

基于层级知识增强和义原知识的 中文隐式情感分析

王红斌¹, 张煊赫¹, 侯明辉²

(1. 昆明理工大学 信息工程与自动化学院, 昆明 650500;

2. 吉林大学 计算机科学与技术学院, 长春 130012)

摘要: 针对隐式情感分析中缺乏明显情感线索、存在混合情感特征、多义性特征以及语境依赖特征等问题, 提出一种基于层级知识增强和义原知识的中文隐式情感分析方法, 先引入基于转换器的双向编码器表示技术的情感预训练模型以增强情感线索识别能力, 然后通过字符级信息获取、区域移动框学习、全局信息学习及多池化操作处理混合情感特征。同时, 结合义原知识和密度矩阵, 利用 HowNet 知识库缓解多义性问题, 并与双向长短期记忆网络特征融合以应对语境依赖特征。实验结果表明, 该方法在有效性、优越性和泛化性方面均表现优异, 为中文隐式情感分析提供了可借鉴的技术路径, 有助于提升社交媒体、用户评论等场景下的情感理解与决策支持能力。

关键词: 隐式情感分析; 外部知识; 知识增强; SentiBERT 模型; 层级知识; 义原知识

中图分类号: TP391 **文献标志码:** A **文章编号:** 1671-5489(2026)03-0568-13

Chinese Implicit Sentiment Analysis Based on Hierarchical Knowledge Enhancement and Sememe Knowledge

WANG Hongbin¹, ZHANG Xuanhe¹, HOU Minghui²

(1. Faculty of Information Engineering and Automation,

Kunming University of Science and Technology, Kunming 650500, China;

2. College of Computer Science and Technology, Jilin University, Changchun 130012, China)

Abstract: Aiming at the problems that there were the lack of explicit sentiment clues, mixed sentiment features, polysemy features and context dependence features in implicit sentiment analysis, we proposed a Chinese implicit sentiment analysis method based on hierarchical knowledge enhancement and sememe knowledge. We first introduced a sentiment pre-training model based on bidirectional encoder representation technology of converters to enhance the ability of sentiment clue recognition. Then we handled mixed sentiment features through character-level information acquisition, region moving box learning, global information learning, and multi-pooling operations. At the same time, we combined sememe knowledge and density matrix, utilized the HowNet knowledge base to alleviate polysemy issues, and integrated with bidirectional long short-term memory network features to tackle context dependence features. Experimental results show that the proposed method performs

收稿日期: 2025-01-26.

第一作者简介: 王红斌(1983—), 男, 汉族, 博士, 教授, 从事自然语言处理的研究, E-mail: whbin2007@126.com. **通信作者**

简介: 侯明辉(1995—), 男, 汉族, 博士研究生, 从事自然语言处理的研究, E-mail: houminghui6@126.com.

基金项目: 国家自然科学基金(批准号: 61966020)和云南省基础研究面上项目(批准号: 202201AT070157).

excellently in terms of effectiveness, superiority, and generalizability, providing a valuable technical path for Chinese implicit sentiment analysis and helping to improve sentiment understanding and decision-making support capabilities in scenarios such as social media and user reviews.

Keywords: implicit sentiment analysis; external knowledge; knowledge enhancement; SentiBERT model; hierarchical knowledge; sememe knowledge

情感分析作为自然语言处理(NLP)领域的一个重要研究方向,近年来受到广泛关注.多数研究致力于通过分析文本中的情感倾向,挖掘人们的情感态度和情绪状态.这些研究在社交媒体舆情分析、产品评论情感挖掘、新闻情感监测等多个领域都取得了显著成果. Liu^[1]将情感归纳为显性和隐性,前者是一种给出意见的主观陈述,后者则通过客观陈述暗示了一种意见.在情感分析的众多分支中,隐式情感分析因其特殊性而面临诸多挑战.

隐式情感分析主要针对没有明显情感线索的文本,情感表达较隐蔽和含蓄.与显式情感分析不同,中文隐式情感分析研究因为无明显情感线索的问题而很难进行^[2],如“高兴”和“愤怒”等,使得基于关键词匹配和情感词典的传统方法很难直接应用于隐式情感分析.如“来动物园的人不是来看动物的,是来看人的!”暗含无奈,却无明显情感词,导致分析困难,称为弱特征问题.同时,文本中可能存在多个情感对象,通过对比等方式隐式表达情感,如“比起去人爆满的香格里拉,还是在家里躺着吧”,对“香格里拉”消极,实则突出对“在家”的积极情感,称为混合情感特征.此外,隐式情感分析还存在多义性特征,如“热”可指天气或热情;以及语境依赖特征,情感表达依赖具体语境,脱离上下文很难准确理解.

在以往研究中,人们通常只关注上下文语境的问题,或者只解决了多义性特征的问题,而未能全面处理隐式情感分析中的混合情感特征.例如,一些研究通过构建复杂的上下文模型捕捉文本中的语境信息,如利用长短期记忆网络(LSTM)或双向长短期记忆网络(BiLSTM)建模词语之间的依赖关系,从而更好地理解词语在特定上下文中的含义^[3].然而,这些方法可能在处理多义性特征时存在不足,因为它们主要依赖于上下文信息消歧,而未充分利用外部知识或语义规则辅助理解词语的多义性.另一方面,也有研究专注于解决多义性特征的问题,如通过引入外部语义知识库(如 WordNet 或 HowNet)提供词语的多种可能含义.但这些方法可能在捕捉上下文语境方面存在局限性,因为它们更多地关注了词语的语义消歧,而未充分考虑词语之间的复杂关系和整体的情感倾向.目前,国内隐式情感分析方法的主要局限性有:1)情感线索较弱;2)混合情感特征;3)多义性特征;4)语境依赖特征.

为解决隐式情感分析中存在的问题,本文提出一种基于层级知识增强和义原知识的中文隐式情感分析方法.该模型旨在更有效地利用外部知识和全局信息特征,以补充情感表达.针对情感线索较弱的问题,本文引入一种全新的预训练模型——SentiBERT^[4],它是一种 BERT 的变体,解决了 BERT 忽略预训练阶段的情感特定知识的问题,从而增强情感线索.为解决混合情感特征,本文先获得句子的字符级信息,然后设立一个区域移动框,通过框的移动学习框中文本的部分信息,再学习全局的信息,最后通过多池化操作保留文本中的最重要部分.在外部知识部分,本文采用最基本的语言单位义原^[5]和密度矩阵^[6],并且引用了外部知识库 HowNet 解决多义性特征的问题^[7].外部知识嵌入后,与双向长短期记忆网络特征进行融合从而解决语境依赖特征.最后,将全局信息特征与外部知识特征进行融合.实验结果表明,本文方法在有效性、优越性和泛化性方面均验证有效.

本文主要贡献如下:

1) 引入了 SentiBERT 预训练模型,它是 BERT 的一种变体,专门针对情感分析任务进行优化. SentiBERT 在预训练阶段融入了情感特定知识,使模型能更好地捕捉并理解文本中的情感信息.这种创新应用有效解决了传统方法在处理隐式情感分析时因缺乏明显情感词汇而导致情感线索较弱的问题,增强了模型对情感倾向的识别能力.

2) 将外部知识与双向长短期记忆网络特征进行融合,构建了一种创新的模型架构,从而有效解决

了语境依赖特征问题。这种创新架构使模型在分析情感时能更好地依赖于具体的语境,提高情感分析的准确性和鲁棒性,同时也为隐式情感分析中语境依赖特征的处理提供了新的思路和方法。

3) 本文采用 SMPECISA 2019 上发表的公共语料库数据集进行实验。实验结果表明,该模型优于几种目前先进的方法,从而证实了该模型的有效性和优越性。

1 相关工作

1.1 隐式情感分析

目前,隐式情感分析的研究主要集中在两个核心领域:一是构建高质量的语料库,以提供丰富的训练和测试数据;二是开发有效的算法和模型,以识别和分析那些不含有直接情感词汇的隐式情感表达。现有大多数语料库都是基于显式情感分析构建的^[8-9]。Ding 等^[10] 通过从数据集 ICWSM 2009 Spinn3r 中筛选并处理个人博客帖子,创建了一个用于情感事件识别的语料库。Liao 等^[11] 提出了一个细粒度、分层、面向社交媒体的标注框架,构建了一个由显式和隐式情感标注句子组成的大型语料库。Zhang 等^[12] 构建了一个汉语隐喻语料库,该语料库包含语言隐喻、情感类别(喜悦、愤怒、悲伤、恐惧、爱、厌恶和惊讶)和强度的注释。Liao 等^[13] 构建了一个用户个性化通用情感分析语料库,涵盖了较完整的文本内容信息、用户社会化属性信息和关系信息,可同时满足面向用户个性化建模的隐式或显式情感分析相关研究任务的需求。

在隐式情感创新模型方面,Ahmad 等^[14] 提出了一种基于统一隐式对比机制的方面级情感分析方法(sEntIMeldCL-ALSA),通过方面特定分割适配器、统一隐式增强模块和显隐式双重对比损失,有效提取方面词与句子情感极性之间的语义关联,验证了该方法在增强显式知识表示方面的优越性。He 等^[15] 提出了一种基于层级隐式特征融合的方面级情感分析模型(CABiLSTM-BERT),有效解决了模型在训练过程中因浅层与中间层隐式特征信息丢失而导致的分类性能下降问题。Mao 等^[16] 提出了一种基于知识增强与上下文信息融合的隐式情感分析模型,通过引入知识图谱实体嵌入并进行检索和筛选,结合动态协同注意力机制有效融合外部常识知识与上下文特征,在中文和英文隐式情感数据集上均取得了优于已有方法的性能。Li 等^[17] 提出了一种基于多提示融合和图神经网络的隐式方面级情感分析生成模型,利用 T5 预训练模型并结合图卷积网络捕捉文本中的结构依赖关系,通过多顺序提示融合和差异化损失函数优化情感四元组的生成,在数据集上达到最优。Ren 等^[18] 提出了一种基于前门调整的因果提示框架(CAPITAL),将链式思维推理中的因果效应分解为输入提示对推理链的影响和推理链对最终输出的影响,通过编码器聚类和 NWGM 近似估计因果效应,有效降低了大语言模型中的内部偏差。Lai 等^[19] 提出了一种两阶段推理和验证框架(RVISA),先利用解码器专用大语言模型通过三跳推理生成蕴含情感要素的推理链,并基于答案正确性构建验证信号,然后在多任务微调框架下对编码器-解码器模型进行联合优化,有效提升了对隐式情感的推理能力与预测可靠性。Wang 等^[20] 提出了一种融合义原知识库的隐式情感分析模型。

1.2 知识图谱嵌入学习

在自然语言处理任务中,已有很多研究引入外部知识进行知识增强的工作。Balahur 等^[21] 通过整合常识知识库,在缺乏直接情感词汇的文本中成功推断出情感倾向。Wang 等^[22] 提出了一种创新的推荐系统模型 RippleNet,该模型通过分析用户与知识图谱实体的互动预测用户偏好,实现个性化推荐。RippleNet 的核心是利用知识图谱内实体的相互关系,结合用户交互数据揭示用户喜好。Liu 等^[23] 开发了一种称为 Entity-duet 的神经排序模型,该模型结合了知识图谱中实体的语义信息和文本查询的语境信息。Entity-duet 模型通过整合来自知识图谱的实体数据和用户的查询内容,提高了对用户需求的理解和预测的准确性。Zhang 等^[24] 在自然语言推理任务中融入了外部知识,先从句子对中识别出关键实体,例如主语、谓语和宾语,然后将这些实体用作知识图谱中的节点,该图谱是预先定义好的,并且包含了丰富的实体关系信息,最后利用双向长短期记忆网络学习这些句子间的语义关系。此外,Zhang 等^[24] 还将这些学习到的语义关系表示与原始文本结合,以进行更深入的推理分析。整合知识信息到预训练模型中已被证明是一种提高模型性能的有效策略。例如,MA-BERT 模型^[25] 通过这种方式

增强了预训练词表示的语义丰富度. Wang 等^[26]修改了 BERT 原有的编码器结构, 增加了实体嵌入输入. 通过这种方式, 在预训练过程中引入外部知识, 提高下游任务的效果. 基于认知计算的情感分析^[27]是一种创新的方法, 它将人类认知过程中的知识整合到模型中. 通过结合二元头脑风暴优化和模糊认知图, 基于认知计算的情感分析模型能更准确地模拟人类的情感识别和决策过程, 从而在处理复杂的情感分析任务时表现出更高的性能和适应性. Axelsson 等^[28]探讨了利用大型语言模型(如 ChatGPT), 在无需特定训练的情况下, 从知识图谱生成自然语言文本的方法. Wei 等^[29]提出了一种基于 GPT(generative pre-trained transformer)的知识上下文框架(KICGPT), 通过集成大型语言模型和传统的结构感知知识图谱模型, 实现了知识图谱补全任务, 并通过知识提示和候选实体的重新排序提高效果, 同时克服了三元组方法和基于文本方法的限制.

2 本文方法

针对目前汉语隐式情感分析中的局限性, 本文提出一种新的情感分析研究方法——基于层级知识增强和义原知识的中文隐式情感分析模型, 其结构如图 1 所示.




图 1 HDSK 框架结构

Fig. 1 HDSK framework structure

由图 1 可见, 该模型主要分为四部分: 输入模块、层级知识增强模块、外部知识模块和特征融合与输出模块. 输入模块将句子输入到预训练模型 SentiBERT 中, 以增强情感线索, 并得到基于字符级别的语义信息. 层级知识增强模块在字符嵌入的基础上, 通过区域嵌入进一步学习局部单元的信息, 可能涉及到使用滑动窗口等技术考虑字符之间的局部关系. 在区域层之后, 模型进一步学习全局信息, 可能涉及到对整个句子的上下文进行建模. 最后, 通过多池化层整合不同层次的信息, 提取最重要的特征. 外部知识模块利用义原知识库 HowNet^[30], 为每个词提供更细粒度的语义信息. 然后通过义原注意力机制, 模型可以学习词与义原之间的关系, 以及这些关系如何影响情感表达. 将义原信息通过密度矩阵建模, 用于捕捉词义之间的复杂关系. 最后与双向长短期记忆网络融合, 用于进一步处理义原信息. 特征融合与输出模块将得到的层级知识增强特征与外部知识嵌入后的特征进行融合, 然后通过全连接层后输入到分类器中.

2.1 模型

2.1.1 输入模块

该模块中使用 BERT 的变体 SentiBERT 作为本文实验的预训练模型, 它可以将 BERT 忽略的预训练阶段的情感特定知识融入, 从而增强情感线索. 将句子输入到 SentiBERT 中进行分词编码, 从而获得基于字符级的特征向量 $\mathbf{F}_{\text{word}}$:

$$\mathbf{F}_{\text{word}} = \text{Senti}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n), \quad (1)$$

其中 $\mathbf{w}_i (i=1, 2, \dots, n)$ 为每个字符的向量表示.

2.1.2 层级知识增强模块

该模块根据 Qiao 等^[31]的研究采用滑动窗口获取局部信息, 并将局部信息与字符信息进行卷积以获得一个基于全局信息的特征向量. 最后通过多池化操作, 筛选出目标句中权重较高的部分, 以解决混合情感特征.

在自然语言处理中, 特别是在情感分析任务中, 词的情感色彩和含义通常不是孤立的, 而是与其周围语境密切相关. 例如, 同一个词在不同语境中可能会表达完全不同的情感色彩. 因此, 为准确捕捉这种细微的情感差异, 模型需能理解词在具体语境中的含义, 从而需利用局部信息向量与全局信息向量.

先设置一个滑动窗口 W , 该滑动窗口大小人为设置, 其中包含 i 个字符向量. 局部单位 W 的大小尺寸如下:

$$W = 2 \times i + 1. \quad (2)$$

在窗口中, 每个字符向量都会与其余字符向量相乘. 在局部单位处理完框中的 i 个字符向量后, 会向后移动一个字符, 并继续处理窗口内信息直到最后一个字符向量处理完, 整个操作可表示为

$$\mathbf{F}_{w_n} = \mathbf{C}_{w_i \pm x} \odot \mathbf{w}_i, \quad (3)$$

其中: $\mathbf{F}_{w_n}$ 表示第 n 个局部单元的信息; $\mathbf{w}_i$ 表示第 i 个字符的向量表示; $\mathbf{C}_{w_i \pm x}$ 表示以目标词向量 $\mathbf{w}_i$ 为中心的上下文嵌入向量 $\mathbf{w}_{i \pm x}$ 的集合, $\mathbf{C}_{w_i \pm x} \in \mathbb{R}^{h \times 2i}$, h 表示嵌入的维度, $2i$ 表示当前未包含目标词的字符数. 通过将上下文嵌入向量 $\mathbf{w}_{i \pm x}$ 与目标词的嵌入向量 $\mathbf{w}_i$ 中的相应元素相乘, 能推导出目标词在第 n 个局部单元的嵌入表示 $\mathbf{F}_{w_n}$. 最后, 将每个局部单元的嵌入表示学习结果进行拼接, 可表示为

$$\mathbf{F}_w = \text{concat}(\mathbf{F}_{w1}, \mathbf{F}_{w2}, \mathbf{F}_{w3}, \dots, \mathbf{F}_{w_n}). \quad (4)$$

特征矩阵 $\mathbf{F}_w$ 表示嵌入了目标语句的局部信息特征, 其整合了字符级别的细节和字符之间局部上下文的关联信息. 然后通过卷积操作获得两个一维向量 $\mathbf{X} = (x_1, x_2, \dots, x_n)$ 和 $\mathbf{Y} = (y_1, y_2, y_3, \dots, y_n)$:

$$\begin{cases} \mathbf{X} = \text{conv}^1(\mathbf{F}_w), \\ \mathbf{Y} = \text{conv}^2(\mathbf{F}_w). \end{cases} \quad (5)$$

为建立每个词与其余词(包括自身)的联系, 将向量 $\mathbf{X}$ 与向量 $\mathbf{Y}$ 的转置进行按元素遍历相加, 得到关系矩阵:

$$\mathbf{Z} = \mathbf{X} \oplus \mathbf{Y}^T. \quad (6)$$

经过全局信息增强处理的矩阵 $\mathbf{Z}$, 在应用 Softmax 函数后, 转化为一个概率矩阵函数 $\mathbf{Z}^S$. 该概率矩阵之后与融合了字符级和局部单元信息的表示矩阵相结合, 以形成更丰富的文本表示学习矩阵 $\mathbf{F}_G$. 这一结合过程通过矩阵乘法实现, 以确保文本的全局性语义特征得到充分捕捉和利用, 从而为情感分析提供更精确的语义基础, 用公式表示为

$$\mathbf{Z}^S = \text{Softmax}(\mathbf{Z}), \quad (7)$$

$$\mathbf{F}_G = \mathbf{Z}^S * \mathbf{F}_w. \quad (8)$$

特征矩阵 $\mathbf{F}_G$ 综合了字符层面、局部单元以及整体信息, 从而能更全面且精确地对文本目标进行建模和表达. 这种综合考量的方式对提升文本分类任务的准确度有显著优势.

本文借鉴了 Chen 等^[32]提出的多池化策略, 以应对文本中混合情感特征的挑战. 通过采用多池化技术, 旨在从文本数据中识别并提取关键特征. 这种方法能管理和解析在单一文本样本中可能呈现的多样情感态度. 多池化层处理的输入是源自之前步骤中生成的表示学习矩阵 $\mathbf{F}_G$, 该矩阵通过卷积边缘

信息操作转换成特征矩阵 F_i , 用公式表示为

$$W_b = \text{conv}(F_G), \quad (9)$$

然后应用非线性激活函数 f 到加权卷积结果上, 表达式为

$$F_i = f(q \times W_b + b), \quad (10)$$

其中 q 表示权重参数, W_b 表示卷积中的边缘元素, b 表示偏置项. 进一步, 在 F_i 矩阵的每列序列中, 用多池化技术挑选出 k 个最具代表性的特征值, 构建特征矩阵, 可表示为

$$F_h = \text{pool}(F_i, k), \quad (11)$$

其中 pool 表示多池化操作, 用于从每个序列中筛选出最重要的 k 个特征值, 从而形成新的特征矩阵 F_h . 这种方法允许模型在处理有多重情感色彩的文本时, 能更细致和精确地识别与表达情感特征.

2.1.3 外部知识模块

为应对汉语隐式情感分析中的多义性和语境依赖问题, 本文引入 HowNet 作为外部知识库, 并采用量子理论中的密度矩阵概念构建全局语义模型. 通过整合 BiLSTM 网络, 实现了上下文信息与义原信息的有效融合.

为获取词汇的义原向量表示, 采用 SAT(sememe attention over target)^[5] 方法. 该方法先通过考虑上下文单词对中心词进行词义消歧, 再使用注意力机制计算上下文对中心词各词义的权重, 然后利用这些权重计算中心词的向量表示. SAT 模型会根据上下文单词对目标词的各义原(词义的最小单位)进行加权, 从而得到一个综合的词向量, 可表示为

$$\mathbf{w} = \sum_{i=1}^{\|\mathbf{S}^{(w)}\|} \text{att}(\mathbf{s}_i) \cdot \mathbf{s}_i, \quad (12)$$

其中 $\mathbf{w}$ 表示目标词的向量表示, $\mathbf{S}^{(w)}$ 表示目标词的所有义原集合, $\mathbf{s}_i$ 表示第 i 个义原的向量表示, $\text{att}(\mathbf{s}_i)$ 表示第 i 个词的注意力. 权重注意力公式为

$$\text{att}(\mathbf{s}_i) = \frac{\exp\{\mathbf{w} \cdot \mathbf{s}_i\}}{\sum_{k=1}^{\|\mathbf{S}^{(w)}\|} \exp\{\mathbf{w} \cdot \mathbf{s}_i\}}, \quad (13)$$

其中 $\mathbf{s}_i$ 表示结合了该义原的所有相关向量信息.

为进一步增强和精确化基于义原的语义表达, 采用密度矩阵层. 该过程步骤如下: 首先, 收集与每个词汇相关联的所有义原向量, 这些向量详细描述了词汇的语义特征; 其次, 使用这些义原向量, 通过计算它们的外积并求和构建密度矩阵. 密度矩阵是一个方阵, 其元素反映了不同义原向量之间的语义相关性或重叠程度. 用 $\mathbf{w}_k$ 表示第 k 个义原向量, 则密度矩阵 F_{dm} 可表示为

$$F_{\text{dm}} = \sum_{k=1}^n |\mathbf{w}_k\rangle \langle \mathbf{w}_k|. \quad (14)$$

通过这种方式得到的密度矩阵 F_{dm} 是一个 $d \times d$ 阶的方阵, 其中 d 为义原向量的维度. 密度矩阵层的作用可以概括为通过量化义原向量之间的相互作用, 为模型提供一个更丰富和结构化的语义空间, 从而在情感分析中更准确地识别和区分不同情感倾向.

在构建密度矩阵 F_{dm} 以丰富义原的语义表示后, 将这些语义信息与 BiLSTM 模型的特征进行融合. 首先, 利用 BiLSTM 模型处理文本数据:

$$\begin{cases} \mathbf{h}_a = \text{LSTM}(\mathbf{F}_{\text{word}}, \mathbf{h}_{t-1}), \\ \mathbf{h}_b = \text{LSTM}(\mathbf{F}_{\text{word}}, \mathbf{h}_{t+1}), \\ \mathbf{F}_{\text{bi}} = (\mathbf{h}_b, \mathbf{h}_a), \end{cases} \quad (15)$$

其中: $\mathbf{h}_a$ 表示时间步 t 的前向隐藏状态; $\mathbf{F}_{\text{word}}$ 表示时间步 t 的输入特征向量, 即 BERT 的输出; $\mathbf{h}_{t-1}$ 表示前一个时间步 t 的前向隐藏状态; $\mathbf{h}_b$ 表示时间步 t 的后向隐藏状态; $\mathbf{h}_{t+1}$ 表示后一个时间步的后向隐藏状态; $\mathbf{F}_{\text{bi}}$ 表示 BiLSTM 输出的特征. BiLSTM 能捕捉文本中的前后文信息, 为每个时间步生成特征向量, 这些向量包含了丰富的上下文语义信息.

其次, 将从密度矩阵中得到的义原向量与 BiLSTM 模型在相应时间步的特征向量对齐, 以确保义

原的语义信息能与文本中的上下文信息相匹配. 然后采用特定的融合策略, 将义原向量与 BiLSTM 特征向量相结合, 可表示为

$$\mathbf{F}_{\text{bd}} = \mathbf{F}_{\text{bi}} \oplus \mathbf{F}_{\text{dm}}. \tag{16}$$

其中 $\oplus$ 表示向量相加. 从而特征向量 $\mathbf{F}_{\text{bd}}$ 不仅包含了 BiLSTM 捕捉到的上下文信息, 还融入了义原的精细语义特征.

2.1.4 输出与融合模块

在特征融合与输出阶段, 采取以下步骤整合并利用从之前模块中提取的特征向量: 首先, 将通过层级知识增强得到的语义特征向量 $\mathbf{F}_h$ 与从义原知识库中获得的特征向量 $\mathbf{F}_{\text{bd}}$ 进行融合, 可表示为

$$\mathbf{F}_{\text{HSK}} = \mathbf{F}_h \oplus \mathbf{F}_{\text{bd}}. \tag{17}$$

其次, 将融合后的特征向量 $\mathbf{F}_{\text{HSK}}$ 送入全连接层, 映射到与情感分类标签相对应的特征空间, 得到特征向量 $\mathbf{v}$. 最后, 应用 Softmax 函数对全连接层的输出进行归一化处理, 转换为情感分类的概率分布, 可表示为

$$\text{label} = \text{Softmax}(\mathbf{W}_0 * \mathbf{v} + b), \tag{18}$$

其中: $\mathbf{W}_0$ 表示全连接层的权重矩阵; b 为偏置项; label 为情感分类的结果, 且维度为 l , l 为情感类别的数量.

2.2 时间复杂度分析

为评估本文模型的计算效率, 下面对模型各主要模块的时间复杂度进行分析. 设输入句子长度为 n , 字符嵌入维度为 d , 义原嵌入维度为 d_s , 义原数量上限为 m .

SentiBERT 编码模块: 时间复杂度为 $O(n^2 \cdot d)$, 主要来自多头自注意力机制中的序列间交互计算. 层级知识增强模块: 区域移动框学习通过滑动窗口(窗口大小为 k)提取局部信息, 复杂度为 $O(n \cdot k \cdot d)$, 全局信息交互通过关系矩阵计算, 复杂度为 $O(n^2 \cdot d)$; 多池化操作选取前 k' 个特征, 复杂度为 $O(n)$. 整体复杂度约为 $O(n^2 \cdot d)$. 外部知识模块: 义原注意力计算复杂度为 $O(n \cdot m \cdot d_s)$; 密度矩阵构建复杂度为 $O(m \cdot d_s^2)$; BiLSTM 模块复杂度为 $O(n \cdot d^2)$. 因此, 模型的整体时间复杂度约为 $O(n^2 \cdot d + n \cdot m \cdot d_s + m \cdot d_s^2)$, 其中 $n^2 \cdot d$ 为主要开销. 在实际训练中, 单轮迭代时间约为基线模型 FSKQ 的 1.3 倍, 但 F_1 分数提升了 2.6%. 后续工作可探索轻量化设计, 如知识蒸馏或替换 SentiBERT 为更高效的小型预训练模型, 以在性能与效率之间取得更好平衡.

3 实验设计

3.1 数据集

实验采用数据集 SMP2019-ECISA, 其为 2019 年社交媒体处理会议中中文隐式情感分析领域的旗舰数据集. 该数据集规模大、权威性高、公开性广. 数据主要来源于微博热点事件讨论以及蚂蜂窝、携程、汽车之家等热门论坛的产品或服务评价. 数据集 SMP2019-ECISA 通常包括训练集、验证集和测试集. 每个样本由文本内容和情感标签组成. 数据集集中的句子分别标注了褒义、贬义和中性情感. 数据集 SMP2019-ECISA 的信息列于表 1.

表 1 数据集 SMP2019-ECISA 的信息
Table 1 Information of SMP2019-ECISA dataset

子集	中性	积极	消极
训练集	6 989	3 828	3 957
验证集	1 654	990	1 000
测试集	2 553	1 232	1 358

图 2 为数据集 SMP2019-ECISA 的一个样例. 由图 2 可见, 一个文档(Doc ID="1")包含两个句子, 其中句子 2 的 label=2 为该句子的情感倾向. $\text{label} \in [0, 1, 2]$, 分别对应情感极性为中性、积极和消极.

```
<Doc ID="1">
  <Sentence ID="1">讨厌谁我就给对方买蒙牛! </Sentence>
  <Sentence ID="2"label="2">别以为政治与你无关, 有人送我蒙牛的产品我会以为对方要害我! </Sentence>
</Doc>
```

图 2 数据集 SMP2019-ECISA 样例
Fig. 2 Example of SMP2019-ECISA dataset

3.2 评价指标

针对数据集 SMP2019-ECISA 中情绪类别的不均衡, 尤其是中性情绪占比较大这一特点, 本文选用准确率 (accuracy) 和 F_1 分数作为衡量模型性能的关键指标. 这种评价体系的多维性有助于对冲不同情绪类别在样本中所占比例对评价结果的影响, 从而使模型性能评估更公正和全面. 评估指标的计算公式如下:

$$Acc = \frac{T_{pos} + T_{neg}}{T_{pos} + F_{pos} + T_{neg} + F_{neg}}, \quad (19)$$

$$R = \frac{T_{pos}}{T_{pos} + F_{neg}}, \quad (20)$$

$$P = \frac{T_{pos}}{T_{pos} + F_{pos}}, \quad (21)$$

$$F_1 = \frac{2 \times P \times R}{P + R}, \quad (22)$$

其中 T_{pos} 和 F_{pos} 分别表示积极语句被模型判断为积极和消极情绪的概率, T_{neg} 和 F_{neg} 分别表示消极语句被模型判断为消极和积极情绪的概率, R 表示召回率 Recall, P 表示预测 Precision.

3.3 实验设置

实验环境为 CPU Intel(R) Core i7-9700K, 内存为 16 GiB, GPU NVIDIA RTX3080×1, 操作系统为 Windows 10 Professional Edition, 集成开发环境为 PyCharm Professional Edition 2019 x64, CUDA v10.0.130, CUDNN 7.3.1, Python 3.7, Tensorflow 1.12.

本文模型的关键参数设置如下: epoch 设为 30, 句子最大长度设为 100, batch_size 设为 24, 学习率设为 5×10^{-5} .

3.4 基线模型

本文主要考虑中文隐式情感分析, 它属于自然语言处理中的文本分类问题. 采用的基线模型如下.

TextRCNN^[33]: 在 TextRCNN 模型的设计中, 采用了创新的双向循环机制, 不仅能有效滤除文本中的噪声, 还能全面捕捉上下文信息. 模型在处理文本时, 特别注重保持词汇的顺序性, 对维护语句的连贯性和语义的准确性至关重要. 通过最大池化策略, 模型能提取并聚焦于文本中最具影响力的部分, 从而进一步提升了分析的精确度和深度.

BiLSTM+attention^[34]: 在近期的自然语言处理领域, 融合了注意力机制的 BiLSTM 模型已经成为一种流行且高效的技术选择, 并在多个任务中展现出卓越性能. 本文采用基于双线性注意力机制的双层 BiLSTM 模型作为基线, 以获得更精准和深入的文本理解能力. 这种模型通过细致的注意力分配, 增强了对文本中关键信息的捕捉, 从而在处理复杂的语言现象时表现出更高的灵活性和鲁棒性. 将基线模型记作 B+A.

BiLSTM+MPOA: 为 Wei 等^[35] 提出的具有多级正交注意力的 BiLSTM 模型, 用于隐式情感分析. 在多级注意力的基础上, 采用正交约束机制, 保证优化过程中能保持区别性能. 将该基线模型记作 B+MPOA.

CMPOA^[36]: 该模型将上下文信息与多级正交注意力 (MPOA) 相结合. 这种融合旨在通过引入丰富的上下文信息弥补目标句子本身信息的不足, 从而增强模型对隐式情感的分析能力.

CsHGCN^[37]: 该模型为一个新的上下文特定的异构图卷积网络框架. 在构图时, 它不仅考虑目标句, 还会将上下文信息加入其中.

KCISA^[38]: 该模型将知识图谱作为隐式情感表达的补充, 并结合了上下文信息提出 KC-ISA 模型. 其可有效整合外部知识和上下文特征, 以提高最后的准确率.

BiLSTM+KG+MPOA^[39]: 其作为一种将情感常识图嵌入多级正交注意力模型学习内隐情感含义的模型. 通过在知识库中引入情感信息, 该模型可对具有隐含情感的句子进行语义扩展. 采用多级正交注意力的双向长短期记忆模型, 将提取的情感知识与语义嵌入融合, 有效丰富句子的表征. 将该基线模型记作 B+KG+MPOA.

BiLSTM+multi-attention^[40-41]: BiLSTM 结合多注意力机制(BiLSTM+multi-attention), 相较于传统的单注意力模型, 其在处理文本时有明显优势. 该模型通过多注意力机制能辨识词汇及其情感倾向之间的细微差别. 当与 BiLSTM 的双向序列捕获能力相结合时, 模型能在序列的每个时间点上, 对输入数据的不同部分应用差异化的关注力度. 这种差异化加权策略不仅丰富了模型对文本的理解, 还提升了对情感语境的敏感度, 使模型在捕捉和解析文本中的关键信息时更精准和有效, 将该基线模型记作 B+MA.

FSKQ^[42]: 该模型采用义原知识库作为外部知识, 补充了目标词的语义知识, 有效提高了模型在汉语隐式情感分析中的性能.

4 实验结果

4.1 隐式情感分析实验

下面选取数据集 SMP2019-ECISA 进行中文隐式情感分析实验, 并将本文模型与一系列基线模型进行性能比较, 实验结果列于表 2. 将本文模型命名为 HDSK, 其中某些基线模型的准确率和 F_1 分数数据来源于原文献.

表 2 中文隐式情感分析实验结果

Table 2 Experimental results of Chinese implicit sentiment analysis

%

模型	准确率	F_1	模型	准确率	F_1
TextRCNN	76.9	73.8	KCISA	78.6	75.5
B+A	76.1	73.4	B+KG+MPOA	—	77.7
B+MA	—	72.6	FSKQ	82.6	85.8
B+MPOA	—	73.7	HDSK(BERT)	80.7	81.1
CMPOA	—	74.6	HDSK(SentiBERT)	81.1	88.4
CsHGCN	77.3	76.4			

由表 2 可见, HDSK(SentiBERT)模型在 F_1 分数上取得了最高成绩, 为 88.4%, 表明该模型在捕捉中文隐式情感特征方面有显著优势. 与传统只注意上下文信息的模型(B+MA)相比, 本文模型在 F_1 分数上提升 15.8 个百分点. 与只考虑外部知识的模型(FSKQ)相比, 在 F_1 分数上提升了 2.6 百分点. 与基线模型 TextRCNN, B+A, B+MA, B+MPOA, CMPOA, CsHGCN 相比, 验证了本文模型在考虑全局信息后, 引入外部义原知识库的有效性. 与只引入外部知识库的 FSKQ 模型相比, 本文模型还证明了引入全局信息也是中文隐式情感分析的一个重要特征. 与 KCISA 和 B+MPOA+KG 模型相比, 本文采取义原外部库并融合层级知识的方法更有效, 分别在 F_1 分数上提高了 12.9 个百分点和 10.7 百分点.

实验结果表明, HDSK 模型在中文隐式情感分析任务上优势明显, 其在准确率和 F_1 分数上也性能优异. 这种性能上的提升证明了 HDSK 模型在处理情感特征时的有效性, 尤其是在理解隐式情感表达方面的高级能力.

为进一步分析本文模型在各情感类别上的性能, 统计了 HDSK(SentiBERT)模型在 SMP2019-ECISA 测试集上对积极、消极、中性 3 个类别的精确率、召回率和 F_1 分数, 并与基线模型 FSKQ 进行对比, 结果列于表 3. 由表 3 可见, HDSK 模型在中性样本上的 F_1 达 90.2%, 相比 FSKQ 提升 2.3 百分点. 这可能得益于层级知识增强模块对全局语义的充分建模, 使模型能更好地识别缺乏明确情感倾向的隐式中性表达. 在积极和消极类别上的 F_1 分别为 87.2% 和 87.8%, 较 FSKQ 模型分别提升

2.7 百分点和 2.8 百分点. 两类别的 F_1 差距仅为 0.6 百分点, 表明模型对正向和负向情感的识别能力较均衡, 未出现偏向某一极性的情况. 本文模型在 3 个情感类别上均实现了性能提升, 尤其在中性和消极类别上效果更显著, 从而验证了本文模型对中文隐式情感分析的全面适用性.

表 3 两种模型在不同情感类别上的实验结果

Table 3 Experimental results of two models on different sentiment categories								%
模型	精确率	召回率	F_1	模型	精确率	召回率	F_1	
FSKQ(积极)	82.0	87.2	84.5	HDSK(积极)	88.3	86.1	87.2	
FSKQ(消极)	86.5	83.6	85.0	HDSK(消极)	86.4	89.2	87.8	
FSKQ(中性)	89.5	86.3	87.9	HDSK(中性)	91.5	89.0	90.2	

4.2 消融实验

为进一步验证各模块对模型是否有积极作用, 本文设计了一系列消融实验, 结果列于表 4. HDSK(无外部知识模块)是模型中只有 SentiBERT 和层级知识增强模块. 由表 4 可见, 层级知识增强模块可在 F_1 分数上提升 4 百分点, 证明了层级知识增强模块的有效性. HDSK(无知识增强模块)是模型中只有 SentiBERT 和义原知识的模块. 由表 4 可见, 义原知识模块可在 F_1 分数上提升 2.7 百分点, 证明加入外部知识有效.

表 4 消融实验结果

Table 4 Results of ablation experiments						%
模型	准确率	F_1	模型	准确率	F_1	
SentiBERT	80.9	83.2	HDSK(无知识增强模块)	82.6	85.9	
HDSK(无外部知识模块)	80.4	87.2	HDSK	81.1	88.4	

4.3 显式情感分析实验

为验证本文模型的泛化性, 在显式情感分析数据集上与其他显示情感分析的经典模型进行对比实验. 实验在 SemEval 2014 的任务 4^[40] 中数据集 Restaurant 上进行, 数据集信息列于表 5. 将本文模型与标准的显示情感模型 ASGCN^[41], ATAE-LSTM^[42], IAN^[43], RAM^[44], MGAN^[45], TransCap^[46] 和 TransEncAsp^[47] 进行对比实验, 结果列于表 6.

表 5 数据集 Restaurant 信息

Table 5 Information of Restaurant dataset					个
子集	积极	中性	消极	总计	
训练集	2 164	805	633	3 602	
测试集	728	196	196	1 120	
Restaurant	2 892	1 001	829	4 722	

表 6 显式情感分析实验结果

Table 6 Experimental results of explicit sentiment analysis									%
模型	ATAE-LSTM	IAN	RAM	MGAN	ASGCN	TransCap	TransEncAsp	HDSK	
准确率	76.9	76.8	80.2	81.2	80.7	79.6	77.1	81.9	
F_1	62.6	67.7	70.8	71.9	72.0	71.4	57.9	73.5	

与传统模型相比, HDSK 模型在 F_1 分数上实现了显著提升, 特别是与 MGAN 模型相比提高了 1.6 百分点, 与基于图神经网络的模型(ASGCN)相比提高了 1.5 百分点, 与基于 Transformer 的模型(TransCap 和 TransEncAsp)相比, HDSK 模型的 F_1 分数显著更高, 说明在显式情感分析中, 仅靠 Transformer 的结构设计不足以应对任务复杂性. 这种改进归因于上下文和外部知识的结合, 解决了传统注意力模型对全局语义信息捕捉不足、图神经网络模型缺乏外部知识支持以及基于 Transformer 模型在任务中特定领域信息提取能力不足的问题. 因此, HDSK 模型通过综合上下文和外部知识的设计, 为显式情感分析任务提供了更丰富的语义表达和更强的情感分类能力, 从而实现了显著的性能提升. 实验结果不仅表明了本文方法的有效性, 也验证了其强大的适应性和泛化力, 从而进一步证实了本文模型能在多样化的情境中发挥重要作用.

综上所述,针对中文隐式情感分析中情感线索较弱、混合情感特征、多义性特征以及语境依赖特征等挑战,本文提出了一种基于层级知识增强和义原知识的方法.通过引入 SentiBERT 预训练模型,有效增强了对情感线索的识别能力.采用字符级信息获取、区域移动框学习、全局信息的学习和多池化操作,成功处理了混合情感特征.同时,结合义原和密度矩阵,利用 HowNet 知识库解决了多义性特征问题,并与 BiLSTM 特征融合以应对语境依赖特征.实验结果表明,该方法在有效性、优越性和泛化性方面均取得了显著提升,为中文隐式情感分析提供了一种新的有效途径.

参 考 文 献

- [1] LIU B. Sentiment Analysis and Opinion Mining [M]. Berlin: Springer Nature, 2022: 1-167.
- [2] WANG H B, HOU M H, LI F, et al. Chinese Implicit Sentiment Analysis Based on Hierarchical Knowledge Enhancement and Multi-pooling [J]. IEEE Access, 2020, 8: 126051-126065.
- [3] LIN Y, LI J P, YANG L, et al. Sentiment Analysis with Comparison Enhanced Deep Neural Network [J]. IEEE Access, 2020, 8: 78378-78384.
- [4] ZHOU J, TIAN J F, WANG R, et al. Sentix: A Sentiment-Aware Pre-trained Model for Cross-Domain Sentiment Analysis [C]//Proceedings of the 28th International Conference on Computational Linguistics. Palo Alto: AAAI Press, 2020: 568-579.
- [5] NIU Y L, XIE R B, LIU Z Y, et al. Improved Word Representation Learning with Sememes [C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. [S.l.]: ACL, 2017: 2049-2058.
- [6] MACKEY G W. Mathematical Foundations of Quantum Mechanics [M]. North Chelmsford: Courier Corporation, 2004: 1-160.
- [7] ZHANG P, MA X D, SONG D W. A Survey of Quantum Language Models [J]. Scientia Sinica Informationis, 2018, 48(11): 1467-1486.
- [8] DENG L J, 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. [S.l.]: ACL, 2015: 1323-1328.
- [9] KIRITCHENKO S, ZHU X D, MOHAMMAD S M. Sentiment Analysis of Short Informal Texts [J]. Journal of Artificial Intelligence Research, 2014, 50: 723-762.
- [10] DING H B, RILOFF E. Acquiring Knowledge of Affective Events from Blogs Using Label Propagation [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2016: 2935-2942.
- [11] LIAO J, LI Y, WANG S G. The Constitution of a Fine-Grained Opinion Annotated Corpus on Weibo [C]//Chinese Computational Linguistics and Natural Language Processing Based on Naturally Annotated Big Data. Berlin: Springer International Publishing, 2016: 227-240.
- [12] ZHANG D Y, LIN H F, YANG L, et al. Construction of a Chinese Corpus for the Analysis of the Emotionality of Metaphorical Expressions [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. [S.l.]: ACL, 2018: 144-150.
- [13] LIAO J, ZHANG K, WANG S G, et al. Research on Implicit Sentiment Analysis Based on Heterogeneous User Knowledge Fusion [C]//Proceedings of the 21st Chinese National Conference on Computational Linguistics. [S.l.]: ACL, 2022: 523-534.
- [14] AHMAD K M, LIU Q, KHAN A A, et al. SEntIMeldCL: Enhancing Explicit Knowledge via Uniform-Based Implicit Contrastive Mechanism for Aspect-Level Sentiment Analysis [J]. Neural Networks, 2025, 191: 107711-1-107711-15.
- [15] HE B, ZHAO R Y, TANG D L. CABiLSTM-BERT: Aspect-Based Sentiment Analysis Model Based on Deep Implicit Feature Extraction [J]. Knowledge-Based Systems, 2025, 309: 112782-1-112782-13.
- [16] MAO Y Y, LIU Q, ZHANG Y. Enhancing Implicit Sentiment Analysis via Knowledge Enhancement and Context Information [J]. Complex & Intelligent Systems, 2025, 11(5): 222-1-222-15.

- [17] LI X, WANG X L, YAO C L, et al. Graph-Enhanced Implicit Aspect-Level Sentiment Analysis Based on Multi-prompt Fusion [J]. *Scientific Reports*, 2025, 15(1): 17460-1-17460-19.
- [18] REN J, ZHOU W H, LI B W, et al. Causal Prompting for Implicit Sentiment Analysis with Large Language Models [EB/OL]. (2025-07-01)[2026-02-10]. <https://arxiv.org/html/2507.00389v1>.
- [19] LAI W W, XIE H R, XU G D, et al. Rvisa: Reasoning and Verification for Implicit Sentiment Analysis [J]. *IEEE Transactions on Affective Computing*, 2025, 16(3): 1760-1771.
- [20] WANG H B, HOU M H. Quantum-Like Implicit Sentiment Analysis with Sememes Knowledge [J]. *Expert Systems with Applications*, 2023, 232: 120720-1-120720-9.
- [21] BALAHUR A, HERMIDA J M, MONTOTOYO A. Detecting Implicit Expressions of Emotion in Text: A Comparative Analysis [J]. *Decision Support Systems*, 2012, 53(4): 742-753.
- [22] WANG H B, ZHANG F Z, WANG J L, et al. Ripplenet: Propagating User Preferences on the Knowledge Graph for Recommender Systems [C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2018: 417-426.
- [23] LIU Z H, XIONG C Y, SUN M S, et al. Entity-Duet Neural Ranking: Understanding the Role of Knowledge Graph Semantics in Neural Information Retrieval [EB/OL]. (2018-05-19)[2025-01-01]. <https://arxiv.org/abs/1805.07591>.
- [24] ZHANG Y, WANG J, YU L C, et al. Ma-bert: Learning Representation by Incorporating Multi-attribute Knowledge in Transformers [C]//*Findings of the Association for Computational Linguistics*. [S.l.]: ACL, 2021: 2338-2343.
- [25] ZHANG Z Y, HAN X, LIU Z Y, et al. ERNIE: Enhanced Language Representation with Informative Entities [EB/OL]. (2019-05-17)[2024-12-20]. <https://arxiv.org/abs/1905.07129>.
- [26] WANG Z K, LI L J, ZENG D. Knowledge-Enhanced Natural Language Inference Based on Knowledge Graphs [C]//*Proceedings of the 28th International Conference on Computational Linguistics*. [S.l.]: ACL, 2020: 6498-6508.
- [27] JAIN D K, BOYAPATI P, VENKATESH J, et al. An Intelligent Cognitive-Inspired Computing with Big Data Analytics Framework for Sentiment Analysis and Classification [J]. *Information Processing & Management*, 2022, 59(1): 102758-1-102758-15.
- [28] AXELSSON A, SKANTZE G. Using Large Language Models for Zero-Shot Natural Language Generation from Knowledge Graphs [EB/OL]. (2023-07-14)[2025-01-01]. <https://arxiv.org/abs/2307.07312>.
- [29] WEI Y B, HUANG Q S, KWOK J T, et al. KICGPT: Large Language Model with Knowledge in Context for Knowledge Graph Completion [EB/OL]. (2024-02-04)[2025-01-10]. <https://arxiv.org/html/2402.02389v1>.
- [30] DONG Z D, DONG Q. HowNet-a Hybrid Language and Knowledge Resource [C]//*International Conference on Natural Language Processing and Knowledge Engineering*. Piscataway, NJ: IEEE, 2003: 820-824.
- [31] QIAO C, HUANG B, NIU G C, et al. A New Method of Region Embedding for Text Classification [EB/OL]. (2018-02-15)[2024-12-30]. <https://openreview.net/pdf?id=BKSDMA36z>.
- [32] CHEN Y B, XU L H, LIU K, et al. Even Texttraction via Dynamic Multi-pooling Convolutional Neural Networks [C]//*Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*. [S.l.]: ACL, 2015: 167-176.
- [33] LAI S W, XU L H, LIU K, et al. Recurrent Convolutional Neural Networks for Text Classification [C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI Press, 2015: 2267-2273.
- [34] ZHOU P, SHI W, TIAN J, et al. Attention-Based Bidirectional Long Short-Term Memory Networks for Relation Classification [C]//*Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*. [S.l.]: ACL, 2016: 207-212.
- [35] WEI J Y, LIAO J, YANG Z F, et al. BiLSTM with Multi-polarity Orthogonal Attention for Implicit Sentiment Analysis [J]. *Neurocomputing*, 2020, 383: 165-173.
- [36] ZUO E G, ZHAO H, CHEN B, et al. Context-Specific Heterogeneous Graph Convolutional Network for Implicit

- Sentiment Analysis [J]. IEEE Access, 2020, 8: 37967-37975.
- [37] 王素格, 王敏, 廖健, 等. 融合上下文信息的隐式情感句判别方法 [J]. 山西大学学报(自然科学版), 2022, 45(2): 380-386. (WANG S G, WANG M, LIAO J, et al. An Implicit Sentiment Sentence Identification Method Base on Context Information [J]. Journal of Shanxi University (Natural Science Edition), 2022, 45(2): 380-386.)
- [38] XU M H, WANG D L, FENG S, et al. KC-ISA: An Implicit Sentiment Analysis Model Combining Knowledge Enhancement and Context Features [C]//Proceedings of the 29th International Conference on Computational Linguistics. [S.l.]: ACL, 2022: 6906-6915.
- [39] LIAO J, WANG M, CHEN X, et al. Dynamic Commonsense Knowledge Fused Method for Chinese Implicit Sentiment Analysis [J]. Information Processing & Management, 2022, 59(3): 102934-1-102934-15.
- [40] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. SemEval-2014 Task 4: Aspect Based Sentiment Analysis [C]//International Workshop on Semantic Evaluation. [S.l.]: ACL, 2014: 27-35.
- [41] ZHANG C, LI Q C, SONG D W. Aspect-Based Sentiment Classification with Aspect-Specific Graph Convolutional Networks [EB/OL]. (2019-09-08)[2024-12-10]. <https://arxiv.org/abs/1909.03477>.
- [42] WANG Y Q, HUANG M L, ZHU X Y, et al. Attention-Based LSTM for Aspect-Level Sentiment Classification [C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. [S.l.]: ACL, 2016: 606-615.
- [43] MA D H, LI S J, ZHANG X D, et al. Interactive Attention Networks for Aspect-Level Sentiment Classification [EB/OL]. (2017-09-04)[2025-01-10]. <https://arxiv.org/abs/1709.00893>.
- [44] CHEN P, SUN Z Q, BING L D, et al. Recurrent Attention Network on Memory for Aspect Sentiment Analysis [C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. [S.l.]: ACL, 2017: 452-461.
- [45] FAN F F, FENG Y S, ZHAO D Y. Multi-grained Attention Network for Aspect-Level Sentiment Classification [C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. [S.l.]: ACL, 2018: 3433-3442.
- [46] CHEN Z, QIAN T. Transfer Capsule Network for Aspect Level Sentiment Classification [C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. [S.l.]: ACL, 2019: 547-556.
- [47] LI Z Y, ZOU Y C, ZHANG C, et al. Learning Implicit Sentiment in Aspect-Based Sentiment Analysis with Supervised Contrastive Pre-training [EB/OL]. (2021-11-03)[2025-01-03]. <https://arxiv.org/abs/2111.02194>.

(责任编辑: 韩 啸)