

基于异构用户知识融合的隐式情感分析研究

廖健

张楷

王素格*

雷佳

张益阳

山西大学计算机与信息技术学院/ 太原, 030006

wsg@sxu.edu.cn

摘要

隐式情感分析因其缺乏显式情感线索的特性是情感分析领域的重要研究难点之一。传统的隐式情感分析方法通常针对隐式情感文本本身的信息进行建模, 没有考虑隐式情感的主观差异性特征。本文提出了一种基于异构用户知识融合的隐式情感分析模型HELENE, 首先从用户数据中挖掘用户异构的内容知识、社会化属性知识以及社会化关系知识, 异构用户知识融合学习框架基于图神经网络模型结合动态预训练模型分别从用户的内部信息和外部信息两个维度对其进行画像建模; 在此基础上与隐式情感文本语义信息进行融合学习, 使得模型可以对隐式情感进行主观差异化建模表示。此外, 本文构建了一个用户个性化通用情感分析语料库, 涵盖了较为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要。在所构建数据集上的实验结果显示, 本文的方法相比基线模型在用户个性化隐式情感分析任务上具有显著的提升效果。

关键词: 隐式情感分析; 用户知识建模; 异构知识融合

Research on Implicit Sentiment Analysis based on Heterogeneous User Knowledge Fusion

Jian Liao

Kai Zhang

Suge Wang*

Jia Lei

Yiyang Zhang

School of Computer and Information Technology, Shanxi University/ Taiyuan, 030006

wsg@sxu.edu.cn

Abstract

Due to the lack of explicit sentimental words, implicit sentiment is one of the most challenging tasks in the area of sentiment analysis. Traditional methods usually focus on the modeling of the implicit sentimental expression itself, without considering the subjective feature of sentiment holder. In this paper, an implicit sentiment analysis model called HELENE based on heterogeneous user knowledge fusion is proposed. Firstly, heterogeneous user knowledge, including content, social attribute and social relation are mined from user data. Then the heterogeneous user knowledge learning framework using graph neural network model and dynamic pre-training model to model users' internal and external information. On this basis, the proposed method can model the user-specific implicit sentiment by fusing the text semantic and heterogeneous user knowledge. In addition, an general sentiment analysis corpus for user-specific modeling, which covers text content, user social attribute and relation, was constructed. The experimental results on the constructed dataset show that the proposed method can

significantly improve the performance of user-specific implicit sentiment analysis task compared with the baseline models.

Keywords: Implicit sentiment analysis , User knowledge modeling , Heterogeneous knowledge fusion

1 引言

随着各类在线服务规模的增长,由用户自主产生的大规模文本和行为数据映射了真实社会经济生活的巨大能量。在发布的文本中,用户对某一事物所反映出的情感是丰富而抽象的,除直接显式地采用情感词给出情感倾向或意见的主观陈述外,还往往采用陈述客观事实或使用修辞的方式隐晦含蓄地表达自己的情感(Liu, 2015; 廖健, 2018)。据统计,汉语中约有近五分之一的句子含有隐式情感(Jian et al., 2016; 廖健, 2018)。几种常见的隐式情感表达示例如下。

例1.1 今天已经是第五天,景区工作人员还没有给一个说法。

例1.2 作为一个5A级景区,你们的服务对得起门票钱吗?

例1.3 太行山南麓属于晋豫共有,但山西游客一般也会选择去河南部分游玩。

例1.1通过陈述一种事实表达了说话人一种焦虑、不耐烦的负面情感。在例1.2中,通过反问句式表达了对景区服务的不满。用户或称情感/观点持有者(sentiment/opinion holder),作为构成情感的五大核心要素之一(Liu, 2015),对于情感分析具有重要的作用。相比于显式情感,隐式情感因其缺乏显式情感词提供情感线索,更容易受到文本上下文和用户的主观差异性影响。同一个隐式情感表达在不同用户眼中受其年龄、性别、知识背景等不同属性的影响会产生不同的情感倾向。如在例1.3中,该句的情感通常与说话人的身份相关,当说话人分别为山西、河南或其他籍贯的游客时,其表达的情感倾向可能存在差异。因此,从用户数据出发,针对用户进行画像建模,并将其与隐式情感的文本信息相融合,是实现主观差异性隐式情感分析的关键。

与显式情感分析相比,隐式情感分析的研究整体仍处于起步阶段。

一方面,从文本深层语义表示出发,结合隐式情感的语言表达特点、上下文语义环境,并引入外部常识知识补充句子中缺失情感线索可以有效提升对隐式情感文本内容的理解。Chen等人(2016)构建了一套双隐式语料库,用于识别不含情感词的情感要素和倾向性。该方法通过关注不同情感极性和隐式情感句词汇之间的差异,并引入上下文信息扩充原有的字面意义,以解决隐式情感自身信息不足的问题。廖健(2019)发现事实型隐式情感具有:上下文情感倾向一致性、语义背景相关性、情感目标相关性以及表达结构相似性等四个基本特点,并在此基础上,构建了多级特征语义融合模型,分别对要素级的情感目标、句子级的句法结构嵌入的情感表达以及篇章级的上下文语义和情感进行建模,并利用卷积网络进行融合表示。隗继耀等人(2020)提出了一种用于隐式情感分析的多极正交注意力模型(MPOA),多极性注意力可以识别词语和情感倾向之间的差异性特征,采用正交约束机制则保证了优化过程中对该特征持续感知。王素格等人(2021)提出一个融合上下文信息的多极性正交注意力的隐式情感句判别方法(C-MPOA)。该方法通过关注不同情感极性和隐式情感句词汇之间的差异,并引入上下文信息扩充原有的字面意义,以解决隐式情感自身信息不足的问题。潘东行(2020)针对隐式表达对上下文内容依赖的特点,设计了一种融合上下文语义特征和注意力机制的分类模型,增强了部分中立性隐式表达句的分类效果。Zuo等人(2020)利用异构图卷积网络结合隐式上下文背景信息嵌入,提高了隐式情感分析的效果。在常识知识引入方面,Shiyun等人(2019)通过在序列神经网络引入情感常识提升情感分析效果。廖健等人(2022)提出了一种基于动态知识表示的正交注意力模型来引入外部常识知识,并将其与隐式情感文本进行融合以学习隐式情感的深层语义表示。Zhou等人(2021)从事件分析角度出发,通过将隐式情感事件表示为主-谓-宾三元组进行分析。Li等人(2021)利用有监督的对比学习机制结合预训练模型的语义知识对识别方面级隐式情感。Cai等人(2021)提出了方面-类别-观点-情感极性四元框架抽取模型,可以用于抽取细粒度的显式和隐式情感。

另一方面,由于隐式情感高度依赖用户自身的背景信息,通过引入异构用户知识并与隐式情感文本信息相融合,可使得模型具有针对隐式情感的个性化建模和分析能力。主流的用户

建模方法通过基于上下文挖掘用户属性，并结合图神经网络模型学习用户-产品之间的关系表示。Andrews和Bishop(2019)使用Transformer架构对时间、分类特征的上下文进行编码，将时间、文本以及上下文向量连接起来表示动作的单个向量，将用户活动映射到一个向量空间，通过几个多头注意力层捕获用户的不变特征相似性。Samih和Darwish(2021)为识别推特用户对特定目标(实体或主题)的立场，使用了两种方法处理用户立场。一种是通过BERT上下文嵌入来表示推文，另一种是从活跃用户的推特中计算共同特征相似性，对给定用户执行无监督分类，根据相似性将用户与训练集中的其他用户进行聚类。Zheng等人(2021a)考虑了用户-产品间的关系类型，提出了异构关系特异性实体表示模型用于用户画像建模。Lyu等人(2020)提出采用多头注意力机制建模评论文档与用户/产品之间的关联，建立用户-词-产品相互注意表示，使用单个用户或产品的所有评论来表示用户和产品。Wu等人(2019)提出了一个层次用户和产品的表示模型，在模型中加入了三层注意力网络来学习用户和产品表示与用户id和产品id嵌入结合，学习个人用户与产品的潜在关联表示。他们进一步提出了一种神经推荐方法Wu et al.(2019)，利用评论内容和用户-产品图信息，构建层次图神经网络捕获用户与产品在用户-产品图中的一阶和二阶交互相关性。He等人(2020)提出了一种名为LightGCN模型，通过在用户-物品交互图上线性传播来学习用户和物品嵌入，并使用在所有层上学习到的嵌入加权作为最终的嵌入。Liu等人(2021)使用用户兴趣构建多视图学习在不同兴趣主题视角下的用户建模表示。Zheng等人(2021b)通过构建层次化的主题兴趣表示，实现了具有良好可解释性的用户建模表示用于社交网络链路预测。

目前该领域大部分研究成果集中于针对隐式情感文本本身的特征建模表示方面，较少涉及对用户自身信息的表示。从充分性的角度来看，传统的模型只针对文本自身信息进行研究，没有考虑用户信息，主要原因在于难以对异构的用户信息和知识进行统一表示与融合学习，同时因为用户自身属性信息因较为敏感而难以获取，导致缺乏高覆盖用户信息的大规模语料库。从必要性的角度来看，与显式情感相比，隐式情感由于其缺乏显式情感词提供情感线索，更容易受到文本上下文和用户的主观差异性影响，这也是情感分析领域的重要难点之一。因此，本文针对这个隐式情感分析的特定任务提出了适用于此任务的方法，研究基于社区和内容的用户社会化知识建模方法，我们从内部信息和外部信息两个维度将异构用户知识细分为用户的社会化属性知识、内容知识和社会化关系知识，异构用户知识表示体系及说明示例如下表1所示。

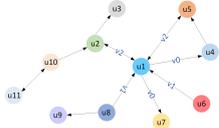
信息维度	用户知识	知识描述	知识示例
内部信息	社会化属性知识	描述用户的基本属性，包括[性别，所属地域，个性签名]	["女"，"山西"，"身体和心灵永远有一个在路上！"]
	用户内容知识	用户发布的历史微博内容 发布微博数量 发布时间	w1:刀削面，炒灌肠。一时半会回不去，吃个家乡菜还是可以的。w2:加油呀！明天早起来直奔清和元喝头脑！ 2 ["2014.12.5"，"2015.1.6"]
外部信息	社会化关系知识	用户的微博关注/被关注关系列表	

Table 1: 异构用户知识表示体系及说明示例

在此基础上针对不同类型的异构用户知识并采用了不同的方法对其进行表示。针对用户内部信息，以预训练模型为基础，结合堆叠多头注意力模型(stack-attention)和transformer编码器分别学习用户的社会化属性知识和内容知识表示。对于用户外部社会化关系信息，通过构建用户的关注关系矩阵，利用图神经网络模型将每个用户的社会化关系进行建模表示。最后将异构用户知识与隐式情感文本表示进行融合。本文的主要贡献如下：

(1) 提出了基于异构用户知识融合的隐式情感分析模型(Heterogeneous user knowledge fusion model, HELENE)，探索了异构的用户知识统一表示与融合方法，“融合”既是不同用户知识的融合，也是用户知识与文本信息的融合，对用户的社会化属性、内容和社会化关系知识进行融合建模，实现了针对隐式情感的主观差异性建模表示；

(2) 针对用户间社会化关系建模提出了用户有向关系图卷积模型(User Directed-Graph Convolutional Network, UD-GCN), 能够对用户间带有方向的不同关系类型进行精细化表示;

(3) 构建了一个用户个性化通用情感分析语料库, 覆盖了较为完整的隐式/显式情感文本内容信息、用户内容信息、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任务需要。

(4) 通过大量的实验验证了本文提出的模型效果, 相比于基线模型在用户个性化隐式情感分析任务上F-marco取得了1.9%-9.8%的效果提升。在论文发表后本文的代码实现可在如下地址⁰获取。

本文的组织安排如下: 第2节介绍了基于异构用户知识融合的隐式情感分析模型, 第3节详细介绍了实验数据集、实验设置并对实验结果展开了分析讨论; 最后对本文的研究进行了总结和展望。

2 基于异构用户知识融合的隐式情感分析模型

本文针对不同类型的异构用户知识并采用了不同的方法对其进行表示。基于表1的异构用户知识分类体系, 针对用户社会化属性知识、内容知识和用户社会化关系知识, 以动态预训练模型为基础, 结合序列模型和图神经网络模型分别学习异构用户知识的表示, 并与隐式情感文本表示进行融合, 实现基于用户差异化建模的隐式情感分析模型, 其整体框架如图1所示。

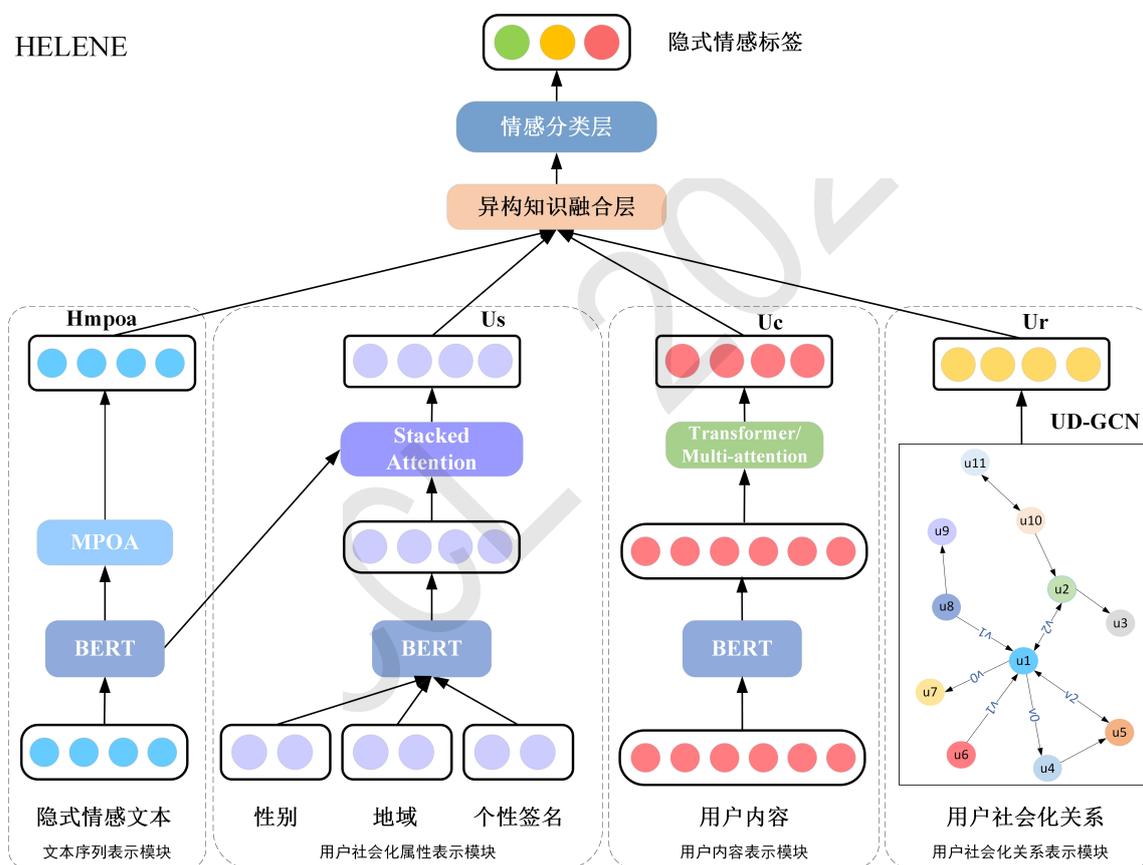


Figure 1: 基于异构用户知识嵌入融合隐式情感分析模型框架图

基于异构用户知识嵌入融合的隐式情感分析模型HELENE核心由文本序列表示模块、用户社会化属性表示模块、用户内容表示模块、用户社会化关系表示模型和异构知识融合层构成, 分别从用户内部和外部两个维度展开知识挖掘与融合研究。

2.1 用户内部知识建模表示

依照前文表1中的异构用户知识划分体系, 用户内部知识可细分为社会化属性知识和内容知

⁰<https://github.com/sxu-nlp/HELENE>

识。二者同属文本序列类型数据，且都反映了用户个体自身的信息。

(1) 社会化属性知识

本文所采集的用户社会化属性知识主要包含用户的性别、所属地域以及用户发布的个性签名信息。对于某一用户 u ，由于需要利用预训练模型学习用户社会化属性的知识表示，将其表示为有语义信息嵌入的向量，使其能够与文本信息统一进行计算，因此用户属性信息集合 I 形式化表示为： $I=[\text{“性别”}, \text{“所属地域”}, \text{“个性签名”}]$ ，将 I 中每个属性拼接成长序列(以[sep]间隔)后，利用BERT编码器获取该信息集合中各元素的特征表示 $I_{gender} \in \mathbb{R}^{gd}$ 、 $I_{location} \in \mathbb{R}^{gd}$ 以及 $I_{signature} \in \mathbb{R}^{md}$ ，其中 g 为性别、所属地域最大序列长度， m 为个性签名的最大序列长度， d 为每个token向量维度。将三者拼接得到用户社会化属性集合 I 的特征表示 $h_f = I_{gender} \oplus I_{location} \oplus I_{signature}$ 。由于隐式情感高度的主观依赖性，我们采用堆叠多头注意力模型(Lyu et al., 2020)建立待识别的隐式情感文本和用户社会化属性表示之间的联系，使得模型学习得到的社会化属性表示能特异性感知待识别隐式情感文本的语义信息，计算过程如公式(1)所示。

$$c_f^{(k)} = \text{stacked-attention}(h_f, h_t, h_t) \quad (1)$$

以待识别的隐式情感文本经BERT编码得到的表示 $h_t \in \mathbb{R}^{td}$ 作为注意力模型的键和值， t 为文本最大长度。以用户社会化属性特征表示 h_f 作为查询， k 为堆叠注意力函数模型的层数。在堆叠多头注意力机制的每一层，利用门控机制得到权重向量 z_f ，来进一步控制社会化属性信息对输出结果的贡献，公式为：

$$z_f = \sigma(W_f c_f + W_t h_t) \quad (2)$$

$$u_f = z_f \otimes c_f \quad (3)$$

其中， W_f 、 W_t 为权重矩阵， σ 为sigmoid函数。 \otimes 为向量元素乘，将门控权重与社会化属性信息加权综合，得到对待识别隐式情感文本的语义信息特异性感知的社会化属性表示向量 u_f 。

(2) 内容知识

用户社会化属性信息通常较为敏感且难以全面获取，而用户发布的内容文本中包含了大量用户隐含的个性化信息，例如语言风格、用词偏好等，进而可以对用户的受教育程度、所在行业、性格特点等进行分析。挖掘这类内容知识对于精准用户建模具有重要的意义。

本文将一个用户发布的所有微博内容视为一个长文本，使用BERT预训练模型(Devlin et al., 2018)获得其表示矩阵 $H_c \in \mathbb{R}^{h \times d}$ ， h 为长文本最大token长度， d 为token向量维度。为了考虑不同层次模型对内容知识建模的影响，分别利用Transformer编码器(Vaswani et al., 2017)和多头自注意力模型机制得到其向量用户内容知识的表示 u_c ，即：

$$u_c^{trans} = \text{Transformer}(H_c) \quad (4)$$

$$u_c^{matt} = \text{multi-attention}(H_c) \quad (5)$$

其中，Transformer编码器使用[cls]占位符的表示作为整个序列的表示， H_c 分别作为多头自注意力模型的查询矩阵、键和值矩阵。

2.2 用户外部知识建模表示

用户的外部知识反映了用户 u 与其他用户之间的交互关系，具有关联关系的用户更容易具备相似的兴趣偏好(Liu et al., 2021)，通常以关系交互矩阵或图结构形式存在。本文受LightGCN模型(He et al., 2020)根据用户-项目交互的无向图矩阵构建关系学习模型的启发，提出了面向用户-用户交互的图卷积模型(User Directed-Graph Convolutional Network, UD-GCN)实现用户间多种有向关系类型的精细建模表示。

基于用户的社会化关注关系列表，首先构建用户关注关系矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$ ，其中 n 为数据集集中的用户个数。任意两个用户 u 与 i 之间的取值定义为 $\mathbf{A}_{ui}=[0,1,2]$ ，分别对应于 u 关注 i 、 i 关

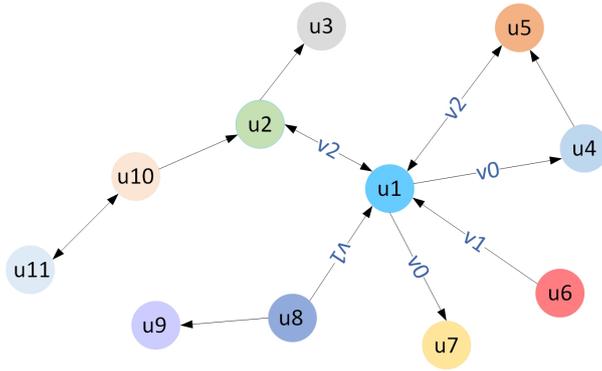


Figure 2: 用户-用户有向关系及类型示意图

注 u 以及 u_i 相互关注。据此构建图 G_d ，根据关注关系的不同分别设置图中对应边的权重参数向量 v_0 、 v_1 和 v_2 。如图2所示。UD-GCN模型对于用户图学习建模过程定义如下：

$$e_u^{(k+1)} = \sum_{i \in N_u} \frac{1}{\sqrt{|N_u|}} v_t \otimes e_i^k \quad (6)$$

其中， v_t 是用户 u 与用户 i 间的关注类型； e_i 是用户 u 的一阶邻居节点用户 i 的表示； N_u 是用户 u 的一阶邻居个数，以其作为归一化系数可以避免节点表示规模过大； \otimes 是对应元素乘操作； k 为迭代轮数。

用户 u 与用户 i 之间的社会化关系预测的目标函数定义为：

$$\tilde{y}_{ui} = \text{softmax}(W_r(e_u \oplus e_i) + b_r) \quad (7)$$

$$\mathcal{L}_{UD-GCN} = - \sum_{i \neq u} y_{ui} \log \tilde{y}_{ui} \quad (8)$$

其中， W_r 和 b_r 是权重矩阵和偏置； e_u 和 e_i 分别为用户 u 与用户 i 的节点表示向量， y_{ui} 为用户 u 和 i 间的真实关注关系状态。我们针对UD-GCN模型进行分阶段的单独优化学习，将优化完成后的节点表示 e_u 作为用户 u 的社会化关系知识表示 u_r 。

2.3 隐式情感文本表示与异构用户知识融合

(1) 隐式情感文本表示

模型的文本序列表示模块使用多极性正交注意力模型(multi-polarity orthogonal Attention model, MPOA)(Jiyao et al., 2020)学习隐式情感文本的嵌入表示，该模型通过构造不同情感极性的注意力模型，能够捕获不同极性下情感注意力的差异性特征，并通过正交限制保持该特征的稳定性和持续性。本文将隐式情感文本序列输入BERT模型后，以其输出经MPOA模型学习得到隐式情感文本的特征表示 h_{mpoa} ，表示公式定义为：

$$\begin{aligned} h_{mpoa} &= v^{q_{pos}} \oplus v^{q_{neg}} \oplus v^{q_{neu}} \\ v^q &= \sum_{i=1}^T \alpha_i^q w_i \\ \alpha_i^q &= \text{softmax}(qMw_i) \end{aligned} \quad (9)$$

其中， \oplus 为向量拼接操作， $q \in \{q_{pos}, q_{neg}, q_{neu}\}$ 为某一情感倾向的注意力查询向量， w_i 为隐式情感文本中的第 i 个词， M 为双线性注意力模型权重矩阵参数随机初始化，通过训练优化。

(2) 异构用户知识融合

以MPOA模型学习得到的隐式情感序列文本表示为基础，本文使用线性加权融合与堆叠注意力融合两种方式将用户内容知识表示 u_c 、社会化属性知识表示 u_f 以及社会化关系知识表

示 u_r 三种异构用户知识与文本表示进行融合，实现面向用户主观差异性建模的隐式情感表示学习。

线性加权融合 直接将三种异构用户知识与隐式情感文本表示进行线性组合并通过神经网络层映射到融合特征空间中，得到最终的融合表示向量 h_o ，定义为：

$$h_o = \tanh(W_m h_{mpoa} + W_f u_f + W_c u_c + W_r u_r) \quad (10)$$

其中， W_m 、 W_f 、 W_c 和 W_r 为融合权重参数，随机初始化再通过训练优化。

堆叠注意力融合 将异构用户知识与隐式情感文本表示通过堆叠注意力模型进行融合，可以自动学习各嵌入知识的融合权重。将 u_c 、 u_f 以及 u_r 分别作为堆叠注意力模型的查询，以隐式情感文本表示 h_{mpoa} 作为键和值，三种异构用户知识与隐式情感文本的融合表示定义为：

$$\begin{aligned} c_{fm}^{(k)} &= \text{stacked-attention}(u_f, h_{mpoa}, h_{mpoa}) \\ c_{cm}^{(k)} &= \text{stacked-attention}(u_c, h_{mpoa}, h_{mpoa}) \\ c_{rm}^{(k)} &= \text{stacked-attention}(u_r, h_{mpoa}, h_{mpoa}) \end{aligned} \quad (11)$$

其中， k 为堆叠注意力模型的层数。在堆叠多头注意力机制的每一层，利用门控机制得到权重向量 z_{fm} 、 z_{cm} 和 z_{rm} ，来控制用户内容知识、社会化属性知识和社会化关系知识对输出结果的贡献，计算过程如下：

$$\begin{aligned} z_{fm} &= \sigma(W_f c_{fm} + W_{fm} h_{mpoa} + b_f) \\ z_{cm} &= \sigma(W_c c_{cm} + W_{cm} h_{mpoa} + b_c) \\ z_{rm} &= \sigma(W_r c_{rm} + W_{rm} h_{mpoa} + b_r) \end{aligned} \quad (12)$$

利用学习得到门控权重与异构用户知识、文本信息加权综合得到最终的融合异构用户知识的隐式情感表示向量 h_o ，计算公式为：

$$h_o = h_{mpoa} + z_{fm} \otimes c_{fm} + z_{cm} \otimes c_{cm} + z_{rm} \otimes c_{rm} \quad (13)$$

(3) 模型输出层

在输出层，使用全连接层将融合异构用户知识的隐式情感文本表示映射到分类空间并使用softmax函数进行归一化得到各类别概率分布 $\tilde{y} = \text{softmax}(W_o h_o + b_o)$ ， W_o 、 b_o 分别为全连接分类层的参数矩阵与偏置。使用交叉熵损失函数来度量预测 \tilde{y} 和真实标签 y 之间的损失 \mathcal{L}_{cls} ，并加入MPOA模型(Jiyao et al., 2020)的多极性注意力查询向量的正交损失 \mathcal{L}_{ort} ，如公式(14)所示，其中 q_i 为第 i 种极性注意力的查询向量， $q_i/q_j \in \{q_{pos}, q_{neg}, q_{neu}\}$ ， $q_i \neq q_j$ 。

$$\mathcal{L}_{ort} = \sum \left| \frac{q_i \cdot q_j}{|q_i| \cdot |q_j|} \right| \quad (14)$$

模型总损失函数定义为公式(15)：

$$\mathcal{L} = \lambda \mathcal{L}_{cls} + (1 - \lambda) \mathcal{L}_{ort} \quad (15)$$

其中，参数 λ 用于调节分类损失 \mathcal{L}_{cls} 与正交损失 \mathcal{L}_{ort} 的比重。

3 实验

3.1 数据集与评价指标

本文采集、整理并构建了一个用户个性化通用情感分析语料库。原始数据来源于2013-2015年的微博数据，包含有约2000万条原始数据，其中包含了用户id、文本内容等基本信息；性别、地域等用户社会化属性信息；以及用户关注/被关注关系等社会关系信息，所有数据已做脱敏处理。构造数据集时，利用了触发词+情感词典对微博内容进行筛选，存在这样规则的句子前后若有三句及三句以上的句子，视为有效的用户内容知识，保留符合规则的内容知识以及对应用户的各类信息，以保证数据具有较为丰富的内部内容知识，并按句子进行分割标注。标注过程采用众包自动标注+人工校对的方式完成，人工校对率为47.87%。我们基于该语料库构

建了2个数据集，D-implicit为隐式情感分析数据集，使用触发词+情感词典筛选了含有显式情感的标注句子，D-general在D-implicit的基础上保留了一部分显式情感句，以验证模型在通用情感分析任务上的泛化能力。两个数据集的标签分布统计如下表2所示。以构建的用户个性化隐式情感分析语料库作为实验数据集，按照5:1:1的比例随机采样对其进行划分得到训练集、验证集和测试集。本文使用各情感倾向标签的精确率(precision)、召回率(recall)、F1值，以及宏平均F1值(F-marco)来评估模型的性能。

	无情感倾向	褒义	贬义	合计标注句子	微博数	用户数	关系边数	平均微博数
D-implicit	4803	3636	4264	12703	11035	3147	5083	3.51
D-general	8763	7272	7791	23836	14714	3546	6049	4.15

Table 2: 用户个性化通用情感分析数据集分析统计表

3.2 实验设置与对比模型

(1) **实验设置** 用户社会化表示模块中的堆叠注意力层数(公式(1))与异构知识融合层中的堆叠注意力层数(公式(11)) k 分别设置为3和3；用户社会化属性最大序列长度(性别，所属地域，个性签名) $[g, g, m]=[6, 6, 24]$ ；用户内容信息序列最大长度 $h=192$ ；token向量维度 $d=768$ ；Transformer编码器层数设置为6；公式(15)中损失函数系数 $\lambda=0.1$ ；使用BERT-Adam优化模型，dropout=0.5， $\eta=2e-5$ ；实验使用pytorch¹框架开发，运行环境为Ubuntu22.04+RTX3090*2。

在实验过程中，为了探索不同的异构用户知识学习以及融合方法的效果，我们设置了五组不同的模型组合方案分别做了五种实验，如下表3所示。

模型	社会化属性知识	用户内容知识	社会化关系知识	融合方法
HELENE-1	BERT	BERT+multi-attention	UD-GCN	线性加权融合
HELENE-2	BERT	BERT+Transformer编码器	UD-GCN	stacked-attention
HELENE-3	BERT+stacked-attention	BERT+Transformer编码器	UD-GCN	stacked-attention
HELENE-4	BERT+stacked-attention	BERT+multi-attention	UD-GCN	线性加权融合
HELENE-5	BERT+stacked-attention	BERT+Transformer编码器	UD-GCN	线性加权融合

Table 3: 实验方案模型组合设置

(2) **对比模型** 本文研究的用户个性化隐式情感分析任务本质上属于文本分类问题。我们使用在中文文本分类和隐式情感分析中表现出色的流行模型作为基线对比模型以验证本文提出的模型的效果，基线模型主要包括：BERT(Devlin et al., 2018)、RoBERTa(Ott et al., 2019)、BERT-CNN、BERT-RNN、BERT-RCNN、BERT-DPCNN²、ERNIE(Sun et al., 2020)、MPOA(Jiyao et al., 2020)、C-MPOA(王素格 et al., 2021)、KG-MPOA(Liao et al., 2022)。

3.3 实验结果与分析

用户个性化隐式情感分析任务要求该模型识别包含隐式情感的句子，并对其情感极性进行分类。各实验模型在D-implicit数据集上的结果如表4所示。P，R分别表示准确率和召回率。

本文实验主要从三个方面进行分析，分别是基线模型对比、消融实验对比以及模型参数实验对比。与基线模型对比，我们提出的模型在传统的只对文本情感分类的基础上，融入了用户的知识信息，使具备处理主观差异性的能力。在消融实验中，将组成模型的各个组块分别去掉，探究各类型异构用户知识对整体的影响。在参数实验对比中，分别探索Transformer不同层数与多头自注意机制、堆叠的多头注意力不同层数对结果的提升效果，使得模型能够达到最优。

表4结果表明，与各基线模型相比，我们提出的模型通过融入了用户的知识信息，从内部外部两个维度对其进行画像建模并与隐式情感文本进行有效地融合表示，使得隐式情感分析模型能够充分利用用户信息，具备处理主观差异性的能力。其中，HELENE-5模型整体取得了最优的个性化隐式情感分析效果，相比于各基线模型在F-marco指标上取得了1.9%-9.8%的性能提

¹<https://pytorch.org/>

²<https://github.com/649453932/BERT-Chinese-Text-Classification-Pytorch>

模型	无情感倾向			隐式褒义			隐式贬义			F-macro
	P	R	F1	P	R	F1	P	R	F1	
BERT	0.491	0.630	0.552	0.667	0.356	0.464	0.579	0.686	0.628	0.548
RoBERTa	0.541	0.414	0.469	0.564	0.500	0.530	0.555	0.748	0.637	0.545
BERT-CNN	0.563	0.482	0.519	0.572	0.524	0.547	0.581	0.714	0.641	0.569
BERT-RNN	0.469	0.622	0.535	0.627	0.242	0.349	0.554	0.714	0.624	0.503
BERT-RCNN	0.629	0.414	0.499	0.558	0.552	0.539	0.559	0.786	0.653	0.564
BERT-DPCNN	0.579	0.430	0.494	0.592	0.446	0.509	0.537	0.808	0.645	0.549
ERNIE	0.567	0.482	0.521	0.590	0.448	0.509	0.577	0.802	0.671	0.567
MPOA	0.588	0.496	0.538	0.600	0.450	0.514	0.566	0.796	0.662	0.571
KG-MPOA	0.441	0.614	0.513	0.564	0.300	0.392	0.556	0.598	0.576	0.498
C-MPOA	0.496	0.652	0.563	0.637	0.428	0.512	0.632	0.682	0.656	0.577
HELENE-1	0.485	0.334	0.396	0.524	0.550	0.537	0.604	0.762	0.674	0.535
HELENE-2	0.530	0.570	0.549	0.572	0.506	0.537	0.631	0.656	0.643	0.576
HELENE-3	0.529	0.592	0.558	0.593	0.496	0.540	0.630	0.658	0.644	0.581
HELENE-4	0.524	0.454	0.487	0.575	0.586	0.580	0.625	0.696	0.658	0.575
HELENE-5	0.565	0.480	0.519	0.591	0.564	0.577	0.635	0.760	0.692	0.596

Table 4: 用户个性化隐式情感分析任务实验结果对比(D-implicit数据集)

升。说明用户内容知识、社会化属性和关系知识对于隐式情感的识别和倾向性分析具有重要的作用。考虑各基线模型的性能，预训练模型(BERT、RoBERTa、ERNIE等)能为深层语义分析提供基础的语义知识表示。在此基础上，通过对情感极性差异性特征建模(MPOA)并引入上下文信息(C-MPOA)能够显著提升模型的识别隐式情感的能力。对于KG-MPOA模型，由于本文标注的语料库句子相对较短，导致能够引入的外部常识知识规模远小于原始文献中引入知识，导致模型未能充分利用外部常识扩展文本语义。这也说明针对用户个性化隐式情感分析研究，高效地引入外部情感常识知识对于隐式情感分析性能提升具有巨大的挖掘潜力。

对比5种不同的HELENE模型，通过BERT+堆叠注意力，BERT+Transformer编码器以及UD-GCN分别对用户社会化属性、内容和社会化关系进行表示(HELENE-3与HELENE-5)能够达到最优的建模效果。而在异构用户数据融合层，使用线性加权融合(HELENE-5)相对于使用堆叠注意力机制(HELENE-3)效果更佳，分析原因我们认为，线性加权融合相对具有更少的信息损失，同时堆叠注意力模型过高地强调了隐式文本表示 h_{mpoa} 的重要性，导致融合过程损失了较多的用户知识信息。

我们同时在D-general数据集上开展了相似实验，以验证模型在用户个性化情感分析任务上的泛化性能。实验结果如下表5所示。

模型	无情感倾向			褒义			贬义			F-macro
	P	R	F1	P	R	F1	P	R	F1	
BERT	0.524	0.698	0.599	0.723	0.479	0.577	0.660	0.667	0.664	0.615
RoBERTa	0.514	0.750	0.610	0.728	0.511	0.600	0.680	0.570	0.620	0.610
BERT-CNN	0.529	0.699	0.602	0.669	0.614	0.641	0.717	0.547	0.621	0.621
BERT-RNN	0.538	0.704	0.610	0.674	0.578	0.622	0.696	0.580	0.633	0.622
BERT-RCNN	0.598	0.579	0.588	0.619	0.683	0.649	0.681	0.631	0.655	0.631
BERT-DPCNN	0.510	0.701	0.590	0.737	0.506	0.600	0.645	0.605	0.624	0.605
ERNIE	0.541	0.708	0.613	0.749	0.512	0.608	0.680	0.685	0.683	0.635
KG-MPOA	0.599	0.423	0.496	0.617	0.716	0.663	0.623	0.706	0.662	0.607
MPOA	0.568	0.677	0.618	0.697	0.631	0.662	0.701	0.634	0.666	0.648
C-MPOA	0.655	0.512	0.575	0.659	0.714	0.685	0.666	0.755	0.708	0.656
HELENE-1	0.615	0.488	0.544	0.686	0.665	0.675	0.640	0.791	0.708	0.642
HELENE-2	0.604	0.626	0.615	0.684	0.640	0.661	0.682	0.702	0.692	0.656
HELENE-3	0.592	0.647	0.618	0.688	0.636	0.661	0.703	0.691	0.697	0.659
HELENE-4	0.631	0.629	0.630	0.709	0.659	0.683	0.694	0.745	0.718	0.677
HELENE-5	0.676	0.580	0.624	0.681	0.695	0.688	0.683	0.766	0.722	0.678

Table 5: 用户个性化情感分析任务实验结果对比(D-general数据集)

从表5结果可知，相较于隐式情感，更简单的显式情感整体提高了所有模型的性能。所提出的模型除HELENE-1外均优于所有的基线模型，说明用户个性化知识对于显式情感建模同样具有重要的意义。

3.4 消融实验与分析

HELENE-5与HELENE-3通过使用BERT+堆叠注意力, BERT+Transformer编码器以及UD-GCN分别对用户社会化属性、内容和社会化关系进行表示, 在上节的用户个性化隐式/通用情感分析任务中分别取得了最优和次优的结果。我们针对2个模型各异构用户知识构成进行了消融分析, 以进一步探究各类型异构用户知识对整体的影响。在D-implicit和D-general数据集上的消融实验结果如下表6和7所示, -f、-c、-r分别表示原HELENE-3/5模型去除了用户社会化属性知识的模型、用户内容知识的模型以及用户社会化关系知识的模型。

模型	无情感倾向			隐式褒义			隐式贬义			F-macro
	P	R	F1	P	R	F1	P	R	F1	
HELENE-3	0.529	0.592	0.558	0.593	0.496	0.540	0.630	0.658	0.644	0.581
HELENE-3-f	0.530	0.570	0.549	0.572	0.506	0.537	0.631	0.656	0.643	0.576
HELENE-3-c	0.525	0.580	0.551	0.587	0.506	0.544	0.621	0.642	0.631	0.575
HELENE-3-r	0.524	0.586	0.553	0.583	0.498	0.537	0.634	0.652	0.643	0.578
HELENE-5	0.565	0.480	0.519	0.591	0.564	0.577	0.635	0.760	0.692	0.596
HELENE-5-f	0.551	0.456	0.499	0.546	0.582	0.563	0.640	0.708	0.672	0.578
HELENE-5-c	0.620	0.394	0.482	0.541	0.622	0.579	0.580	0.798	0.672	0.577
HELENE-5-r	0.554	0.454	0.499	0.579	0.566	0.572	0.607	0.730	0.663	0.578

Table 6: HELENE-3/5模型在隐式情感分析任务上消融实验对比(D-implicit数据集)

模型	无情感倾向			褒义			贬义			F-macro
	P	R	F1	P	R	F1	P	R	F1	
HELENE-3	0.592	0.647	0.618	0.688	0.636	0.661	0.703	0.691	0.697	0.659
HELENE-3-f	0.579	0.631	0.604	0.675	0.612	0.642	0.686	0.689	0.687	0.644
HELENE-3-c	0.591	0.632	0.611	0.680	0.635	0.657	0.694	0.691	0.692	0.653
HELENE-3-r	0.588	0.629	0.608	0.684	0.627	0.654	0.684	0.694	0.689	0.650
HELENE-5	0.676	0.580	0.624	0.681	0.695	0.688	0.683	0.766	0.722	0.678
HELENE-5-f	0.652	0.591	0.620	0.690	0.671	0.680	0.679	0.761	0.718	0.673
HELENE-5-c	0.582	0.668	0.622	0.689	0.633	0.660	0.699	0.652	0.675	0.652
HELENE-5-r	0.661	0.562	0.608	0.678	0.681	0.680	0.667	0.764	0.712	0.667

Table 7: HELENE-3/5模型在情感分析任务上消融实验对比(D-general数据集)

由表6和7可知, 在去掉异构用户知识各组成部分后, 在隐式情感或通用情感分析任务上模型的性能均有所降低。以HELENE-5模型为例, 在去除了用户社会化属性知识、用户内容知识、用户社会化关系知识后, 在两个数据集上的F-macro分别降低了1.8%, 1.9%, 1.8%(D-implicit)和0.5%, 2.6%, 1.1%(D-general), 验证了通过用户发布历史内容知识, 可以从中分析出大量的用户潜在信息, 对于精准用户画像建模具有重要的作用, 这可为后续相关工作提供借鉴。除此之外, 用户的社会化关系准确反映了“人以类聚”的特征, 通过用户有向图关系建模可以较好的学习用户的群体类别特征。用户社会化属性知识由于所含内容相对较少, 能够提供的用户信息有限, 但仍能较准确地为涉及地域、性别身份信息的用户画像提供支持。

3.5 案例分析

本文对模型预测结果进行案例分析, 以表8中如下两个数据为例分析解释模型预测结果, 表中内容知识IS表示待分析隐式情感句。

在表8中, 案例1中待识别的句子为“边走湿透的裤子里面水直往鞋子里流!”。根据待识别句子所在的用户内容信息中“雨”、“真变态”、“不像样”, 对应用户的社会化属性信息中“得不到”、“骚动”此类偏消极词信息, 以及该用户社会化关注关系知识, 与待识别的句子信息融合, 我们的模型将其判别为贬义类型。而在案例2中, 待识别的句子为“夏天来了, 去年蝉蜕下的壳还会在吗。”, 本身带了一种因怀念过去而感到悲凉的气息, 却被判别为褒义。我们认为由于在对应的内容信息中的“鸽子”、“放飞蓝天”、“过得更好”等偏积极的信息在识别情感时对模型产生了误导, 因此导致模型出现错误预测。

4 结论与展望

本文提出了一种基于异构用户知识融合的隐式情感分析的模型HELENE, 从用户的内部外部两个维度对其进行画像建模, 挖掘了用户的内容、社会化属性和社会化关系三种不同的异构

案例	隐式情感句	内容知识	社会化属性知识	真实标签	模型预测
1	边走湿透的裤子里面水直往鞋子里流!	这雨下的真变态! <i>IS</i> 上身更不用说的惨全身湿的不像样了!, 赶紧热水澡搞起.....	["女", "湖南长沙", "得不到的永远在骚动!"]	贬	贬
2	夏天来了, 去年蝉蜕下的壳还会在吗。	这种天气就像鸽子成群放飞蓝天, 齐齐拍动翅膀的爽朗声响, 心情也被太阳晒得明晃晃的。 <i>IS</i> 我相信, 怀念只是为了让我们过得更好。	["男", "福建厦门", "时间它只负责流动, 不负责育你成长。"]	贬	褒

Table 8: 模型预测结果案例分析

知识, 并将其与隐式情感文本进行有效地融合表示, 使得隐式情感分析模型能够充分利用用户个性化信息, 具备处理主观差异性的能力。本文同时构建了一个具有覆盖用户属性-关系-文本信息的较大规模通用情感分析语料库, 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要。在构建数据集上的实验结果表明, 文本提出的方法相比于基线模型在个性化隐式情感分析任务上F-marco取得了1.9%-9.8%的效果提升。

未来的工作将主要集中于针对多视角用户建模的隐式情感分析方面, 以期实现更精细化的用户表示与知识融合。

参考文献

- Nicholas Andrews and Marcus Bishop. 2019. Learning invariant representations of social media users. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 1684–1695, Hong Kong, China, November. Association for Computational Linguistics.
- Hongjie Cai, Rui Xia, and Jianfei Yu. 2021. Aspect-category-opinion-sentiment quadruple extraction with implicit aspects and opinions. In *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, pages 340–350, Online, August. Association for Computational Linguistics.
- Huan-Yuan Chen and Hsin-Hsi Chen. 2016. Implicit polarity and implicit aspect recognition in opinion mining. In *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, ACL 2016, August 7-12, 2016, Berlin, Germany, Volume 2: Short Papers*. The Association for Computer Linguistics.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2018. BERT: pre-training of deep bidirectional transformers for language understanding. *CoRR*, abs/1810.04805.
- Xiangnan He, Kuan Deng, Xiang Wang, Yan Li, Yongdong Zhang, and Meng Wang. 2020. Lightgcn: Simplifying and powering graph convolution network for recommendation. In *Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval*, pages 639–648.
- Liao Jian, Li Yang, and Wang Suge. 2016. The constitution of a fine-grained opinion annotated corpus on weibo. In *Chinese Computational Linguistics and Natural Language Processing Based on Naturally Annotated Big Data*, pages 227–240. Springer.
- Liao Jian, Wang Suge, and Li Deyu. 2019. Identification of fact-implied implicit sentiment based on multi-level semantic fused representation. *Knowledge-Based Systems*, 165:197–207.
- Wei Jiayao, Liao Jian, Yang Zhenfei, Wang Suge, and Zhao Qiang. 2020. Bilstm with multi-polarity orthogonal attention for implicit sentiment analysis. *Neurocomputing*, 383:165–173.
- Zhengyan Li, Yicheng Zou, Chong Zhang, Qi Zhang, and Zhongyu Wei. 2021. Learning implicit sentiment in aspect-based sentiment analysis with supervised contrastive pre-training. In *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, pages 246–256, Online and Punta Cana, Dominican Republic, November. Association for Computational Linguistics.

- Jian Liao, Min Wang, Xin Chen, Suge Wang, and Kai Zhang. 2022. Dynamic commonsense knowledge fused method for chinese implicit sentiment analysis. *Information Processing & Management*, 59(3):102934.
- Fan Liu, Zhiyong Cheng, Lei Zhu, Zan Gao, and Liqiang Nie. 2021. Interest-aware message-passing gcn for recommendation. In *Proceedings of the International Conference of World Wide Web*, pages 1296–1305.
- Bing Liu. 2015. *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. Cambridge University Press.
- Chenyang Lyu, Jennifer Foster, and Yvette Graham. 2020. Improving document-level sentiment analysis with user and product context. In *Proceedings of the 28th International Conference on Computational Linguistics*, pages 6724–6729, Barcelona, Spain (Online), December. International Committee on Computational Linguistics.
- Myle Ott, Sergey Edunov, Alexei Baevski, Angela Fan, Sam Gross, Nathan Ng, David Grangier, and Michael Auli. 2019. fairseq: A fast, extensible toolkit for sequence modeling. In *Proceedings of NAACL-HLT 2019: Demonstrations*.
- Y. Samih and K. Darwish. 2021. A few topical tweets are enough for effective user-level stance detection. In *The 16th conference of the European Chapter of the Association for Computational Linguistics (EACL)*.
- Chen Shiyun, Lin Xin, Xiao Yanghua, and He Liang. 2019. Sentiment commonsense induced sequential neural networks for sentiment classification. In *Proceedings of the 28th ACM International Conference on Information and Knowledge Management*, pages 1021–1030.
- Yu Sun, Shuohuan Wang, Yukun Li, Shikun Feng, Hao Tian, Hua Wu, and Haifeng Wang. 2020. Ernie 2.0: A continual pre-training framework for language understanding. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 34, pages 8968–8975.
- Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Lukasz Kaiser, and Illia Polosukhin. 2017. Attention is all you need. In *Advances in neural information processing systems*, pages 5998–6008.
- Chuhan Wu, Fangzhao Wu, Mingxiao An, Tao Qi, Jianqiang Huang, Yongfeng Huang, and Xing Xie. 2019. Neural news recommendation with heterogeneous user behavior. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 4874–4883.
- J. Zheng, Q. Li, and J. Liao. 2021a. Heterogeneous type-specific entity representation learning for recommendations in e-commerce network. *Information Processing & Management*, 58(5):102629.
- J. Zheng, Q. Li, J. Liao, and S. Wang. 2021b. Explainable link prediction based on multi-granularity relation-embedded representation. *Knowledge-Based Systems*, 230(15):107402.
- Deyu Zhou, Jianan Wang, Linhai Zhang, and Yulan He. 2021. Implicit sentiment analysis with event-centered text representation. In *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, pages 6884–6893, Online and Punta Cana, Dominican Republic, November. Association for Computational Linguistics.
- Enguang Zuo, Hui Zhao, Bo Chen, and Qiuchang Chen. 2020. Context-specific heterogeneous graph convolutional network for implicit sentiment analysis. *IEEE Access*, 8:37967–37975.
- 廖健. 2018. 基于表示学习的事实型隐式情感分析研究. Ph.D. thesis, 山西大学.
- 潘东行, 袁景凌, 李琳, and 盛德明. 2020. 一种融合上下文特征的中文隐式情感分类模型. *计算机工程与科学*, 42(2):10.
- 王素格, 王敏, 廖健, and 陈鑫. 2021. 融合上下文信息的隐式情感句判别方法. *山西大学学报(自然科学版)*, 165:1–7.