

文章编号: 1003-0077 (2016) 00-0000-00

一种针对短文本的主题情感混合模型*

谢珺, 郝洁, 苏婧琼, 邹雪君, 李思宇

(太原理工大学 信息工程学院, 山西省 晋中市 030600)

摘要: 主题情感混合模型可以同时提取语料的主题信息和情感倾向。针对短文本特征稀疏的问题, 主题情感联合分析方法较少的问题, 本文提出了 BJSTM 模型 (Biterm Joint Sentiment Topic Model), 在 BTM 模型 (Biterm Topic Model) 的基础上, 增加情感层的设置, 从而形成“情感-主题-词汇”的三层贝叶斯模型。对每个双词的情感和主题进行采样, 从而对整个语料的词共现关系建模, 一定程度上克服了短文本的稀疏性。实验表明, BJSTM 模型在无监督情感分类和主题提取方面都有不错表现。

关键词: 主题情感混合模型; 情感分类; BTM

中图分类号: TP391

文献标识码: A

A Topic and Sentiment Unification Model for Short Texts

Xie Jun, Hao Jie, Su Jingqiong, Zou Xuejun, Li Siyu

(Information Engineering College, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China)

Abstract: The topic and sentiment unification model can efficiently detect topics and emotions for the given corpus. Faced with the sparsity of short texts and the lack of sentiment/topic analysis methods, this paper proposes a novel way called Biterm Joint Sentiment Topic Model (BJSTM). A sentiment layer is added to Biterm Topic Model, thus a three-layer Bayesian model of “sentiment-topic-term” is formed. By sampling the sentiment and topic of each biterm, BJSTM could depict the word co-occurrence of the whole corpus and overcome the sparsity of short texts to some extent. The experiments show that BJSTM gets better results in sentiment classification as well as topic extraction.

Key words: the topic and sentiment unification model; sentiment classification; BTM

1 引言

随着博客、微博、微信等自媒体的流行, 网络购物的盛行和网购评价体系的不断完善, 互联网中, 对事件的观点、对物品的评价等具有情感倾向的文本越来越多。这些信息对于政府部门的舆情监控、企业的经营决策和个人的购买决定, 都起着至关重要的作用。

主题情感混合模型由于可以同时提取语料的主题信息和情感倾向而在文本情感分析领域得到了越来越广泛的关注, 并被应用于情感信息抽取和情感分类等领域。有学者指出, 互联网评论文本的长度与数量呈幂律关系^[1], 即短文本占绝大多数, 这些文本特征稀疏, 很多传统的文本分析方法无法直接使用, 目前针对短文本的主题情感联合分析方法较少。

Lin 等人提出了 LSM 模型 (Latent Sentiment Model), 该模型将情感作为主题的特例, 认为文档中词汇的分布与情感有关, 从而实现了文档的无监督情感分类, 但无法识别出更细粒度的主题信息^[2]。TSM 模型 (Topic Sentiment Mixture Model) 能够无监督地抽取文档的主题和情感信息, 但 TSM 模型以 PLSA 算法 (Probability Latent Semantic Analysis) 为基础,

* 收稿日期: 定稿日期:

基金项目: 山西省回国留学人员科研资助项目 (2015-045, 2013-033); 山西省留学回国人员科技活动择优资助项目 (2013 年度); 山西省自然科学基金 (2014011018-2)

作者简介: 谢珺 (1979—), 女, 副教授, 主要研究领域为粒计算、粗糙集、数据挖掘和智能信息处理; 郝洁 (1992—), 女, 硕士研究生, 主要研究领域为自然语言处理、粗糙集; 苏婧琼 (1992—), 女, 硕士研究生, 主要研究领域为自然语言处理、粒计算; 邹雪君 (1991—), 女, 硕士研究生, 主要研究领域为自然语言处理、粗糙集; 李思宇 (1992—), 男, 硕士研究生, 主要研究领域为自然语言处理、粗糙集。

受其限制容易产生过拟合^[3]。ASUM 模型 (Aspect and sentiment unification model) 建立了“句子-主题-词”的三层模型, ASUM 以 LDA 为基础, 泛化能力较强, 但该模型认为一个句子中的所有词均属于同一方面, 该假设过于严格^[4]。JST 模型 (Joint Sentiment/Topic model) 是一种可以无监督地提取文档主题和情感信息的四层贝叶斯网络, 和以上提到的这些方法类似, 主要考虑单个文档内的词共现信息, 更适用于长文本主题情感联合分析^[5]。熊蜀峰提出了面向短文本的情感主题模型 SSTM (Short-text sentiment-topic model), 提升了文档情感分类精度, 但这种方法基于每个主题下均有正负两种情感的假设, 与实际情况不完全相符, 该算法在推断文档情感时, 对每个词情感的二值化也影响到情感分类的精度^[6]。

本文在双词话题模型 (Biterm Topic Model, BTM)^[7]的基础上, 增加情感层的设置, 从而形成“情感-主题-词汇”的三层贝叶斯模型。不仅可以无监督地提取语料的主题信息和情感倾向, 由于捕捉到语料级别丰富的词共现关系, 也在一定程度上克服了单个短文本特征的稀疏性。

2 背景知识——BTM 模型

BTM 模型^[7]是一种针对于短文本的主题模型, 通过直接对语料中的双词进行建模, 从而避免了文本过短而造成的内容稀疏。该模型的主题学习过程无需借助任何外部数据, 这也是目前首个通用的短文本主题模型。

对于短文本语料 $\mathbf{D} = \{d_1, d_2, \dots, d_{N_d}\}$, 对应的双词集合为 $\mathbf{B} = \{b_1, b_2, \dots, b_{N_b}\}$, 其中,

$b_i = (w_{i,1}, w_{i,2})$, $z \in [1, K]$ 为一个主题, K 为主题数目, θ 表示语料的主题分布, 服从先验参数为 α 的狄利克雷分布, φ 表示主题的词分布, 服从先验参数为 β 的狄利克雷分布。

算法 1. BTM 模型文档产生过程.

Step 1 对语料采样一个主题分布 $\theta \sim \text{Dir}(\alpha)$

Step 2 对每个主题 $k \in [1, K]$

采样一个词汇分布 $\varphi_k \sim \text{Dir}(\beta)$

Step 3 对每个双词 $b_i \in \mathbf{B}$

采样一个主题 $z_i \sim \text{Mult}(\theta)$

根据主题, 独立采样两个词 $w_{i,1}, w_{i,2} \sim \text{Mult}(\varphi_{z_i})$




图 1 BTM 图模型

在 BTM 模型中, 隐含变量 θ 和 φ 可按公式(1)和公式(2)估计:

$$\varphi_{k,w} = \frac{n_{w|k} + \beta}{n_{\cdot|k} + W\beta} \quad (1)$$

$$\theta_k = \frac{n_k + \alpha}{n_B + K\alpha} \quad (2)$$

其中， $n_{w|k}$ 表示词 w 被分配到主题 k 的次数， $n_{\cdot|k} = \sum_{w=1}^W n_{w|k}$ ， n_k 表示主题为 k 的双词个数， n_B 为双词总数。

在 BTM 建模中，没有涉及文档的产生过程，故通过文档中双词的主题来估计文档的话题比例。假设文档 d 包含 N_d 个双词 $\{b_{i_j} | j \in [1, N_d]\}$ ，则该文档中主题 k 的比例为：

$$\begin{aligned} p(z=k|d) &= \sum_{j=1}^{N_d} p(z|b_{i_j})p(b_{i_j}|d) \\ &= \sum_{j=1}^{N_d} \frac{\theta_k \phi_{k,w_{i_j},1} \phi_{k,w_{i_j},2}}{\sum_k \theta_k \phi_{k,w_{i_j},1} \phi_{k,w_{i_j},2}} \cdot \frac{n_d(b_{i_j})}{N_d} \end{aligned} \quad (3)$$

其中， $n_d(b_{i_j})$ 表示文档 d 中的双词 b_{i_j} 出现的次数。

3 BJSTM 模型

3.1 模型结构

对于短文本语料 $\mathbf{D} = \{d_1, d_2, \dots, d_{N_D}\}$ ，对应的双词集合为 $\mathbf{B} = \{b_1, b_2, \dots, b_{N_B}\}$ ，其中，

$b_i = (w_{i,1}, w_{i,2})$ ， $l \in [1, S]$ 为一个情感， $z \in [1, K]$ 为一个主题， $\boldsymbol{\pi}$ 表示语料的情感分布，服从先验参数为 γ 的狄利克雷分布， $\boldsymbol{\theta}$ 表示语料的主题分布，服从先验参数为 α 的狄利克雷分布， $\boldsymbol{\Phi}$ 表示主题的词分布，服从先验参数为 β 的狄利克雷分布。




图 2 BJSTM 图模型

图 2 为 BJSTM 的图模型，按本模型的假设，一篇文档的生成过程见算法 2：

算法 2. BJSTM 模型文档产生过程.

Step 1 对整个语料采样一个情感分布 $\boldsymbol{\pi} \sim \text{Dir}(\gamma)$

Step 2 对每个情感 $l \in [1, S]$

采样一个主题分布 $\boldsymbol{\theta}_l \sim \text{Dir}(\alpha)$

Step 3 对每个主题 $k \in [1, K]$

对每个情感 $l \in [1, S]$

采样一个词汇分布 $\boldsymbol{\phi}_{k,l} \sim \text{Dir}(\beta)$

Step 4 对每个双词 $b_i \in \mathbf{B}$

采样一个情感 $l_i \sim \text{Mult}(\boldsymbol{\pi})$

根据情感 l_i ，采样一个主题 $z_i \sim \text{Mult}(\boldsymbol{\theta}_{l_i})$

根据情感 l_i 和主题 z_i ，独立采样两个词 $w_{i,1}, w_{i,2} \sim \text{Mult}(\boldsymbol{\varphi}_{z_i l_i})$

按上述文档生成过程，若已知 $\boldsymbol{\pi}$ ， $\boldsymbol{\theta}$ ， $\boldsymbol{\Phi}$ ，双词 b_i 的产生概率为：

$$\begin{aligned} P(b_i | \boldsymbol{\pi}, \boldsymbol{\theta}, \boldsymbol{\Phi}) &= \sum_{s=1}^S \sum_{k=1}^K (P(l_i = s | \boldsymbol{\pi}_s) P(z_i = k | l_i = s, \boldsymbol{\theta}_{sk}) \cdot \\ &\quad P(w_{i,1} | l_i = s, z_i = k, \boldsymbol{\varphi}_{skw_{i,1}}) P(w_{i,2} | l_i = s, z_i = k, \boldsymbol{\varphi}_{skw_{i,2}})) \\ &= \sum_{s=1}^S \sum_{k=1}^K \pi_s \theta_{sk} \varphi_{skw_{i,1}} \varphi_{skw_{i,2}} \end{aligned} \quad (4)$$

给定参数 α ， β ， γ ，对整个双词集合，似然函数为：

$$P(\mathbf{B} | \alpha, \beta, \gamma) = \prod_{i=1}^{N_B} \int \int \int \sum_{s=1}^S \sum_{k=1}^K \pi_s \theta_{sk} \varphi_{skw_{i,1}} \varphi_{skw_{i,2}} d\boldsymbol{\pi} d\boldsymbol{\theta} d\boldsymbol{\Phi} \quad (5)$$

3.2 参数估计

本文通过吉布斯采样估计 $\boldsymbol{\pi}$ ， $\boldsymbol{\theta}$ ， $\boldsymbol{\Phi}$ 。采样的后验分布为：

$$P(l_i = s, z_i = k | \mathbf{I}_{-i}, \mathbf{z}_{-i}, \mathbf{B}) = \frac{P(\mathbf{I}, \mathbf{z}, \mathbf{B})}{P(\mathbf{I}_{-i}, \mathbf{z}_{-i}, \mathbf{B})} \propto \frac{P(\mathbf{B} | \mathbf{I}, \mathbf{z}) P(\mathbf{z} | \mathbf{I}) P(\mathbf{I})}{P(\mathbf{B}_{-i} | \mathbf{I}_{-i}, \mathbf{z}_{-i}) P(\mathbf{z}_{-i} | \mathbf{I}_{-i}) P(\mathbf{I}_{-i})} \quad (6)$$

其中，

$$\begin{aligned} P(\mathbf{I}) &= \int P(\mathbf{I} | \boldsymbol{\pi}) P(\boldsymbol{\pi}) d\boldsymbol{\pi} \\ &= \int \left(\prod_{i=1}^{N_B} P(l_i | \boldsymbol{\pi}) \right) P(\boldsymbol{\pi}) d\boldsymbol{\pi} \\ &= \int \prod_{s=1}^S \pi_s^{n_s} \cdot \frac{\Gamma(S\gamma)}{\Gamma(\gamma)^S} \prod_{s=1}^S \pi_s^{\gamma-1} d\boldsymbol{\pi} \\ &= \int \frac{\Gamma(S\gamma)}{\Gamma(\gamma)^S} \prod_{s=1}^S \pi_s^{n_s + \gamma - 1} d\boldsymbol{\pi} \\ &= \frac{\Gamma(S\gamma)}{\Gamma(\gamma)^S} \frac{\prod_{s=1}^S \Gamma(n_s + \gamma)}{\Gamma(N_B + S\gamma)} \end{aligned} \quad (7)$$

类似地，可以得到：

$$P(\mathbf{z} | \mathbf{I}) = \left(\frac{\Gamma(K\alpha)}{\Gamma(\alpha)^K} \right)^S \prod_{s=1}^S \frac{\prod_{k=1}^K \Gamma(n_{sk} + \alpha)}{\Gamma(n_{s\cdot} + K\alpha)} \quad (8)$$

$$P(\mathbf{B} | \mathbf{I}, \mathbf{z}) = \left(\frac{\Gamma(W\beta)}{\Gamma(\beta)^W} \right)^{SK} \prod_{k=1}^K \prod_{s=1}^S \frac{\prod_{w=1}^W \Gamma(n_{skw} + \beta)}{\Gamma(n_{sk\cdot} + W\beta)} \quad (9)$$

$$P(\mathbf{I}_{-i}) = \frac{\Gamma(S\gamma)}{\Gamma(\gamma)^S} \frac{\prod_{s=1}^S \Gamma(n_{-i,s} + \gamma)}{\Gamma(N_{-i,B} + S\gamma)} \quad (10)$$

$$P(\mathbf{z}_{-i} | \mathbf{I}_{-i}) = \left(\frac{\Gamma(K\alpha)}{\Gamma(\alpha)^K} \right)^S \prod_{s=1}^S \frac{\prod_{k=1}^K \Gamma(n_{-i,sk} + \alpha)}{\Gamma(n_{-i,s} + K\alpha)} \quad (11)$$

$$P(\mathbf{B}_{-i} | \mathbf{z}_{-i}, \mathbf{l}_{-i}) = \left(\frac{\Gamma(W\beta)}{\Gamma(\beta)^W} \right)^{SK} \prod_{k=1}^K \prod_{s=1}^S \frac{\prod_{w=1}^W \Gamma(n_{-i,skw} + \beta)}{\Gamma(n_{-i,sk\cdot} + W\beta)} \quad (12)$$

其中, n_s 表示被分配给情感 s 的双词数目, $N_B = \sum_{s=1}^S n_s$, 为双词总数, n_{sk} 表示情感为 S 的双词中, 被分配给主题 k 的双词数目, $n_s = \sum_{k=1}^K n_{sk}$, 表示情感为 s 的双词总数, n_{skw} 表示词 w 情感为 S 主题为 k 的次数, $n_{sk\cdot} = \sum_{w=1}^W n_{skw}$, 表示情感为 S 主题为 k 的词汇个数。将(7)-(12)式代入(6), 化简后得到:

$$P(l_i = s, z_i = k | \mathbf{l}_{-i}, \mathbf{z}_{-i}, \mathbf{B}) = \frac{(n_{-i,s} + \gamma)(n_{-i,sk} + \alpha)(n_{-i,skw_{i,1}} + \beta)(n_{-i,skw_{i,2}} + \beta)}{(N_{-i,B} + S\gamma)(n_{-i,s} + K\alpha)(n_{-i,sk\cdot} + W\beta)^2} \quad (12)$$

按照(13)-(15)估计 π_s , θ_{sk} , φ_{skw} :

$$\pi_s = \frac{n_{-i,s} + \gamma}{N_{-i,B} + S\gamma} \quad (13)$$

$$\theta_{sk} = \frac{n_{-i,sk} + \alpha}{n_{-i,s} + K\alpha} \quad (14)$$

$$\varphi_{skw} = \frac{n_{-i,skw} + \beta}{n_{-i,sk\cdot} + W\beta} \quad (15)$$

本文通过文档中双词的情感来估计文档的情感比例。假设文档 d 包含 N_d 个双词 $\{b_j | j \in [1, N_d]\}$, 则该文档中情感 s 的比例为:

$$\begin{aligned} p(l = s | d) &= \sum_j^{N_d} p(l | b_j) p(b_j | d) \\ &= \sum_{j=1}^{N_d} \frac{\pi_s \theta_{sk} \phi_{sk, w_{i,1}} \phi_{sk, w_{i,2}}}{\sum_{s'} \pi_{s'} \theta_{s'k} \phi_{s'k, w_{i,1}} \phi_{s'k, w_{i,2}}} \cdot \frac{n_d(b_j)}{N_d} \end{aligned} \quad (16)$$

则文档 d 的情感倾向:

$$E_d = \arg \max(\mathbf{P}_{ed}) \quad (17)$$

其中, \mathbf{P}_{ed} 为文档 d 中各情感的比例。

4 实验

4.1 实验设置

实验语料为从去哪儿网¹爬取的 26533 条酒店评论, 其中包含正向情感文本 13934 条和负向情感文本 12599 条。经过分词和去停用词等预处理后, 每篇文档的平均词数为 22 词, 去除在整个语料中出现次数小于 3 次的词。正面和负面情感种子词来自知网《中文情感分析


¹ <http://hotel.qunar.com/>

用词语集》²。从中筛选出在语料中出现频次最高的正负各 35 个情感词。正面情感种子词包括“好”、“舒适”、“干净”等，负面情感种子词包括“不好”、“差”、“旧”等。本文通过网格搜索确定 BJSTM 模型各个参数取值，即 $\alpha=50/K$ ， $\beta=0.01$ ， $\gamma=0.1$ 。JST 和 SSTM 两种模型的参数分别与文献[4]和文献[5]保持一致。BJSTM、JST 和 SSTM 三模型的迭代次数均为 1000。

4.2 情感分类精度


按照公式(16)计算每个文档的情感比例，将比例最大的情感作为该文档的情感，图 3 展示了无先验信息时各模型情感分类精度。

图 3 无先验信息时各模型情感分类精度对比



在没有引入种子词前，JST 模型的情感分类精度徘徊在 0.5-0.6，相对较低，SSTM 居中，BJSTM 模型在各个主题数目下的情感分类精度较高。

图 4 带先验信息时各模型情感分类精度对比



引入种子词后，各模型分类精度随主题数目变化的波动均有所减小，JST 模型的情感分类性能提升较大，BJSTM 比 JST 稍高。正如前文提到的，SSTM 模型由于假设每个主题下均有

² http://www.keenage.com/html/c_bulletin_2007.htm

正负两个情感，对单个词语的情感二值化也会引入误差，在本次实验中，各个主题数目下 BJSTM 模型的情感分类精度均优于 SSTM 模型。

以 $K = 10$ 为例，表 1 列举了各模型对正面、负面及全部文档的情感分类精度。Baseline1 和 baseline2 表示直接根据某文档中包含的已知情感极性的词的数量进行多数表决，其中，baseline1 使用的情感种子词与其他三种方法一致，baseline2 使用的是知网《中文情感分析用词语集》的全部情感词汇。

表 1 $K=10$ 时各方法分类精度对比

	种子词个数 (正向/负向)	Pos	Neg	Overall
baseline1	35/35	0.1899	0.2903	0.2376
baseline2	4566/4370	0.8469	0.3228	0.5980
JST	0/0	0.6260	0.5212	0.5762
SSTM	0/0	0.7187	0.3242	0.5314
BJSTM	0/0	0.7480	0.6341	0.6939
JST	35/35	0.8465	0.7685	0.8094
SSTM	35/35	0.9675	0.3787	0.6879
BJSTM	35/35	0.9447	0.7091	0.8328

由于 BJSTM 模型对整个语料的词共现关系直接建模，在无先验信息和带先验信息时都有不错的情感分类精度。由于所列举的几种算法均未考虑到词序信息，可能丢失部分信息，在负面情感的文本中体现的尤为明显。另外，baseline2 中，即使使用了全部的情感词汇，其精度也只是和无监督的 JST/SSTM/BJSTM 相当，反映了网络评论由于文本长度较短而产生的稀疏性和可能存在的用词不规范。

4.3 关键词对比

在主题模型中，一般通过各个主题下概率最大的词汇表征主题的含义。表 2-表 4 列举了 $K = 10$ 、带先验信息时 JST、SSTM 和 BJSTM 关键词，并对各个主题的主要内容进行了人工归纳。

表 2 JST 模型关键词

情感	正面情感					负面情感				
	主题 1	主题 2	主题 3	主题 4	主题 5	主题 1	主题 2	主题 3	主题 4	主题 5
内容归纳	性价比	交通	接机	环境 服务 位置 性价比	卫生 服务	设施	卫生	服务 环境	环境 位置	环境 服务
关键词	还	方便	很	好	很	没有	房间	好	还	差
	不错	很	服务	很	好	房间	很	很	房间	环境
	价格	交通	好	环境	干净	空调	味道	环境	设施	一般
	可以	很近	接送	不错	房间	没	小	一般	一般	房间
	环境	位置	不错	服务	不错	不好	感觉	不错	地理位置	不好
	实惠	不错	机场	方便	环境	晚上	太小	服务	很	隔音
	算	好	环境	位置	卫生	热水	卫生间	还	酒店	服务态度
	酒店	机场	方便	交通	服务	用品	大	位置	不错	太
	总体	酒店	机	地理位置	挺	坏	很小	酒店	旧	酒店
	便宜	外滩	接机	性价比	酒店	房	干净	态度	可以	服务

可以看到，在短文本语料的背景下，JST 模型得到的主题含义不明晰，如正面情感下的主题 4、主题 5 和负面情感下的主题 3、主题 4、主题 5，均包含多方面的内容。另外，个别

主题的情感也存在摇摆不定，如负面情感下的主题 3，在展示出的十个关键词及其后的若干词中，均包含正负两种情感倾向的词汇。

表 3 SSTM 关键词

主题	主题 1		主题 2		主题 3		主题 4		主题 5	
	正面	负面	正面	负面	正面	负面	正面	负面	正面	负面
内容 归纳	交通	环境	接机	卫生	服务	环境	性价比	环境	环境	环境
关键词	很	房间	很	房间	很	没有	还	空调	很	差
	方便	一般	接送	很	好	房间	不错	很	好	环境
	交通	设施	机场	小	服务	没	可以	晚上	不错	不好
	好	很	服务	味道	环境	用品	价格	不好	干净	一般
	不错	环境	不错	不好	不错	洗漱	环境	吵	环境	酒店
	位置	酒店	方便	卫生间	前台	房	酒店	隔音	房间	房间
	很近	旧	好	没有	态度	窗户	性价比	热水	方便	服务
	环境	还	机	太小	服务态度	还	好	房间	服务	太
	酒店	好	酒店	差	挺	大床	算	声音	酒店	服务态度
	地理位置	不错	免费	很小	贴心	小	位置	好	交通	隔音

SSTM 模型得到的单个主题某情感下的关键词的一致性比 JST 强，但在真实语料下，并不是每个主题下都对应两种情感。在本实验中，只有主题 4 和主题 5 基本符合 SSTM 模型的假设，得到的是“酒店环境”这一主题下的正负两种情感色彩的关键词，其他三个主题分别是“交通便利”和“设施老旧”对应，“有接机服务”和“环境卫生差”对应，“服务贴心”和“缺乏必备设施”对应，涉及到的主要内容不一致，与模型假设不符，这也影响到 SSTM 的情感分类精度。

表 4 BJSTM 关键词

情感	正面情感					负面情感				
	主题 1	主题 2	主题 3	主题 4	主题 5	主题 1	主题 2	主题 3	主题 4	主题 5
内容 归纳	性价比	服务	接机	交通	环境	环境	卫生	服务 环境	环境	环境
关键词	还	很	很	很	很	空调	房间	差	一般	没有
	不错	好	接送	方便	好	房间	很	态度	房间	酒店
	可以	服务	服务	交通	不错	不好	小	前台	环境	房间
	环境	环境	机场	好	干净	很	味道	服务	差	洗漱
	价格	不错	不错	不错	房间	没	没有	环境	设施	用品
	好	前台	好	很近	环境	没有	卫生间	不好	很	房
	服务	态度	方便	位置	方便	晚上	不好	服务态度	酒店	没
	酒店	服务态度	机	环境	酒店	隔音	感觉	酒店	不好	很
	性价比	酒店	免费	酒店	挺	吵	太小	服务员	服务	最差
	算	热情	酒店	便利	卫生	热水	干净	太	隔音	大床

虽然在情感分类精度上，带有先验信息的 BJSTM 模型仅略高于 JST 模型，但 BJSTM 模型得到的各情感下的主题关键词表意明显强于 JST 模型。这主要是因为 JST 模型基于 LDA 产生，针对的是单篇文档内的词共现关系，BJSTM 模型基于 BTM，刻画了语料中全局的词共现关系。网络评论文本长度较传统文本更短，单篇文档内的词共现关系十分有限，BJSTM 模型一定程度上克服了其稀疏性。

5 结论

本文提出了 BJSTM 主题情感混合模型, 构建了“情感-主题-词汇”的三层贝叶斯网络。通过刻画语料级别的词汇共现关系, 一定程度上克服了单个短文本特征稀疏的问题。实验表明, BJSTM 模型能够较为有效地提取各情感下主题的关键词, 并得到了较好的情感分类精度。如何将词序信息加入到模型当中和如何定量评价关键词的质量是下一步工作的重点。

参考文献:

- [1] 张林, 钱冠群, 樊卫国, 等. 轻型评论的情感分析研究[J]. 软件学报, 2014(12):2790-2807.
- [2] Lin C, He Y, Everson R. A comparative study of Bayesian models for unsupervised sentiment detection [J]. *Grb Coordinates Network*, 2011(12255):144--152.
- [3] Mei Q, Ling X, Wondra M, et al. Topic sentiment mixture: modeling facets and opinions in weblogs [C]//*International Conference on World Wide Web*. New York, NY, USA: ACM, 2010:171--180.
- [4] Yohan Jo, AH Oh. Aspect and Sentiment Unification Model for Online Review Analysis [C]//*ACM International Conference on Web Search and Data Mining*. New York, NY, USA: ACM, 2011: 815-824.
- [5] Lin C, He Y. Joint sentiment/topic model for sentiment analysis [C]// *ACM Conference on Information & Knowledge Management*. New York, NY, USA: ACM, 2009:375-384.
- [6] 熊蜀峰, 姬东鸿. 面向产品评论分析的短文本情感主题模型[J]. *自动化学报*, 2016, 42(8):1227-1237
- [7] Yan X, Guo J, Lan Y, et al. A biterm topic model for short texts[C]// *International Conference on World Wide Web*. New York, NY, USA: ACM, 2013:1445-1456.

作者简介:



谢珺(1979—), 女, 副教授, 主要研究领域为粒计算、粗糙集、数据挖掘和智能信息处理。

Email: xiejun@tyut.edu.cn



郝洁(1992—), 女, 硕士研究生, 主要研究领域为自然语言处理、粗糙集。

Email: tyhj_415@163.com



苏婧琼(1991—), 女, 硕士研究生, 主要研究领域为自然语言处理、粒计算。

Email: 1138224810@qq.com

邹雪君 (1991—), 女, 硕士研究生, 主要研究领域为自然语言处理、



粗糙集。

Email: 924991559@qq.com



李思宇（1992—），男，硕士研究生，主要研究领域为自然语言处理、粗糙集。

Email: 593737285@qq.com