰富语义的文本词向量, 有效的解决了中文文本存在的一词多义、语义混乱的问题。

Bert 模型的构成主要由: 输入层、嵌入层、编码层、池化层和输出层, 模型输入、输出及模型内部结构如图 2.3, 2.4 所示, 模型各层功能如下。

①模型的输入过程是输入一段文本, 通过标记器 (tokenizer) 对字词进行分割, 设定 seq_length 超参数固定输入序列的长度, 标记完成的序列由字向量、文本向量、位置向量表示, 它详细解释了整个文本的语义信息、词与词之间的语义关系以及不同位置的信息差异。

②嵌入层主要由嵌入 (embedding)、层规范化 (layer normalization) 和随机停用 (dropout) 组成。通过这三个组件将输入层中离散的向量编码转化成连续的分布式向量形式。

③编码层主要由多个结构相同但参数不同的隐藏层组成。其作用是对嵌入层输出的状态以非线性形式表示, 从而提取出隐藏层的特征。隐藏层主要由线性变换、激活函数、多头自注意力机制、跳跃连接、层标准化和随机停用组成。

④池化层通过线性变换将[CLS]分类标记对应的序列取出, 经过激活函数的变换, 作为整个序列的词向量表示。

⑤输出层是输出所有的标记和整体的序列表示，为下游的任务做准备。

Bert 模型通过预训练来进行评论文本的特征提取，预训练涉及 MLM 和 NSP 两种子训练任务。其中，MLM 是将输入的句向量，用[Mask]标记随机替换一定百分比的 token，然后利用 Bert 模型对其掩盖掉的词向量进行预测，即预测[Mask]标记；NSP 是由于自然语言处理过程中，有很多重要的下游任务需要理解两个句子之间的关系，如机器人问答，NSP 就是为了判断两组不同的词向量分布是否具有上下文的联系。综上所述，Bert 训练过程可处理多种预训练任务。而针对细粒度情感分析，Bert 采用 MLM 任务对评论文本进行预训练，将其序列文本转化成词向量，内部转化过程如图 2.4 所示。具体过程为：首先，分别通过 embedding 层，将离散的向量转化为词嵌入、段嵌入和位置嵌入三种连续的分布式向量；然后，通过两个双向的 transformer，进一步提取评论文本中的特征信息；最后，通过输出层输出上下文的特征向量，为进行下游的分类任务提供动态词向量。

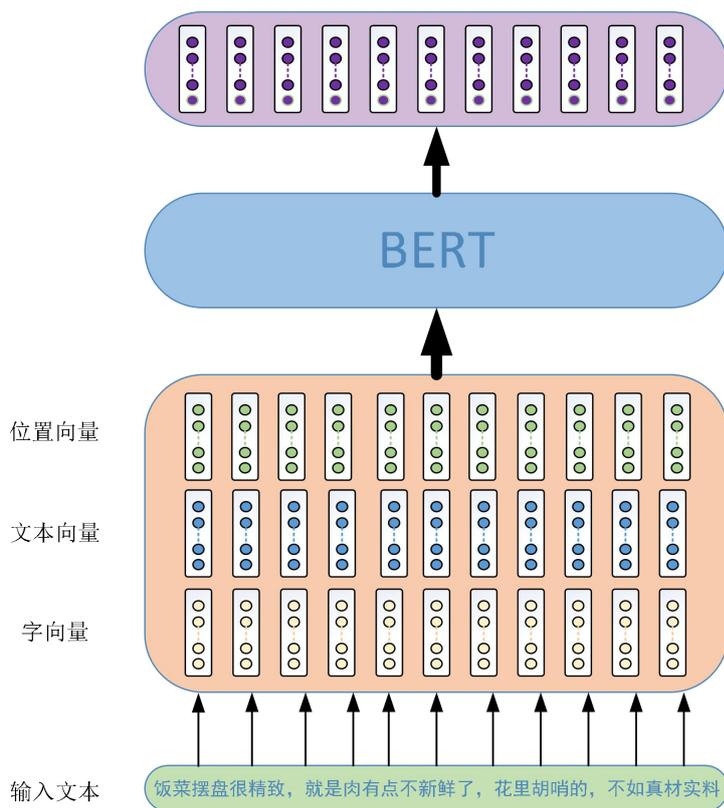


图2.3 Bert模型输入输出结构

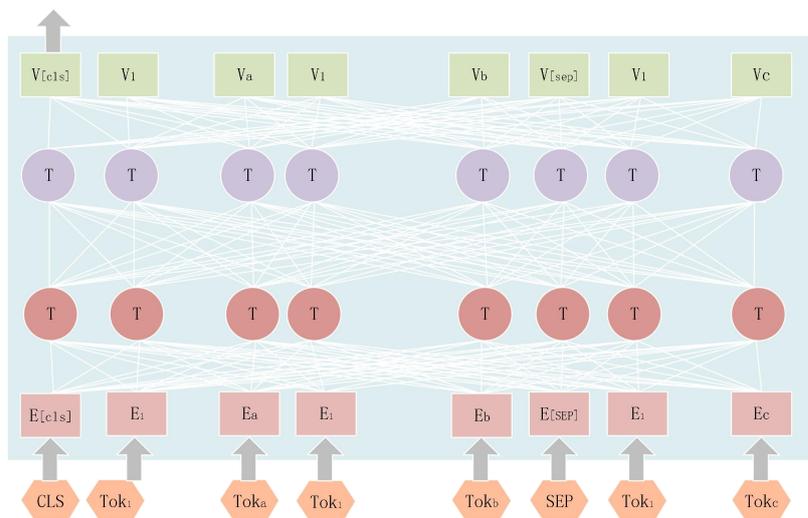


图2.4 Bert模型内部结构

(2) Albert 预训练模型

Albert 是 Bert 预训练模型的改进，因为 Bert 模型自身复杂程度高，参数量巨大，训练过程中耗费大量的资源，因此 Google Research^[51] 提出 Albert 这种轻量型的预训练模型，其主要从改变模型结构和训练方法两方面进行改进。在模型结构方面：利用 embedding 分解、改变原有 Bert 模型嵌入层参数大小、停止隐藏层参数共享等方式提高模型性能；在模型训练方法方面：通过去除 NSP 预训练语言模型、按照序列顺序预测句子、采用自监督损失函数等方式简化模型复杂程度。

2.3 相关深度学习模型

目前深度学习技术已经在自然语言处理、语音识别、视觉识别等多个方面广泛应用，其在细粒度情感分析中也取得良好的效果。将中文文本评论经过预训练模型后，生成包含大量特征信息的动态词向量，然后输入到深度学习模型中，进行细粒度情感极性的判别，从而提高情感分析的准确率。本节主要对文章所使用的深度学习模型进行阐述。

2.3.1 BiLSTM 基线模型

为了解决LSTM单项处理文本的问题，Graves A^[52] 等人首次提出了BiLSTM模型，BiLSTM模型是由两个方向相反的LSTM叠加而构成，其结构如图 2.5 所示。

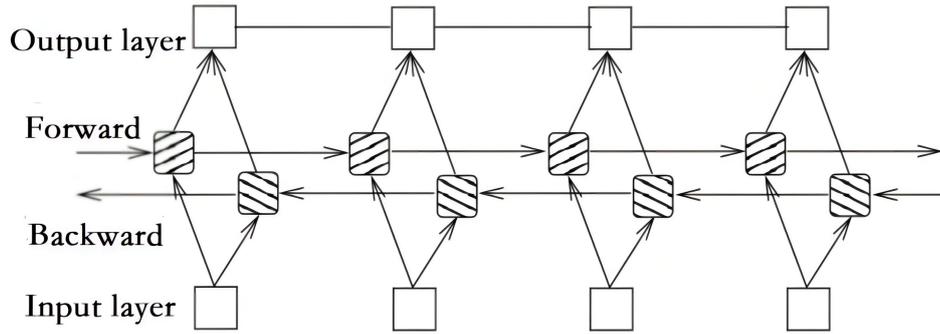


图2.5 BiLSTM单元结构

BiLSTM的参数如表 2.1 所示，其中 x_t 是BiLSTM隐藏层的输入向量， \vec{h}_t 是 t 时刻BiLSTM的正向输出向量， \overleftarrow{h}_t 是反向输出向量， \overrightarrow{W} 是正向网络权重矩阵， \overleftarrow{V} 是反向网络的权重矩阵， \vec{b} 是网络的偏置向量， \vec{h}_{t-1} 是前一时间BiLSTM的正向输出向量， \overleftarrow{h}_{t-1} 是前一时间BiLSTM的反向输出向量。

表2.1 BiLSTM参数表

参数	意义	参数	意义
\vec{h}_t	t 时刻BiLSTM正向输出	\overleftarrow{V}	反向网络的权重矩阵
\vec{h}_{t-1}	前一时间BiLSTM正向输出	\overrightarrow{W}	正向网络的权重矩阵
\overleftarrow{h}_t	t 时刻BiLSTM反向输出	\vec{b}	网络的偏置向量
\overleftarrow{h}_{t-1}	前一时间BiLSTM反向输出	x_t	BiLSTM隐藏层输入向量

BiLSTM计算过程为：首先通过正向传播的LSTM层，计算出 t 时刻的正向输出细胞状态 \vec{h}_t ，然后通过反向传播的LSTM层，计算出 t 时刻的反向输出细胞状态 \overleftarrow{h}_t ，最后分别将正向的细胞状态和反向的细胞状态点乘对应的权重矩阵，加上 t 时刻的偏置向量 \vec{b} ，得到 t 时刻的BiLSTM输出，计算过程如式 (2.7) 所示：

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \quad \overleftarrow{h}_t = LSTM(x_t, \overleftarrow{h}_{t-1}) \quad h_t = W\vec{h}_t + V\overleftarrow{h}_t + b_t \quad (2.7)$$

2.3.2 BiSRU 基线模型

BiLSTM 模型虽在理解上下文语义过程中有着突出表现，但是难以进行并行计算，易导致长文本词向量对应位置混乱。而 BiSRU 模型作为一个双向特征提取最快的循环神经网络，其内部的并行结构可对文本序列特征进行并行提取，使得语义信息更加完整准确表达，因此引入 BiSRU 模型来解决 BiLSTM 模型无法并行处理的问题。BiSRU 模型是由两个方向相反的 SRU 叠加而成，SRU 的网络模型如图 2.6 所示。

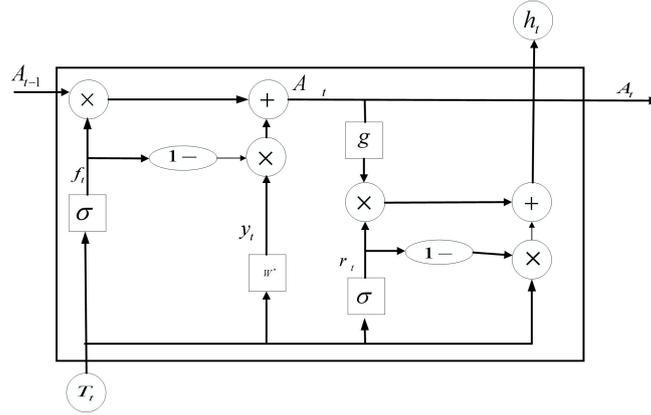


图2.6 SRU单元结构

图 2.6 中的参数含义，如表 2.2 所示。

表2.2 SRU参数表

参数	意义	参数	意义
A_{t-1}	$t-1$ 时刻隐藏层状态	f_t	遗忘门
h_t	t 时刻SRU的正向输出	σ	Sigmoid函数
A_t	当前 t 时刻隐藏层状态	r_t	重置门
g	激活函数	y_t	输入门
W^*	网络的权重矩阵	T_t	t 时刻的输入

SRU计算过程为：首先，SRU将预训练模型输出的词向量 T_t 输入到模型内部，计算出该时刻保存的信息 A_t ；然后，经过重置门确定重置的信息 r_t ，通过遗忘门丢弃不必要信息，输出信息 f_t ；最后，经过系列矩阵乘法操作和激活函数，输出当前时刻隐藏层向量 h_t 。模型内部计算公式如式（2.8）-（2.10）所示：

$$f_t = \sigma(W_f T_t + b_f) \quad r_t = \sigma(W_r T_t + b_r) \quad y_t = \sigma(W^* T_t) \quad (2.8)$$

$$A_t = (1 - f_t) \times y_t + A_{t-1} \times f_t \quad (2.9)$$

$$h_t = r_t \times g(A_t) + (1 - r_t) \times T_t \quad (2.10)$$

其中， W_f 、 W_r 、 W^* 为对应门控的权重， b_f 、 b_r 为对应门控的偏置向量。

因SRU输入不再依赖上一时刻 h_{t-1} 隐含层的输出，式（2.9）和（2.10）可同时进行计算，从而SRU实现了并行计算。BiSRU模型是由两个SRU上下叠加构成，用于提取长文本语义信息。具体处理过程为：首先，将词向量 T_t 分别输入到正反SRU模型中；然后，将正向SRU和反向SRU输出的 \bar{h}_t 和 \bar{h}_t 进行

concat 连接；最后，经过一个时间步 t 输出结果 H_t ，计算公式如式 (2.11) 所示：

$$H_t = \text{concat}\{\vec{h}_t, \overleftarrow{h}_t\} = \text{BiSRU}(T_i) \quad (2.11)$$

其中 \vec{h}_t 和 \overleftarrow{h}_t 是 SRU 在 t 时刻正向和反向隐藏层向量输出， H_t 为最终 BiSRU 模型在 t 时刻输出的隐藏层状态^[53]。

2.3.3 多头自注意力机制

(1) 注意力机制

在自然语言处理中，注意力机制是一种通过计算注意力权重从而关注到重要信息的组合函数。具有 transformer 体系结构的注意力机制（如图 2.7 所示），可自动学习文本序列中的权重值，提高了神经网络的可解释性。其计算过程为：首先，计算输入向量对应位置权重，根据权重值对各位置向量进行加权平均；然后，将输出的注意力机制 u_{ij} 输入到 softmax 函数中，得到不同区域的权重值 a_{ij} ，权重值越高，说明该区域的信息重要程度较高；最后，在隐藏层输出 h_i ，与 a_{ij} 相乘后再相加，得到注意力机制最终的输出向量 c_j ^[54]，计算公式如式 (2.12) 所示：

$$u_{ij} = \tanh(W_i h_i + W' b)$$

$$c_j = \sum_{i=1}^T \alpha_{ij} h_i \quad (2.12)$$

其中 \tanh 为非线性函数， W_i 和 W' 是指定层的权重值。

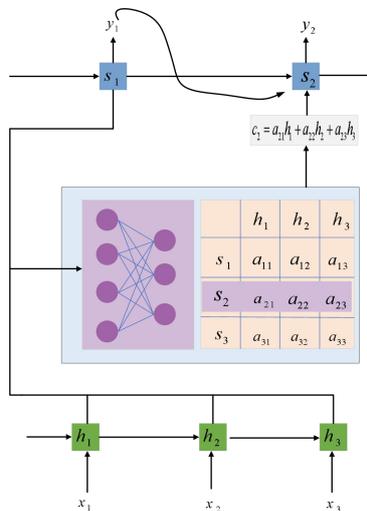


图 2.7 Attention 网络结构

(2) 自注意力机制

RNN, LSTM, BiLSTM 都是典型的序列模型, 将数据的相对位置依次转化为时间步计算, 无法进行并行计算; 而自注意力机制可对输入的向量 $x_1, x_2, x_3, \dots, x_r$ 进行并行计算, 其工作原理如图 2.8 所示。因此, 利用自注意力机制来解决序列模型无法并行的问题^[55]。

自注意力机制计算过程为: 首先分别将输入向量 $x_1, x_2, x_3, \dots, x_r$ 与 W^o, W^k, W^v 进行点积计算, 如式 (2.13) - (2.15), 得到注意力矩阵 $a_{T,i}$, 如式 (2.16); 然后, 为得到[0,1]区间的注意力权重值, 经过式 (2.17) 处理后, 得到 $\hat{a}_{T,i}$; 最后, 将 $\hat{a}_{T,i}$ 分别与对应位置的 v_i 相乘求和, 如式 (2.18), 得到 b_r ^[56]。

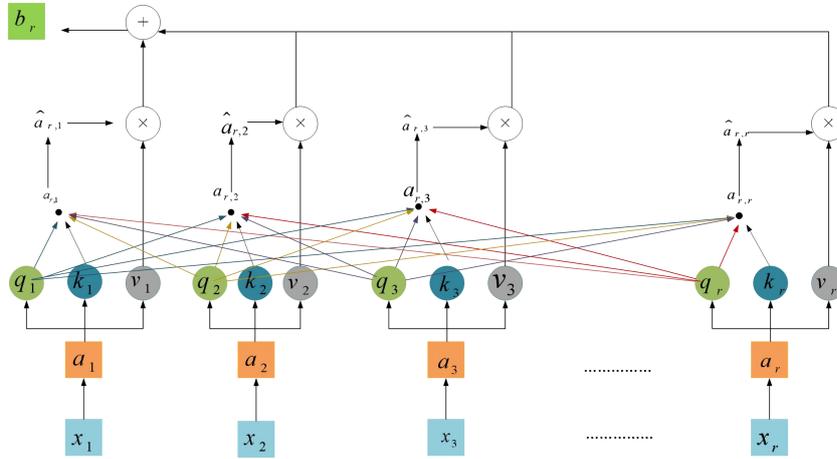


图 2.8 Self-Attention 网络结构

$$[q_1, q_2, q_3, \dots, q_r] = W^o \cdot [a_1, a_2, a_3, \dots, a_r] \quad (2.13)$$

$$[k_1, k_2, k_3, \dots, k_r] = W^k \cdot [a_1, a_2, a_3, \dots, a_r] \quad (2.14)$$

$$[v_1, v_2, v_3, \dots, v_r] = W^v \cdot [a_1, a_2, a_3, \dots, a_r] \quad (2.15)$$

$$a_{T,i} = \begin{bmatrix} a_{1,1} & a_{1,2} & a_{1,3} & \dots & a_{1,r} \\ a_{2,1} & a_{2,2} & a_{2,3} & \dots & a_{2,r} \\ a_{3,1} & a_{3,2} & a_{3,3} & \dots & a_{3,r} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ a_{r,1} & a_{r,2} & a_{r,3} & \dots & a_{r,r} \end{bmatrix} = \frac{Q_r^{transpose} \cdot k_i}{\sqrt{d_{q,k}}} \quad (2.16)$$

$$\hat{a}_{T,i} = \text{soft max}(a_{T,i}) \quad (2.17)$$

$$b_T = \sum_{i=1}^T \hat{a}_{T,i} v_i \quad (2.18)$$

(3) 多头自注意力机制

然而，自注意力机制在对当前位置信息编码时，往往会出现过度将注意力集中于自身位置，因此可利用多头自注意力机制解决这个问题。多头自注意力机制构建过程为：将一组 $Attention(Q,K,V)$ 设为一头，图 2.9 以 Head=3 为例，输入 a_1 经过多头自注意力机制，分别输出 $b_{head}^1, b_{head}^2, b_{head}^3$ 进行首尾向量的拼接，通过线性变换得到 b_1 [57]。

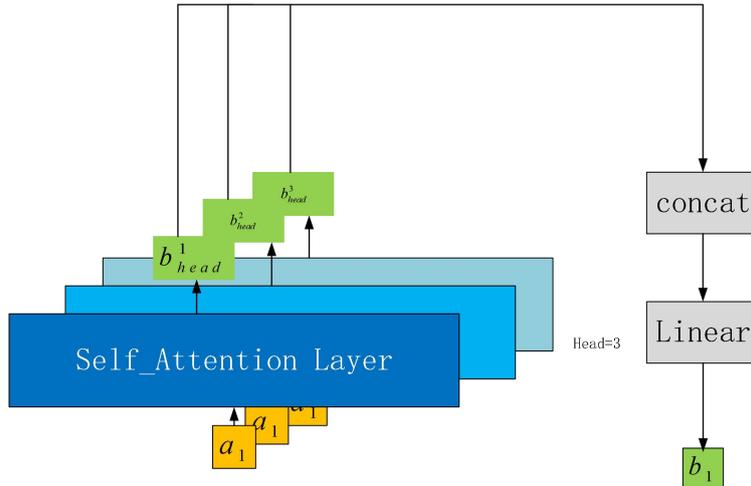


图 2.9 MulSelf-Attention 网络结构

2.3.4 TextCNN 基线模型

BiLSTM、SRU 是改进后的循环神经网络，其通过上一个时间步 T_{t-1} 信息可以充分理解上下文的语义信息，但是对于 500 字以上的长评论文本序列，会出现梯度消失的现象，而 TextCNN 利用卷积操作，有效避免此类问题的出现。该模型的基本思路是利用大小不同的卷积窗口提取句子的局部特征信息，TextCNN 不仅可处理多文本信息，且对于长文本评论信息同样适用。模型由输入层、卷积层和池化层构成 [58]。

TextCNN 的输入层是基于预训练模型的词向量矩阵，每一行代表一个文本的词向量，输入层的词向量可以是固定不变的，也可以根据自身反向传播动态更新 [59]。将不同映射方式的动态词向量矩阵进行拼接，如式 (2.19) 所示：

$$x_{1:n} = x_1 \oplus x_2 \oplus \dots \oplus x_n \tag{2.19}$$

其中 $x_{1:n}$ 为从句子标注的第一个位置到最后的位置的向量表征， x_i 表示第 i 个位置的词组所代表的词向量 [59]。

TextCNN 的卷积层是采用多通道一维卷积网络，将卷积核与实际词向量进行卷积操作，分别对输入的字向量矩阵相乘再相加，保持矩阵宽度一致，然后对文本序列词向量进行纵向移动，根据评论文本长度实时调整卷积核大小^[60]。设卷积核宽度为 d ，卷积核为 w ，上下滑动窗口为 h ，则需要更新的参数为 $h*d$ ，经过输入层的矩阵 $x_{1:n}$ ，则卷积操作如式 (2.20) 所示：

$$o_i = w \cdot x[i:i+h-1], i = 1, 2 \dots, s-h+1 \quad (2.20)$$

$$c_i = f(o_i + b)$$

其中， b 是偏置向量， f 是在句子上进行滑动卷积操作的非线性运算，最终得到 Feature Map 为 $c = [c_1, c_2, \dots, c_{n-h+1}]$ 。

TextCNN 的池化层是处理卷积核产生的 Feature Map，通过操作每个特征图的池化函数，得到具有相同维度的特征向量。常见的池化操作有：最大池化、平均池化、动态池化等，可根据当前主要任务选择不同的池化操作^[61]。本文采用最大池化对特征向量进行拼接，并筛选出滑动窗口中产生的最大特征向量，记为 $z = [\hat{c}_1, \hat{c}_2, \dots, \hat{c}_m]$ ，然后利用 softmax 函数进行 K 种分类，预测分类结果。

2.4 本章小节

本章阐述了细粒度情感分析的相关理论和技术，首先介绍了文本预处理流程；其次以动态词向量和静态词向量为基础，讨论了现有词向量语言模型的常用方法；最后分析了相关神经网络模型及其计算过程，包括 BiLSTM 模型、BiSRU 模型、多头自注意力机制、TextCNN 模型四类深度学习模型。本章所介绍的理论和技术为后续构建餐饮评论细粒度情感分析模型奠定了基础。

3 餐饮评论细粒度情感分析流程及数据预处理

3.1 餐饮评论细粒度情感分析流程

餐饮评论细粒度情感分析的主要流程为数据预处理、预训练模型特征提取、细粒度情感分析三个部分（如图 3.1 所示）。首先，对数据进行预处理，分为数据清洗、分词、去停用词等工作，通过以上操作可提升数据质量，有利于提高后续特征提取的准确率；其次，利用预训练模型进行特征提取，动态获取餐饮评论的特征词和情感词，并以动态词向量形式输入到下游的情感分析模型中；最后，利用混合神经网络进行餐饮评论细粒度情感分析。本文按照餐饮评论细粒度情感分析流程，分别构建了 Bert-BiSRU-Att 单通道细粒度情感分析模型，Bert-BiSRU-At-TextCNN 多通道细粒度情感分析模型和 KW-Bert-BiSRU-At-TextCNN 多通道细粒度情感分析模型，通过优化情感分析模型和预训练模型的方法，有效提升了餐饮评论细粒度情感分析的效果。

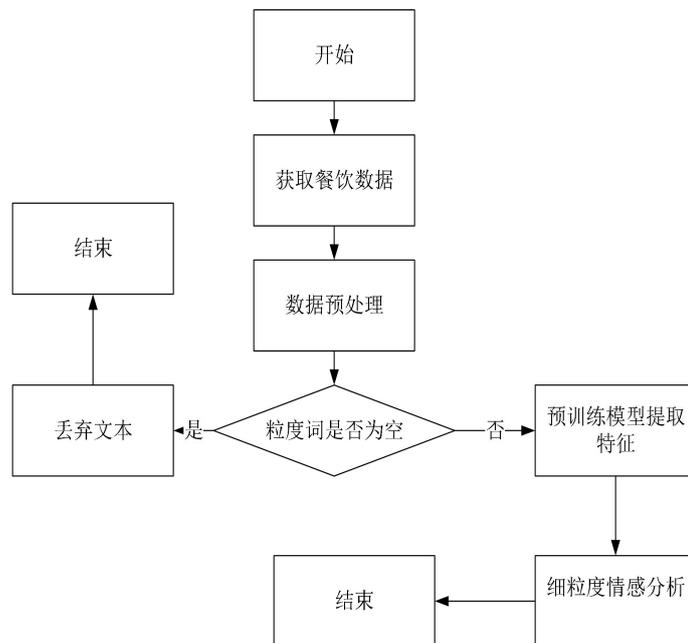


图 3.1 情感分析系统流程图

3.2 餐饮评论数据集及预处理

本文选择 AI Challenge2018 用户餐饮评论数据作为实验数据集，该评论数据集是目前最大最丰富的中文文本细粒度情感分析数据集，共有 20 个粒度要素值，各粒度的情感倾向为“积极”、“消极”、“中性”和“未提及”，分别用[1,-1,0,-2]进行标注。一般的情感极性分为“积极”、“中性”和“消极”三种情感类别，而本数据集将情感极性分为“积极”、“消极”、“中性”和

“未提及”，加入“未提及”的原因在于，用户日常评论过程中涉及到的粒度词有限，不会面面俱到，因此对未涉及到的粒度词，标注为“未提及”以保证数据结构的完整性。该数据集由 10.5 万条训练数据、1.5 万条验证数据、1.5 万条测试数据构成，评论内容来自“美团大众点评”的真实公开数据，数据量大，粒度丰富，具有较高的研究价值。

中文评论文本在输入到模型之前需要进行一系列预处理工作，评论文本中会出现较多的标点符号、表情符号、乱码，所以在中文文本转化成动态词向量之前，需要对数据进行清洗、分词、去停用词等一系列数据增强的操作，本文数据预处理具体步骤如图 3.2 所示：

(1) 判断评论文本是否为空，对空文本进行删除处理，对“未提及”标记频率高于 70% 的评论进行删除；

(2) 对评论文本中标点符号、表情符号删除，并对繁体字进行“繁化简”操作；

(3) 采用停用词表对语气词进行删除；

(4) 对包含情感极性的特殊符号进行正则化处理；

(5) 采用 jieba 分词对评论进行分词处理；

在数据预处理过程中发现部分粒度词“未提及”出现的频率过高，说明该粒度词受重视程度低、分析意义小。为获得重视程度高的粒度词，本文基于原评论数据对粒度词标注的“未提及”进行频次统计，如图 3.3 所示，进一步分析可得到以下结论：（1）餐馆的地理位置及停车的便利度在评论中“未提及”频次较多，说明该粒度在日常的餐饮过程中，食客关注度较低，不是影响食客评价的主要方面；（2）餐品的口感、价格以及服务员态度在评论中“未提及”频次较少，说明食客更加关注这几个方面的体验；（3）食客会根据此次消费的感受，在评论结尾进行推荐或者踩雷的评述（如图 3.3 所示），“未提及”的频次最少。

综合上述分析且考虑到设备算力因素，对“未提及”标签出现频次高于 70% 的粒度进行删除处理，处理后的结果共 13 个粒度词，如图 3.4 所示。

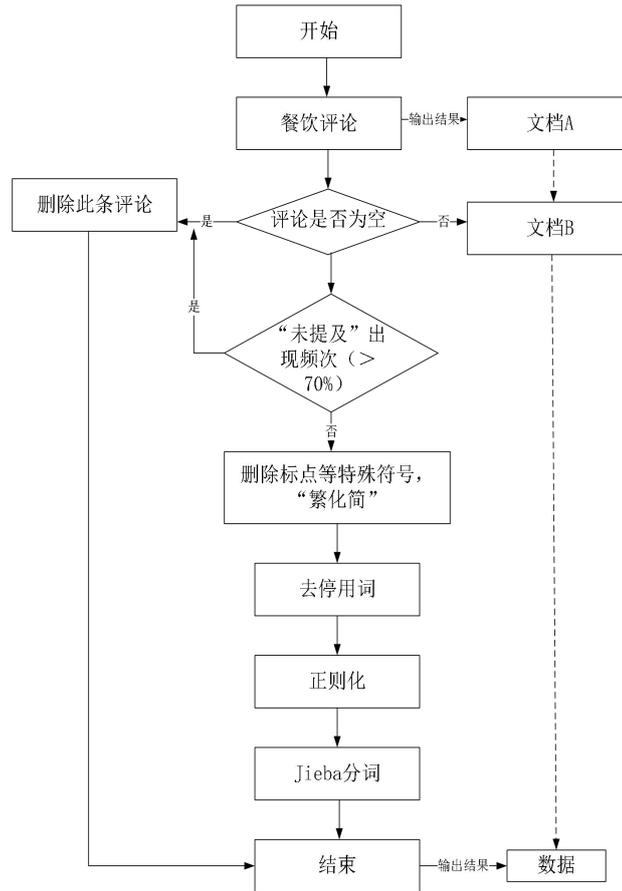


图 3.2 预处理流程

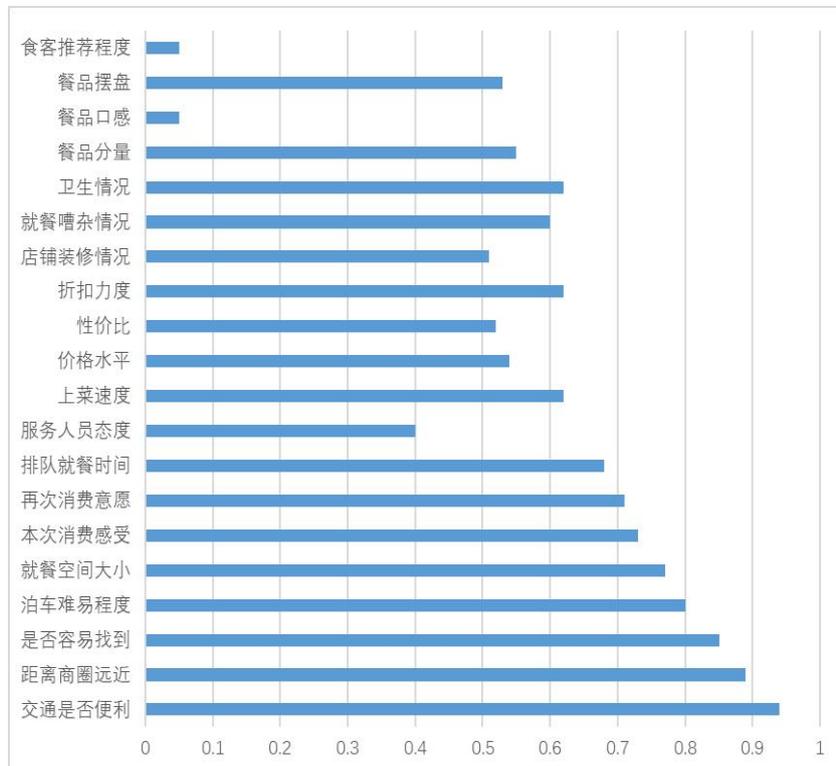


图 3.3 评论中各细粒度“未提及”标注情况

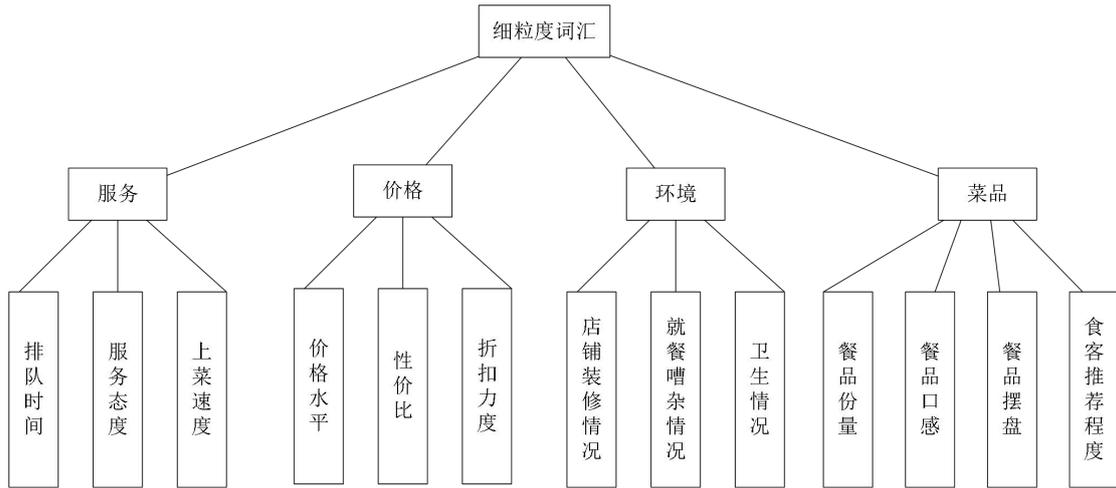


图 3.4 餐饮评论细粒度词

在数据清洗阶段对评论语句进行首尾引号、空白符号的删除，利用“zh-hant”进行“繁化简”的处理。处理结果如图 3.5 所示。

“十一點半準時開始，位於cbd中心珠江新城地鐵站附近，位置比較容易找，環境不錯，來自自助餐的客人不多，上座率大概80%左右，主要以酒店客人為主。這裏相當安靜，適合聚會聊天。食物供應品種豐富，不過吃完了就沒有，由於客人不多，不會出現哄搶的情況，可以慢慢來。生鮮類主要以蝦，青口，大花螺，三文魚，金槍魚為主。甜品方面，一口泡芙，蛋糕，布丁，雪糕，雪糕口味有太妃味，值得一試。服務態度非常好，及時清空碟子，部分廚師顏值還挺高。”

十一点半准时开始，位于cbd中心珠江新城地铁站附近，位置比较容易找，环境不错，来自自助餐的客人不多，上座率大概80%左右，主要以酒店客人为主。这里相当安静，适合聚会聊天。食物供应品种丰富，不过吃完了就没有，由于客人不多，不会出现哄抢的情况，可以慢慢来。生鲜类主要以虾，青口，大花螺，三文鱼，金枪鱼为主。甜品方面，一口泡芙，蛋糕，布丁，雪糕，雪糕口味有太妃味，值得一试。服务态度非常好，及时清空碟子，部分厨师颜值还挺高。

图 3.5 数据“繁化简”处理

在日常评论过程中，人们通常会采用数字、百分比、英文缩写等不同的表述方式来展现对餐品的综合评价，这些特殊符号中包含着一定的情感倾向，不可直接进行分词处理，否则会导致语义丢失。因此，在数据分词阶段，本文将其视为一个整体，在去停用词后，先对餐饮评论进行正则化处理，将评论文本中数字表达进行标签替换，再经过jieba分词处理，评论文本中的数字会被作为一个整体分割出来，使其在后续的预训练和文本向量表示过程中更好的学习到这部分特征，部分处理结果如表 3.1 所示。

表 3.1 部分评论语料正则化和分词处理

原始评论	未正则化处理分词文本	正则化处理分词文本
十一点半准时开始，位于 cbd 中心珠江新城地铁站附近，位置比较容易找	['十一点半', '准时', '开始', '位于', 'cbd', '中心', '珠江', '新城', '地铁站', '附近', '位置', '比较', '容易', '找']	['十一点半', '准时', '开始', '位于', 'PMUM', '中心', '珠江', '新城', '地铁站', '附近', '位置', '比较', '容易', '找']
环境不错，来自助餐的客人不多，上座率大概 80%左右	['环境', '不错', '来自', '自助', '自助餐', '的', '客人', '不多', '上座率', '大概', '80', '%', '左右']	['环境', '不错', '来自', '自助', '自助餐', '的', '客人', '不多', '上座率', '大概', 'PNUM', '左右']

3.3 本章小结

本章重点介绍了餐饮评论细粒度情感分析的流程和数据预处理，其中情感分析的流程为：首先，将预处理后的评论文本序列输入到预训练模型中，获得包含丰富语义信息的动态词向量；然后，将动态词向量输入到下游情感分类模型中；最后，获得各粒度的情感极性。而数据预处理的流程为：首先，判断评论是否为空；其次，对“未提及”出现频次高于 70%的粒度词进行删除处理；再次，删除特殊符号并进行“繁化简”处理；最后，对评论文本进行去停用词、正则化和 jieba 分词处理。

4 Bert-BiSRU-Att 单通道细粒度情感分析模型

4.1 概述

细粒度情感分析的主要工作分为预训练模型的特征提取和下游深度学习模型的情感极性判别两部分。本章采用 Bert 预训练模型对文本序列进行特征提取，并将提取到的动态词向量输入到下游细粒度情感分析模型中，为不同粒度设置不同的输出通道，得到细化情感极性。

4.1.1 当前方法的不足及面临的问题

目前的情感分析方法主要为基于情感字典和规则的方法、基于机器学习的方法和基于深度学习的方法。其中，基于情感字典和规则的方法是通过计算情感值来判断情感极性，但由于计算准确率不高，现在被普遍用来辅助判别情感极性；基于机器学习的方法是构建情感分类器，预测句子情感极性，但是准确率受原始数据标签标注的影响，局限性较大；而基于深度学习的方法是利用复杂的神经网络判断情感极性，已成为主流判别情感极性的手段，但是单一的深度学习模型存在泛化能力不足，准确率低等问题。具体来说，使用单一深度学习模型进行情感分析存在以下两方面的主要问题：一是文本序列所包含的信息并不同等重要，预训练后的词向量并未对词与词之间的重要程度进行标注，对于长文本、长距离的词向量信息可能会丢失文本序列中重要信息；二是在细粒度情感分析任务中，隐式信息并未明显对应粒度词，如“这家味道太赞了，就是人太多了”，此评论中“人太多了”可能指就餐环境嘈杂，也可能指排队时间长，难以准确将隐式信息对应到正确的粒度词中。故本章采用混合神经网络模型的方法，对餐饮评论细粒度进行情感极性的判别。

4.1.2 本文采用方法

为了解决以上问题，本文引入 BiSRU-Att 深度学习模型，旨在提高餐饮评论细粒度情感分析的准确率。首先，引入多头自注意力机制，对文本序列中的重点信息进行权重赋值，提取权重高的特征信息，避免丢失重要的特征信息；同时注意力机制具有参数少、计算速度快的优点，其每一步计算结果都不依赖上一时刻的结果，从而大大提高了计算效率；其次，引入 BiSRU^[50]模型解决了循环神经网络不能像卷积神经网络一样进行并行处理的问题，虽然 BiLSTM 模型等循环神经网络对于理解上下文语义信息有着突出表现，但是易丢失隐式信

息，而并行计算可保存对应位置信息，保证隐式信息位置不会混乱。

因此，根据上述分析，本章将多头自注意力机制和 BiSRU 模型进行融合得到 BiSRU-Att 模型，该模型充分利用了注意力机制和 BiSRU 模型的优点，突出粒度词与情感词之间的关联关系，自主地在文本序列中抓取、识别、定位情感词的信息，进而对预训练后的词向量信息进行情感极性的判别，实现多粒度词、多标签的情感分类。

4.2 Bert-BiSRU-Att 的单通道模型构建

针对传统深度学习模型存在准确率低的问题，本章提出了 Bert-BiSRU-Att 单通道细粒度情感分析模型，模型结构如图 4.1 所示，包含输入层、BiSRU-Att 层，输出层。

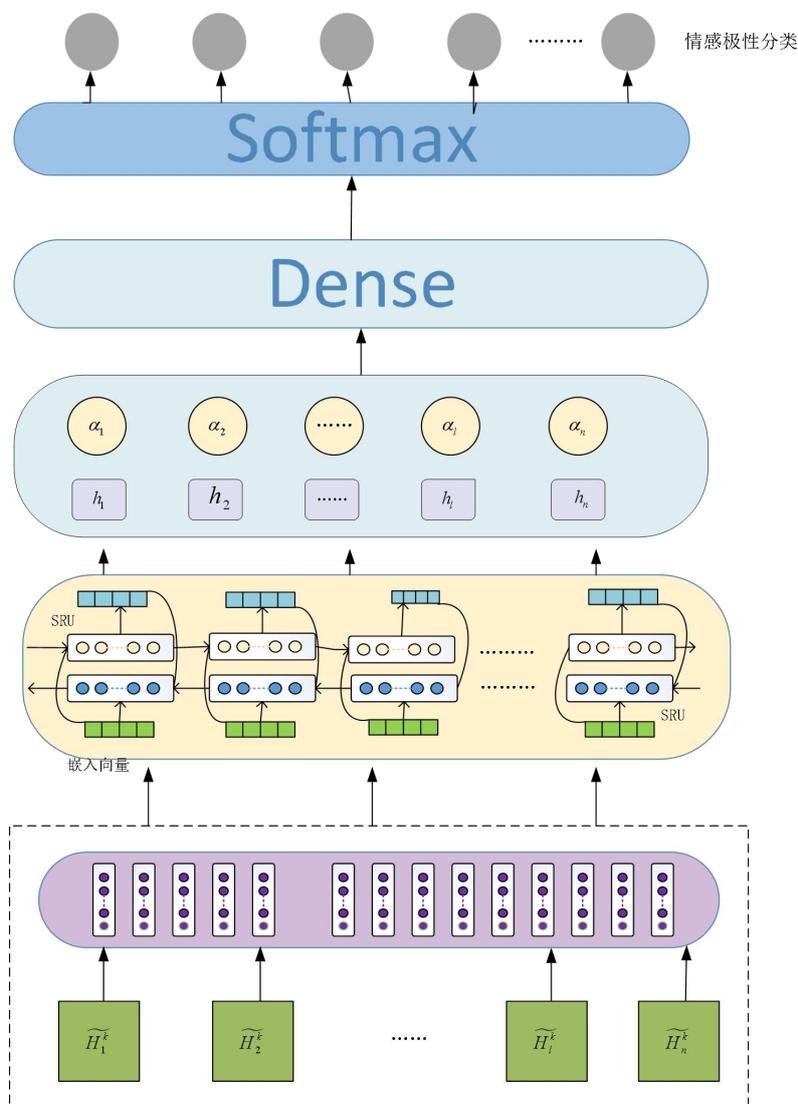


图 4.1 BiSRU-Att 模型结构

4.2.1 输入层

模型的输入层采用了 Bert 预训练模型得到词向量，充分利用了 Bert 中 Transformer 强大的文本处理能力，提取了关于评论语句的上下文情感信息。Bert 预训练输出的词向量为动态词向量，优于传统 Word2vec 所表示的静态词向量，对长度为 n 的评论语句，其表示形式为 $H_n = [H_1, H_2, \dots, H_n]$ 。

4.2.2 BiSRU-Att 层

该层是由 BiSRU 模型与多头自注意力机制结合而成，模型构建过程为：首先，将预处理后的词向量输入到 BiSRU-Att 模型的输入层中；然后，通过 BiSRU 模型网络结构获得词向量 \widetilde{H}_t^{BiSRU} ；最后，将其输入到注意力机制层，通过注意力机制对不同的情感信息进行权重计算和赋值。具体计算过程为：首先，将每个时间步输出的 \widetilde{H}_t^{BiSRU} 乘以矩阵 W_l 得到向量 g_l ，利用 \tanh 函数进行线性处理，如式 (4.1) 所示；然后，计算得到评论中不同词语的权重值 α_l ，如式 (4.2) 所示；最后，对每个时间步 t 对应的 \widetilde{H}_t^{BiSRU} 与权重 α_l 相乘后求和，得到 BiSRU-Att 层输出向量 G_l ，如式 (4.3) 所示。

$$g_l = \tanh(W_l \widetilde{H}_t^{BiSRU} + b_l) \quad (4.1)$$

$$\alpha_l = \frac{\exp(g_l)}{\sum_t \exp(g_l)} \quad (4.2)$$

$$G_l = \sum_t \alpha_l \widetilde{H}_t^{BiSRU} \quad (4.3)$$

其中， W_l 和 b_l 分别为权值矩阵和偏置向量， α_l 是 \widetilde{H}_t^{BiSRU} 词向量包含的粒度词信息权重。

4.2.3 输出层

输出层是将经过注意力机制处理后的词向量信息 G_l 映射到全连接层，利用 softmax 函数对每个粒度的情感极性进行概率 \widehat{y}_{ji} 的计算，计算公式如式 (4.4) 和 (4.5) 所示。

$$\widehat{y}_{ji} = \text{soft max}(W_y G_l + b_y) \quad (4.4)$$

$$\text{cross-entropy-loss} = (1 - \varepsilon) \log(\widehat{y}_{ji}) + \varepsilon \sum \frac{\log(\widehat{y}_{ji})}{N} \quad (4.5)$$

其中, \hat{y}_j 为第 j 个粒度词下第 i 个情感极性的概率分布, ε 为随机扰动项, N 为情感极性数量 ($N=4$)。

基于以上分析, BiSRU 和 BiSRU-Att 的伪代码如表 4.1、4.2 所示。

表 4.1 BiSRU 伪代码

BiSRU 的伪代码

输入: 训练集 $D = \{(x^{(n)}, y^{(n)})\}_{n=1}^N$; SRU 遗忘门 f_t ; 重置门 r_t ; A_t 当前时刻隐藏层的状态; W_f , v_f 权重矩阵; 全连接层 fc ;
 输出: 文本标签预测结果 \bar{y} ;

1. repeat
2. for x in D :
3. for t in T :
4. $f_t \leftarrow \sigma(W_f x_t + v_f \odot A_{t-1} + b_f)$
5. $A_t \leftarrow f_t \odot A_{t-1} + (1 - f_t) \odot (W_f x_t)$
6. $r_t \leftarrow \sigma(W_r x_t + v_r \odot A_{t-1} + b_r)$
7. $\bar{h}_t \leftarrow r_t \odot A_t + (1 - r_t) \odot x_t$
8. 同理逆向得 \bar{h} , 并得到 SRU 输出 $out \leftarrow [H_1, H_2, \dots, H_t]$, 其中 $H_t = [\bar{h}, \bar{h}]$
9. 取第 T 步隐藏向量作为句向量 $S \leftarrow H_T$
10. 将句向量 s 送入全连接层 $\bar{S} \leftarrow fc(H_T)$
11. 送入 softmax 层得标签概率 $\bar{y} \leftarrow \text{soft max}(\bar{S})$

表 4.2 BiSRU-Att 伪代码

BiSRU-Att 的伪代码

输入: 训练集 $D = \{(x^{(n)}, y^{(n)})\}_{n=1}^N$; SRU 遗忘门 f_t ; 重置门 r_t ; A_t 当前时刻隐藏层的状态; W_f , v_f 权重矩阵; 全连接层 fc ;
 输出: 文本标签预测结果 \bar{y} ;

1. repeat
2. for x in D :
3. for t in T :
4. $f_t \leftarrow \sigma(W_f x_t + v_f \odot A_{t-1} + b_f)$
5. $A_t \leftarrow f_t \odot A_{t-1} + (1 - f_t) \odot (W_f x_t)$
6. $r_t \leftarrow \sigma(W_r x_t + v_r \odot A_{t-1} + b_r)$
7. $\bar{h}_t \leftarrow r_t \odot A_t + (1 - r_t) \odot x_t$
8. 同理逆向得 \bar{h} , 并得到 SRU 输出 $out \leftarrow [H_1, H_2, \dots, H_t]$, 其中 $H_t = [\bar{h}, \bar{h}]$
9. 取第 T 步隐藏向量作为句向量 $S \leftarrow H_T$
10. $u \leftarrow \tanh(W_w \odot out)$
11. $att \leftarrow W_u \odot u$
12. $score \leftarrow \text{soft max}(att)$
13. $\bar{s} \leftarrow out \odot score$

续表

14. 将句向量 s 送入全连接层 $\bar{S} \leftarrow fc(H_T)$ 15. 送入 softmax 层得标签概率 $\bar{y} \leftarrow soft \max(\bar{S})$

4.3 实验对比与分析

4.3.1 实验环境

本文所有实验环境基于 Pytorch 框架，具体实验环境参数如表 4.3 所示。

表 4.3 实验环境

参数	配置
Python	3.6
内存	32G
CPU	i5-11400k
GPU	NVIDIA GeForce rtx3070ti
主板	b560h
Pytorch 框架	1.8.0
操作系统	Windows 10
CUDA Version	11.4
编程软件	Pycharm Professional
其他训练方式	MistGPU 共享 AI 计算平台、Google 提供的免费服务器 colab

4.3.2 评价指标

本文选择情感分析领域常用的评价指标 ACC、LOSS 和 F1 值，对特征提取和情感极性的结果进行评价。ACC 用来评估正确分类评论数占总评论数的比重，计算公式如式 (4.6) - (4.8) 所示；

$$ACC_i^j = \frac{TP_i^j + TN_i^j}{TP_i^j + TN_i^j + FP_i^j + FN_i^j} \quad (4.6)$$

$$ACC_i = \frac{\sum_{j=1}^4 ACC_i^j}{4} \quad (4.7)$$

$$ACC = \frac{\sum_{i=1}^{13} ACC_i}{13} \quad (4.8)$$

其中 TP_i^j 是在第 i 个粒度词下第 j 个情感极性预测为 j 实际为 j 的数量， FP_i^j 是在第 i 个粒度词下第 j 个情感极性预测为 j 实际为非 j 的数量， TN_i^j 是在第 i 个粒度词下第 j 个情感极性预测为非 j 实际为非 j 的数量， FN_i^j 是在第 i 个粒度词下第 j 个情感极性预测为非 j 实际为 j 的数量。

损失函数 (LOSS) 是衡量模型好坏的一种有效方式，在细粒度情感分析过

程中，情感极性为多标签分类问题，因此采用交叉熵损失函数处理多标签问题。同时，情感分析模型在训练过程中会出现过度拟合和过度自信的问题，因此在交叉熵损失函数中加入 LSR 进行正则化处理，通过扰动输出向量 y ，限制 softmax 最大概率不高于标签值，从而提高预测的准确性，避免了过度拟合和过度自信的问题出现，优化后的损失函数如式 (4.9) - (4.11) 所示：

$$C = -\sum_{j=1}^m \sum_{i=1}^n -y_{ji} \log(\hat{y}_{ji}) - (1-y_{ji}) \log(1-\hat{y}_{ji}) \quad (4.9)$$

其中， m 为每一时间步的样本量， n 为情感类别数， y_{ji} 为实际的情感极性， \hat{y}_{ji} 为预测的情感极性。

$$\hat{y}_{ji} = (1-\varepsilon) \times y_{ji} + \varepsilon \times u(y) = (1-\varepsilon) \times y_{ji} + \frac{\varepsilon}{n} \quad (4.10)$$

其中， ε 为平滑标签的随机扰动项， $u(y) = \frac{1}{n}$ ， $u(y)$ 服从均匀分布。

因此结合以上两式，得出优化后的损失函数，如式 (4.11) 所示：

$$\text{cross-entropy-loss} = (1-\varepsilon)ce(i) + \varepsilon \sum \frac{ce(i)}{N} \quad (4.11)$$

其中 $ce(x)$ 表示式 (4.9) 中的 $\log(\hat{y}_{ji})$ ， i 为预测为真的情况。

F1 值是通过求解精确率 (Precision) 和召回率 (Recall)，计算二者的调和平均数，来评估模型的准确率，计算公式如式 (4.12) - (4.15) 所示。由于本文存在多个粒度词和多个情感极性，在求解过程中，先计算在第 i 个粒度词下第 j 个情感极性的指标，然后通过加权平均获得最终的指标评价结果。

$$\text{Recall}_i^j = \frac{TP_i^j}{TP_i^j + FN_i^j} \quad \text{Precision}_i^j = \frac{TP_i^j}{TP_i^j + FP_i^j} \quad (4.12)$$

$$\text{Recall}_i = \frac{\sum_{j=1}^4 \text{Recall}_i^j}{4} \quad \text{Precision}_i = \frac{\sum_{j=1}^4 \text{Precision}_i^j}{4} \quad (4.13)$$

$$\text{Recall} = \frac{\sum_{i=1}^{13} \text{Recall}_i}{13} \quad \text{Precision} = \frac{\sum_{i=1}^{13} \text{Precision}_i}{13} \quad (4.14)$$

$$F1_i = \frac{2 \times \text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad F1 = \frac{\sum_{i=1}^{13} F1_i}{13} \quad (4.15)$$

4.3.3 参数设置

Bert-BiSRU-Att 模型所涉及到的参数如表 4.4 所示。其中，预训练过程中使用的是 chinese_BERT_base_L-12_H-768_A-12，输入序列的最后一维是 768，最大长度为 300，随机参数更新 dropout 率为 0.3；情感分析模型维度设置为 100，学习率为 $2e-5$ ，权值衰减 $1e-4$ ，批处理的大小为 128，导入数据的子进程数量为 2，单个模型每次训练的最大进程数为 10，隐藏层为 256，注意力维度为 128。

表 4.4 模型训练参数

参数名称	参数取值	参数说明
input_size	768	输入序列的最后一维
max_sentence_length	300	Bert 输入序列最大长度
dropout	0.3	随机激活参数更新
Lr	$2e-5$	Adam 的学习率
weight_decay	$1e-4$	Adam 的权值衰减
batch_size	128	批处理数据量大小
num_workers	2	导入数据的子进程数量
gpus	8	GPU 使用情况
max_epochs	10	每次训练最大迭代次数
attention_size	128	注意力机制维度
hidden_size	256	各模型隐藏层状态

4.3.4 对比实验与结果分析

为了验证本章所提 Bert-BiSRU-Att 模型的有效性，选取 RCNN、ATAE、HEAT、GCAE 等多个网络模型（如表 4.5 所示），在同一餐饮评论数据集上进行训练，通过对比实验，验证 Bert-BiSRU-Att 模型的优越性。

表 4.5 网络模型特性对比

模型	特性
RCNN	候选区域 CNN 算法，利用滑动窗口确定候选区域，通过 CNN 对局部特征进行提取；采用词向量进行输入
BiSRU	基于 RNN 的改进，可以并行处理上下文的语义信息，且学习特征能力强，速度快；采用词向量进行输入
ATAE ^[62]	基于 LSTM，通过结合粒度词和注意力机制对情感信息进行加权；并将字向量和词向量作为编码联合输入
HEAT ^[63]	利用双层的注意力机制学习句中粒度词，再利用 BiGRU 进行编码，重点关注注意力机制学习到的粒度词；采用词向量进行输入
BiLSTM	基于 RNN 的改进，解决长距离序列信息容易遗忘问题，同时双向计算，充分对上下文语义信息进行理解；采用词向量进行输入
GCAE ^[64]	利用 CNN 和门控单元对细粒度情感分析任务进行分析，先对粒度词进行卷积，后经过门控单元与池化层，最终在全连接层输出情感极性，解决了 RNN 和注意力机制不能并行的问题；采用词向量进行输入

续表

BiSRU-Att	将 BiSRU 后添加注意力机制以区分特征信息的重要程度，同时保留 BiSRU 快速提取的特性；采用词向量进行输入
BiSRU-Att-BiLSTM	结合 BiSRU-Att 和 BiLSTM 的特征进行多通道处理，分别将提取到的信息通过各自通道输出后，经过 concat 合并后输出；采用词向量进行输入

将 Bert-BiSRU-Att 与表 4.5 各模型在餐饮评论数据集上进行对比实验，实验结果如表 4.6 所示。

表 4.6 模型实验对比结果

模型名称	F1
RCNN	0.6508
HEAT	0.6632
ATAE	0.6728
BiLSTM	0.6769
GCAE	0.6790
BiSRU	0.6908
BiSRU-Att	0.7224
BiSRU-Att-BiLSTM	0.7227

从表 4.6 中可知，BiSRU-Att 模型的 F1 值为 0.7224，相较于 RCNN 模型、ATAE 模型和 HEAT 模型的 F1 值分别提升 0.0716，0.0591 和 0.0496，因此该模型效果最好。进一步分析可知，RCNN 模型虽然通过滑动窗口逐一对特征进行提取，但由于大量特征信息无重要程度区分，造成提取到的特征信息无法准确应用到 RCNN 模型的网络结构中；ATAE 模型和 HEAT 模型较 RCNN 模型表现更优，这两个模型都是通过引入不同层数的注意力机制，对特征信息进行权重赋值，准确把握不同情感词的重要程度，同时 ATAE 模型改变词向量输入方式，采用词向量和句向量相结合的方式弥补词向量在中文文本序列中产生的句序混乱问题，其实验结果优于 HEAT 模型，说明改变输入方式，对模型 F1 值有一定提高。因此，虽然 ATAE 和 HEAT 两个基线模型的 F1 值低于 BiSRU-Att 模型，但引入注意力机制和改变输入方式会提高情感分类模型的准确率，为本文下一步工作提供了思路。

此外，BiSRU 模型连接注意力机制，对提取到的重要特征信息赋值，使得 BiSRU-Att 模型的 F1 值比 BiSRU 模型的 F1 值高 0.0316，比 BiLSTM 模型的 F1 值高 0.0455，说明本章提出的 BiSRU-Att 模型对餐饮评论细粒度情感分析有较好的效果。其原因为 BiSRU 模型内部是并行结构，可以对文本序列进行并行分析，使得语义信息表达的更加准确完整。但是由于 BiSRU-Att 模型局部特征提取能力有限，而 GCAE 模型不同于循环神经网络，其将卷积操作引入情感分析过程中，使 GACE 模型的 F1 值较 BiLSTM 模型高 0.0021，说明未进行大规模

优化的卷积神经网络在餐饮评论领域有一定的优势，但 GACE 模型较 BiSRU 模型的 F1 值低 0.0118，说明卷积神经网络有改进的空间。

4.4 本章小结

本章针对中文餐评论细粒度情感分析在基线模型准确率低的问题，提出基于 BiSRU-Att 模型的单通道细粒度情感分析模型。该模型首先将预处理后的评论文本经过 Bert 预训练模型获得动态词向量；然后经过 BiSRU 模型进一步获得上下文的语义信息；并通过注意力机制层将所获得的语义信息和有关粒度词的情感信息进行权重赋值，进一步准确获取粒度词的情感信息；最后通过输出层分类情感极性。通过与其他相关模型进行对比，发现该模型优于大部分模型，但依旧存在不足。因此，下一章将通过改变输入方式，优化输入层的向量信息来弥补词向量信息无法包含字和句子信息的问题，同时引入对局部特征提取有优势的 TextCNN 模型提高模型的整体性能。

5 Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型

5.1 概述

在进行情感分析过程中，BiSRU-Att 模型的实验参数通过训练验证已经达到最优效果，因此需通过其他方法来改进模型，以进一步提高餐饮评论细粒度情感分类的准确率。

5.1.1 当前方法不足及面临的问题

在进行细粒度情感分析的过程中，单通道模型面临以下主要问题：一是单通道对深层的语义特征信息识别效率不高，在中文文本细粒度情感分析任务中，粒度词一旦确定后是固定不变的，但在实际的评论语句中，粒度词可由多种不同词汇进行表达，是变化的。如对餐饮口感方面进行评价时，用“大人小孩都爱吃”进行评价和“美味珍馐”进行评价都是对口感的赞赏，但在粒度词的识别过程中，难以准确定位到“口感”这一粒度词。而且对于中文文本而言，句子的含义也十分重要，单通道神经网络不能充分利用文本的句法特征信息，也不能准确识别中文文本的多义性，这将影响情感分析最终结果；二是 BiSRU 模型作为时序神经网络，在长距离文本的上下文语义提取上有着较好的表现，但无法对长文本信息进行局部特征提取，造成长文本评论信息在局部信息的抓取上精度不高。

5.1.2 本文采用的方法

针对上述问题，本文采用多通道的方式输入中文文本序列，可以进一步识别序列中多个不同的语义信息。具体过程为：首先，利用 Bert 预训练模型输出文本序列的词向量和句向量信息；然后，输入到不同通道中，既保留了原始评论语句的语法顺序，又在各个通道中对文本序列的特征信息进行进一步提取；最后，针对 BiSRU 模型局部特征精度不高的问题，本文引入结构轻巧且局部特征提取效果表现优良的 TextCNN 模型，对关键词的局部信息进行特征提取，并通过池化层筛选对应特征信息。

因此，基于上述分析，为了丰富句词向量信息，获取更多情感特征，本章采用 Bert-BiSRU-Att-TextCNN 的多通道网络模型融合的方式，对中文餐饮评论进行细粒度情感分析，从而提高细粒度情感分析的准确率。

5.2 Bert-BiSRU-Att-TextCNN 的多通道模型构建

本章将基于第四章提出的 BiSRU-Att 模型进一步改进，增设句向量通道和 TextCNN 通道，以保持模型对整体句式的理解和提高挖掘局部信息的能力。通过改变向量输入方式，充分利用各通道的优点，BiSRU-Att 模型作为时序循环神经网络，有较强的保留上下文语义信息的能力，对不同词向量赋予不同权重，弥补 TextCNN 模型易丢失长距离文本序列上下文语义关系的缺陷。同时 TextCNN 模型对于局部信息的提取能力优于 BiSRU-Att 模型，句向量通道可保持整体语义的连贯性，故采用三通道分别对评论文本进行粒度特征的提取和情感极性的分析。该模型结构图如图 5.1 所示，包括输入层、多通道层、全连接层和输出层。

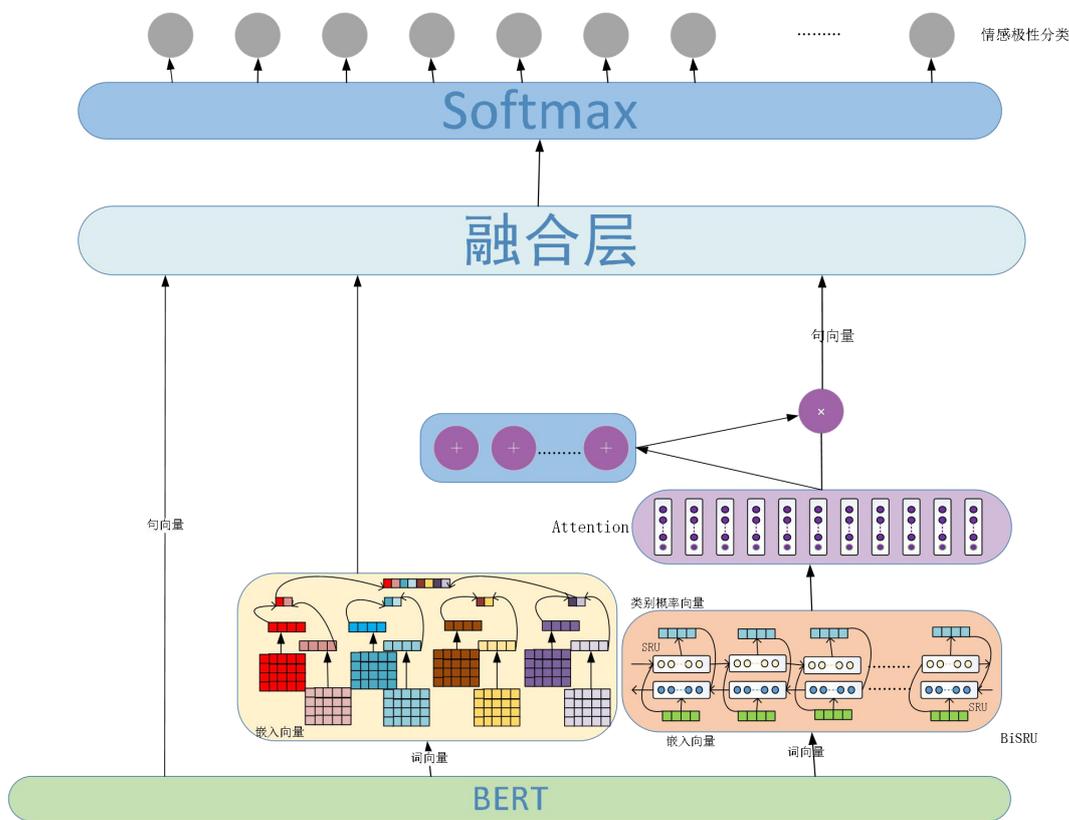


图 5.1 BiSRU-Att-TextCNN 模型结构

5.2.1 输入层

输入层首先将预处理后的评论文本转化成 Bert 可以识别的特征序列，再利用 Bert 预训练模型将评论文本中的句子和对应粒度词进行向量化，分别输出动态词向量和句向量，然后将句向量和词向量分别输入到下一层的不同通道中。因此，设给定的序列文本为 $H_n = [H_1, H_2, \dots, H_n]$ ，经过 Bert 模型将单词映射成句向量 $s_n = [s_1, s_2, \dots, s_n]$ 和词向量 $w_n = [w_1, w_2, \dots, w_n]$ 。

5.2.2 三通道层

构建三通道可以进一步对预训练模型所表达的向量进行特征提取，在该层将词向量 $w_n = [w_1, w_2, \dots, w_n]$ 分别输入到 BiSRU-Att 通道和 TextCNN 通道，将 Bert 的句向量单独构建一个通道，最终形成如图 5.1 所示的网络模型图。由图 5.1 可知，多通道模型是 BiSRU-Att 通道、TextCNN 通道和句向量通道构成，每条通道对词句向量的全局和局部特征进行特征提取，从而获得对同一条餐饮评论的多层次语义理解。

通道 1: TextCNN 通道。该通道是由 TextCNN 输入层、卷积层和池化层构成，处理过程如下：首先，采用大小不同的卷积核对词向量 $w_n = [w_1, w_2, \dots, w_n]$ 进行卷积操作，在卷积操作中，滑动窗口对所覆盖区域中的词进行一一映射，从而将新的特征记作 c_i ，计算过程如式 (5.1) 所示：

$$c_i = f(w_c \cdot [w_1, w_2, \dots, w_{i+h-1}] + b_c) \quad (5.1)$$

其中 b_c 为在 $i+h$ 滑动区域下的偏置向量， w_c 为卷积核， $[w_1, w_2, \dots, w_{i+h-1}]$ 为动态词向量。

其次，将生成的特征向量图通过池化层表示所获得的局部特征信息，选择采用最大池化操作对所获得的全部特征信息进行池化处理，将单个滑动窗口生成的特征向量图进行拼接，形成每条评论语句的局部特征向量 v_{h_i} 。

最后，将对应位置的词向量与得到的局部特征向量进行点乘，得到 $H_{TextCNN}$ 作为该通道的最终特征向量，计算过程如式 (5.2) - (5.5) 所示：

$$\hat{C}_i = \max(c_i) \quad (5.2)$$

$$v_{h_i} = (\hat{C}_{w_1}, \hat{C}_{w_2}, \dots, \hat{C}_{w_n}) \quad (5.3)$$

$$w_i v_{h_i} = (V_{w_1}, V_{w_2}, \dots, V_{w_n}) \quad (5.4)$$

$$H_{TextCNN} = (V_{w_1}, V_{w_2}, \dots, V_{w_n}) \quad (5.5)$$

其中， c_i 为输入层新的特征， \hat{C}_i 为最大池化操作后的特征信息， y_{h_i} 为拼接后的局部特征向量， w_i 为对应位置词向量， V_{w_i} 为池化输出特征向量。

通道 2: BiSRU-Att 通道。该通道是主要用于获得评论的全局特征信息，并通过加入注意力机制来提高对重点信息的特征提取。处理过程如下：首先，将预训练后的词向量输入到 BiSRU 网络中，得到矩阵 M_{H_k} ，该矩阵的每一列向量

记录了评论文本中粒度词的位置和对应语义信息；然后，通过矩阵 M_{H_k} 判断评论中是否有粒度词，若矩阵非 0 则可得到粒度词出现的位置；最后，经过 BiSRU 网络结构后，将词向量输入到注意力机制层，对重要信息赋较高的权重。具体计算过程如 4.2.2 小节。

通道 3: Bert 预训练模型生成的文本句向量通道。因生成的句向量能准确表征句子的语义，故以句向量通道的形式保证句子语义信息不会颠倒混乱。由于原生 Bert 句向量受空间的各向异性影响，高频词相对集中，低频词相对分散，不能很好的表示出词在句子中空间分布的情况，因此采用微调的方式对 Bert 的句向量进行改进。具体过程为：首先，将两个句子分别输入到参数相同的 Bert 网络中；然后，将句子 1 生成的句向量 u ，句子 2 生成的句向量 v 以及两个向量的差值 $|u - v|$ 进行 concat 拼接，生成的句向量输出到下一层。具体过程如图 5.2 所示：

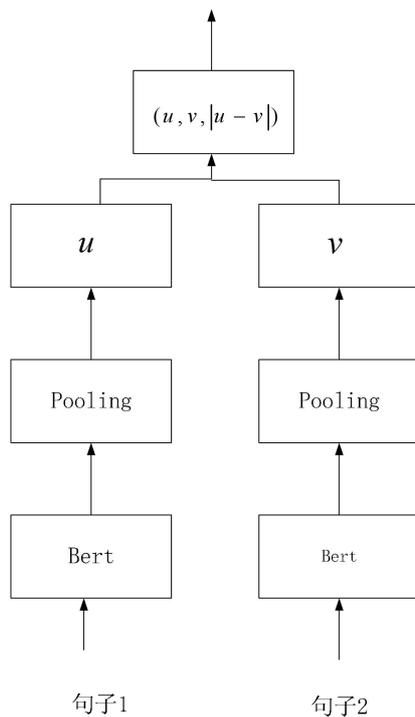


图 5.2 Bert 微调过程

5.2.3 融合层

融合层对三通道的所有特征信息进行合并，生成多特征向量，进而可以获得对同一条餐饮评论的多层次语义理解。将 Bert 预训练模型微调后生成的句向量，BiSRU-Att 通道获得的 \widehat{H}_l^{BiSRU} ，TextCNN 通道中获得的 $H_{TextCNN}$ ，作为融合

层的输入，最后在模型训练过程中，使用改进后的损失函数（见 4.3.3）计算预测值与实际值的偏差。

5.2.4 输出层

输出层是将融合层提取到的多层次语义信息，通过 dropout 随机选择神经元得到结果特征信息，最后通过 softmax 得到 13 种粒度的情感分类结果，计算过程与 4.2.3 一致。

基于以上分析，TextCNN 和 BiSRU-Att-TextCNN 的伪代码如表 5.1、5.2 所示。

表 5.1 TextCNN 伪代码

TextCNN 的伪代码

输入：训练集 $D = \{(x^{(n)}, y^{(n)})\}_{n=1}^N$ ； \bar{S} 经过全连接层的句向量；全连接层 fc ；卷积层 $[Conv_1, Conv_2, \dots, Conv_c]$ ；池化层 $[Pool_1, Pool_2, \dots, Pool_c]$ ；
输出：文本标签预测结果 \bar{y} ；

1. repeat
2. for i in c :
3. $c_i \leftarrow Pool_i(Conv(x^{(n)}))$
4. 将 c_i 进行拼接得 $out \leftarrow [c_1, c_2, \dots, c_c]$
5. $\bar{S} \leftarrow fc(out)$
6. 送入 softmax 层得标签概率 $\bar{y} \leftarrow soft \max(\bar{S})$

表 5.2 BiSRU-Att-TextCNN 伪代码

BiSRU-Att-TextCNN 的伪代码

输入：训练集 $D = \{(x^{(n)}, y^{(n)})\}_{n=1}^N$ ；SRU 遗忘门 f_t ；重置门 r_t ； A_t 当前时刻隐藏层的状态； W_f ， v_f 权重矩阵； \bar{S} 经过全连接层的句向量；全连接层 fc 、 fc_{cnn} ；Bert 模型；卷积层 $[Conv_1, Conv_2, \dots, Conv_c]$ ；池化层 $[Pool_1, Pool_2, \dots, Pool_c]$ ；
输出：文本标签预测结果 \bar{y} ；

1. repeat
2. for t in T :
3. $f_t \leftarrow \sigma(W_f x_t + v_f \odot A_{t-1} + b_f)$
4. $A_t \leftarrow f_t \odot A_{t-1} + (1 - f_t) \odot (W_f x_t)$
5. $r_t \leftarrow \sigma(W_r x_t + v_r \odot A_{t-1} + b_r)$
6. $\vec{h}_t \leftarrow r_t \odot A_t + (1 - r_t) \odot x_t$
7. 同理逆向得 \vec{h} ，并得到 SRU 输出 $out \leftarrow [H_1, H_2, \dots, H_t]$ ，其中 $H_t = [\vec{h}, \vec{h}]$
8. 取第 T 步隐藏向量作为句向量同时为目标相量 $S \leftarrow H_T$
9. $u \leftarrow \tanh(W_w \odot out)$
10. $att \leftarrow W_u \odot u$

续表

-
11. $score \leftarrow soft \max(att)$
 12. $\bar{s} \leftarrow out \odot score$
 13. for i in c:
 14. $c_i \leftarrow Pool_i(Conv(x^{(n)}))$
 15. 将 c_i 进行拼接得 $out \leftarrow [c_1, c_2, \dots, c_c]$
 16. $\bar{s}_{Bert} \leftarrow Bert(x^{(n)})$
 17. $\bar{s}_{cnn} \leftarrow fc_{cnn}(out)$
 18. $\bar{s} \leftarrow [\bar{s}_{sru}, \bar{s}_{cnn}, \bar{s}_{Bert}]$
 19. 送入 softmax 层得标签概率 $\bar{y} \leftarrow soft \max(\bar{S})$
-

5.3 实验对比与分析

5.3.1 参数设置

Bert-BiSRU-Att-TextCNN 模型所涉及到的参数如表 5.3 所示。其中，预训练模型使用的实验数据与第四章一致，情感分析模型为多通道的输入方式，BiSRU-Att 通道参数设置与第四章一致，TextCNN 通道卷积核的大小为[2, 3, 4]，经过卷积神经网络后输出的通道数为 52。

表 5.3 模型训练参数

参数名称	参数取值	参数说明
kernel_size	[2, 3, 4]	卷积核的大小
out_channel	52	输出的通道数

5.3.2 对比试验及结果分析

本章提出的 BiSRU-Att-TextCNN 模型与其他基线模型在中文餐饮评论数据集上的实验结果如表 5.4 所示，由表 5.4 可知，该模型的 F1 值为 0.751，高于其他基线模型，可见该模型效果最优。

表 5.4 情感分析模型实验结果

模型名称	F1
BiLSTM	0.6769
BiLSTM-BiSRU	0.6788
Bert	0.7193
BiSRU	0.6908
BiSRU-Att	0.7224
BiSRU-Att-BiLSTM	0.7227
TextCNN	0.743
BiSRU-Att-TextCNN	0.751

基于表 5.4 可得以下结论，在 F1 值方面：（1）TextCNN 模型在餐饮评论中有着较好的效果。本章利用 TextCNN 模型进行情感分析，其 F1 值为 0.743，比 Bert-BiSRU-Att 模型的 F1 值高 0.0206，说明 TextCNN 模型在局部特征提取上有

突出表现，有效避免长文本梯度消失问题；同时发现 BiLSTM 模型在餐饮评论细粒度情感分析中表现较差，其 F1 值相较于单一 BiSRU 模型低 0.012，因此考虑将表现较好的 TextCNN 模型代替 BiLSTM 模型融合至多通道模型中，得 BiSRU-Att-TextCNN 模型的 F1 值为 0.751，比 BiSRU-Att-BiLSTM 多通道模型 F1 值高 0.0283，说明了本章所提融合 TextCNN 模型的合理性。（2）改变输入方式，可提高情感分类模型的准确率。多通道 BiSRU-Att-TextCNN 模型的 F1 值可达到 0.751，与单通道 TextCNN 模型相比提升了 0.008，比 BiSRU-Att 模型提升了 0.0286，比 BiSRU-Att-BiLSTM 模型提升了 0.0873，说明本章所提 BiSRU-Att-TextCNN 模型最优。

为了进一步分析情感分析模型是否训练充分，本文绘制部分基线模型的 ACC、LOSS 和 F1 值随迭代次数变化的曲线。图 5.3 为模型训练过程的 ACC 值，BiSRU-Att-TextCNN 模型经过 10 次迭代，ACC 值是逐步提升的。同时 BiSRU-Att-TextCNN 模型准确率上升速度较快且始终比其他三个子模型的效果好，在 epoch 为 3 的时候增速变缓，趋于稳定，最终 ACC 结果稳定在 0.8 附近。图 5.4 为模型训练过程的 LOSS 值，BiSRU-Att-TextCNN 模型经过 10 次迭代，LOSS 值的变化趋势逐步放缓。同时 BiSRU-Att-TextCNN 模型损失值下降速度较快且损失值低于其他三种模型，在 epoch 为 2 的时候随着模型训练逐步趋近收敛，下降趋势逐步减缓，且呈轻微波动状，最终 LOSS 结果稳定在 0.43 附近。图 5.5 为模型训练过程的 F1 值，BiSRU-Att-TextCNN 模型经过 10 次迭代，F1 值的变化趋势逐步放缓。同时 BiSRU-Att-TextCNN 模型的 F1 值上升速度较快且 F1 值高于其他三种模型，在 epoch 为 2 的时候随着模型训练逐步趋于稳定，最终 F1 结果稳定在 0.751 附近。说明该模型的有效性。

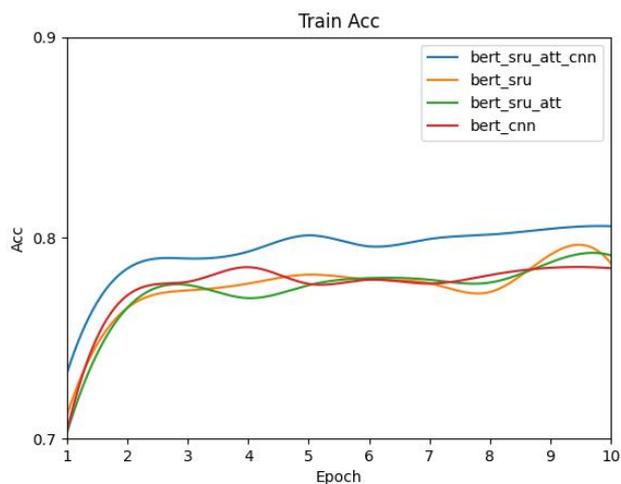


图 5.3 情感分析模型 ACC 实验结果

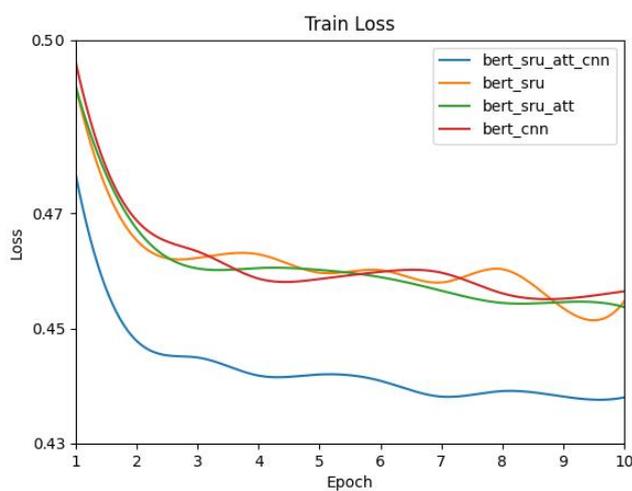


图 5.4 情感分析模型 LOSS 实验结果

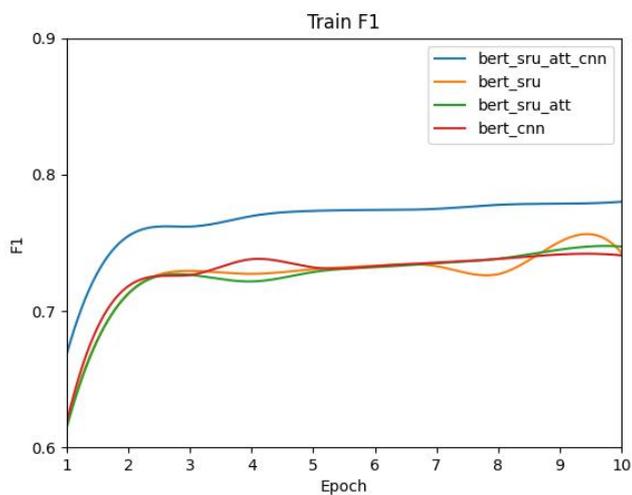


图 5.5 情感分析模型 F1 实验结果

综上所述，本文提出的 Bert-BiSRU-Att-TextCNN 多通道网络模型通过融合 BiSRU、TextCNN 模型并引入多头自注意力机制的方法，有效的提升了餐饮评论细粒度情感分析的准确率。

5.4 本章小结

本章构建了基于 Bert-BiSRU-Att-TextCNN 多通道情感分析模型，具体过程如下：首先将预处理后的评论文本输入到 Bert 预训练模型中，动态地提取文本特征向量；然后将单通道模型引入局部提取效果好的 TextCNN 模型和保留句子语义信息的 Bert 动态句向量，采用三通道的特征向量融合的方式，构建 Bert-BiSRU-Att-TextCNN 模型；最后通过对比实验，验证该模型有效性，为细粒度情感分析领域提供了一种有效的方式。

6 KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型

6.1 概述

因 Bert-BiSRU-Att-TextCNN 多通道餐饮评论细粒度情感分析模型各类参数在训练过程中已达最优，若想提升其准确率，则需要考虑提高输入词句向量的质量。而预训练模型特征提取准确率的高低，将决定了下游情感极性判别结果的好坏。因此，本章在 Bert 预训练模型基础上，进一步优化特征提取模型的准确率，以多种信息融合的方式提升预训练模型特征提取的效果，从而进一步提高餐饮评论细粒度情感分析的准确率。

6.1.1 当前方法不足及面临的问题

目前提取显性的主题词、情感词及其之间的关系有着较多的研究成果，如：采用领域词典、词袋模型、浅层神经网络算法进行评论文本的特征提取，但是存在模型效果差、特征信息提取不足等问题。具体来说存在以下两方面的问题：一是基于词典、词袋模型的特征提取，对语料库的质量和与文本匹配程度要求较高，并且静态特征难以反映位置信息，造成评价不同粒度的情感词位置混乱，最终影响准确性；同时评论文本的序列位置信息难判别，对提取出的特征词只考虑与临近文本之间的关系，忽略了特征词在不同位置的情况；此外，数据自身偏斜会极大程度影响最终的提取效果。而应用浅层神经网络，如卷积神经网络^[65]、随机场网络等进行特征提取，虽有一定进步，但提取能力有限，仅能提取浅层的语义信息，对深层特征信息，语义语法等复杂特征难以提取，导致准确率不高及计算效果差等问题；二是传统的方法，特征提取任务单纯采用序列标注方法，使用 jieba 分词和 ICTCLAS 分词，基于统计词典对输入的句子进行切分后，利用汉语词性对照表进行词性的标注，获得序列标注信息，但由于序列标注无法表达整体的评论文本信息，标注的序列信息缺乏词句之间的关系对照，句子中可能存在三元组关系未被提取，导致提取准确率不高，可见传统序列标注方法存在一定的局限性。

6.1.2 本文采用的方法

基于以上分析，传统的预训练模型存在着关联关系词提取混乱、隐式信息难提取等问题。因此，本文引入开源知识图谱，通过考虑特定领域知识之间的联系，解决关联词语提取混乱的问题，从而获取关联词语之间的语义和语法信

息。本文使用目前规模最大的开源知识图谱 HowNet，通过对评论文本的自动标注，将标注的实体利用知识图谱的关系维度进行解析，协助预训练模型提供有意义的语义知识。通过知识图谱中标注的词汇知识可以为评论增加额外的特征信息，以此训练大规模的评论数据，为下游情感分析任务提供更多的语义和语法信息。

此外，为解决隐式信息难提取的问题，本文构建了餐饮评论词向量表，增加对隐式信息的识别能力，从而提高特征提取的准确率。由于本文选择的是开源知识图谱，对特定领域信息提取不足。因此，本文在前期学者研究基础上，利用特定领域的词向量表增强对特定领域的特征提取。具体构建过程为：首先利用 kd-tree 最近邻相似度搜索方法高效进行检索，构建餐饮评论词向量表；然后将词向量表的 Word Embedding 整合到 Bert 底层，从而有助于预训练模型在特征提取过程中对特殊领域词汇的高效识别。

6.2 构建餐饮领域情感词向量表

情感词典是对某领域进行细粒度情感分析的一种常用工具，使用较多的情感词典一种是通用情感词典，另一种是某一领域的情感词典。常见的中文通用情感词典有知网 HowNet 词典、台湾大学的 NTUSD 词典、清华大学李军的褒贬义词典、大连理工大学的中文情感词汇本体库等。而专用领域的情感词典，通常仅涉及到单个领域或几个相近领域，覆盖面小，种类少，但词的划分更加精细，二级分类词汇更多。传统的情感词典存在训练与构建成本高，词语更新速度慢等问题，同时在处理过程中，需利用相关方法将其转化成词向量形式。为简化词向量转化步骤，避免维度过高引起的内存爆炸，本节利用腾讯词向量表，通过树的查找方式，构建餐饮领域情感词向量表。同时对餐饮领域情感词和主题词进行整理总结，以词向量的形式进入词典适配器中进行训练，从而提高整个预训练模型的特征提取效果。

腾讯词向量表拥有庞大的中文训练词条，提供了各种类型的词和短语句，是一个相对完美的词向量库。对词向量表的查找与构建工作流程如图 6.1 所示，构建后的词向量表部分内容如表 6.1 所示，词向量表具体构建伪代码如表 6.2 所示^[66]。

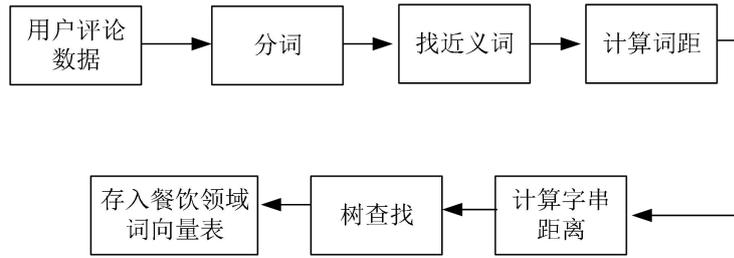


图 6.1 餐饮领域词向量表构建流程

表 6.1 餐饮领域词向量表（部分）

餐饮领域词向量表
[('服务员高呼欢迎入伙', 1.0),
('服务员说欢迎光临', 0.8969845483779907),
('服务员鼓掌欢迎', 0.8633822949409485),
('服务员鞠躬示意', 0.8461149090257263),
('门口迎宾标语', 0.8455002903938293),
('门口汉服迎宾', 0.8435534834861755)]
[('主题餐厅装修独特', 1.0),
('餐厅装修风格喜欢', 0.8896299481391907),
('墙上彩绘图案独特', 0.8729812383651733),
('西域风格独具特色', 0.8673266053199768),
('吊顶灯很少见', 0.8562214756011963),
('曲水流觞的旋转餐盘', 0.84421728229522)]

表 6.2 构建餐饮领域词向量表的伪代码

构建餐饮领域词向量表的伪代码
输入: trie_tree; word_vocab; word_embedding; 加载前 max_scan_num 个词向量餐饮评论词典编码; 词典树 trie_tree;
输出: 餐饮评论词向量表;
1. 开始匹配
2. for s in sentence:
3. for t in T:
matched_words ← get_words_from_text(text, trie_tree)
4. 将匹配好的 matched_words 词向量写入 save_file
5. 构建餐饮评论词向量编码
6. 构建单词和 id 的映射 word_vocab、embed_dim
7. for idx,word in enumerate(word_vocab.idx2token):
8. if word in word_embed_dict:
9. 餐饮评论词向量表中加入词向量和对应的 id
10. matched += 1
11. else:
12. 不加入餐饮评论词向量表
13. not_matched += 1

6.3 KW-Bert 预训练模型构建

本文在 Bert 预训练模型的基础上，进一步加强对细粒度特征提取的研究，提出了融合开源知识图谱和构建词向量表的预训练模型。为了加强对局部细粒

度特征的准确提取，Liu^[67]等人于 2020 年提出 K-Bert，将知识图谱应用于预训练模型中，解决了词向量和知识图谱中实体向量不连续的问题，同时修改 Bert 中的 Transformer，引入 visible matrix 降低导入过多知识带来的语义失真问题。这种巧妙结合的方式，使得 Bert 在中文各领域有着较好地优势，但由于 K-Bert 在情感分析领域效果并不明显，考虑开源知识图谱中缺少相关细化粒度词语及相关情感词，因此在此基础上，提出构建餐饮领域词向量表来提高 K-Bert 预训练模型的特征提取效果。

基于以上分析，本章所构建的 KW-Bert 预训练模型结构如图 6.2 所示，包括知识层、句词对序列层、可视化层、词典-知识图谱增强的 Transformer 层、词典适配器层。

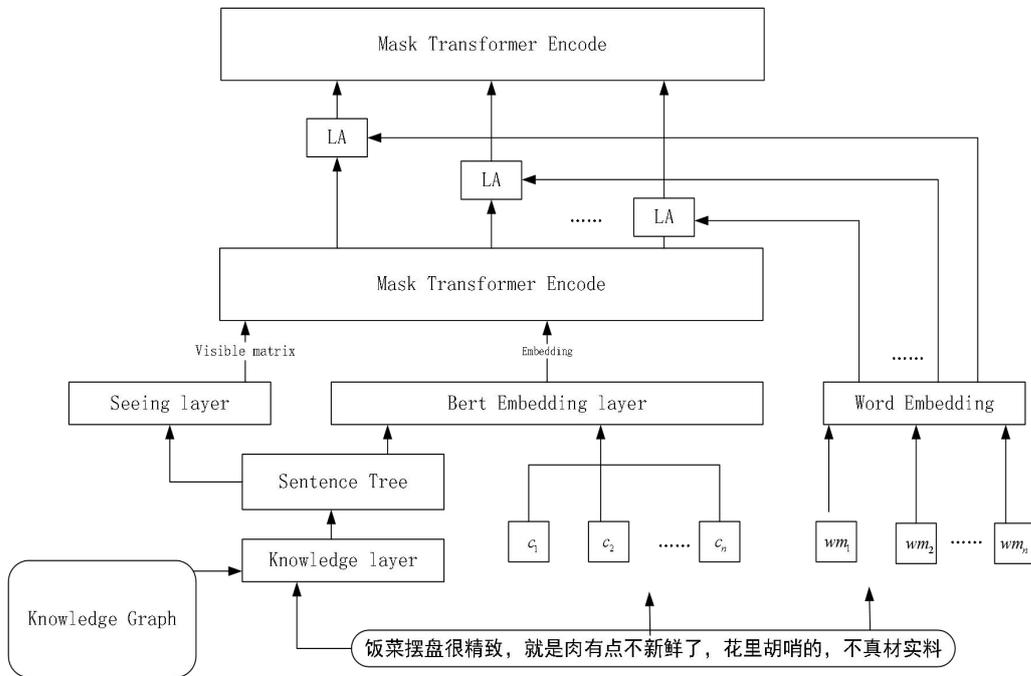


图 6.2 KW-Bert 模型结构

6.3.1 知识层

知识层的目的是将开源知识图谱中的[实体，关系，实体]三元组信息转化成三元组字向量形式，形成特定领域的句子树（depth=1）。主要工作分为知识查询和知识注入。具体过程中为：首先，将输入的评论数据通过去停用词、分词提取出语料中具有实际价值的词组、关系及情感词，以 $s = [w_1, w_2, \dots, w_n]$ 形式呈现在知识层；再利用开源的知识图谱 KG 查找处于知识层的所有的实体 E 和关系 R，查询过程如式（6.1）所示，其中 E 经过 KG 查询后，得到

$E = [(w_1, r_1, w_{1,0}), (w_2, r_2, w_{2,1}), \dots, (w_n, r_n, w_{n,k})]$ 三元组形式；然后，利用初始三元组构建 $s = [w_1, w_2, \dots, w_n]$ 的句子树，形式如 (6.2)；最后，通过知识注入的方式将查询的三元组 E 关联到句子 s 对应实体 w_i 中，生成新的句子树，如式 (6.3) 所示：

$$E = K_Query(s, KG) \quad (6.1)$$

$$T = [w_0, w_1, \dots, w_i[(r_{i,0}, w_{i,0}), \dots, (r_{i,k}, w_{i,k})], \dots, w_n] \quad (6.2)$$

$$T' = K_Inject(s, E) \quad (6.3)$$

6.3.2 嵌入层

嵌入层在特征提取的预训练模型中具有重要作用。该层的处理过程为：首先，将中文文本序列转化为可以被计算机识别的数字化向量；然后，通过合并、连接、转化将具有语义信息的数字转化成向量形式输入到模型的 Transformer 中。KW-Bert 的词嵌入层主要由两部分构成，一是融合 KG 知识树的 Bert Embedding layer，另一个是融合词典信息的 Word Embedding layer。

(1) Bert Embedding layer

Bert Embedding layer 主要包含来自 KG 知识树的词嵌入向量和传统的文本词向量。对于 KG 知识树的词嵌入序列，其句子树不同于传统文本序列，无法直接以词向量形式转化到嵌入层，因此 Liu^[67] 等人为保留句子树存在的结构信息，通过令牌嵌入、位置嵌入和段嵌入的方式修正 Bert 内部结构。具体过程为：首先，通过令牌查找表将句子树转化为 H 维的嵌入向量，使用 [cls] 和 [MASK] 分别进行分类标记和掩码操作；其次，利用硬位置索引将句子树平铺，对于乱序的句子结构信息再利用软位置索引和可见矩阵解决语序混乱的问题，继而避免知识噪声的产生 (Knowledge noises, KN)，其后令牌序列依次向后移动；最后，利用段嵌入标识不同的句子。

(2) Word Embedding layer

该层在预训练特征提取过程中，将预处理后的评论文本利用 Word2vec 进行字符序列的词向量表示，并基于餐饮评论词向量表获取包含语义信息的词汇向量，再将两个向量合并得到字符词对序列。具体过程为：首先，输入评论文本 s ，其文本序列为 $s = [c_1, c_2, \dots, c_n]$ ，领域词向量为 D ，通过遍历所有文本子序列，以在 D 中获得匹配的单词；然后，将对应的文本序列与匹配的单词向量合

并得到 $X_i = \{(c_1, wm_1), (c_2, wm_2), \dots, (c_n, wm_n)\}$ ，其中 c_i 是文本序列第 i 个嵌入向量， wm_i 是对应 c_i 匹配单词的嵌入向量。

经过 Bert Embedding layer 和 Word Embedding layer 对开源知识和文本序列的转化，最终将其输入到改进后的 KW Transformer 中，从而获得多特征语义信息。同时，因合并后的词向量中所提取到的特征信息是不可修改的，可避免在后期训练过程中丢失相关的特征信息。

6.3.3 可视化层

从 6.3.1 节可知，知识层生成的句子树，由于句子树的分支直接插入到对应节点位置，会产生语序混乱，句子不通畅的问题，因此在可视化层通过可见矩阵 M 来限制词与词之间的联系，当两个词 w_i, w_j 位于同一支路的句子树时，可见矩阵值为 0；而当两个词 w_i, w_j 不在同一支路上，可见矩阵值为 $-\infty$ 。可见矩阵 M 定义如式 (6.4) 所示：

$$M_{ij} = \begin{cases} 0 & w_i \Theta w_j \\ -\infty & w_i \not\Theta w_j \end{cases} \quad (6.4)$$

通过可见矩阵的操作，使得同一支路上两个不同位置的词可见或不可见，从而保证了词嵌入只来自同一棵句子树，对应位置不变，不同枝干的词之间不会互相影响。

6.3.4 词向量-知识图谱增强的 Transformer 层

KW Transformer Encode 的输入分别为可视化层输出的可见矩阵 M_{ij} 和嵌入层合并后的文本序列 X_i ，由于 Bert 中的 Transformer 不能接收 M_{ij} 作为本层的输入，Liu^[67] 等人对 Bert 中 Self-attention 块的堆叠做出修改，将 M_{ij} 的计算加入到 Self-attention 的 softmax 函数中，具体计算公式如 (6.5) - (6.7) 所示：

$$Q^{i+1}, K^{i+1}, V^{i+1} = h^i W_q, h^i W_k, h^i W_v \quad (6.5)$$

$$S^{i+1} = \text{soft max} \left(\frac{Q^{i+1} K^{i+1T} + M}{\sqrt{d_k}} \right) \quad (6.6)$$

$$h^{i+1} = S^{i+1} V^{i+1} \quad (6.7)$$

其中 W_q, W_k, W_v 是该模型在 Self-attention 需要学习的参数， h^i 是第 i 个隐藏层 Self-attention 的块， d_k 是缩放因子，在式 (6.6) 中加入 M_{ij} ，当两个词 w_i, w_j 处于不同支路，互不可见时，取值为 $-\infty$ ， S^{i+1} 的系数为 0，在隐藏层状态下为

不可见状态，Transformer 内部结构如图 6.3 所示。

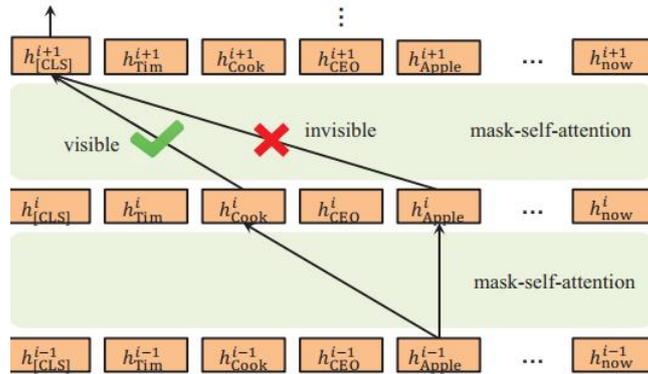


图 6.3 Transformer 变化图示

从 6.3.2 节可知，嵌入层的一条 $s = [c_1, c_2, \dots, c_n]$ 的评论文本，生成合并后的文本序列为 $X_i = \{(c_1, wm_1), (c_2, wm_2), \dots, (c_n, wm_n)\}$ ，其在 Transformer 具体过程为：首先，将字符 $\{c_1, c_2, \dots, c_n\}$ 输入到 Embedding 中，通过添加令牌嵌入、位置嵌入输出 $E = \{e_1, e_2, \dots, e_n\}$ ；然后，将 E 输入到 Transformer 中，每个 Transformer 计算如式 (6.8) - (6.9) 所示：

$$G = \text{soft max}(H^{l-1} + \text{MuAtt}(H^{l-1})) \quad (6.8)$$

$$H^l = \text{soft max}(G + \text{FFN}(G)) \quad (6.9)$$

其中， H^l 表示第 l 层隐藏层的输出， MuAtt 为经过可见矩阵 M_{ij} 修正后的 self-Att，经过归一化处理输出 G 。

6.3.5 词典适配器层

为进一步提高文本序列中特征提取的准确率，在对合并后的文本序列 X_i 进行特征词的准确匹配，在第 K 个和 $K+1$ 个 Transformer 中引入词典适配器^[68]，直接将餐饮领域词向量表信息导入 KW-Bert 中。因此，由图 6.2 可知，词典适配器的输入由 KW Transformer Encode 输出的 H^l 和 Word Embedding layer 输出的 x^{wm} 组成。而 x^{wm} 包含了所有符合 H^l 的词向量，因此，在 x^{wm} 序列中，第 j 位置的词为 $x_{ij}^{wm} = \{x_{i1}^{wm}, x_{i2}^{wm}, \dots, x_{im}^{wm}\}$ 。为了使二者的在同一纬度上对齐，使用非线性变化，如式 (6.10) 所示：

$$V_{ij}^{wm} = W_2(\tanh(W_1 x_{ij}^{wm} + b_1)) + b_2 \quad (6.10)$$

其中， W_1 是 H^l 包含合并序列 X_i 矩阵维度及隐藏层大小， W_2 是 x^{wm} 领域词典矩阵维度及隐藏层大小， b_1 和 b_2 是向量偏差。

进一步对 V_{ij}^{wm} 进行相关系数计算，得到在所有匹配的单词中选择相关程度最大的单词，然后对所有单词进行的加权，最后将词典适配器两部分的输入合并，公式如式 (6.11) - (6.13) 所示：

$$\alpha_i = \text{soft max}(H_i^l W_{att} V_{ij}^{wm}) \quad (6.11)$$

$$z_i^{wm} = \sum_{j=1}^m \alpha_{ij} V_{ij}^{wm} \quad (6.12)$$

$$\tilde{H}_i = H_i^l + z_i^{wm} \quad (6.13)$$

其中， W_{att} 是自注意力权重矩阵， α_i 为领域词典相关性系数， \tilde{H}_i 为输入词典适配器的序列向量。

将 \tilde{H}_i 输入到第 K 个和 $K+1$ 个 Transformer 的词典适配器中，首先可以得到经过 K 层连续的 $\tilde{H}_i^k = \{[H_1^{kl}, z_1^{wm}], [H_2^{kl}, z_2^{wm}], \dots [H_n^{kl}, z_n^{wm}]\}$ ，将 \tilde{H}_i^k 中的词对依次输入到词典适配器中，公式如式 (6.14) 所示：

$$\tilde{H}_i^k = LA(H_i^k, z_i^{wm}) \quad (6.14)$$

将 \tilde{H}_i^k 依次输入到 KW-Bert 其他剩余的 Transformer，最后获得特征提取任务的输出。

基于以上分析，KW-Bert 预训练模型的伪代码如表 6.2 所示。

表 6.2 KW-Bert 伪代码

KW-Bert 的伪代码	
输入:数据集 text; 知识图谱 KG; 腾讯词向量表;	
输出: output1; output2; output3; output4;	
1.遍历数据集, 找出数据集中的所有单词, 根据腾讯词向量表构建餐饮评论词向量表查找 word_embedding_label, 并将 word_embedding_label 数据加载到模型的 embedding 层	
2.读取文本 text, 通过知识图谱获得 mask, tokens, pos, vm	
3.读取文本 text, 遍历每一句话, 进行编码, 得到 word 和 word_mask, 并添加 padding.	
for sentence in text:	
tokens, pos, vm, = kg.add_knowledge_with_vm(sentence, max_length= seq_length)	
mask = [1 if t != PAD_TOKEN else 0 for t in tokens]	
word = word_vocab(sentence)	
word = [[0] * max_word_num] + word + [[0] * max_word_num]	
padding_length =seq_length - len(word)	
word += [[0] * max_word_num] * padding_length	
mask = (word_ids != 0)	
其中, kg.add_knowledge_with_vm()是添加知识图谱的函数, word_vocab()是转换词向量的函数, seq_length 是 256, PAD_TOKEN 初始值是 0, max_word_num 是 5	
4.将数据装载进 dataloader, 分批次进行训练	
5. repeat	
6. for text, mask, pos, vms, word, word_mask, label in data:	
output1 = model.embedding(text, mask, pos, vms)	# 对文本向量用 bert 编码

续表

```

output2 = model.transformers[1](output1) # 经过第一层 transformer
output3 = model.word_embedding(word, word_mask) # 词向量编码
output4 = model.lexicon_adapter(output2, output3) # 文本向量和词向量融合
for j in 2-12:
    output4 = model.transformers[j](Output4) # 经过其他 transformer
pred=model.classifier(Output4) # 分类层
loss = loss_fuc(pred, label) #计算损失
update gradient # 更新梯度
    
```

6.4 KW-Bert-BiSRU-Att-TextCNN 多通道模型构建

将 KW-Bert 预训练模型与下游多通道细粒度情感分析模型融合，既优化了词句向量特征提取的效果，又以多通道的方式分析各粒度情感极性，可有效提升餐饮评论细粒度情感分析的准确率。融合后的 KW-Bert-BiSRU-Att-TextCNN 模型结构如图 6.4 所示。该模型由两部分构成，因上文对两个模型有较详细的介绍，在此不再赘述。

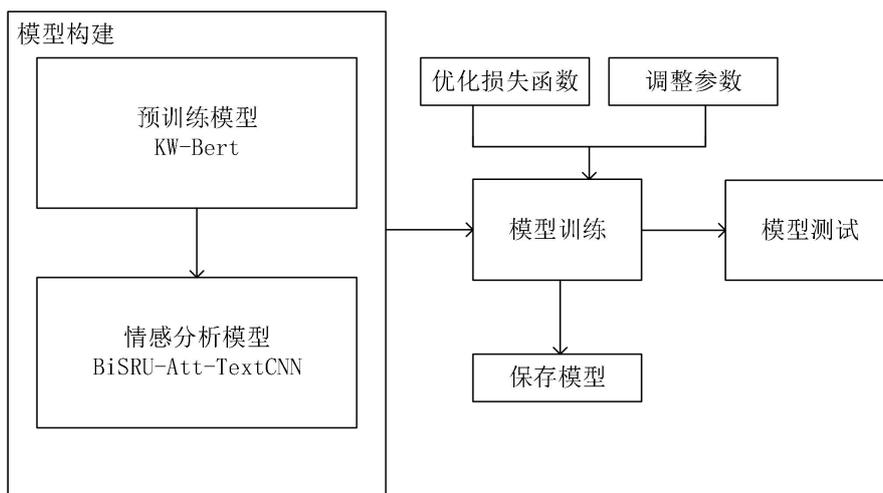


图 6.4 KW-Bert-BiSRU-Att-TextCNN 模型结构

6.5 实验对比与分析

6.5.1 预训练模型参数设置

KW-Bert 预训练模型所涉及到的参数如表 6.3 所示。其中，预训练编码器选择 Bert，副编码器采用平均池化策略获得固定的词向量长度，个数为 2，前馈全连接层维度为 3072，隐藏层单元的个数为 768，隐藏层的层数为 12 层，隐藏层的 dropout 设置为 0.1。在训练前没将知识图谱添加到预训练模型中的原因是避免知识图谱将文本序列中的两个相近的实体识别为一个，导致出现语义损失的情况，知识图谱的引入在微调过程中实现。

表 6.3 KW-Bert 参数设置

Bert 参数	参数取值	参数说明
encoder	Bert	预训练编码器的选择
subencoder	avg	副编码器使用策略
sub_layers_num	2	副编码器层数为 2
feedforward_size	3072	前馈全连接层维度
hidden_size:	768	隐藏层单元数
att_heads_num	12	在 encoder 中注意头的个数
hidden_layers_num	12	隐藏层数
hidden_dropout	0.1	隐藏层的随机失活函数

6.5.2 预训练模型对比实验及结果分析

本小节将 KW-Bert 模型与 Bert 模型、Albert 模型、K-Bert 模型进行对比实验，从而验证该模型的有效性，实验结果如表 6.4 所示。

表 6.4 预训练模型实验结果

模型名称	F1
Albert	0.703
Bert	0.719
K-Bert	0.735
KW-Bert	0.742

基于表 6.4 可得以下结论，KW-Bert 模型的 F1 值为 0.742，比 K-Bert 模型高 0.007，比 Bert 模型高 0.023，比 Albert 模型高 0.039，可见，该模型优于各基线模型；进一步分析可知，单纯的开源知识图谱以三元组形式优化了隐式关系的提取，对下游情感分析准确率的提升有一定效果。而构建的餐饮词向量表补充了知识图谱中缺少的餐饮情感词，进而提高了预训练模型的特征提取。因此，KW-Bert 的特征提取效果最好，说明本章改进的预训练模型有良好效果。

6.5.3 KW-Bert-BiSRU-Att-TextCNN 对比实验及结果分析

本小节将 KW-Bert-BiSRU-Att-TextCNN 与基线模型对比实验，从而验证该模型的有效性，实验结果如表 6.5 所示。

表 6.5 KW-Bert-BiSRU-Att-TextCNN 模型对比实验结果

模型名称	F1
Bert-BiSRU	0.6908
Bert-BiSRU-Att	0.7224
Bert-BiSRU-Att-BiLSTM	0.7227
Bert-TextCNN	0.743
Bert-BiSRU-Att-TextCNN	0.751
KW-Bert-BiSRU-Att-TextCNN	0.766

基于表 6.5 可得以下结论，改进后的模型 KW-Bert-BiSRU-Att-TextCNN 的 F1 值达到 0.766，相比模型 Bert-BiSRU-Att-TextCNN 提升了 0.015。可见，本文所提出的 KW-Bert-BiSRU-Att-TextCNN 多通道模型在餐饮评论细粒度情感分析方面有着良好的表现。

6.6 本章小结

本章构建了基于 KW-Bert-BiSRU-Att-TextCNN 多通道情感分析模型。首先对中文餐饮评论的细粒度情感分析的特征提取进行了研究，提出 KW-Bert 预训练模型，通过融合 HowNet 知识图谱并构建餐饮领域词向量表的方法，提升了餐饮评论的特征提取准确率；然后将 KW-Bert 预训练模型与 BiSRU-Att-TextCNN 多通道情感分析模型进行融合；最后通过对比实验，验证本文所提 KW-Bert-BiSRU-Att-TextCNN 模型的合理性及有效性。

7 总结与展望

7.1 总结

近年来自然语言处理技术被广泛应用于各个领域，而情感分析作为自然语言处理的重要分支扮演着越来越重要的角色。本文在大量阅读文献的基础上，提出优化预训练模型和情感分类模型，解决中文餐饮评论细粒度情感分析准确率不高的问题。本文的主要研究成果如下：

(1) 构建了 BiSRU-Att 单通道的细粒度情感分析模型。针对传统循环神经网络情感分析准确度低的问题，采用注意力机制、调节最优参数及优化损失函数的方式，对预处理后的中文评论文本进行情感极性的分析，并通过与 HEAT、ATAE、GCAE 等基线模型对比，验证模型的合理性，同时发现模型改进方向。

(2) 构建了 Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型。根据研究发现细粒度情感分析可进一步通过卷积神经网络和多通道的输入方式提高情感分析的准确性。因此构建了 BiSRU-Att-TextCNN 的多通道网络模型，以 BiSRU-Att、TextCNN 和句向量三通道的形式对中文评论进行情感极性的分析。并通过与单通道模型和基线模型对比，验证本文构建模型有效性。

(3) 构建了 KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型。通过引入开源知识图谱，利用标注词汇增加额外特征信息。基于腾讯词向量表，采用 kd-tree 对词向量进行相似度检验，将相似词组合构建成餐饮评论词向量表，整合到 K-Bert 底层，有助于在特征提取过程中对特殊领域的词汇高效的识别，为下游情感分析任务提供更多丰富的语义和语法信息。

7.2 展望

细粒度情感分析作为自然语言处理的重要组成部分，其在英文领域研究成果较多，由于中文表达情感的方式丰富，不同情感词在不同语境下表达实际意义不同且现有词典资源质量不细致，语料库标注不充分，中文细粒度情感分析仍是现阶段的研究热点。本文提出 KW-Bert-BiSRU-Att-TextCNN 多通道细粒度情感分析模型，虽然较其他传统情感分析模型在准确率上有一定的提升，但仍有完善和改进的空间，未来将在以下几个方面展开研究。

(1) 模型效率提升及内部结构优化。本研究采用的深度学习模型计算效率

不高，在训练过程中存在显卡内存溢出，训练速度慢的问题。为进一步提高情感分析的处理速度，目前相关研究利用轻量级模型和分布式计算方法，改善模型的计算效率和速度。

(2) 词对关系特征提取困难。隐式特征由于不具备实际的意义，在预训练过程中难以及时发现，对情感分析准确率产生较大影响。本文对预训练模型进行了一定的优化，但是由于缺乏特殊领域的知识图谱^[69]，开源知识图谱提供的语义信息不足，下一步将研究特定领域知识图谱与特征提取之间的关系。

(3) 模型泛化能力需进一步深入研究。本文采用同一领域的中文餐饮评论数据，模型学习到的规律相似，因此应用领域局限性较大。下一步将增强模型的泛化能力，通过标注其他不同领域的的数据训练模型，使得模型广泛应用于各个领域。

(4) 针对网络化用语及标点符号的表达需进一步研究。层出不穷的网络流行语已经深入到生活的方方面面，人们表达不同看法的过程中，会使用更为复杂的网络用语和标点符号，而通常这些词汇和标点在文本预处理过程中被删除，削弱了对情感分析的辨别程度。下一步将针对评论文本中出现的网络用语和特殊标点进行情感分析研究，以增强情感分析的强度。

参考文献

- [1] Salton G, Yu C T. On the construction of effective vocabularies for information retrieval [J]. *Acm Sigplan Notices*, 1973, 10(1): 48-60.
- [2] 李方涛. 基于产品评论的情感分析研究 [D]. 清华大学, 2011.
- [3] Irsoy O, Cardie C. Opinion Mining with Deep Recurrent Neural Networks [C]. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014, 37(1): 1567-1578.
- [4] Sang-Min Park, Sung Joon Lee, Byung-Won On. Topic Word Embedding-Based Methods for Automatically Extracting Main Aspects from Product Reviews [J]. *Applied Sciences*, 2020, 10(11): 31-38.
- [5] Peng J, Zhang C, Fu H, et al. An Approach Based on Tree Kernels for Opinion Mining of Online Product Reviews [C]. *ICDM 2010, The 10th IEEE International Conference on Data Mining, Sydney, Australia, 14-17 December 2010*. IEEE, 2010.
- [6] Lau R, Li C, Liao S. Social analytics: Learning fuzzy product ontologies for aspect-oriented sentiment analysis [J]. *Decision Support Systems*, 2014, 65(sep.): 80-94.
- [7] Wang T, Cai Y, Leung H F, et al. Product aspect extraction supervised with online domain knowledge [J]. *Knowledge-Based Systems*, November 2014, Vol. 71, pp. 86-100.
- [8] Zhijun Yan, Meiming Xing, Dongsong Zhang, et al. EXPRS: An extended pagerank method for product feature extraction from online consumer reviews [J]. *Information & Management*, 2015, 52(7): 850-858.
- [9] BKRA, AVR. A survey on opinion mining and sentiment analysis: Tasks, approaches and applications [J]. *Knowledge-Based Systems*, 2015, 89: 14-46.
- [10] Fermín L, Cruz, José A. ‘Long autonomy or long delay?’ the importance of domain in opinion mining [J]. *Expert Systems with Applications*, 2013, 40(8): 3174-3184.
- [11] Hu M, Liu B. Mining and summarizing customer reviews [J]. *Proc.ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2004, KDD (p./pp. 168-177).
- [12] Tan Y, Zhang Y, Min Z, et al. A Unified Framework for Emotional Elements Extraction Based on Finite State Matching Machine [J]. *Springer Berlin*

- Heidelberg, 2013, 60-71.
- [13] 陈炳丰, 郝志峰, 蔡瑞初, 温雯, 王丽娟, 黄浩, 蔡晓凤. 面向汽车评论的细粒度情感分析方法研究 [J]. 广东工业大学学报, 2017, 34(03): 8-14.
- [14] Zhu J, Wang H, Zhu M, et al. Aspect-Based Opinion Polling from Customer Reviews [J]. IEEE Transactions on Affective Computing, 2011, 2(1): 37-49.
- [15] Duyu Tang, Furu Wei, Bing Qin, Ming Zhou, Ting Liu. Building Large-Scale Twitter-Specific Sentiment Lexicon: A Representation Learning Approach. [C]. Proceedings of coling 2014, the 25th international conference on computational linguistics: Technical papers. 2014: 172-182.
- [16] Lin C, He Y, Everson R, et al. Weakly Supervised Joint Sentiment-Topic Detection from Text [J]. IEEE Transactions on Knowledge and Data Engineering, 2011, 24(6): 1134-1145.
- [17] 彭云, 万常选, 江腾蛟, 刘德喜, 刘喜平, 廖国琼. 基于语义约束 LDA 的商品特征和情感词提取 [J]. 软件学报, 2017, 28(03): 676-693.
- [18] Liu K, Xu L, Zhao J. Co-Extracting Opinion Targets and Opinion Words from Online Reviews Based on the Word Alignment Model [J]. Knowledge & Data Engineering IEEE Transactions on, 2018, 27(3): 636-650.
- [19] Guang Qiu et al. Opinion Word Expansion and Target Extraction through Double Propagation [J]. Computational Linguistics, 2011, 37(1): 9-27.
- [20] L. Liu, X. Nie and H. Wang, "Toward a fuzzy domain sentiment ontology tree for sentiment analysis,". 2012 5th International Congress on Image and Signal Processing, 2012, pp. 1620-1624.
- [21] Zhen Hai et al. An Association-Based Unified Framework for Mining Features and Opinion Words [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2015, 6(2): 1-21.
- [22] 肖璐, 陈果, 刘继云. 基于情感分析的企业产品级竞争对手识别研究——以用户评论为数据源 [J]. 图书情报工作, 2016, 60(01): 83-97.
- [23] Yang X, Su J. Coreference Resolution Using Semantic Relatedness Information from Automatically Discovered Patterns [C]. ACL 2007, Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics, 2007, 6: 23-30.
- [24] 郎君, 忻舟, 秦兵, 刘挺, 李生. 集成多种背景语义知识的共指消解 [J]. 中文信息学报, 2009, 23(03): 39-109.

- [25] Amplayo R K, Lee S, Song M. Incorporating product description to sentiment topic models for improved aspect-based sentiment analysis [J]. *Information Sciences*, 2018, 454: 200-215.
- [26] Zeng, L., Li, F. A Classification-Based Approach for Implicit Feature Identification [M]. *Chinese Computational Linguistics and Natural Language Processing Based on Naturally Annotated Big Data*, 2013, vol 8202, 35-43.
- [27] Lazhar F. Implicit feature identification for opinion mining [J]. *International Journal of Business Information Systems*, 2019, 30(1): 13-30.
- [28] Sun L, Sheng L, Li J Y, et al. A novel context-based implicit feature extracting method [C]. *International Conference on Data Science and Advanced Analytics. (DSAA)*. IEEE, 2014: 420-424.
- [29] Hua Xu and Fan Zhang and Wei Wang. Implicit feature identification in Chinese reviews using explicit topic mining model [J]. *Knowledge-Based Systems*, 2015, 76: 166-175.
- [30] 唐晓波, 兰玉婷. 基于特征本体的微博产品评论情感分析 [J]. *图书情报工作*, 2016, 60(16): 121-127+136.
- [31] Baccianella S, Esuli A, Sebastiani F. SentiWordNet 3.0: An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining [C]. *Proceedings of the International Conference on Language Resources and Evaluation, LREC*, 2010, 17-23.
- [32] Deng Shuyuan, Sinha Atish P., Zhao Huimin. Adapting sentiment lexicons to domain-specific social media texts [J]. *Decision support systems*, 2017, 94(FEBa): 65-76.
- [33] Khan F H, Qamar U, Bashir S. A semi-supervised approach to sentiment analysis using revised sentiment strength based on SentiWordNet [J]. *Knowledge and Information Systems*, 2017, 51(3): 851-872.
- [34] Chihli H. Word of mouth quality classification based on contextual sentiment lexicons [J]. *Information Processing & Management*, 2017, 53(4): 751-763.
- [35] Nguyen T H, Shirai K. Aspect-based sentiment analysis using tree kernel based relation extraction [C]. *International Conference on Intelligent Text Processing and Computational Linguistics*. Springer, Cham, 2015: 114-125.
- [36] Turney P D. Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews [J]. *Association for Computational*

- Linguistics, 2002, 6: 32-36.
- [37] Gaikwad G, Joshi D J. Multiclass mood classification on twitter using lexicon dictionary and machine learning algorithms [C]. 2016 international conference on inventive computation technologies (icict). IEEE, 2016, 1: 1-6.
- [38] B. Pang, L. Lee, and S. Vaithyanathan, "Thumbs up?: Sentiment classification using machine learning techniques." [J]. ACL Conf. Empirical Methods Natural Language Process., Stroudsburg, PA, USA, 2002, 2: 79-86.
- [39] Singh J, Singh G, Singh R. Optimization of sentiment analysis using machine learning classifiers [J]. Human-centric Computing and information Sciences, 2017, 7(1): 1-12.
- [40] Abbas A K, Salih A K, Hussein H A, et al. Twitter sentiment analysis using an ensemble majority vote classifier [J]. Journal of Southwest Jiaotong University, 2020, 55(1): 21-25.
- [41] Zou H, Tang X, Xie B, et al. Sentiment classification using machine learning techniques with syntax features [C]. 2015 International Conference on Computational Science and Computational Intelligence (CSCI). IEEE, 2015, 5(2): 175-179.
- [42] 樊振, 过弋, 张振豪, 韩美琪. 基于词典和弱标注信息的电影评论情感分析 [J]. 计算机应用, 2018, 38(11): 3084-3088.
- [43] Wang J, Sun C, Li S, et al. Aspect sentiment classification towards question-answering with reinforced bidirectional attention network [C]. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019, 7(3): 3548-3557.
- [44] 张柳, 王晰巍, 黄博, 刘宇桐. 基于字词向量的多尺度卷积神经网络微博评论的情感分类模型及实验研究 [J]. 图书情报工作, 2019, 63(18): 99-108.
- [45] Yang J, et al. Aspect Based Sentiment Analysis with Self-Attention and Gated Convolutional Networks [C]. 2020 IEEE 11th International Conference on Software Engineering and Service Science (ICSESS). IEEE, 2020, 6(1):33-37.
- [46] Guo X, Zhang G, Wang S, et al. Multi-way matching based fine-grained sentiment analysis for user reviews [J]. Neural Computing and Applications, 2020, 32(10): 5409-5423.
- [47] 林哲, 陈平华. 基于块注意力机制和 involution 的文本情感分析模型 [J/OL]. 数据分析与知识发现: 1-11.

- [48] 郭荣荣, 高建瓴, 徐瑞涓. 融合多特征图卷积神经网络的方面级情感分析 [J/OL]. 小型微型计算机系统: 1-10.
- [49] Pan S J, Yang Q. A survey on transfer learning [J]. IEEE Transactions on knowledge and data engineering, 2009, 22(10): 1345-1359.
- [50] Zeng, DaojianDai, YuanLi, FengWang, JinSangaiah, Arun Kumar. Aspect based sentiment analysis by a linguistically regularized CNN with gated mechanism [J]. Journal of intelligent & fuzzy systems: Applications in Engineering and Technology, 2019, 36(5): 41-45.
- [51] Lan Z, Chen M, Goodman S, et al. Albert: A lite bert for self-supervised learning of language representations [J]. ICLR 2020 Conference Blind Submission, Dec 2019, 1909-1923.
- [52] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures [J]. Neural networks, 2005, 18(5-6): 602-610.
- [53] Fiebelkorn I C, Kastner S. Functional specialization in the attention network [J]. Annual review of psychology, 2020, 71: 221-249.
- [54] Guo M H, Lu C Z, Liu Z N, et al. Visual attention network [J]. arXiv:2202.09741, 2022.
- [55] Zhao H, Jia J, Koltun V. Exploring self-attention for image recognition [C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 10076-10085.
- [56] Zhang H, Goodfellow I, Metaxas D, et al. Self-attention generative adversarial networks [C]. International conference on machine learning. PMLR, 2019: 7354-7363.
- [57] Zhang X, Song X, Feng A, et al. Multi-self-attention for aspect category detection and biomedical multilabel text classification with bert [J]. Mathematical Problems in Engineering, 2021, 2021: 1-6.
- [58] Yu L, Chen L, Dong J, et al. Detecting malicious web requests using an enhanced textcnn [C]. 2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC). IEEE, 2020: 768-777.
- [59] Wang Q, Qian Q. Malicious code classification based on opcode sequences and textCNN network [J]. Journal of Information Security and Applications, 2022, 67: 103-151.

- [60] Zhang T, You F. Research on short text classification based on textcnn [C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1757(1): 012-092.
- [61] De Angeli K, Gao S, Danciu I, et al. Class imbalance in out-of-distribution datasets: Improving the robustness of the TextCNN for the classification of rare cancer types [J]. Journal of biomedical informatics, 2022, 125: 103-157.
- [62] Tang, D., Qin, B., Feng, X., and Liu, T., Effective LSTMs for Target-Dependent Sentiment Classification [J]. Computer Science, 2016, 3298-3307.
- [63] Cheng J, Zhao S, Zhang J, et al. Aspect-level Sentiment Classification with HEAT (HiErarchical ATtention) Network [C]. ACM, 2017: 97-106.
- [64] Wei X, Tao L. Aspect Based Sentiment Analysis with Gated Convolutional Networks [J]. Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018, 2514-2523.
- [65] Wang L, Cao Z, De Melo G, et al. Relation classification via multi-level attention cnns [C]. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2016: 1298-1307.
- [66] Wu S, He Y. Enriching pre-trained language model with entity information for relation classification [C]. Proceedings of the 28th ACM international conference on information and knowledge management. 2019: 2361-2364.
- [67] Liu W, Zhou P, Zhao Z, et al. K-BERT: Enabling Language Representation with Knowledge Graph [J]. 2019, 70-74.
- [68] Liu W, Fu X, Zhang Y, et al. Lexicon Enhanced Chinese Sequence Labeling Using BERT Adapter [J]. 2021, 66-71.
- [69] 叶子诚, 闫桂英. 基于图模型的关键词提取算法研究 [J]. 系统科学与数学, 2021, 41 (04): 967-975.

致谢

明朝即长路，惜取此时心。三年的研究生生活即将走到终点，此刻的自己百感交集。回首过往，唯有感谢！

一朝沐杏雨，一生念师恩。感谢我的导师王玉珍教授，感谢老师在选题与撰写过程中给予了我充分的支持以及学术上的指导。从论文的选题到最终成文，从宏观结构到微观调整，感谢您陪我字斟句酌，倾尽所能指导我。事非经过不知难，成如容易却艰辛。不论是学业，生活亦或未来规划，感谢您的指导、帮助和关心，同时，感谢信息工程学院的所有老师，您所教授的课程使我受益匪浅，承蒙教诲，不胜感激。希望老师工作顺利，平安幸福。

焉得援草，言树之背，我十分感恩我的父母，家人。求学二十余载，是他们一直以来给予我支持与鼓励。感谢我的母亲永远鼓励我，从小到大教育我自立自强，从您身上能看到女性的坚韧、独立、自强的优秀特质；感谢我的父亲永远支持我，支持我的任何爱好和行为，让我能够心无旁骛地坚持自己的梦想；感谢我的爷爷总是相信我，用自己英勇事迹激励我踔厉奋发，笃行不怠。希望亲人平安顺遂，健康喜乐。

春日不迟，相逢有期。我记得 106 窗外的艳阳高照，也记得黄河边的日落时分，还记得白塔山的晴空如洗，我更记得身边同学、朋友的春风化雨。感谢我的师兄师姐在学习生活中给予的宝贵意见和指导，感谢我的师妹们坚持不懈的为我加油打气，感谢我的室友、同窗们在就业、学习、生活方方面面给予的帮助。相遇一场，皆是缘分，希望大家岁岁常欢愉，年年皆胜意。

人间烟火气，最抚凡人心。最后，我想感谢自己，感谢不断成长的自己。感谢自己始终没有放弃充实自己的决心，感谢一路走来不完美但一直默默坚持的自己，作为一个积极地悲观主义者，时而自信，偶尔自卑，时而克制，时而放纵，我无法做到“大凡治事”，那就脚踏实地地走在时代的大潮中，尽我所能，做我该做的事。

最后，人生海海，祝你我有帆有岸。

攻读硕士学位期间发表的论文及科研情况

[1]秦精俏,王彤,王玉珍.基于 Word2vec_BiLSTM 的用餐评论情感分析[J].枣庄学院学报,2022,39(02):37-44.

[2]王玉珍,秦精俏.基于熵权 TOPSIS 法的营商环境办事便捷度评价——以甘肃省为例[J].河西学院学报,2022,38(01):47-54.

[3]丁申宇,王玉珍,秦精俏.乡村旅游电商发展的影响因素研究——基于 SWOT-AHP 模型[J].洛阳师范学院学报,2021,40(08):24-27+38.

[4]参与兰州财经大学项目：甘肃省乡村旅游电商发展对策研究；项目编号：2021SL02.

[5]参与兰州财经大学项目：突发事件舆情传播与舆情引导研究；项目编号：lzufe-ix-2021-020.

[6]参与兰州财经大学项目：甘肃省营商环境评价及优化问题研究；项目编号：20CX9ZA062.