



# 计算机科学

COMPUTER SCIENCE

## 基于UGC的产品改进:属性提取和属性情感分类的方法与应用综述

隋浩然, 周晓航, 张宁

引用本文

隋浩然, 周晓航, 张宁. 基于UGC的产品改进:属性提取和属性情感分类的方法与应用综述[J]. 计算机科学, 2024, 51(11A): 240400070-9.

SUI Haoran, ZHOU Xiaohang, ZHANG Ning. [Product Improvement Based on UGC:Review on Methods and Applications of Attribute Extractionand Attribute Sentiment Classification](#) [J]. Computer Science, 2024, 51(11A): 240400070-9.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [基于多模态融合的动态恶意软件检测方法](#)

Multimodal Fusion Based Dynamic Malware Detection

计算机科学, 2024, 51(11A): 240200098-7. <https://doi.org/10.11896/jsjcx.240200098>

### [基于开放集的入侵检测方法研究](#)

Study on Open Set Based Intrusion Detection Method

计算机科学, 2024, 51(11A): 231000033-6. <https://doi.org/10.11896/jsjcx.231000033>

### [基于CNN结合BiGRU的恶意流量分类算法研究](#)

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU

计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

### [基于深度学习智能反射面辅助通信系统的联合波束成形](#)

Deep Learning Based Joint Beamforming in Intelligent Reflecting Surface Enhanced Wireless Communication Systems

计算机科学, 2024, 51(11A): 231200125-5. <https://doi.org/10.11896/jsjcx.231200125>

### [基于因果关系的领域泛化长尾学习](#)

Domain Generalization and Long-tailed Learning Based on Causal Relationships

计算机科学, 2024, 51(11A): 240300041-8. <https://doi.org/10.11896/jsjcx.240300041>

# 基于 UGC 的产品改进:属性提取和属性情感分类的方法与应用综述

隋浩然<sup>1</sup> 周晓航<sup>2,3</sup> 张宁<sup>1</sup>

1 青岛大学商学院 山东 青岛 266000

2 青岛城市学院工商管理学院 山东 青岛 266000

3 上海财经大学信息管理与工程学院 上海 200000

(shr9918@163.com)

**摘要** 用户生成内容(User-generated Content,UGC)包含了大量用户对产品及其属性的真实看法。随着数字技术的持续发展,企业日益重视利用 UGC 来洞察用户需求,从而指导产品改进。在这一过程中,属性提取与属性情感分类被视为两大核心环节。属性提取旨在从 UGC 中识别出关键的产品属性,其方法可归为有监督学习和无监督学习两类;属性情感分类则用于分析用户对这些属性的情感态度,主要包括基于词典与规则、基于统计机器学习以及基于深度学习的方法。文中首先对属性提取与属性情感分类方法的理论框架及技术要点进行系统梳理,随后结合实际应用进行阐述,以期利用 UGC 指导产品改进的企业和研究者提供有价值的参考。最终,探讨了当前属性提取与属性情感分类所面临的挑战及未来的研究方向。

**关键词:** 用户生成内容;产品改进;属性提取;属性情感分类;机器学习;深度学习

**中图分类号** TP391

## Product Improvement Based on UGC: Review on Methods and Applications of Attribute Extraction and Attribute Sentiment Classification

SUI Haoran<sup>1</sup>, ZHOU Xiaohang<sup>2,3</sup> and ZHANG Ning<sup>1</sup>

1 School of Business, Qingdao University, Qingdao, Shandong 266000, China

2 School of Management, Qingdao City University, Qingdao, Shandong 266000, China

3 School of Information Management and Engineering, Shanghai University of Finance and Economics, Shanghai 200000, China

**Abstract** User-generated content(UGC) contains a wealth of authentic user feedback on products and their attributes. With the continuous advancement of digital technology, enterprises are increasingly relying on UGC to gain insights into user needs and guide product improvements. In this process, attribute extraction and attribute sentiment classification are considered as two core steps. Attribute extraction aims to identify key product attributes from UGC and is mainly categorized into supervised and unsupervised learning methods. Attribute sentiment classification, meanwhile, focuses on analyzing users' emotional attitudes towards these extracted attributes, primarily including approaches based on dictionaries and rules, statistical machine learning, and deep learning. Firstly, systematically outlines the theoretical frameworks and technical essentials of attribute extraction and attribute sentiment classification methods. Subsequently, these methods are illustrated through practical applications, aiming to offer valuable references for enterprises and researchers utilizing UGC to inform product enhancements. Finally, this paper explores the current challenges faced by attribute extraction and sentiment classification, as well as directions for future research.

**Keywords** User-generated content, Product improvement, Attribute extraction, Attribute sentiment classification, Machine learning, Deep learning

## 1 引言

在快速变化的市场环境中,为确保产品能够持续满足用户需求,企业积极地将用户纳入产品改进的流程。过去,企业主要依赖焦点小组、问卷调查、头脑风暴和观察等传统方法来收集和分析用户需求。然而,这些方法在成本效益和样本代表性方面存在局限性,其实用性和广泛性受到挑战<sup>[1]</sup>。

随着数字技术的不断进步,用户与企业之间的互动方式发生了深刻变革。当前,用户可以通过社交网络平台、在线

社区、电子商务网站等多种渠道轻松生成并分享用户生成内容(UGC)<sup>[2]</sup>。这些 UGC 中包含了大量用户对产品及其属性的真实评价、期望等,极大地降低了企业搜集用户信息的成本和难度。通过对 UGC 进行系统地收集和分析,企业可以更加精准地洞察用户的真实需求和偏好,从而指导产品的优化和改进<sup>[3]</sup>。

在基于 UGC 的产品改进过程中,企业首先需要从海量的 UGC 中提取出用户提及的产品属性,并依据提及频率判断用户对该属性的关注程度或重要性;随后,针对已提取出的

基金项目:山东省自然科学基金(ZR2022MG022,ZR2023MG076)

This work was supported by the Natural Science Foundation of Shandong Province, China(ZR2022MG022, ZR2023MG076).

通信作者:张宁(zhang\_ning1980@126.com)

属性进行情感分类,以判断用户对各个属性的满意度或性能评价<sup>[4]</sup>;最终,利用属性的重要性、满意度或在二者基础上建立的其他指标,企业可以从用户需求等角度出发,定量或定性地评估各属性在产品改进中的潜在价值或优先级,从而明确产品优化的具体方向,为后续的行动提供指导。因此,属性提取和属性情感分类是这一过程的两项基础与核心环节。

当前,针对属性提取和情感分类这两个环节,已经发展出一系列多元化的技术方法。这些方法各有其特点和适用

场景,并表现出不同的优势和局限性。然而,鉴于 UGC 的复杂性以及产品间的差异性,目前还未能形成一套能够广泛适用且效果最优的方法,以支持基于 UGC 的产品改进。因此,本文旨在对属性提取和属性情感分类的方法进行系统的综述,并探讨它们在基于 UGC 的产品改进相关研究中的应用,以为该领域的研究和实践提供有益的参考和借鉴。其中,属性提取和属性情感分类的方法框架如图 1、图 2 所示。

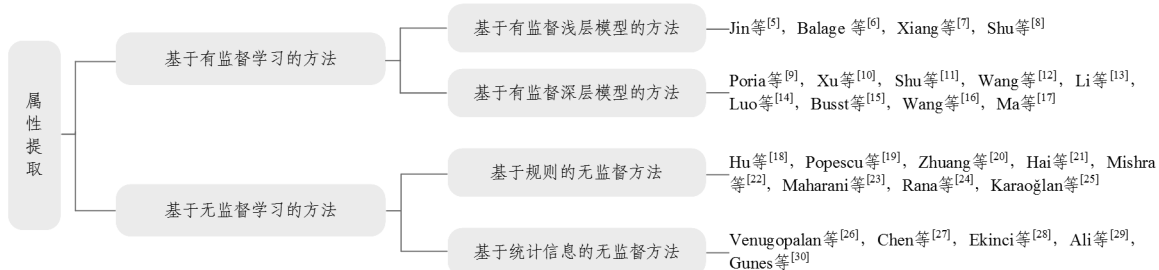


图 1 属性提取的方法框架

Fig. 1 Framework of attribute extraction methods

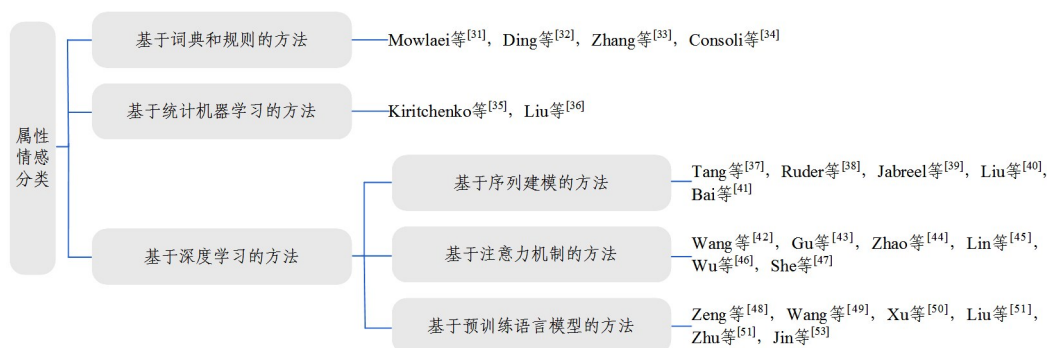


图 2 属性情感分类的方法框架

Fig. 2 Framework of attribute sentiment classification methods

## 2 属性提取

属性提取是制定基于 UGC 的产品改进策略的基础步骤,其目标在于精准识别用户所关注的产品属性,并为情感分类等后续分析工作奠定基础。这一过程的关键是从大量的 UGC 中提取出具体的产品属性词汇。当前,如表 1 所列,该领域的研究主要采用基于有监督学习和无监督学习两类方法。

表 1 属性提取方法及其优缺点

Table 1 Attribute extraction methods and their pros and cons

方法类型	优点	缺点
基于有监督学习的方法	利用标注数据进行学习,适用于特定任务的精确属性提取	需要大量标注数据,成本高,泛化能力受限
基于无监督学习的方法	不依赖标注数据,适用于大规模数据集	准确性和可解释性可能弱于有监督方法

### 2.1 基于有监督学习的方法

基于有监督学习的属性提取方法已取得显著的成果。这类方法使用标注数据对模型进行精确引导,使提取结果具有较高的准确性,根据模型的结构复杂度,可以分为基于有监督浅层模型的方法和基于有监督深层模型的方法。

#### 2.1.1 基于有监督浅层模型的方法

在利用有监督方法进行属性提取的任务中,一些学者采

用了浅层学习模型进行训练,其中包括隐马尔可夫模型(Hidden Markov Model, HMM)和条件随机场(Conditional Random Field, CRF)等经典算法。Jin 等<sup>[5]</sup>构建了基于词汇化 HMM (Lexicalized HMMs) 的自动学习框架,该框架利用 Bootstrapping 增强学习效果,从而在提取低频和未在训练集中出现的新属性方面有良好表现。关注到属性的语义背景, Balage 等<sup>[6]</sup>在训练 CRF 提取属性时,除了采用传统的单词、词性和分块信息等特征外,还创新地融入了语义角色标签(SRL)和 FrameNet 中的最高动词框架信息,有效提升模型的精确度。Xiang 等<sup>[7]</sup>将 MFE 与 CRF 相结合,在通过 MFE 增强文本的语义表示后,应用 K-means++ 算法对词汇和 MFE 进行聚类,并将聚类结果作为补充的位置特征输入 CRF 模型中,从而在提取属性时能够更好地捕捉到文本中的隐含语义和上下文信息。此外,Shu 等<sup>[8]</sup>借鉴终身机器学习(Lifelong Machine Learning, LML)的理念,提出 L-CRF(Lifelong CRF)模型。该模型能够从过去多个领域的提取结果中自动挖掘知识并积累经验,以便在新领域的监督训练完成后,通过积累的知识与经验来进一步提升其性能。

#### 2.1.2 基于有监督深层模型的方法

相比浅层学习模型,深度学习通常不需要人工设计和选择特征,在处理 UGC 等文本密集型任务中表现出更强大的实力,因而近年来被广泛应用于属性提取任务。

Poria 等<sup>[9]</sup>首次将深度学习技术引入属性提取,结合启发式语言模式与包含七层架构的卷积神经网络(Convolutional Neural Networks, CNN),实现对文本中单词及短语属性的有效提取。随后,学者们对基于 CNN 的方法做出进一步拓展。Xu 等<sup>[10]</sup>提出 DE-CNN(Dual Embeddings CNN)模型,该模型结合通用与特定领域的预训练词嵌入,并利用 CNN 实现高效的属性提取。传统的 CNN 模型训练过程中,所有 CNN 层的参数同步更新,这可能会导致模型过度拟合。针对这一问题,Shu 等<sup>[11]</sup>在 DE-CNN 模型的基础上,引入了嵌入控制模块(Embedding Control Module)和 CNN 控制模块(CNN Control Module),并通过异步参数更新策略交替优化这些模块与 CNN 层的参数,从而增强模型的泛化能力。此外,Wang 等<sup>[12]</sup>将递归神经网络和 CRF 的优势相结合,利用句子的依存树结构构建递归神经网络来学习单词的深层次特征表示,并将这些特征输入 CRF 中,以实现从高级特征到属性标签的有效映射。

循环神经网络在属性提取中也得到了广泛应用。将观点词作为属性提取的重要指示性线索,Li 等<sup>[13]</sup>提出了一种基于长短期记忆网络(Long Short-Term Memory)的任务学习框架 MIN(Memory Interaction Network)。该框架使用两个配备了扩展记忆的 LSTM,分别用于提取属性和观点,并通过两者之间的记忆交互机制强化了属性和观点术语之间的共现关系,有效提升属性术语提取的精确度。Luo 等<sup>[14]</sup>首次将树结构和序列信息同时融入到属性提取任务中,提出了一个端到端的框架 BiDTreeCRF。其中,BiLSTM 用于捕获序列特征,BiDTree 则通过双向传播机制提取树结构特征。这两种特征融合后被输入 CRF 层,以实现从属性术语的提取。Busst 等<sup>[15]</sup>提出 Ensemble BiLSTM 模型,该模型结合了 BERT 词嵌入技术所提供的句法、语义和上下文属性,以及通过集成多个 BiLSTM 捕获的文本序列特征,在提取显性和隐性属性方面均有出色表现。Wang 等<sup>[16]</sup>结合门控循环单元(Gated Recurrent Unit, GRU)与胶囊神经网络(Capsule Networks, CAP)提出了 GRU-CAP 模型。其中,模型的隐藏层集成了胶囊通道和门控循环通道,分别负责分离产品属性以及捕捉文本语义,二者协同工作能够实现从多源信息的综合分析。为了弥补传统序列标注方法在捕捉句子整体信息和处理标签依赖性方面的不足, Ma 等<sup>[17]</sup>将属性提取任务重新定义为序列到序列(Sequence-to-Sequence, Seq2Seq)学习任务,其中源序列由文本中的单词构成,目标序列则是相应的标签。通过引入门控单元网络(Gated Unit Networks, GUN),该方法能够在解码过程中充分利用句子的全局信息,并解决对标签依赖性处理不足的问题。另外,模型引入的位置感知注意力机制(Position-Aware Attention, PAA)与传统的注意力机制不同,其能够通过考虑单词间的距离来调整权重,使得模型在解码当前单词的标签时能够对相邻单词给予更多关注。

## 2.2 基于无监督学习的方法

有监督模型的性能高度依赖于训练数据的质量和数量。然而,在本文所探讨的利用 UGC 指导产品改进的场景中,产品的多样化可能会带来高额的数据标记成本且不利于有监督模型的泛化。因此,无需训练数据的无监督方法在处理大规模、新领域的 UGC 数据集时显示出明显的优势。

### 2.2.1 基于规则的无监督方法

一部分无监督的属性提取依赖于人工规则,包括基于

频繁项、基于依存关系或序列模式的规则。

当用户评论产品属性时,他们使用的词语会趋同,因此有学者使用基于频繁项的无监督方法展开属性提取工作。Hu 等<sup>[18]</sup>利用 Apriori 算法进行关联挖掘,识别频繁的名词和名词短语构建候选属性集,并通过紧密度和冗余度剪枝进一步筛选,以排除非属性词汇。在此基础上,Popescu 等<sup>[19]</sup>提出基于频率和点互信息(Pointwise Mutual Information, PMI)的方法,通过计算并过滤 PMI 值低于预设阈值的候选属性,优化提取结果。基于频繁项的方法简单高效,但同时容易错误地提取出常见却无效的属性,或忽略不常见但有效的属性。

基于依存关系规则或序列模式规则的方法也常被用来提取属性。Zhuang 等<sup>[20]</sup>在构建属性词和情感词列表的基础上,利用设定的依存关系规则来提取与情感词相关的属性。考虑到传统的属性提取方法通常仅依赖于单个评论语料库的挖掘模式,忽略了不同语料库中单词分布特征的差异,Hai 等<sup>[21]</sup>在利用设定的依存关系规则从特定领域语料库中提取候选属性词列表后,分别计算每个候选属性词在领域相关和领域无关语料库上的内在域相关性和外在域相关性分数,以衡量属性词与特定领域的关联度以及跨领域的通用性。最后通过设定阈值,筛选出不太通用和更特定的候选属性作为最终属性。不同于先前研究在属性提取上主要关注名词或名词短语,且通常仅限于提取两个词以内的属性,Mishra 等<sup>[22]</sup>将动词以及长度超过两个词的属性也纳入考量,提出一种基于依存关系规则和根节点技术的方法。该方法利用根节点技术制定的 31 条依存关系规则,能够有效提取由名词和动词构成的单词以及多词属性,在处理属性长度随领域变化的问题方面表现出色。

然而,这些基于依存关系规则的方法对文本的语法结构和语言表达有着较高的要求。由于用户在表达对产品的看法时往往不遵循这些要求,因此部分属性可能会因语法或拼写错误而被忽略。相比之下,基于序列模式规则的方法能够更灵活地适应用户的实际表达方式,从而有效地解决这一问题。Maharani 等<sup>[23]</sup>通过观察序列模式在数据集中的频率分布,提出一系列新的序列模式规则。他们将这些新规则与现有的规则结合起来,在实验中尝试它们的不同组合,发现使用全部规则时效果最佳。直接使用基于模式规则的方法会提取大量与产品无关的属性,而基于频率的剪枝则可能会导致不常见但重要的属性被遗漏。为解决这一问题,Rana 等<sup>[24]</sup>在采用基于序列模式的规则提取并剔除低于预设阈值的属性之后,利用归一化 Google 距离进一步识别与产品直接相关但低频的属性,确保提取的准确性与完整性。Karaoglan 等<sup>[25]</sup>的方法融合了序列模式与依存关系规则的优点。他们创新地运用基于序列模式的文本预处理方法优化输入文本,在高效移除不兼容标点符号的同时,保留对句子意义和结构重要的元素。在随后的属性提取阶段,他们引入新的依存关系规则支持对多词表达式的处理。

### 2.2.2 基于统计信息的无监督方法

另一部分无监督的属性提取依赖于统计信息,包括主题模型、聚类等方法。

部分学者使用设计或改进的主题模型进行属性提取,其中一个主要的思路是利用先验知识来指导主题模型的建模

过程。Venugopalan 等<sup>[26]</sup>提出一种引导式 LDA (Latent Dirichlet Allocation) 模型, 利用每个属性类别中的最小属性种子词来指导模型识别用户感兴趣的隐藏主题。同时, 他们采用经过多重过滤的、基于序列模式规则的正则表达式来引导输入, 过滤过程包括命名实体识别、高频和低频过滤。特别地, 低频过滤器与基于 BERT 的语义过滤器相结合, 能够有效强化模型的语义处理能力。Chen 等<sup>[27]</sup>关注先验知识的质量, 认为从多个领域中挖掘的共享属性知识有助于改进每个领域以及新领域中的属性提取。因此, 他们提出了一种直接从大量相关数据中挖掘先验知识的自动化方法, 该方法通过在多个领域语料库上运行 LDA 模型得到原始主题, 随后在对这些主题进行聚类的基础上, 利用 FPM 技术从每个簇中挖掘知识, 作为指导后续主题建模的先验知识。针对 LDA 等主题模型在捕捉文档深层次语义信息方面的不足, Ekinci 等<sup>[28]</sup>提出了 Concept-LDA 模型, 该模型通过从 Babely 中提取概念和命名实体来丰富评论的特征空间, 生成同时包含共现词和语义相关词的主题, 从而更有效地提取 UGC 文档中的潜在属性。

对于聚类方法, Ali 等<sup>[29]</sup>首先利用词嵌入和多特征嵌入 (MFE) 技术将文本中的单词和短语转换为向量, 再通过自组织映射 (SOM) 降维, 最后利用  $K$ -means++ 聚类算法与特征过滤获得属性。Gunes 等<sup>[30]</sup>提出一种提取结构化属性模式的方法, 该方法首先对名词短语进行聚类, 并利用显著性点互信息 (cPMD) 技术识别名词短语中的多词表达和层次结构, 从而构建出基础的结构化属性模式。进一步地, 他们制定了一系列泛化规则对基础模式进行处理, 包括对数字表达和非内容词等的转换, 以及对属性术语泛化的具体限制, 有效实现了提高召回率与准确提取之间的平衡。

另外, 基于深度学习的无监督方法也被运用到属性提取当中。如, Sokhin 等<sup>[54]</sup>在其属性提取模型中引入了卷积多注意力机制 (CMAM)。该机制通过不同大小的卷积核来捕获句子局部或全局的多层次特征, 并基于这些特征构建了加权的注意力句子表示。这些表示通过赋予与特定属性最相关的信息更高的注意力权重来突出重要内容, 有效提升了属性提取的性能。

无监督方法无需人工注释大量数据, 能够有效节省时间和成本。类似地, 半监督、弱监督方法也能以较小的工作量实现良好的应用效果。例如, Ansari 等<sup>[55]</sup>提出了基于图的半监督学习方法, 通过标签传播算法来提取属性; Tao 等<sup>[56]</sup>开发了 WordNet 引导的弱监督深度学习来进行属性提取。

### 3 属性情感分类

提取出 UGC 文本所涉及的产品属性后, 需要进一步针对属性进行情感分类。当前对属性情感分类的研究中, 一部分学者简化操作流程, 在实现属性词到句子的映射后, 直接以句子的情感极性作为属性词的情感判断; 另一部分学者则深入考虑了属性词与上下文、其他属性的关系以及语言结构, 通过细化属性情感分类的过程, 得到更为准确的结果。鉴于这种方法的优点, 我们将重点综述这一方向的现有研究, 并围绕基于词典和规则的方法、基于统计机器学习的方法和基于深度学习的方法展开。各类方法的优缺点如表 2 所列。

表 2 属性情感分类方法及其优缺点

Table 2 Attribute sentiment classification methods and their pros and cons

方法类型	优点	缺点
基于词典和规则的方法	结果具有较强的可解释性, 易于理解和验证	需要维护和更新词典, 对新兴词汇和表达的适应性有限
基于统计机器学习的方法	能够处理大规模数据, 自动提取特征	高度依赖特征工程, 对资源投入的需求较大
基于深度学习方法	自动提取特征, 适应复杂数据	计算成本高, 模型可能过拟合, 解释性有限

#### 3.1 基于词典和规则的方法

基于词典和规则的属性情感分类通过匹配观点词与词典内容, 运用规则计算属性情感分数、判定情感倾向或情绪类别, 其性能依赖于词典的构建与规则的制定。

国内外学者已针对不同的任务和语言构建了丰富的通用词典, 但通用词典与特定领域词典之间存在差异。以产品改进为目的从 UGC 中提取产品情感信息时, 产品或服务领域的多样性使得通用词典不再适用<sup>[34]</sup>。因此, 大多数学者依据研究目的构建特定领域词典, 以全面、准确地对属性情感分类。此外, 通用词典大多为静态词典, 其中的词汇通常被赋予固定的情感标签, 忽略了属性词在不同上下文中的情感极性差异。为解决这一问题, Mowlaei 等<sup>[31]</sup>建立了动态的属性级情感词典, 对基于频率和基于遗传算法构建情感词典的方法进行拓展, 不再仅考虑句子极性, 而是考虑属性词的极性及其与观点词之间的距离, 从而构建能够捕捉属性词上下文情感的情感词典。然而, 动态词典相比静态词典可能无法提供稳定的情感分数。为了综合动态与静态词典的优势, 他们将提出的两个动态词典与一组常见的通用词典融合, 基于 Hu 等<sup>[57]</sup>的客户评论数据集进行实验, 结果表明这种融合方法优于每种类型词典的单独使用。

属性情感分类在规则设计上关注观点词与属性词之间的对应关系。为了捕捉这种关系, Ding 等<sup>[32]</sup>在综合分析否定词和转折词对情感词倾向的影响的基础上, 进一步将同一句子中情感词与属性词之间的距离作为计算属性词情感得分的重要考量因素。Zhang 等<sup>[33]</sup>以属性词为中心设置滑动窗口, 捕捉其周围的情感词和程度词, 结合自定义的快递服务的领域词典计算属性词情感值。此外, 属性词与上下文之间的语义关系也被纳入考量, 以更全面地理解情感表达。Consoli 等<sup>[34]</sup>基于设定的 8 种语义规则, 从句子中提取属性词及其相关词并形成链接, 利用针对经济和金融领域构建的 SentiBig-Nomics 细粒度词典为各词分配情感极性分数, 并由链接末端向前依次调整, 最终得到属性词的情感极性。

另外, 为了更高效地处理情感分析任务, VADER, SentiStrength 等基于词典和规则的情感分析工具被开发出来, 为属性情感分类提供便利。

在基于词典和规则的情感分类中, 单词的语义规则和情感得分透明直观, 因此其结果具有较强可解释性。然而, 由于研究领域的多样性和网络词汇的持续增长, 情感词典需要不断适应新领域并补充新词汇, 这就要求大量的时间和精力投入。

#### 3.2 基于统计机器学习的方法

基于统计机器学习的方法经常利用支持向量机 (Support Vector Machine, SVM)、贝叶斯理论 (Bayesian Theory)<sup>[58]</sup>等

统计理论模型。Kiritchenko 等<sup>[35]</sup>在 SemEval-2014 竞赛的属性级情感分析任务中提出一种基于 SVM 的四级属性级情感分类方法。他们依据词性标注和依存解析结果,围绕属性词及其句子上下文提取情感、词性等特征,从而有效训练模型。实验结果显示,该方法在笔记本电脑数据集上的准确率排名第一。考虑到 SVM 在分类时仅关注类间最大距离而忽略了类内特征相似性,Liu 等<sup>[36]</sup>将 Fisher 规则融入 SVM,设计出自适应的支持向量机(Adaptive Support Vector Machine,ASVM)以平衡类间与类内距离。他们利用多头自注意力(Multi-Heads Self-Attention, MHSA)网络、1-hop 注意力机制等提取属性词及其上下文特征,并基于此构建 ASVM 分类器,实现对属性情感极性的预测。该方法在 SemEval2014, SemEval2016 和 Twitter 数据集上均有良好的性能表现。

基于统计机器学习的方法在处理大规模数据时优势显著,能够自动提取关键特征,减少了对人工规则的依赖,展现出更高的适应性和灵活性。然而,这一过程高度依赖于特征工程,对特征的选择、抽取和预处理等有较高的要求,对资源投入的需求较大。

### 3.3 基于深度学习的方法

相较于统计机器学习,深度学习凭借其自动提取特征的能力,显著降低了对特征工程的依赖,从而减少了相关成本。当前,深度学习在属性情感分类领域受到了广泛的研究和应用。主流研究方法包含基于序列建模的方法、引入注意力机制的方法和使用预训练语言模型的方法 3 类。

#### 3.3.1 基于序列建模的方法

序列模型适用于处理时序文本,循环神经网络(Recurrent Neural Network, RNN)是最具代表性的模型之一。由于 RNN 在处理长序列时存在局限性,长短期记忆网络(LSTM)<sup>[59]</sup>和门控循环单元(GRU)<sup>[60]</sup>等基于 RNN 的模型被开发出来,它们引入门控机制和记忆单元来优化信息流动,从而在属性情感分类等任务中实现更优的性能,并得到广泛应用。

与属性词相关的上下文信息是学者们关注的重点。Tang 等<sup>[37]</sup>将属性信息引入 LSTM,分别提出 TD-LSTM(Target-Dependent LSTM)和 TC-LSTM(Target-Connection LSTM)两种模型。其中 TD-LSTM 对句中属性词之前与之后两个方向的上下文分别建模;TC-LSTM 则在此基础上,将属性词向量结合句子上下文词向量作为输入,实现对属性词与其上下文之间交互关系的捕获。考虑到评论中句子结构对属性词情感分类的影响,Ruder 等<sup>[38]</sup>假设一个句子中仅包含一个属性,提出 H-LSTM(Hierarchical bidirectional Long Short-Term Memory)模型,分层双向捕获句内与句间的关系。他们将句子中的词嵌入输入句子级双向 LSTM 中,再将其最终状态与属性词嵌入相结合输入双向评论级 LSTM,最终实现对属性词情感的判别。相比 LSTM,GRU 结构简单、更易操作,可以作为模型的主体框架或组件使用。Jabreel 等<sup>[39]</sup>提出了 TD-biGRU(Target-Dependent bidirectional Gated Recurrent Unit),该模型连接属性词向量与前、后上下文向量,构建出包含语义、句法和/或情感信息的综合句子向量,最终通过 Softmax 分类器判断情感极性。上下文词和属性词之间的位置信息是属性情感分类的重要因素。Liu 等<sup>[40]</sup>以一个句子由多个情感线索组成为前提假设,提出 GANN(Gated

Alternate Neural Network)。其中专门设计了模块 GTR(Gate Truncation Layer RNN)用于学习属性相关的情感线索表示。在这些表示中,每个上下文单词和属性词之间的相对距离、序列信息以及情感线索内的语义依赖性被同时编码。区别于先前研究中离散的位置信息,Bai 等<sup>[41]</sup>在提出的 PG-RNN(Position-Gated Recurrent Neural Networks)模型中,利用核函数将属性词和周围上下文词之间的位置信息映射为连续分布,有效模拟位置的影响。另外,为学习语义表征,识别属性词上下文不同词的重要性,众多学者在模型中将注意力机制(Attention Mechanism)与 LSTM,GRU 等融合,提出 ATAELSTM(Attention-based LSTM with Aspect Embedding)<sup>[42]</sup>,IAN(Interactive Attention Network)<sup>[61]</sup>,RAM(Recurrent Attention on Memory)<sup>[62]</sup>以及上述的 GANN,PG-RNN 等一系列模型。

#### 3.3.2 基于注意力机制的方法

在属性级情感分类中,注意力机制通过对属性词与上下文的语义关联进行建模,捕获上下文词对属性词的重要性,从而聚焦与属性词情感倾向最为相关的上下文信息,忽略不相关的噪声,提高情感分类的准确性。当前,各类注意力机制被广泛应用于属性情感分类,与多种神经网络结合构成多样化的属性情感分类框架。

Wang 等<sup>[42]</sup>提出 ATAELSTM(Attention-based LSTM with Aspect Embedding)模型,在结合注意力机制与 LSTM 的基础上引入属性词嵌入,利用该嵌入与句子的隐藏表示共同计算注意力权重,并将其与句子中的单词嵌入一起作为模型的输入。考虑到位置信息对识别属性词情感的重要性,Gu 等<sup>[43]</sup>提出基于 Bi-GRU 的 PBAN(Position-aware Bidirectional Attention Network)模型,将属性词及其对应句子中每个单词的位置嵌入视为输入的一部分。模型中的双向注意力机制不仅对属性词与句子中不同单词之间的关系建模,还利用位置信息更准确地判断属性词的情感极性。Zhao 等<sup>[44]</sup>结合双向注意力机制与 GCN,提出能够捕获属性之间情感依赖关系的 SDGCN(Sentiment Dependencies with Graph Convolutional Networks)模型,该模型首先利用带有位置编码的双向注意力机制提取特定于属性的表征,随后借助 GCN 捕获句子中不同属性间的情感依赖关系。Lin 等<sup>[45]</sup>提出 DSMN(Deep Selective Memory Network)框架,通过动态选择上下文记忆来指导多跳注意力机制,并将属性间信息与深度记忆网络集成。借助基于距离信息的选择性注意力机制,该框架在不同记忆层中关注关键上下文,捕获丰富的属性感知上下文信息。Wu 等<sup>[46]</sup>将残差注意力机制与 CNN 相结合,提出 RA-CNN(Residual Attention CNN)和 RAO-CNN(Residual Attention and Other aspects CNN)两种模型。RA-CNN 利用残差注意力机制捕捉文本中属性词的语义信息,弱化了常规注意力机制容易丢失原始信息的问题;RAO-CNN 则在 RA-CNN 的基础上增加了其他属性词的处理机制,减少它们对情感分析的干扰。为进一步减弱远离属性词的非局部上下文对属性词的影响并增强靠近属性词的局部上下文的作用,She 等<sup>[47]</sup>结合交互式多头自注意力与胶囊网络模型,提出了 IM-HSACap(Interactive Multi-Head Self-Attention Capsule network model),通过局部上下文掩码(Local Context Mask, LCM)和交互式注意力机制,交互式地提取局部上下文和全

局上下文间的长期依赖关系,进而结合胶囊网络来处理多级特征并输出分类结果。

### 3.3.3 基于预训练语言模型的方法

近年来,预训练模型在属性情感分类中备受欢迎。通过大规模数据训练积累先验知识,再结合特定领域数据的微调,模型能迅速适应不同任务情境,提供精准高效的情感分类方案。

一方面,由于预训练语言模型出色的词嵌入表征能力,学者们将其用于处理输入文本。Zeng 等<sup>[48]</sup>基于对属性词情感极性与其局部上下文之间关系的考虑,提出 LCF(Local Context Focus)机制,并采用 BERT 共享层来捕获局部上下文和全局上下文的内部长期依赖关系,据此构建的 LCF-BERT 模型在属性情感分类上展现出卓越的性能。Wang 等<sup>[49]</sup>提出一种集成多重注意力机制的新型神经网络 MAMN(Multiple Attention Mechanism Network)模型,该模型采用 BERT 来构建词嵌入向量,相较于 Word2vec 或 Glove 等常见方法有显著优势。

另一方面,学者们对预训练过程中所学习外部知识的内容与方法进行调整,以实现更优的性能。Xu 等<sup>[50]</sup>提出一种适用于 RRC(Review Reading Comprehension)任务的 BERT-PT(Post-Training BERT)模型,通过掩码还原任务对 BERT 进行后训练,并在属性级数据集上微调,有效提升其在阅读理解、属性情感分类等任务上的性能。预训练数据集与下游目标数据集间的领域差异导致知识转移受阻,限制了预训练语言模型在属性情感分类任务中的性能。为解决这一问题,Liu 等<sup>[51]</sup>创新性地提出了一种预训练框架 UIKA(Unified Instance and Knowledge Alignment)。该框架利用从粗到精的检索策略,从预训练数据集中采样实例并学习先验知识,进而通过知识指导学习策略迁移这些先验知识,学习领域不变特征,从而有效缓解领域转移问题。为解决训练集中标记数据不平衡而导致的性能波动和对模糊情感理解不佳的问题,Zhu 等<sup>[52]</sup>基于 BERT 设计出一种结合语义细化的通用提示模型 Prompt-CSR(Prompt model with Combined Semantic Refinement)。他们首先提出包含情感关键词槽的提示模板,以增强提示的语义完整性,并通过多提示学习进行数据增强,有效缓解不同极性数据的不平衡问题。最后,结合全局语义细化和多粒度局部语义提取,提出改进的 BERT 语义细化方法,深化模型对带提示评论的理解和分析。此外,多数使用预训练语言模型进行属性情感分类的方法侧重于利用编码器参数,忽略解码器参数,使得模型中的先验知识未得到充分利用。针对这一问题,Jin 等<sup>[53]</sup>提出 WordTransABSA(Target Word Transferred Aspect-based Sentiment Analysis)方法,创新性地提出一种不同于掩码语言模型任务的序列级优化策略,使预训练语言模型整体从解码序列中预测情感相关的枢轴

标记,从而识别属性词的情感极性。WordTransABSA 利用了编码器和解码器部分的所有参数,最大限度地保留了预训练语言模型原有的特性,在数据不足的场景中具有显著优势。

## 4 方法应用

属性提取和属性情感分类是企业利用 UGC 指导产品改进的基础环节。企业可以根据属性提取的结果,获得不同产品属性的出现频率,并根据频率的高低判断用户对该属性的关注程度或重要性;而通过属性情感分类可以获得用户对不同属性的情感得分,属性情感分数能够体现用户对该属性表现的满意程度或性能评价。

属性频率和属性情感分数可以作为衡量产品属性的独立指标。企业可以分别利用属性提取和属性情感分类的结果进行产品改进。例如,Srinivas 等<sup>[63]</sup>集合 pLSA、基于变分推理的 LDA(LDA-VI)以及基于吉布斯采样的 LDA(LDA-GS) 3 种主题建模方法构建集成主题模型(EA-TM),集合 AFFIN,SentiStrength,VADER 3 种情感分析工具构建集成情感分析器(E-SA),进而利用两种集成方法测得属性频率以及每个服务属性的情感分布,识别乘客认为的航空公司关键服务属性及各属性的满意度情况。Li 等<sup>[64]</sup>结合 TF-IDF 和专家咨询生成产品属性集,随后使用微调的 BERT 模型分析目标产品属性的情感倾向,发现用户对新能源汽车的外观最为关注,对动力最为满意,对智能方面投诉最多。He 等<sup>[65]</sup>聚焦于产品族改进策略的制定,利用 TF-IDF、WordNet 和层次聚类技术完成基于语义的属性提取,其中每个属性术语的频率被定义为重要程度。进一步,在识别各属性对应的具体规格后,利用基于词典的情感分析获得各规格的情感分数,并将其作为满意度指标。

企业也可以通过机会算法(Opportunity Algorithm)<sup>[45,66]</sup>、IPA(重要性-绩效分析)以及改进的 Kano 模型等<sup>[65,67]</sup>将属性频次和情感得分相结合,构建出更为综合的属性评估指标,为企业的产品改进工作提供更为精准的指引,具体描述如表 3 所列。例如,Zhang 等<sup>[67]</sup>运用 BTM 从 UGC 中提取用户对智能产品-服务系统的需求,并基于主题的频率分布和 SnowNLP 的情感分析结果,分别得到属性需求的重要性和满意度。他们将这些数据带入 IPA-Kano 模型对需求进行分类,发现智能语音服务、外观设计、移动终端服务是用户的关键需求。Sun 等<sup>[68]</sup>将车辆制造商官方的文本内容考虑在内,根据创建的属性词典识别官方内容和车辆论坛 UGC 中的产品属性,并利用 TF-IDF 来测量每个属性术语的重要性权重;随后使用深度学习工具 fasttext 模型从 UGC 中识别产品属性的情感倾向;最终将不同属性词的重要性、情感倾向的动态变化融入机会算法当中,为车辆属性提升策略提供参考。

表 3 产品属性评估指标描述

Table 3 Description of product attribute evaluation indicators

指标名称	描述	应用案例
机会算法	通过计算属性的重要性与满意度之差,量化产品改进的潜在价值,其中机会分数=重要性+max(0,重要性-满意度)	Zhang 等 <sup>[67]</sup> 使用该算法分析用户对智能产品-服务系统的需求,识别关键需求
IPA(重要性-绩效分析)	通过评估属性的重要性和绩效表现,将产品属性分为 4 个类别:高重要性-高绩效、高重要性-低绩效、低重要性-高绩效、低重要性-低绩效,以指导资源分配和改进措施	Sun 等 <sup>[68]</sup> 应用 IPA 模型分析车辆属性,确定用户关注点
改进的 Kano 模型	用户需求分类与优先级排序工具,通过分析产品服务的质量特性与用户满意度之间的关系,将需求分为基本型、期望型、兴奋型、无差型型和反向型 5 类	He 等 <sup>[65]</sup> 利用 Kano 模型分析产品属性,指导扫地机器人产品族改进策略

此外,在属性提取和属性情感分类的基础上,结合其他信息对 UGC 进一步挖掘,能够对产品属性进行更全面深入的评估。Du 等<sup>[69]</sup>以多种智能音箱的 UGC 为研究对象,分别利用 LDA 和 LSTM 获取产品属性频率及情感倾向,并结合概率语言术语集和用户权重构建属性评价矩阵。以该矩阵为基础,他们结合改进的 Borda 方法和后悔/高兴决策法计算各属性的权重,发现音质、用户交互体验、质量和功能为用户最关心的 4 个属性类别。Joung 等<sup>[70]</sup>提出了一种基于可解释神经网络的 Kano 分类方法。他们基于 Word2vec 词嵌入,利用 AP 聚类算法来提取产品属性,并通过 Vader 情感分析确定其情感,进而使用基于 SHAP 的可解释神经网络估计各属性情感对星级的影响,并根据结果划分其 Kano 类别。Wang 等<sup>[71]</sup>开发了一种用户体验分析框架,该框架运用 BERT 模型从 UGC 中提取出用户情绪、产品属性及其使用环境 3 类内容,并在利用 NRC-EIL 词典微调后对用户情绪进行分类,最终通过关联规则挖掘技术,揭示 3 类内容之间的重要关联模式,确定与不同情绪关联性最强的产品属性及使用环境。

## 5 面临的挑战与未来展望

### 5.1 面临的挑战

1) UGC 的非规范化问题。UGC 普遍展现出明显的非规范化语言特征,这些特征包括频繁的语法错误、错别字,以及广泛融入的表情符号、网络俚语、缩写等非正规表达方式。部分用户倾向于使用隐式表达,如比喻和暗示,使得产品属性的准确提取变得复杂。另外,反讽、夸张等修辞手法的使用也进一步增加了情感分析的难度。这些多样化的非规范化元素相互作用,形成了 UGC 处理过程中的一项重要挑战。

2) 模型泛化能力的挑战。目前,属性提取与属性情感分类领域的高质量标注数据集主要集中于英语,而中文等其他语言的数据集在数量和质量上尚显不足。此外,特定领域训练的模型往往面临跨领域应用的挑战,由于领域间语义和上下文的差异,模型迁移存在一定障碍。因此,受语言和领域差异的影响,模型的泛化能力面临挑战。

### 5.2 未来展望

1) 多模态数据分析。UGC 不仅包括文本,还涵盖图像、音频等多种形式。多模态数据分析通过整合不同模态的信息,能够提供更全面和深入的理解,从而增强属性提取和情感分类的精确性。例如,将产品评论的文本内容与用户上传的图片相结合,可以更准确地解读用户对产品属性的描述和情感倾向,尤其是在面对非规范化表达时,多模态数据的互补性极大地增强了分析的深度和准确性。

2) 弱监督、无监督与迁移学习技术的升级及应用。弱监督和无监督学习方法通过减少对大规模标注数据的依赖,能够有效应对数据稀缺的挑战。迁移学习技术则通过跨领域知识迁移,显著增强模型对新领域数据的适应性和泛化能力。未来研究可继续推进这些技术的发展,并将其应用至属性提取和情感分类任务中,解决模型泛化能力受限的问题。

3) 属性提取与情感分类的关联性研究。属性提取和情感分类在评估产品属性的 UGC 分析中互为补充。未来的研究可以探索多任务联合学习方法,通过共享特征和增强模型间的交互,深化这两项任务的协同效应,实现模型性能的整体提升。

**结束语** 属性提取与属性情感分类是利用 UGC 指导产品改进的重要环节。本文系统综述了这两种方法的具体技术及其应用。然而,虽然现有方法已颇有成效,但仍需面对非规范化语言和模型泛化能力不足的挑战。未来可以通过多模态数据分析提高模型的准确性;通过无监督、弱监督及迁移学习技术来提升模型的泛化能力;同时,通过深入探索属性提取与属性情感分类之间的关联性,进一步增强整体的分析效果。本文旨在为相关研究提供有益的参考和借鉴。

## 参 考 文 献

- [1] HU Y H, CHEN Y L, CHOU H L. Opinion mining from online hotel reviews—a text summarization approach[J]. *Information Processing & Management*, 2017, 53(2): 436-449.
- [2] LI S, LIU F, ZHANG Y, et al. Text mining of user-generated content(ugc) for business applications in e-commerce: A systematic review[J]. *Mathematics*, 2022, 10(19): 3554.
- [3] HO-DAC N N. The value of online user generated content in product development [J]. *Journal of Business Research*, 2020, 112: 136-146.
- [4] LI M F, ZHANG G X, ZHAO L T, et al. Extracting product competitiveness through user-generated content: A hybrid probabilistic inference model [J]. *Journal of King Saud University-Computer and Information Sciences*, 2022, 34(6): 2720-2732.
- [5] JIN W, HO H H, SRIHARI R K. A novel lexicalized HMM-based learning framework for web opinion mining[C]// *Proceedings of the 26th Annual International Conference on Machine Learning*. Citeseer, 2009.
- [6] BALAGE FILHO P, PARDO T. NILC\_USP: aspect extraction using semantic labels[C]// *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*. 2014: 433-436.
- [7] XIANG Y, HE H, ZHENG J. Aspect term extraction based on MFE-CRF[J]. *Information*, 2018, 9(8): 198.
- [8] SHU L, XU H, LIU B. Lifelong learning CRF for supervised aspect extraction[J]. arXiv:1705.00251, 2017.
- [9] PORIA S, CAMBRIA E, GELBUKH A. Aspect extraction for opinion mining with a deep convolutional neural network[J]. *Knowledge-Based Systems*, 2016, 108: 42-49.
- [10] XU H, LIU B, SHU L, et al. Double embeddings and CNN-based sequence labeling for aspect extraction[J]. arXiv:1805.04601, 2018.
- [11] SHU L, XU H, LIU B. Controlled CNN-based sequence labeling for aspect extraction[J]. arXiv:1905.06407, 2019.
- [12] WANG W, PAN S J, DAHLMEIER D, et al. Recursive neural conditional random fields for aspect-based sentiment analysis [J]. arXiv:1603.06679, 2016.
- [13] LI X, LAM W. Deep multi-task learning for aspect term extraction with memory interaction[C]// *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*. 2017: 2886-2892.
- [14] LUO H, LI T, LIU B, et al. Improving aspect term extraction with bidirectional dependency tree representation [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2019, 27(7): 1201-1212.
- [15] BUSST M M A, ANBANANTHEN K S M, KANNAN S, et al. Ensemble BiLSTM: A Novel Approach for Aspect Extraction

- From Online Text[J]. *IEEE Access*, 2024, 12: 3528-3539.
- [16] WANG Z, HU S, LIU W. Product feature sentiment analysis based on GRU-CAP considering Chinese sarcasm recognition [J]. *Expert Systems with Applications*, 2024, 241: 122512.
- [17] MA D, LI S, WU F, et al. Exploring sequence-to-sequence learning in aspect term extraction[C]// *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. 2019: 3538-3547.
- [18] HU M, LIU B. Mining and summarizing customer reviews [C]// *Proceedings of the tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2004: 168-177.
- [19] POPESCU A M, ETZIONI O. Extracting product features and opinions from reviews[M]// *Natural Language Processing and Text Mining*, 2007: 9-28.
- [20] ZHUANG L, JING F, ZHU X Y. Movie review mining and summarization [C]// *Proceedings of the 15th ACM International Conference on Information and Knowledge Management*. 2006: 43-50.
- [21] HAI Z, CHANG K, KIM J J, et al. Identifying features in opinion mining via intrinsic and extrinsic domain relevance [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2013, 26(3): 623-634.
- [22] MISHRA P, PANDA S K. Dependency Structure-Based Rules Using Root Node Technique for Explicit Aspect Extraction From Online Reviews [J]. *IEEE Access*, 2023.
- [23] MAHARANI W, WIDYANTORO D H, KHODRA M L. Aspect extraction in customer reviews using syntactic pattern [J]. *Procedia Computer Science*, 2015, 59: 244-253.
- [24] RANA T A, CHEAH Y N. A two-fold rule-based model for aspect extraction [J]. *Expert systems with applications*, 2017, 89: 273-285.
- [25] KARAOĞLAN K M, FINDIK O. Extended rule-based opinion target extraction with a novel text pre-processing method and ensemble learning [J]. *Applied Soft Computing*, 2022, 118: 108524.
- [26] VENUGOPALAN M, GUPTA D. An enhanced guided LDA model augmented with BERT based semantic strength for aspect term extraction in sentiment analysis [J]. *Knowledge-based Systems*, 2022, 246: 108668.
- [27] CHEN Z, MUKHERJEE A, LIU B. Aspect extraction with automated prior knowledge learning [C]// *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. 2014: 347-358.
- [28] EKINCI E, İLHAN OMURCA S. Concept-LDA: Incorporating Babely into LDA for aspect extraction [J]. *Journal of Information Science*, 2020, 46(3): 406-418.
- [29] ALI N M, ALSHAHRANI A, ALGHAMDI A M, et al. Extracting Prominent Aspects of Online Customer Reviews: A Data-Driven Approach to Big Data Analytics [J]. *Electronics*, 2022, 11(13): 2042.
- [30] GÜNEŞ Ö F, FURCHE T, ORSI G. Structured aspect extraction [C]// *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*. 2016: 2321-2332.
- [31] MOWLAEI M E, ABADDEH M S, KESHAVARZ H. Aspect-based sentiment analysis using adaptive aspect-based lexicons [J]. *Expert Systems with Applications*, 2020, 148: 113234.
- [32] DING X, LIU B, YU P S. A holistic lexicon-based approach to opinion mining [C]// *Proceedings of the 2008 International Conference on Web Search and Data Mining*. 2008: 231-240.
- [33] ZHANG N, ZHANG R, PANG Z, et al. Mining express service innovation opportunity from online reviews [J]. *Journal of Organizational and End User Computing (JOEUC)*, 2021, 33(6): 1-15.
- [34] CONSOLI S, BARBAGLIA L, MANZAN S. Fine-grained, aspect-based sentiment analysis on economic and financial lexicon [J]. *Knowledge-Based Systems*, 2022, 247: 108781.
- [35] KIRITCHENKO S, ZHU X, CHERRY C, et al. NRC-Canada-2014: Detecting aspects and sentiment in customer reviews [C]// *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*. 2014: 437-442.
- [36] LIU M, ZHOU F Y, HE J K, et al. Self-attention networks and adaptive support vector machine for aspect-level sentiment classification [J]. *Soft Computing*, 2022, 26(18): 9621-9634.
- [37] TANG D, QIN B, FENG X, et al. Effective LSTMs for target-dependent sentiment classification [J]. *arXiv:1512.01100*, 2015.
- [38] RUDER S, GHAFFARI P, BRESLIN J G. A hierarchical model of reviews for aspect-based sentiment analysis [J]. *arXiv:1609.02745*, 2016.
- [39] JABREEL M, HASSAN F, MORENO A. Target-dependent sentiment analysis of tweets using bidirectional gated recurrent neural networks [J]. *Advances in Hybridization of Intelligent Methods, Models, Systems and Applications*, 2018, 185: 39-55.
- [40] LIU N, SHEN B. Aspect-based sentiment analysis with gated-alternate neural network [J]. *Knowledge-Based Systems*, 2020, 188: 105010.
- [41] BAI Q, ZHOU J, HE L. PG-RNN: using position-gated recurrent neural networks for aspect-based sentiment classification [J]. *The Journal of Supercomputing*, 2022, 78(3): 4073-4094.
- [42] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification [C]// *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*. 2016: 606-615.
- [43] GU S, ZHANG L, HOU Y, et al. A position-aware bidirectional attention network for aspect-level sentiment analysis [C]// *Proceedings of the 27th International Conference on Computational Linguistics*. 2018: 774-784.
- [44] ZHAO P, HOU L, WU O. Modeling sentiment dependencies with graph convolutional networks for aspect-level sentiment classification [J]. *Knowledge-Based Systems*, 2020, 193: 105443.
- [45] LIN P, YANG M, LAI J. Deep selective memory network with selective attention and inter-aspect modeling for aspect level sentiment classification [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2021, 29: 1093-1106.
- [46] WU C, XIONG Q, YANG Z, et al. Residual attention and other aspects module for aspect-based sentiment analysis [J]. *Neurocomputing*, 2021, 435: 42-52.
- [47] SHE L, GONG H, ZHANG S. An interactive multi-head self-attention capsule network model for aspect sentiment classification [J]. *The Journal of Supercomputing*, 2024, 80(7): 9327-9352.
- [48] ZENG B, YANG H, XU R, et al. Lcf: A local context focus

- mechanism for aspect-based sentiment classification[J]. *Applied Sciences*, 2019, 9(16): 3389.
- [49] WANG X, TANG M, YANG T, et al. A novel network with multiple attention mechanisms for aspect-level sentiment analysis[J]. *Knowledge-based Systems*, 2021, 227: 107196.
- [50] XU H, LIU B, SHU L, et al. BERT post-training for review reading comprehension and aspect-based sentiment analysis[J]. *arXiv*: 1904. 02232, 2019.
- [51] LIU J, ZHONG Q, DING L, et al. Unified instance and knowledge alignment pretraining for aspect-based sentiment analysis [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2023, 31: 2629-2642.
- [52] ZHU X, KUANG Z, ZHANG L. A prompt model with combined semantic refinement for aspect sentiment analysis[J]. *Information Processing & Management*, 2023, 60(5): 103462.
- [53] JIN W, ZHAO B, ZHANG Y, et al. WordTransABSA: Enhancing Aspect-based Sentiment Analysis with masked language modeling for affective token prediction[J]. *Expert Systems with Applications*, 2024, 238: 122289.
- [54] SOKHIN T, KHODORCHENKO M, BUTAKOV N. Unsupervised neural aspect search with related terms extraction [J]. *arXiv*: 2005. 02771, 2020.
- [55] ANSARI G, SAXENA C, AHMAD T, et al. Aspect term extraction using graph-based semi-supervised learning [J]. *Procedia Computer Science*, 2020, 167: 2080-2090.
- [56] TAO J, ZHOU L. A weakly supervised WordNet-Guided deep learning approach to extracting aspect terms from online reviews [J]. *ACM Transactions on Management Information Systems (TMIS)*, 2020, 11(3): 1-22.
- [57] HU M, LIU B. Mining opinion features in customer reviews [C]// *AAAI*. 2004, 4(4): 755-760.
- [58] MUBAROK M S, ADIWIJAYA A, ALDHI M D. Aspect-based sentiment analysis to review products using Naïve Bayes[C]// *AIP Conference Proceedings*. AIP Publishing, 2017.
- [59] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [60] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. *arXiv*: 1406. 1078, 2014.
- [61] MA D, LI S, ZHANG X, et al. Interactive attention networks for aspect-level sentiment classification [J]. *arXiv*: 1709. 00893, 2017.
- [62] CHEN P, SUN Z, BING L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]// *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*. 2017: 452-461.
- [63] SRINIVAS S, RAMACHANDIRAN S. Passenger intelligence as a competitive opportunity: Unsupervised text analytics for discovering airline-specific insights from online reviews[J]. *Annals of Operations Research*, 2024, 333(2): 1045-1075.
- [64] LI Q, YANG Y, LI C, et al. Energy vehicle user demand mining method based on fusion of online reviews and complaint information[J]. *Energy Reports*, 2023, 9: 3120-3130.
- [65] HE C, LI Z, LIU D, et al. Improving the functional performances for product family by mining online reviews[J]. *Journal of Intelligent Manufacturing*, 2023, 34(6): 2809-2824.
- [66] JEONG B, YOON J, LEE J M. Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis[J]. *International Journal of Information Management*, 2019, 48: 280-290.
- [67] ZHANG K, LIN K Y, WANG J, et al. UNISON framework for user requirement elicitation and classification of smart product service system[J]. *Advanced Engineering Informatics*, 2023, 57: 101996.
- [68] SUN H, GUO W, SHAO H, et al. Dynamical mining of ever-changing user requirements: A product design and improvement perspective[J]. *Advanced Engineering Informatics*, 2020, 46: 101174.
- [69] DU Y, LIU D, DUAN H. A textual data-driven method to identify and prioritise user preferences based on regret/rejoicing perception for smart and connected products[J]. *International Journal of Production Research*, 2022, 60(13): 4176-4196.
- [70] JOUNG J, KIM H. Interpretable machine learning-based approach for customer segmentation for new product development from online product reviews[J]. *International Journal of Information Management*, 2023, 70: 102641.
- [71] WANG J, LIU Y L. Deep learning-based social media mining for user experience analysis: A case study of smart home products [J]. *Technology in Society*, 2023, 73: 102220.



**SUI Haoran**, born in 1999, postgraduate, is a member of CCF (No. T8983G). Her main research interests include product innovation and business data analysis.



**ZHANG Ning**, born in 1980, Ph.D, professor. His main research interests include product innovation and business data analysis.