

## 融入类别标签和主题信息的用户兴趣识别方法

康智勇, 李弼程, 林煌

引用本文

康智勇, 李弼程, 林煌. [融入类别标签和主题信息的用户兴趣识别方法](#)[J]. 计算机科学, 2024, 51(6A): 230500169-8.

KANG Zhiyong, LI Bicheng, LIN Huang. [User Interest Recognition Method Incorporating Category Labels and Topic Information](#) [J]. Computer Science, 2024, 51(6A): 230500169-8.

---

## 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)

[RM-RT<sup>2</sup>NI:融合评论时效与可信近邻影响力的推荐模型](#)

RM-RT<sup>2</sup>NI:A Recommendation Model with Review Timeliness and Trusted Neighbor Influence  
计算机科学, 2024, 51(6A): 230800160-7. <https://doi.org/10.11896/jsjcx.230800160>

[卷烟厂卷包车间工人违规作业行为检测方法](#)

Detection Method for Workers' Illegal Operation Behavior in Packaging Workshop of Cigarette Factory  
计算机科学, 2024, 51(6A): 230700123-8. <https://doi.org/10.11896/jsjcx.230700123>

[感受野扩展与多分支聚合的目标检测方法](#)

Object Detection with Receptive Field Expansion and Multi-branch Aggregation  
计算机科学, 2024, 51(6A): 230600151-6. <https://doi.org/10.11896/jsjcx.230600151>

[基于YOLOP-L的多特征融合道路全景驾驶检测](#)

Multi Feature Fusion for Road Panoramic Driving Detection Based on YOLOP-L  
计算机科学, 2024, 51(6A): 230700185-8. <https://doi.org/10.11896/jsjcx.230700185>

[基于时频融合特征的肺动脉高压心音分类模型](#)

Classification Model of Heart Sounds in Pulmonary Hypertension Based on Time-Frequency Fusion Features  
计算机科学, 2024, 51(6A): 230800091-7. <https://doi.org/10.11896/jsjcx.230800091>

# 融入类别标签和主题信息的用户兴趣识别方法

康智勇 李弼程 林煌

华侨大学计算机科学与技术学院 厦门 361021

(21014083062@stu.hqu.edu.cn)

**摘要** 社交网络用户兴趣发现对信息过载缓解、个性化推荐和信息传播正向引导等方面具有重要意义。目前已有的兴趣识别研究未能同时考虑文本主题信息及其对应的类别标签信息对模型学习文本特征的帮助,文中提出了一种融入类别标签和主题信息的用户兴趣识别方法。首先,利用BERT预训练模型、BiLSTM模型和多头自注意力机制分别获取文本和标签序列的语义特征;其次,引入标签注意力机制,使模型更加关注文本与其类别标签更相关的词语信息;然后,利用LDA主题模型和Word2Vec模型得到文本主题特征;接着,设计门控机制进行特征融合,使模型能够自适应地融合多种特征,进而实现微博文本兴趣类别分类;最后,统计用户发表的所有文本在各个兴趣类别上的数量,将数量最多的兴趣类别确定为用户兴趣识别结果。为验证所提方法的有效性,文中构建了一个微博兴趣识别数据集。实验结果表明,该模型在微博文本兴趣类别分类和用户兴趣识别任务中均取得了最优性能。

**关键词:** 社交网络;兴趣识别;主题模型;标签注意力机制;特征融合

**中图分类号** TP391

## User Interest Recognition Method Incorporating Category Labels and Topic Information

KANG Zhiyong, LI Bicheng and LIN Huang

College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China

**Abstract** The discovery of social media user interest is of great significance in information overload alleviation, personalized recommendation, and positive guidance of information dissemination. Existing research of interest recognition fails to consider the help of topic information and corresponding category labels information for model learning text features at the same time. Therefore, a user interest recognition method incorporating category labels and topic information is proposed. Firstly, semantic features of text and label sequences are extracted separately by using the BERT pre-trained model, BiLSTM model, and multi-head self-attention mechanism. Then, a label attention mechanism is introduced to make the model pay more attention to the words related to the text's corresponding category label. Secondly, text topic features are obtained by using the LDA topic model and Word2Vec model. Subsequently, a gating mechanism is designed for feature fusion to enable the model to adaptively merge multiple features, thereby realizing text interest classification. Finally, the number of texts published by users in each interest category is counted, and the interest category with the highest count is determined as users' interest recognition results. To verify the effectiveness of the proposed method, a Weibo users' interest recognition dataset is constructed. Experimental results show that the model achieves optimal performance in Weibo text classification and user interest recognition tasks.

**Keywords** Social network, Interest recognition, Topic model, Label attention mechanism, Feature fusion

## 1 引言

近年来,互联网的迅速发展和进步,以及移动设备的快速更新换代,带动了微博、微信、Twitter等社交媒体平台的发展,为人们随时随地从互联网中获取其所需的信息提供了极大便利。并且,随着社交平台使用便捷性的进一步提高,互联网中用户的参与度越来越高,越来越多的用户愿意在社交平台上分享日常生活或针对其自身感兴趣的事件、话题或产品发表观点,实现信息交换、传播与共享。然而,随着社交网络用户数量和信息资源的爆炸性增长,人们从信息匮乏时代迅速过渡到了信息过载时代,如何精准地从信息的海洋中快速、

有效地获取用户感兴趣的信息,提高信息使用率,成为了当今互联网时代困扰网民们的主要问题之一。

新浪微博以其内容的精简性、原创性和即时共享性吸引了广大网民,每天有数以亿计的用户在微博平台上产生发表、转发、点赞和收藏等行为,这些网络行为都在不同程度上反映了用户的兴趣偏好。若能采取高效、准确的方式从大量微博信息中自动识别微博用户的兴趣,则有望缓解信息超载问题,预防信息迷航,从而有助于改善用户体验。同时,用户兴趣识别在个性化信息推荐、商品推荐与广告精准投放等方面都具有重要的经济价值或社会意义。

目前,用户兴趣识别的研究主要包括基于用户行为和基

基金项目:装备预研教育部联合基金(8091B022150)

This work was supported by the Joint Fund of Equipment Pre-research and Ministry of Education(8091B022150).

通信作者:李弼程(lbclm@163.com)

于用户文本内容的兴趣识别。其中,基于用户文本内容的兴趣识别可进一步分为基于主题模型、深度学习及主题模型和深度学习相结合的兴趣识别3种。基于隐含狄利克雷分布(Latent Dirichlet Allocation, LDA)<sup>[1]</sup>等主题模型对用户在社交网络中产生的文本进行兴趣挖掘是一种简单有效的方式,然而, LDA模型虽然能够从文本中提取隐含主题信息,但其未考虑文本词语之间的顺序语义关系,因此仅利用LDA模型无法从文本中得到连贯的主题语义信息。近年来,随着深度学习技术的飞速发展与广泛应用,基于深度学习的用户兴趣识别方法应运而生。然而,该类方法目前大多侧重于如何从用户发表的文本中挖掘具有区分度的丰富语义特征进行兴趣识别,而忽略了文本对应的标签类别信息对学习文本特征表示的帮助。文本中每个词语对其类别标签预测的贡献度是不同的,以“今天跟朋友吃了海鲜大餐,这些食物真的很美味”这一属于“美食”类别标签的句子为例,“海鲜”“大餐”“食物”和“美味”这些词语与“美食”类别的相关性更大,故这些词语在该类别的权重应该较大,而其他词语在该类别的权重应该较小。因此,如何在用户兴趣识别中融入类别标签信息,突出文本中与其对应类别标签最相关的词语,是一个值得研究的问题。

针对上述问题,本文提出了一种融入类别标签和主题信息的用户兴趣识别方法,该方法使用BERT(Bidirectional Encoder Representation from Transformers)<sup>[2]</sup>预训练模型、BiLSTM模型和多头自注意力机制来获取文本和标签语义特征,利用LDA主题模型提取文本隐含的主题信息,并引入标签注意力机制来关注文本与其类别标签更相关的词语信息。此外,为综合考虑文本原始语义信息、主题信息及其对应的类别标签信息,设计了门控机制,自适应地融合多种特征,以提高用户兴趣识别的效果。

## 2 相关工作

相关工作包括两部分:社交网络用户兴趣识别和融入标签信息的文本分类。

### 2.1 用户兴趣识别

社交网络用户兴趣识别主要分为两种:基于用户行为的兴趣识别和基于用户文本内容的兴趣识别。

#### 2.1.1 基于用户行为的兴趣识别

基于用户行为的兴趣识别指通过用户转发、点赞、评论、关注等网络行为轨迹来挖掘用户的兴趣信息。Zhao等<sup>[3]</sup>认为不同的网络行为反映了用户的不同兴趣,首先构建用户各个行为的行为-主题矩阵,然后进行矩阵分解以学习潜在的行为-主题嵌入空间,最后利用该潜在空间构建用户兴趣画像。然而,用户在社交平台上的行为轨迹较为稀疏、分散且不规律,难以获取完整可用的行为数据。此外,大多数社交平台具有用户隐私保护机制,导致用户行为数据获取难度增加。针对缺少背景信息、发帖量较少的沉默用户,Zhong等<sup>[4]</sup>从其关注用户背景的标签信息来挖掘用户兴趣。但是,用户自我展示的背景信息通常只包含少数关键词,难以从有限的关键词信息中完整、准确地挖掘用户兴趣。用户行为数据的不完整性与隐私性,限制了该类方法的兴趣识别准确性和流行性。

#### 2.1.2 基于用户文本内容的兴趣识别

基于用户文本内容的兴趣识别方法指从用户历史发表的文本内容中挖掘用户的兴趣信息。该类方法可进一步划分为

基于主题模型的兴趣识别方法、基于深度学习的兴趣识别方法及主题模型和深度学习相结合的兴趣识别方法3种。

基于主题模型的兴趣识别指利用LDA及其改进模型从用户参与的文本内容中提取主题特征,进而实现兴趣挖掘。LDA主题模型能够有效提取用户文本中隐含的主题信息,因此被广泛应用于用户兴趣识别的研究中。Rajendran等<sup>[5]</sup>利用LDA模型从用户历史浏览的文本内容中提取主题特征,使用协同过滤方法预测用户兴趣并进行信息推荐。He等<sup>[6]</sup>提出了一种双标签主题概率模型(Bi-Label LDA),从沉默用户所关注知名用户的背景信息和文本内容中挖掘知名用户感兴趣的主体信息,进而间接推断出沉默用户的兴趣。针对微博文本短小稀疏的问题,Yu等<sup>[7]</sup>提出了一种结合用户内部数据的User-LDA主题模型,并将其与在外部语料库训练的词向量结合,得到狄利克雷混合多项式主题模型(ULW-DMM),基于该模型从微博短文本中挖掘有效主题信息,进而实现用户兴趣识别。Qiu等<sup>[8]</sup>提出了一种组合潜在狄利克雷分布模型(CLDA),该模型能够同时学习微博长文本和短文本的主题信息,更准确地挖掘用户的兴趣偏好。此外,Zheng等<sup>[9]</sup>综合考虑微博文本的时效性、互动性,提出了三层兴趣网络模型(TIN-LDA)来动态、分层地挖掘用户兴趣,该模型通过构建兴趣层次关系网络和计算动态兴趣函数来预测微博用户的动态兴趣。

随着深度学习相关技术的快速发展,许多学者开始研究基于深度学习的用户兴趣识别方法。Kang等<sup>[10]</sup>提出了一种基于双向门控循环单元(Bidirectional Gating Recurrent Unit, BiGRU)<sup>[11]</sup>和卷积神经网络(Convolutional Neural Networks, CNN)<sup>[12]</sup>的模型架构,用于预测社交网络用户兴趣,利用Word2Vec词向量模型<sup>[13]</sup>和BiGRU获取句子级文本语义特征,然后输入到CNN模型中进行分类,进而实现用户兴趣识别。Jiang等<sup>[14]</sup>提出了一种基于多尺度时间感知的用户兴趣建模网络(MTIN),设计时间感知掩码网络得到用户兴趣的动态变化趋势,然后引入兴趣掩码网络对用户的兴趣集群进行聚合,从而得到用户兴趣分布。

此外,部分学者将深度学习技术和主题模型结合,多层面、多粒度地从文本中提取深层次的语义信息进行兴趣识别。Du等<sup>[15]</sup>提出了一种基于主题增强卷积神经网络的兴趣识别方法,利用Word2Vec和Labeled LDA主题模型<sup>[16]</sup>分别获取文本语义特征和主题特征,并构建一个双通道CNN模型融合两种特征,进而挖掘微博用户兴趣。Yu等<sup>[17]</sup>提出了一种基于多粒度文本特征表示的微博用户兴趣识别方法,从主题、词序和词汇3个层面构造丰富的文本语义特征表示,然后利用CNN分类模型得到用户的兴趣分布。

### 2.2 融入标签信息的文本分类

在文本分类任务中,大量研究学者都致力于研究如何从文本中提取深层次的语义特征。在这种思路下,文本对应的类别标签信息未能在模型学习的过程中得到充分利用。近年来,部分研究学者开始探索融入类别标签信息的文本分类方法,实验结果表明,类别标签信息能够间接地对模型学习文本特征表示产生影响。

Guo等<sup>[18]</sup>设计了一种标签混淆模型,通过计算文本与标签之间的语义相似度来模拟标签分布,从而捕获两者之间的依赖关系。Mueller等<sup>[19]</sup>提出了标签语义感知的预训练方法(LSAP),将标签语义整合到T5(Text-to-Text Transfer

Transformer, T5)<sup>[20]</sup>预训练语言模型中,实现对标签语义信息的有效利用。Zhang 等<sup>[21]</sup>首先获取标签语义信息的多方面描述,然后从标签嵌入的角度提出基于描述增强的标签嵌入网络模型(DELE),以提高模型文本分类的性能。

此外,Wang 等<sup>[22]</sup>提出了基于标签注意力机制的文本分类模型(LEAM),将词语级文本特征和标签特征共同嵌入到潜在共享空间进行联合学习,得到标签参与的文本语义特征。Gaonkar 等<sup>[23]</sup>基于 LEAM 架构提出标签注意力网络,显式地建模标签语义信息,并利用其引导模型从文本中提取情感信息,从而提高模型在文本情感分类任务中的推理能力。Li 等<sup>[24]</sup>提出了浅层文档级和深层词语级标签注意力机制模块,多层次地学习标签参与的文本语义特征。Liu 等<sup>[25]</sup>提出了一种文本-标签共同注意力机制(CNLE),用于获得文本参与的标签特征和标签参与的文本特征,并同时利用两种特征构建自适应分类器进行分类,该模型在 7 个多类和 2 个多标签数据集上都取得了较好的实验结果。

目前,基于标签注意力机制的研究大多集中于以学术论文摘要文本、新闻文本等为数据集的多标签文本分类任务。然而,相比这类用词表达规范、主题明确的书面文本,微博等社交网络文本具有表达形式、内容和主题自由随意的特点,能否有效地将类别标签信息融入以社交网络文本为数据集的用户兴趣识别中,还需进一步研究验证。

### 3 融入类别标签和主题信息的用户兴趣识别方法

融入类别标签和主题信息的用户兴趣识别方法的整体流程如图 1 所示。该模型主要由 4 个模块组成:语义编码模块、主题特征提取模块、特征融合模块和分类预测模块。其中,语义编码模块使用 BERT 预训练语言模型、BiLSTM 模型和多头自注意力机制获取文本和标签语义特征,并通过标签注意力机制将类别标签信息融入到文本语义特征中;主题特征提取模块负责利用 LDA 主题模型和 Word2Vec 词向量模型从文本中挖掘主题信息;特征融合模块通过引入门控机制使模型能够自适应地选择所需要的信息。

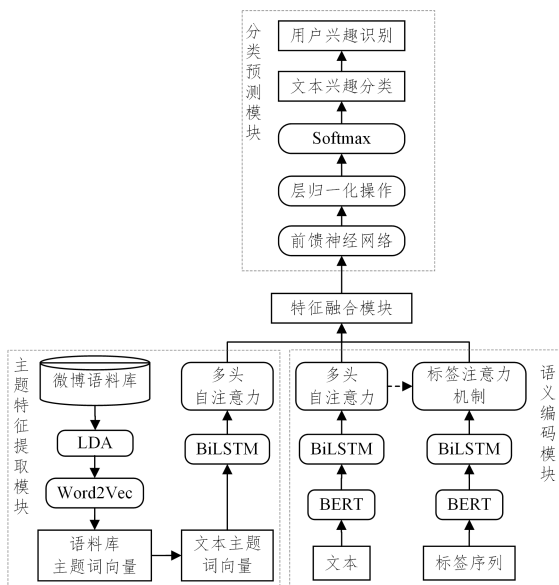


图 1 整体流程图

Fig. 1 Overall flowchart

#### 3.1 语义编码模块

文本语义特征获取过程如下:首先,对用户发表的每条文本进行删除标点符号、停用词过滤、分词等预处理操作,并利用 BERT 模型得到文本词向量表示;然后,将其依次输入到双向长短时记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)<sup>[26]</sup>和多头自注意力机制<sup>[27]</sup>中,进一步融合全局上下文语义并突出关键词语信息,得到文本语义特征。

标签语义特征获取过程与文本编码类似:首先,将整个类别标签序列输入到 BERT 模型得到标签词向量表示;然后,使用 BiLSTM 模型进一步捕捉标签之间的相关性。此处,标签序列为用户文本对应的所有兴趣类别标签的集合。例如,在本文中,标签序列为微博 10 个兴趣类别的标签集合,即{教育、生活、财经、时尚、娱乐、美食、健康、体育、科技、社会}。

文本中每个词语对其类别标签预测的贡献程度不同,类别标签信息的引入能够帮助模型筛选出文本中与其类别标签最相关的词语信息。本文引入标签注意力机制,联合标签语义和文本特征进行交互计算,得到文本中每个词语在各个标签下的注意力权重,进而利用该权重突出关键词语信息。

首先,利用 L2-标准化操作处理文本和标签语义特征,以得到更稳定的特征分布并加快模型的收敛速度,即:

$$X_{\text{norm}} = L2\text{-Norm}(X_{\text{att}}) \quad (1)$$

$$L_{\text{norm}} = L2\text{-Norm}(L_{\text{enc}}) \quad (2)$$

式中, $X_{\text{att}} \in R^{n \times d}$ 和 $L_{\text{enc}} \in R^{k \times d}$ 分别表示由语义编码模块得到的文本和标签特征, $n$ 表示文本单词数, $d$ 表示文本词向量维度, $k$ 表示标签类别数目; $X_{\text{norm}} \in R^{n \times d}$ 和 $L_{\text{norm}} \in R^{k \times d}$ 分别表示标准化后的文本和标签特征。

其次,通过点积注意力操作及 ReLU 激活函数使文本信息和标签信息充分交互,即:

$$W = \text{ReLU}(X_{\text{norm}} \odot L_{\text{norm}}^T) \quad (3)$$

其中, $W = \{\omega_1, \omega_2, \dots, \omega_n\}$ 表示文本中各个词语在各个类别标签下的注意力权重, $\omega_i \in R^k$ 。

然后,通过最大池化操作获取文本各个词语在所有标签下的权重最大值,得到词语-标签注意力权重矩阵 $a = \{a_1, a_2, \dots, a_n\}$ ,即:

$$a_i = \max\_pooling(\omega_i), i \in [1, n] \quad (4)$$

接着,利用 Softmax 函数对权重矩阵 $a$ 进行归一化,得到文本各个词语最终的标签注意力权重矩阵 $\alpha$ ,即:

$$\alpha = \text{softmax}(a) \quad (5)$$

最后,将每个词语的权重与其对应的词语特征向量进行加权求和,得到融入类别标签信息的文本语义特征(简称标签-文本特征),即:

$$X_{\text{label}} = \sum_{i=1}^n \alpha_i \odot x_{\text{att}}^i \quad (6)$$

其中, $X_{\text{label}} \in R^d$ 表示标签-文本特征, $\alpha_i$ 表示文本第 $i$ 个词语的标签注意力权重分数, $x_{\text{att}}^i \in R^d$ 表示文本语义特征 $X_{\text{att}}$ 中第 $i$ 个词语的向量表示。

#### 3.2 主题特征提取模块

社交网络文本具有篇幅短小、形式和内容表达自由随意的特点,仅使用深度学习技术提取得到的文本特征所包含的语义信息通常有限。LDA 等主题模型能够有效地提取文本中潜在的主题信息,而用户兴趣正是通过其对各类主题感兴趣的概率表征的。若能有效提取主题信息并融入到文本特征中,则有助于提高模型兴趣识别的性能。因此,本文引入

LDA 主题模型挖掘文本潜在的主题特征,使模型学习得到




图 2 主题向量生成流程图

Fig. 2 Flowchart of topic vectors generation

首先,统计整个语料库中词语的词频信息并建立词典,利用词袋模型(Bag of Word, BOW)编码得到语料-词频矩阵;然后,将该矩阵输入到 LDA 模型中,得到语料-主题分布和主题-词语分布,进一步得到语料库主题词以及每条文本的主题词;最后,将语料库主题词输入 Word2Vec 模型进行训练,得到主题向量表示。

在得到语料库主题词的向量表示后,将每条文本的主题词与语料库主题词向量进行匹配,得到每条文本的主题词向量表示。然后,进一步将其输入到 BiLSTM 模型和多头自注意力机制中进行语义建模,得到文本主题特征。

### 3.3 特征融合模块

文本潜在主题信息和类别标签信息的加入,能够帮助模型从用户文本中提取得到更加丰富的信息。但是对于不同的文本来说,每种特征对兴趣识别的贡献程度往往并不相同。因此,本文设计特征融合模块,通过引入门控单元,使模型能够自适应地从类别标签信息和主题信息中选择其需要的信息,如图 3 所示。

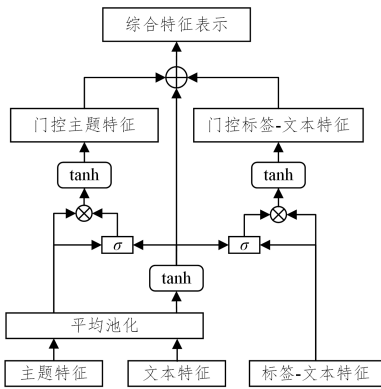


图 3 特征融合原理图

Fig. 3 Schematic diagram of feature fusion

首先,将词组级文本特征和主题特征进行平均池化,得到句子级文本和主题特征,即:

$$X_{\text{avg}} = \text{mean\_pooling}(X_{\text{att}}) \quad (7)$$

$$T_{\text{avg}} = \text{mean\_pooling}(T_{\text{att}}) \quad (8)$$

其中,  $X_{\text{att}} \in R^{n \times d}$  和  $T_{\text{att}} \in R^{t \times d}$  分别表示由语义编码模块和主题特征提取模块得到的文本和主题特征,  $t$  为文本主题词数目;  $X_{\text{avg}} \in R^d$  和  $T_{\text{avg}} \in R^d$  分别表示句子级文本特征和主题特征。

然后,利用 tanh 函数激活句子级文本特征,并利用 Sigmoid 函数计算其与主题特征和标签-文本特征的门控信息融合系数,使模型自适应地决定融入主题信息和类别标签信息的数量,即:

$$g_{\text{label}} = \sigma(W_{\text{label}} \odot X_{\text{label}} + W_{\text{label-text}} \odot X_{\text{act}} + b_{\text{label}}) \quad (9)$$

更加丰富的语义信息,如图 2 所示。

$$g_{\text{topic}} = \sigma(W_{\text{topic}} \odot T_{\text{avg}} + W_{\text{topic-text}} \odot X_{\text{act}} + b_{\text{topic}}) \quad (10)$$

其中,  $g_{\text{label}} \in R^d$  和  $g_{\text{topic}} \in R^d$  表示标签-文本特征  $X_{\text{label}}$  和句子级主题特征  $T_{\text{avg}}$  的门控融合系数,  $X_{\text{act}}$  表示激活后的句子级文本特征,  $W$  和  $b$  为模型可学习的权重参数和偏置项。

最后,将门控信息融合系数与其对应的主题和标签-文本特征相乘,并利用 tanh 函数进一步激活,进而将其与文本语义特征拼接,得到文本-标签-主题综合特征表示,即:

$$L_{\text{label}} = \tanh(g_{\text{label}} \odot X_{\text{label}}) \quad (11)$$

$$T_{\text{topic}} = \tanh(g_{\text{topic}} \odot T_{\text{avg}}) \quad (12)$$

$$X_{\text{con}} = \text{concat}(X_{\text{avg}}, L_{\text{label}}, T_{\text{topic}}) \quad (13)$$

其中,  $L_{\text{label}} \in R^d$  和  $T_{\text{topic}} \in R^d$  表示门控融合后的主题和标签-文本特征,  $X_{\text{con}} \in R^{3d}$  表示将 3 种特征拼接得到的文本-标签-主题综合特征表示。

### 3.4 分类预测模块

在经过上述步骤得到文本-标签-主题综合特征之后,为进一步提取深层次的综合语义特征,首先将其输入到线性层进行维度转换;然后,将其输入到由 2 个线性层和 1 个 ReLU 激活函数组成的前馈神经网络中,并进一步使用层归一化操作得到更加稳定的特征分布,形成最终的综合特征表示,即:

$$X_{\text{final}} = \text{LN}(\text{ReLU}(X_{\text{proj}} \odot W_1 + b_1) \odot W_2 + b_2) \quad (14)$$

其中,  $X_{\text{final}} \in R^d$  表示最终的综合特征,  $X_{\text{proj}} \in R^d$  表示维度转换后的综合特征; LN 表示层归一化操作;  $W$  和  $b$  表示模型可学习的权重参数。

在分类预测阶段,使用 softmax 函数得到用户文本在各个兴趣类别标签上的概率分布,根据概率值确定每条文本的类别标签,即:

$$\hat{y} = \text{Softmax}(W \odot X_{\text{final}} + b) \quad (15)$$

其中,  $\hat{y}$  为用户文本类别标签的预测概率,  $W$  和  $b$  为模型可学习的权重参数。

在整个模型训练过程中,使用交叉熵作为损失函数:

$$\text{Loss} = - \sum_{i=1}^N [y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i)] \quad (16)$$

其中,  $N$  表示兴趣类别数,  $y_i$  为样本的真实类别标签,  $\hat{y}_i$  为样本的预测标签。

最后,统计用户发表的所有文本在各个兴趣类别上的数量,将数量最多的兴趣类别作为用户兴趣表征,从而实现用户兴趣识别。

## 4 实验

### 4.1 数据集

由于用户社交网络数据具有隐私性,目前国内没有能够用于用户兴趣识别任务的公开数据集。因此,本文采集微博用户公开发表的文本数据,并进行人工标注,形成微博用户兴

趣识别数据集。首先,以类别体系覆盖面广、类别之间区分度大为原则,设定了10个微博兴趣类别,包括教育、生活、财经、时尚、娱乐、美食、健康、运动、科技、社会。然后,收集上述10个类别具有代表性的话题评论数据,并由人工检查删除与话题无关的评论,作为部分训练集;最后,采集1000名真实用户发表的文本数据,由人工标注兴趣标签,并从中分别抽取200名用户数据作为训练集补充语料和验证集,剩余的600名用户数据则作为测试集。其中,人工标注规则如下:

1)由10名标注人员对1000名真实用户文本逐一进行兴趣类别标注,在标注过程中丢弃与设定的10种兴趣类别无关的内容;

2)由3名标注人员利用随机抽样等方式对标注数据进行检查,若对某位微博用户抽样检查后发现标注质量较差,则对该用户的所有文本内容重新进行标注,提高数据标注质量;

3)统计每名用户发表的微博文本在各个兴趣类别下的数量,将数量最多的类别确定为该用户的兴趣标签。

最终,各个兴趣类别下训练集、验证集和测试集的微博文本数量如表1所列。

表1 数据集分布  
Table 1 Dataset distribution

兴趣类别	训练集数量	验证集数量	测试集数量
教育	7125	2201	2058
生活	17883	6512	6093
财经	7294	2302	2469
时尚	6094	1966	1889
娱乐	7962	2940	3869
美食	7171	2155	2369
健康	6290	1843	1957
运动	7432	2113	2811
科技	6951	1976	2429
社会	7547	2281	3784
总计	81749	26289	29728

## 4.2 评价指标

### 4.2.1 微博文本分类效果评估

本文通过准确率(Accuracy, Acc)、精确率(Precision, P)、召回率(Recall, R)和F1值(F1-score, F1)来评估微博文本分类的效果。首先,分别计算每种兴趣类别的 $P_i, R_i, F1_i$ 值;然后,取平均值,得到最终的 $P, R$ 和 $F1$ 值。某一兴趣类别的混淆矩阵定义如表2所列。

表2 某一兴趣类别的混淆矩阵

Table 2 Confusion matrix for a particular interest category

真实类别	预测类别 $y_i$	预测类别非 $y_i$
$y_i$	$TP_i$	$FN_i$
非 $y_i$	$FP_i$	$TN_i$

表2中, $TP_i$ 表示文本真实类别和预测类别均为 $y_i$ 的样本数量; $FN_i$ 表示真实类别为 $y_i$ ,但预测类别非 $y_i$ 的样本数量; $FP_i$ 表示预测类别为 $y_i$ ,但真实类别非 $y_i$ 的样本数量; $TN_i$ 表示非 $y_i$ 类别被正确预测的样本数量。

$P_i, R_i, F1_i$ 和 $Acc$ 的定义如下:

$$P_i = \frac{TP_i}{TP_i + FP_i} \quad (17)$$

$$R_i = \frac{TP_i}{TP_i + FN_i} \quad (18)$$

$$F1_i = \frac{2 \times P_i \times R_i}{P_i + R_i} \quad (19)$$

$$Acc = \frac{\sum_{i=1}^K TP_i + TN_i}{\sum_{i=1}^K TP_i + TN_i + FN_i + FP_i} \quad (20)$$

### 4.2.2 用户兴趣识别效果评估

在对微博用户发表的每条文本进行兴趣分类后,统计各个兴趣类别下的文本数量分布,将数量最多的兴趣类别确定为该用户兴趣识别结果;然后,与人工标注的用户真实兴趣类别进行对比,计算准确率 Acc、精确率 P、召回率 R 和 F1 值,以评估用户兴趣识别效果。

## 4.3 基线模型

本文选择以下基线模型进行对比实验。

1)BERT:BERT是由Google团队的Devlin等<sup>[2]</sup>提出的大型预训练语言模型,该模型被广泛用于各种NLP任务中并取得了出色的效果。

2)基于多粒度文本特征表示的微博用户兴趣识别模型(简称MGTF-UIR):MGTF-UIR模型由Yu等<sup>[17]</sup>提出,该模型结合文本原始语义信息、主题信息和外部词向量知识进行兴趣识别。

3)LSAN:LSAN是Xiao等<sup>[28]</sup>提出的基于注意力机制的多标签分类模型,该模型融合文本自注意力和标签注意力机制联合学习文本特征来提高分类性能。

4)LabelAtt:LabelAtt是Xu等<sup>[29]</sup>提出的基于标签嵌入注意力机制的文本分类模型,该模型联合文本词频特征和标签信息来学习与分类任务更相关的文本特征。

其中,由于目前缺乏预训练好的开源中文GloVe模型,因此在使用LabelAtt模型进行对比实验时,采用BERT预训练模型代替GloVe获取文本词向量表示,模型结构其余部分均不变;由于MGTF-UIR模型是将用户所有文本整合为一篇文档后进行兴趣识别,而非对逐条文本进行分类,因此对于该模型仅评估用户兴趣识别效果,不评估微博文本分类效果。

## 4.4 实验参数设置

本文实验参数主要设置如下:

1)综合考虑数据集中各兴趣类别的文本长度,将文本最大长度设定为128。

2)文本和标签词向量维度为768,BiLSTM模型的隐藏层维度设置为384。

3)在主题特征提取方面,采用基于Gibbs采样方法训练LDA模型,其中文档隐含主题数设置为200,每个主题的词语数目为15,主题训练迭代次数为10,超参数 $\alpha$ 设置为 $50/k$ , $\beta$ 为0.01;采用Word2Vec的CBOW模型及负采样方式训练主题向量,主题向量维度设置为64,窗口大小设置为10,学习率为 $1 \times 10^{-4}$ 。

4)在模型优化方面,使用AdamW优化器优化模型,并针对不同的参数设置不同的学习率:针对BERT模型参数,学习率设置为 $5 \times 10^{-6}$ ;针对其他参数,学习率设置为 $1 \times 10^{-5}$ 。此外,为缓解模型过拟合现象,将BiLSTM的dropout设置为0.3,并在维度转换层设置dropout为0.5。

## 4.5 对比实验

为评估本文方法对于用户兴趣识别任务的有效性,本文使用上述构建的微博数据集与4个基线模型进行对比实验,其中每条微博文本的兴趣类别分类效果评估如表3所列,用户兴趣识别效果评估如表4所列,表中各个兴趣类别的最优

结果均以粗体表示。

根据表 3 可知,本文方法在 10 个兴趣类别的微博文本分类中均取得了最优性能。具体来说,与微调的 BERT 模型相比,该方法的 Acc 和 F1 值分别提高了 2.56% 和 2.66%,这说明类别标签和主题信息的引入能够提高微博文本兴趣分类的效果。同时,相比基于标签注意力机制的 LSAN 和 LabelAtt 模型,本文方法的 Acc 和 F1 值分别提升了 3.60%, 3.42% 和 2.00%, 1.80%, 这说明与只引入类别标签信息的模型相比,同时考虑类别标签和主题信息能够使模型从文本

中学习得到更丰富的语义信息。此外,相比 BERT 模型, LabelAtt 模型的 Acc 和 F1 值分别提升了 0.56% 和 0.86%, 这也说明了标签信息的引入能够提升微博文本分类的效果。并且,相比 LSAN 模型,本文方法、BERT 和 LabelAtt 3 种模型都取得了更好的实验结果,这是由于 LSAN 使用 Word2Vec 训练文本词向量,而其他 3 种模型均使用预训练好的 BERT 模型来得到文本原始语义特征,这表明使用 BERT 预训练模型能够得到更丰富、准确的文本原始语义特征,从而提升微博文本分类的效果。

表 3 微博文本分类对比实验结果

Tabel 3 Comparative experimental results of Weibo text classification

兴趣类别	Ours			BERT			LSAN			LabelAtt		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
教育	80.49	<b>86.94</b>	<b>83.59</b>	<b>92.31</b>	68.24	78.47	82.66	78.24	80.39	84.91	79.80	82.27
生活	<b>84.87</b>	79.55	<b>82.12</b>	79.31	80.30	79.80	78.28	77.28	77.78	76.90	<b>81.47</b>	79.12
财经	<b>92.55</b>	87.57	<b>89.99</b>	90.65	86.80	88.68	86.70	87.40	87.05	88.02	<b>89.87</b>	88.94
时尚	<b>94.81</b>	91.85	<b>93.30</b>	84.54	<b>93.97</b>	90.10	87.76	88.78	88.26	90.80	92.48	91.63
娱乐	88.35	<b>92.74</b>	<b>90.49</b>	87.58	88.42	88.00	85.41	87.28	86.34	<b>90.45</b>	87.36	88.88
美食	<b>92.58</b>	92.19	<b>92.39</b>	91.33	90.29	90.81	90.15	87.34	88.72	89.84	<b>92.53</b>	91.16
健康	81.38	<b>81.50</b>	<b>81.44</b>	<b>81.76</b>	73.74	77.54	78.66	78.54	78.60	79.73	78.39	79.05
运动	<b>94.85</b>	<b>94.31</b>	<b>94.58</b>	91.94	93.70	92.81	93.38	91.28	92.32	93.60	93.10	93.35
科技	89.14	<b>93.91</b>	<b>91.46</b>	<b>91.25</b>	87.61	89.39	89.77	89.58	89.68	90.22	89.67	89.94
社会	79.53	81.84	<b>80.67</b>	72.26	<b>84.28</b>	77.81	74.66	78.73	76.64	<b>79.88</b>	75.63	77.70
平均	<b>87.85</b>	<b>88.24</b>	<b>88.00</b>	86.49	84.73	85.34	84.74	84.45	84.58	86.43	86.03	86.20
Acc		<b>87.22</b>			84.66			83.62			85.22	

根据表 4 可知,在用户兴趣识别效果评估中,本文方法的 Acc 和 F1 值分别达到了 94.67% 和 95.13%。同时,除社会类外,该方法在其他 9 个兴趣类别的 F1 值均达到 90% 以上,并在 5 个兴趣类别中取得了最高的 F1 值,其中时尚类和美食类的 F1 值达到 100%。观察测试数据集发现,与其他兴趣类别相比,这两类用户发表的微博文本几乎每条都与其对应的时尚或美食类别相关。例如,某位美食类用户,其发表的 50 条微博文本中,有 47 条是与美食内容相关的文本,这巨大的文本数量优势使得模型易于将该用户的兴趣确定为美食类。

在这种情况下,这两类用户兴趣识别的 F1 值达到了 100%。

此外,相比使用 Word2Vec 词嵌入模型来获取文本原始语义特征并只引入主题信息的 MGTf-UIR 模型,本文方法的 Acc 和 F1 值分别提升了 12.34% 和 10.57%, 这表明 BERT 预训练语言模型和类别标签信息的引入有助于提高实验性能。此外,虽然 LSAN 和 LabelAtt 取得了与本文方法相近的 Acc 和 F1 值,但本文方法在细粒度的微博文本分类中取得了更好的性能。以上实验结果均说明,本文方法能够有效地引入类别标签和主题信息,从而实现更准确的用户兴趣识别。

表 4 用户兴趣识别对比实验结果

Tabel 4 Comparative experimental results of user interest recognition

兴趣类别	Ours			BERT			MGTf-UIR			LSAN			LabelAtt		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1	P	R	F1
教育	95.12	<b>97.50</b>	<b>96.30</b>	<b>100</b>	82.50	90.41	90.00	90.00	97.37	92.50	94.87	100	92.50	96.10	
生活	<b>98.13</b>	89.74	<b>93.75</b>	92.11	89.74	90.91	85.00	58.12	69.04	94.64	90.60	92.58	90.32	<b>95.73</b>	82.95
财经	98.18	96.43	97.30	98.15	94.64	96.36	91.67	98.21	94.83	<b>98.21</b>	<b>98.21</b>	<b>98.21</b>	98.21	98.21	98.21
时尚	<b>100</b>	<b>100</b>	<b>100</b>	100	100	100	97.67	97.67	97.67	100	100	100	100	100	100
娱乐	92.59	<b>94.94</b>	<b>93.75</b>	94.74	91.14	92.90	74.39	77.22	75.78	92.31	91.14	91.72	<b>97.18</b>	87.34	92.00
美食	<b>100</b>	<b>100</b>	<b>100</b>	100	100	100	89.13	93.18	91.11	97.73	97.73	97.73	97.78	100	98.88
健康	87.18	<b>97.14</b>	91.89	93.94	88.57	91.18	62.26	94.29	75.00	<b>94.44</b>	97.14	<b>95.77</b>	91.89	97.14	<b>94.44</b>
运动	93.22	<b>96.49</b>	94.83	<b>96.43</b>	94.74	95.58	92.16	82.46	87.04	94.74	94.74	94.74	94.83	96.49	<b>95.65</b>
科技	93.65	<b>98.33</b>	95.93	96.61	95.00	95.80	95.00	95.00	95.00	96.72	98.33	<b>97.52</b>	95.08	96.67	95.87
社会	88.24	86.96	87.59	75.00	<b>95.65</b>	84.08	63.53	78.26	70.13	85.33	92.75	88.89	<b>89.71</b>	88.41	<b>89.05</b>
平均	94.63	<b>95.75</b>	95.13	94.70	93.20	93.72	84.08	86.44	84.56	95.15	95.31	95.20	<b>95.50</b>	95.25	<b>95.32</b>
Acc		<b>94.67</b>			93.00			82.33			94.50			94.67	

#### 4.6 消融实验

为进一步验证主题信息和类别标签信息的加入对于用户兴趣识别任务的作用,同时验证本文方法各个模块的有效性,本文设置以下几组消融实验:1) 移除主题特征得到 Ours(-topic) 模型,以验证引入主题信息的有效性; 2) 移除类别标签特征得到 Ours(-label) 模型,以验证类别

标签信息对兴趣识别任务的帮助; 3) 同时移除主题特征和类别标签特征,得到 Ours(text) 模型,以验证同时引入主题和类别标签信息的有效性; 4) 将特征融合方式由门控机制改为直接拼接,得到 Ours(-gate) 模型,以验证引入门控机制能否帮助模型自适应地筛选对任务更有用的信息。

表5 微博文本分类消融实验结果

Table 5 Ablation experiment results of Weibo text classification

兴趣类别	Ours			Ours(-topic)			Ours(-label)			Ours(text)			Ours(-gate)		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1	P	R	F1
教育	80.49	86.94	<b>83.59</b>	81.33	85.92	83.56	84.93	82.95	83.93	72.10	<b>91.02</b>	80.46	<b>86.81</b>	82.81	84.76
生活	<b>84.87</b>	79.55	<b>82.12</b>	83.24	79.14	81.13	83.36	78.61	80.92	84.77	73.82	78.92	80.65	<b>82.58</b>	81.61
财经	<b>92.55</b>	87.57	89.99	91.74	88.58	90.13	91.06	<b>89.51</b>	<b>90.28</b>	91.81	88.13	89.94	92.01	88.58	90.26
时尚	<b>94.81</b>	91.85	<b>93.30</b>	83.35	<b>96.98</b>	89.65	90.55	93.86	92.18	93.66	89.20	91.38	94.01	92.17	93.08
娱乐	88.35	<b>92.74</b>	<b>90.49</b>	90.21	90.26	90.23	86.00	92.53	89.14	93.00	86.56	89.67	<b>94.31</b>	85.22	89.53
美食	92.58	<b>92.19</b>	<b>92.39</b>	92.62	91.14	91.87	<b>93.34</b>	89.87	91.57	92.95	90.21	91.56	91.67	91.98	91.82
健康	81.38	<b>81.50</b>	<b>81.44</b>	<b>84.93</b>	73.74	78.94	83.10	75.63	79.19	82.54	77.57	79.98	80.62	78.85	79.72
运动	94.85	94.31	<b>94.58</b>	95.34	92.39	93.84	<b>96.47</b>	81.28	93.80	91.68	<b>95.30</b>	93.46	94.89	93.77	94.33
科技	89.14	<b>93.91</b>	<b>91.46</b>	<b>95.35</b>	87.77	91.40	90.31	91.72	91.01	94.25	86.33	90.12	89.68	92.30	90.97
社会	<b>79.53</b>	81.84	<b>80.67</b>	75.41	86.05	80.38	74.36	83.22	78.54	69.89	<b>88.08</b>	77.94	75.57	84.51	79.79
平均	87.85	<b>88.24</b>	<b>88.00</b>	87.35	87.19	87.11	87.35	86.92	87.06	86.67	86.62	86.34	<b>88.02</b>	87.28	87.59
Acc		<b>87.22</b>			86.41			86.15			85.26			86.65	

表5所列结果表明,与仅使用文本语义信息的Ours(text)模型相比,本文方法的Acc和F1值分别提升了1.96%和1.66%,这表明引入主题信息和类别标签信息能够提升用户兴趣识别的效果。同时,实验表明单独引入主题和类别标签信息的实验性能均不如本文方法,其中,Ours(-label)模型的Acc和F1值分别下降了1.07%和0.94%,Ours(-topic)模型分别下降了0.81%和0.89%,这说明同时融合类别标签和主题信息能够使模型从文本中学习到更加丰富的信息,从而提高用户兴趣识别的性能。此外,在特征融合阶段,将特征融合方式由门控机制改为直接拼接后,Ours(-gate)模型的Acc和F1值分别下降了0.57%和0.41%,这说明门控机制的引

入在一定程度上能够使模型在训练的过程中自适应地筛选出对用户兴趣识别任务更有用的信息,并过滤掉与任务无关的噪声信息。

表6所列结果表明,与本文方法相比,取消门控机制的Ours(-gate)模型的Acc和F1值分别下降0.5%和0.24%,取消主题信息的Ours(-topic)模型分别下降1.34%和1.14%,取消类别标签信息的Ours(-label)模型分别下降0.34%和0.14%,而仅使用文本语义信息的Ours(text)模型Acc和F1指标值分别下降2.67%和2.09%,以上数据均说明本文引入的各个模块能帮助模型得到更丰富的文本特征,从而提高用户兴趣识别的效果。

表6 用户兴趣识别消融实验结果

Table 6 Ablation experiment results of user interest recognition

兴趣类别	Ours			Ours(-topic)			Ours(-label)			Ours(text)			Ours(-gate)		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1	P	R	F1
教育	95.12	<b>97.50</b>	96.30	<b>97.50</b>	97.50	<b>97.50</b>	97.50	97.50	97.50	86.67	97.50	91.76	97.44	95.00	96.20
生活	<b>98.13</b>	89.74	93.75	95.61	93.16	94.37	96.36	90.60	93.39	96.04	82.91	88.99	94.83	<b>94.02</b>	<b>94.42</b>
财经	98.18	<b>96.43</b>	97.30	96.36	94.64	95.50	<b>100</b>	96.43	<b>98.18</b>	100	96.43	98.18	98.18	96.43	97.30
时尚	<b>100</b>	<b>100</b>	<b>100</b>	100	100	100	100	100	100	100	97.67	98.82	100	100	100
娱乐	92.59	<b>94.94</b>	<b>93.75</b>	93.24	87.34	90.20	91.25	92.41	91.82	94.44	86.08	90.07	<b>95.71</b>	84.81	89.93
美食	<b>100</b>	<b>100</b>	<b>100</b>	100	100	100	97.73	97.73	97.73	97.78	100.00	98.88	100	100	100
健康	87.18	<b>97.14</b>	91.89	93.75	85.71	89.55	<b>94.12</b>	91.43	92.75	91.43	91.43	91.43	91.89	97.14	<b>94.44</b>
运动	93.22	<b>96.49</b>	<b>94.83</b>	96.36	92.98	94.64	<b>96.36</b>	92.98	94.64	94.64	92.98	93.81	96.36	92.98	94.67
科技	93.65	98.33	95.93	96.61	95.00	95.80	96.67	<b>96.67</b>	<b>96.67</b>	<b>98.25</b>	93.33	95.73	96.67	96.67	96.67
社会	<b>88.24</b>	86.96	<b>87.59</b>	75.00	91.30	82.35	81.25	94.20	87.25	72.04	<b>97.10</b>	82.72	79.01	92.75	85.33
平均	94.63	<b>95.75</b>	<b>95.13</b>	94.44	93.76	93.99	<b>95.12</b>	94.99	94.99	93.13	93.54	93.04	95.01	94.98	94.89
Acc		<b>94.67</b>			93.33			94.33			92.00			94.17	

**结束语** 本文提出了一种融入类别标签和主题信息的用户兴趣识别方法,通过LDA主题模型、标签注意力机制和门控机制来综合考虑文本潜在的主题信息和类别标签信息对模型学习文本特征的帮助。实验结果表明,相比不引入类别标签和主题信息或仅引入其中之一的模型,同时引入类别标签和主题信息能够使模型从文本中学习得到更加丰富的信息,从而提高兴趣识别性能。然而,社交网络中还包含用户社交关系和行为等多种用户特征,仅利用用户发表的微博文本内容难以全面地挖掘用户兴趣。因此,下一步的工作重点是结合知识图谱相关技术构建用户社交关系和行为特征图,考虑多种用户特征,更深层次地挖掘用户兴趣,进而实现更精准的信息推荐。

## 参考文献

- [1] BLEI D M, NG A Y, JORDAN M I. Latent dirichlet allocation [J]. Journal of Machine Learning Research, 2003, 3 (Jan): 993-1022.
- [2] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [C]// Proceedings of the 57th Conference of the North American Chapter of the Association for Computational Linguistics. Minneapolis: Association for Computational Linguistics, 2019: 4171-4186.
- [3] ZHAO Z, CHENG Z, HONG L, et al. Improving user topic interest profiles by behavior factorization [C]// Proceedings of the

- 24th International Conference on World Wide Web. Florence: ACM, 2015: 1406-1416.
- [4] ZHONG Z M, GUAN Y, HU Y, et al. Mining user interests on microblog based on profile and content[J]. Journal of Software, 2017, 28(2): 278-291.
- [5] RAJENDRAN D P D, SUNDARRAJ R P. Using topic models with browsing history in hybrid collaborative filtering recommender system: Experiments with user ratings[J]. International Journal of Information Management Data Insights, 2021, 1(2): 100027.
- [6] HE J, LIU H, ZHENG Y, et al. Bi-labeled LDA: Inferring interest tags for non-famous users in social network[J]. Data Science and Engineering, 2020, 5: 27-47.
- [7] YU J, QIU L. ULW-DMM: An effective topic modeling method for microblog short text[J]. IEEE Access, 2018, 7: 884-893.
- [8] QIU L, JIA Y. CLDA: An effective topic model for mining user interest preference under big data background[J]. Complexity, 2018, 2018: 1-10.
- [9] ZHENG W, GE B, WANG C. Building a TIN-LDA model for mining microblog users' interest [J]. IEEE Access, 2019, 7: 21795-21806.
- [10] KANG J, CHOI H S, LEE H. Deep recurrent convolutional networks for inferring user interests from social media[J]. Journal of Intelligent Information Systems, 2019, 52: 191-209.
- [11] CHO K, VAN M B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha: EMNLP, 2014: 1724-1734.
- [12] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha: EMNLP, 2014: 1746-1751.
- [13] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C]//Proceedings of the 26th International Conference on Neural Information Processing Systems. Nevada: Curran Associates Inc, 2013: 3111-3119.
- [14] JIANG H, WANG W, WEI Y, et al. What aspect do you like: Multi-scale time-aware user interest modeling for micro-video recommendation[C]//Proceedings of the 28th ACM International conference on Multimedia. New York: ACM, 2020: 3487-3495.
- [15] DU Y M, ZHANG W N, LIU T. Topic augmented convolutional neural network for user interest recognition[J]. Journal of Computer Research and Development, 2018, 55(1): 188-197.
- [16] RAMAGE D, HALL D, NALLAPATI R, et al. Labeled LDA: A supervised topic model for credit attribution in multi-labeled corpora[C]//Proceedings of the 2009 Conference on Empirical Methods in Natural Language Processing. Singapore: EMNLP, 2009: 248-256.
- [17] YU Y Q, LI B C. Microblog user interest recognition based on multi-granularity text Feature representation [J]. Computer Science, 2021, 48(12): 219-225.
- [18] GUO B, HAN S, HAN X, et al. Label confusion learning to enhance text classification models[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2021: 12929-12936.
- [19] MUELLER A, KRONE J, ROMEO S, et al. Label Semantic Aware Pre-training for Few-shot Text Classification[J/OL]. Eprint Arxiv, 2022. <https://arxiv.org/abs/2204.07128>.
- [20] RAFFEL C, SHAZEER N, ROBERTS A, et al. Exploring the limits of transfer learning with a unified text-to-text transformer [J]. The Journal of Machine Learning Research, 2020, 21(1): 5485-5551.
- [21] ZHANG K, WU L, LV G, et al. Description-Enhanced Label Embedding Contrastive Learning for Text Classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023: 1-14.
- [22] WANG G Y, LI C Y, WANG W L, et al. Joint embedding of words and labels for text classification[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Melbourne: Association for Computational Linguistics, 2018: 2321-2331.
- [23] GAONKAR R, KWON H, BASTAN M, et al. Modeling label semantics for predicting emotional reactions[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Dublin: Association for Computational Linguistics, 2020: 1087-1094.
- [24] LI F F, SU P Z, DUAN J W, ZHANG S C, et al. Multi-label text classification with enhancing multi-granularity information relations [J/OL]. Journal of Software. <http://www.jos.org.cn/1000-9825/6802.html>.
- [25] LIU M, LIU L, CAO J, et al. Co-attention network with label embedding for text classification [J]. Neurocomputing, 2022, 471: 61-69.
- [26] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30: 1-11.
- [28] XIAO L, HUANG X, CHEN B, et al. Label-specific document representation for multi-label text classification[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Hong Kong: Association for Computational Linguistics, 2019: 466-475.
- [29] XU Y M, FAN Z W, CAO H. A multi-task text classification model based on label embedding of attention mechanism[J]. Data Analysis and Knowledge Discovery, 2022, 6(2/30): 105-116.



**KANG Zhiyong**, born in 1998, postgraduate. His main research interests include natural language processing, user portraits and personalized recommendation.



**LI Bicheng**, born in 1970, Ph.D, professor, Ph.D supervisor. His main research interests include intelligent information processing, network ideological security, network public opinion monitoring and guidance, big data analysis and mining.