

在线评论情感计算与博弈预测

卜 湛¹, 伍之昂¹, 曹 杰¹, 朱桂祥²

(1. 南京财经大学江苏省电子商务重点实验室, 江苏南京 210003; 2. 南京理工大学计算机科学与技术学院, 江苏南京 210094)

摘 要: 传统的情感分析研究大多立足于解决主观性文本的情感分类问题, 面向复杂交互式文本的情感演化分析却力所不逮. 本文以天涯论坛短文本中文在线评论为研究对象, 首先提出一种高效的情感计算框架捕捉在线评论所蕴含的情感倾向; 然后将情感计算和博弈论相结合提出情感演化预测算法, 以混合纳什均衡策略作为交互行为的预测结果; 最后在大规模评论数据集上, 验证了情感计算框架的有效性和情感演化预测算法的准确性.

关键词: 情感分析; 在线评论; 情感计算; 博弈论; 情感演化

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112 (2015)12-2530-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2015.12.028

Affective Computing and Game Theory Based Prediction for Online Reviews

BU Zhan¹, WU Zhi-ang¹, CAO Jie¹, ZHU Gui-xiang²

(1. Jiangsu Provincial Key Laboratory of E-Business, Nanjing University of Finance and Economics, Nanjing, Jiangsu 210003, China;

2. College of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China)

Abstract: Most of the existing sentiment analysis was performed in the sentiment classification for subjective texts; the emotional evolution analysis for complex interactive texts was not yet thoroughly targeted by the research community. This paper is concerned on short-text Chinese online reviews collected from Tianya forum. Firstly, an efficient affective computing framework is proposed to capture the underlying emotions of online reviews. Secondly, a game theory based emotional evolution prediction algorithm combining the affective computing is proposed, in which the mixed Nash Equilibrium strategies are calculated as the future emotional behavior of interactive users. Experimental results on the large-scaled review dataset are provided to demonstrate the effectiveness and accurateness of our approaches.

Key words: sentiment analysis; online reviews; affective computing; game theory; emotional evolution

1 引言

社会网络的迅速发展使得越来越多的人习惯借助微博和论坛等平台发表在线评论参与话题讨论. 情感分析^[1]作为机器学习和计算机语言学的重要分支, 包含情感计算和情感演化分析. 情感计算的任务是识别主观性文本的情感极性, 并对极性强度进行判定. 情感演化是分析复杂交互式文本的情感随时间的演化规律. 在线评论的情感分析对网络舆情监控、口碑营销和信息预测等诸多应用都起着基础性支撑作用, 已成为社会网络分析领域的热点议题之一.

国内外学者已经在情感计算上做了大量研究工作, 取得了很多丰硕的成果. 根据文本处理粒度的不同, 情

感计算可以分为词语级、语句级和篇章级三个研究层次. 词语级^[2,3]情感计算是文本情感计算的基础, 包括基于语料库和基于词典两种方法. 连词连接的两个形容词的情感倾向往往存在一定的关联性, Hatzivassiloglou 等根据这一现象从大语料库中发掘出大量的形容词性的评价词语^[2]. Turney 等更进一步提出了互信息的方法判别某个词语是否是评价词语^[3]. 该方法适用于各种词性的评价词语的识别, 但是较为依赖种子褒/贬词语集合. 语句级^[4]和篇章级^[5]情感计算侧重于从整体上判断语句或篇章的情感倾向, 其主要包括基于情感知识的方法以及基于特征分类的方法.

已有的情感计算研究在文本情感分类上获得较好的效果. 面向复杂交互式文本(如论坛评论)的情感演化

收稿日期: 2014-10-15; 修回日期: 2015-01-09; 责任编辑: 李勇锋

基金项目: 国家自然科学基金(No. 71372188); 国家级电子商务信息处理国际联合中心(No. 2013B01035); 国家科技支撑计划(No. 2013BAH16F01); 江苏省科技支撑计划工业部分(No. BE2014141, No. BE2012185); 江苏省高校自然科学基金项目(No. 12KJA520001, No. 14KJA520001, No. 14KJB520015); 江苏高校优势学科建设工程资助项目

分析却力所不逮. 尽管 Galik 等提出的基于 agent 的模型可模拟在线交互的情感轨迹^[6]; Li 等提出的基于影响力分析的混合动力系统可对在线情感进行实时监控^[7]. 但这些工作仅仅监测了在线评论的情感在一段时间内的分布, 没有分析情感变化的内在原因, 不能对未来的交互行为进行有效预测.

社会网络中交互用户间支持与反对的行为, 可以视为彼此间的情感博弈^[8]. 一方面用户可以发表积极评论提升自身的受欢迎度; 另一方面用户也可以发表消极评论发泄心中的不满. 由于用户间态度是相互影响的, 表现为用户 i 收到用户 j 支持或反对的回复时, 自身满意度会随之上下波动, 该用户往往在追求自身满意度最大化的基础上, 根据双方历史情感交互行为做出最合理的决策, 回馈用户 j 一条支持或消极的评论. 因此, 本文将情感计算和博弈论相结合提出情感演化预测算法, 以混合纳什均衡策略作为交互行为的预测结果. 该模型可根据两个用户历史交互情感预测双方在未来交互过程中相互之间所持的情感态度.

2 评论情感计算

用户在社会网络上发布的帖子和评论都蕴含着自己的各种情感. 简化起见, 本文考虑用户之间的两种典型情感: 支持和反对. 情感演化分析试图基于用户间历史交互评论, 预测两个用户在未来交互过程中相互之间所表现出的情感态度. 因此, 准确捕捉历史评论所蕴含的情感成为本文研究的起点. 社会网络数据量庞大, 人工难以完成对评论的情感标注, 因此需要利用情感计算技术自动识别评论情感. 研究表明^[11], 短文本情感主要由一些无二义性的特征词汇来表达. 因此, 本节首先学习评论集中高频词汇的情感值, 再融合词的极性计算出整条评论的情感倾向.

国内社会网络中的评论文本大多由中文词汇构成, 同时包含少量英文单词和必要的标点符号. 给定包含 m 条评论的文本集合 $C = \{c_1, c_2, \dots, c_m\}$, 利用分词工具 ICTCLAS* 对 C 中所评论文本分词, 得到词汇集合. 由于词汇数量极大, 学习所有词汇的情感极性代价过高. 考虑到大部分词汇与情感表达无关、且出现频率极低. 因此, 我们根据 ICTCLAS 所标注的词性, 选择包括形容词、副词、名词和动词等词性的 Top- n 个高频词形成特征词汇集, 在后续实验中, n 设为 533 时, 就能有效实现评论情感的计算.

设 $F^{(n)} = \{f_1, f_2, \dots, f_n\}$ 为特征词汇集合, 为了计算 $F^{(n)}$ 中所有特征词汇的情感, 首先按照特征词汇出现频率由高到低的次序, 人工将高频词汇标注为支持和否定两种极性, 前者表示积极肯定的情感, 后者则表示消极否定的情感. 最终获得由无二义性的 45 个正面词汇

和 45 个负面词汇组成正/负范例集, 分别记为 F_p 和 F_N . 对于任意未在 F_p 和 F_N 中出现的词汇 f_i , 情感极性 $S(f_i)$ 计算公式为:

$$S(f_i) = \sum_{f_j \in I_p} \text{MI}(f_i, f_j) - \sum_{f_j \in I_N} \text{MI}(f_i, f_j) \quad (1)$$

$\text{MI}(f_i, f_j)$ 表示两个词汇之间的互信息:

$$\text{MI}(f_i, f_j) = \log_2 \sigma(\{f_i, f_j\}) / (\sigma(\{f_i\}) \cdot \sigma(\{f_j\})) \quad (2)$$

样本评论集中每一条评论可以表示为特征词汇的集合, 其满足 $c_i \in F^{(n)}, 1 \leq i \leq m$. $\sigma(X)$ 表示特征词汇集 X 的支持度, 即评论集中包含特征集 X 的评论所占比. 上述 $\text{MI}(f_i, f_j)$ 的取值范围在 $-\infty$ 和 $+\infty$ 之间, 为了避免 $\sigma(\{f_i, f_j\})$ 的取值为 0, 我们采用拉普拉斯校准, 即在 $\sigma(\{f_i, f_j\})$ 取值基础上加 0.01.

式(1)表示词汇 f_i 与正范例集中特征词汇的关联度之和高于 f_i 与负范例集中特征词汇的关联度之和, f_i 表达支持的情感, 反之亦然. 理论上, $S(f_i)$ 的取值介于 $-\infty$ 和 $+\infty$ 之间, 值越大, 则 f_i 越积极. 为了消除不同词汇情感值数量级的差异, 我们采用 Max-Min 对 $S(f_i)$ 进行规格化, 如式(3)所示:

$$S'(f_i) = \begin{cases} 0.5 \cdot S(f_i) / S^{\max} + 0.5 & S(f_i) \geq 0 \\ 0.5 \cdot S(f_i) - S^{\min} / -S^{\max} & S(f_i) < 0 \end{cases} \quad (3)$$

其中, S^{\min} 和 S^{\max} 分别为 $S(f_i)$ 的最小值和最大值. 规格化之后, 当 f_i 表示支持时 (即 $S(f_i) > 0$), $S'(f_i) \in [0.5, 1]$; 反之, $S'(f_i) \in [0, 0.5]$. 本文将情感值规格化为 0 到 1, 是基于以下两个角度考量的: (1) 情感计算是数据驱动的, 表现为最终计算得到的情感词汇极性的数量级存在较大差异, 因此本文采用 Max-Min 对 $S(f_i)$ 进行规格化. (2) 从概率的角度解释用户的交互行为, 规格化的情感值表示用户 i 给用户 j 积极评论的概率, 且与情感演化预测中用户的策略选择概率相统一 (见 3.3 节). 在这种概率框架下, 如果用户 i 对用户 j 积极评论的概率为 0.5, 表示用户 i 对用户 j 的态度偏向中立. 因此, 本文区分情感正负的临界值为 0.5.

令 c_{ijk}^T 为用户 i 对 j 在主题 T 下的第 k 次评论文本, $k=1$ 表示时间最早的一次评论, c_{ijk}^T 的情感值 E_{ijk}^T 定义为:

$$E_{ijk}^T = \sum_{f_i \in c_{ijk}^T} S'(f_i) / |c_{ijk}^T| \quad (4)$$

$|c_{ijk}^T|$ 表示 c_{ijk}^T 中特征词的个数. E_{ijk}^T 取值范围是 $[0, 1]$, 取值越大表示评论的态度越积极; 反之, 则越消极.

3 基于博弈模型的情感演化预测

3.1 博弈模型

给定用户 i 和 j , 已知他们在主题 T 下的相互评论

* <http://ictclas.nlpir.org/>

集合,利用第 2 节提出的情感计算方法,我们可以获得两者在主题 T 下历史交互评论情感.情感演化分析试图根据两者历史评论情感预测在未来相互之间所持有的情感态度,即:已知 E_{ij}^T 和 $E_{ji}^T (1 \leq l \leq k-1)$, 预测 E_{ik}^T 和 E_{jk}^T , 如图 1 所示.




图1 用户*i*和*j*基于主题*T*的讨论

个体为什么选择使用在线社会网络? 这是社会心理学研究者在考察在线社会网络用户个体行为时首先面对的问题. 已有的研究主要集中在以下两个动机: (1)信息沟通^[9], 包括获取与发布信息和沟通等; (2)情感满足^[10], 包括获得支持和宣泄情感等. 本文从个体情感满足角度研究交互双方的情感演化问题. 在情感交互过程中, 个体获得“主观满意度”有两种策略选择: 一是发表支持的帖子, 以获得交互对方的支持; 二是发表反对的帖子, 以充分发泄自己的不满情绪. 从博弈模型应该具备参与人、策略组合、博弈所得三个要素的评判标准来看, 图 1 中的用户交互关系显然符合这三个评判标准: 用户 i 和 j 构成博弈模型的两个参与人, 交互双方围绕“主观满意度”可以做出不同的策略选择, 且这些策略的不同组合会产生不同的博弈所得 (详见图 2), 因此, 本文采用博弈模型对用户之间的情感交互建模, 进而利用博弈模型中的优化策略实现情感演化趋势的预测. 用户 i 和 j 之间的博弈过程可以建模为一个二元组:

$$G_{ij} = [A_{ij} := \{A_i^+, A_i^-, A_j^+, A_j^-\}, U_{ij} := \{U_i, U_j\}] \quad (5)$$

其中, A_{ij} 是用户 i 和 j 的策略集合: A_i^+ 和 A_i^- 分别表示用户 i 做出给 j 回复支持和反对评论的决策, U_{ij} 是两个用户效用函数的集合, 用来衡量其选择不同策略的满意度.

		User j	
		A_j^+	A_j^-
User i	A_i^+	$U_i(A_i^+, A_j^+)U_j(A_i^+, A_j^+)$	$U_i(A_i^+, A_j^-)U_j(A_i^+, A_j^-)$
	A_i^-	$U_i(A_i^-, A_j^+)U_j(A_i^-, A_j^+)$	$U_i(A_i^-, A_j^-)U_j(A_i^-, A_j^-)$

图2 情感交互博弈模型

用户 i 和 j 之间所持的情感极性 (支持或反对) 将形成 4 种策略组 (见图 2), 博弈模型试图寻求双方满意度最大化的策略组合. 不失一般性, 从用户 i 角度出发, 针对用户 j 可能采取的策略, 用户 i 希望选择一条占优

策略以获得最大满意度. 针对这一问题, 首先定义衡量用户满意度的效用函数, 在此基础上提出用户选择占优策略的 3 条规则.

3.2 效用函数定义

效用指用户与他人交互过程中获得的主观满意度, 是交互双方彼此历史评论情感值的函数. 不失一般性, 我们考虑用户 i 的效用函数定义: $U_{ik}^T(A_i^+, \cdot)$ 表示用户 i 基于话题 T 的第 k 次交互时发给用户 j 一条支持评论所得的主观满意度, 此时, 用户 i 的效用主要取决于用户 j 回复的情感值: 若用户 j 给予 i 支持的回复, 那么用户 i 会很满意, 获得极高的效用; 如果用户 j 给予 i 反对的回复, 那么 i 会很失望, 获得极低的效用. 由此, $U_{ik}^T(A_i^+, \cdot)$ 的定义如下:

$$U_{ik}^T(A_i^+, A_j^+) = \sum_{l=1}^{k-1} w_l E_{jl}^T + \xi, \quad (6)$$

$$U_{ik}^T(A_i^+, A_j^-) = \sum_{l=1}^{k-1} w_l E_{jl}^T - \xi$$

式(6)中, ξ 为惩罚因子, 表示用户 i 收到用户 j 支持/反对评论时主观满意度的变化; w_l 是第 $l (1 \leq l \leq k-1)$ 条评论情感值的权重, 在本文中, 设 $w_l = 2^{-(k-l)} / \sum_l 2^{-(k-l)}$, 表示距离当前越近的历史评论情感对用户效用的影响越大.

当用户 i 发给用户 j 一条反对评论时, i 的效用主要取决于用户 i 发出的情感值: 如果用户 i 对 j 抨击的很尖锐, 他/她会很满意; 相反, 如果批评的很一般, 那么其效用值会比较低. 这样, 用户 i 基于话题 T 的第 k 次交互时发给用户 j 一条消极评论所得的效用值, $U_{ik}^T(A_i^-, \cdot)$, 定义如下:

$$U_{ik}^T(A_i^-, A_j^+) = \sum_{l=1}^{k-1} w_l (1 - E_{jl}^T) - \xi,$$

$$U_{ik}^T(A_i^-, A_j^-) = w_l (1 - E_{jl}^T) + \xi \quad (7)$$

其中惩罚因子 ξ 的表征意义同式(6)中相同. 对用户 j 的相关定义类似, 在此不再累述. 本文假设, 当用户 i 和 j 在交互过程中, 双方对彼此的效用函数值是充分了解的.

3.3 情感演化预测

基于效用函数定义, 我们可以借助博弈模型预测用户 i 和 j 基于话题 T 在第 k 次交互时的相互态度. 从用户 i 的角度, 分析其可能对 j 采取的策略: 要么发一条支持评论, 要么发一条反对评论. 由效用函数的定义可知, 用户 i 的主观满意度不仅仅取决于自己的决策, 还受用户 j 决策的影响. 接下来, 我们介绍用户 i 选择占优策略的三条规则.

规则 1 如果用户 i 存在主导策略^[6], 即:

$$\exists A_i^* \in \{A_i^+, A_i^-\}, U_{ik}^T(A_i^*, A_j^*) \geq U_{ik}^T(A_i^*, A_j^-) \quad (8)$$

在未来交互过程中, 用户 i 一定会采取该主导策略

A_i^* .

令 p_{ijk}^T 为的第 k 次互动时用户 i 采取策略 A_i^+ 的概率为 p_i , $1 - p_{ijk}^T$ 为此时用户 i 采取策略 A_i^- 的概率. 用户 i 满足规则 1 时 p_{ijk}^T 的可定义如式(9)所示, $p_{ijk}^T = 1$ 表示用户 i 的主导策略为 A_i^+ , 反之, $p_{ijk}^T = 0$ 说明用户 i 的主导策略为 A_i^- .

$$p_{ijk}^T = f(A_i^*) = \begin{cases} 1, & A_i^* = A_i^+ \\ 0, & A_i^* = A_i^- \end{cases} \quad (9)$$

规则 2 如果用户 i 不存在主导策略, 而用户 j 存在主导策略, 即:

$$\exists A_i^* \in \{A_i^+, A_i^-\}, U_{ik}^T(A_i^*, A_j^\pm) \geq U_{ik}^T(A_i^\pm, A_j^\pm)$$

$$\exists A_j^* \in \{A_j^+, A_j^-\}, U_{jk}^T(A_i^\pm, A_j^*) \geq U_{jk}^T(A_i^\pm, A_j^\pm) \quad (10)$$

用户 i 会选择面对 j 主导策略 A_j^* 的最优响应^[6], 即:

$$U_{ik}^T(A_i^*, A_j^*) \geq U_{ik}^T(A_i^\pm, A_j^*) \quad (11)$$

从概率角度看, 与规则 1 相同, p_{ijk}^T 仍取 1 或 0.

规则 3 如果用户 i 和 j 都不存在主导策略, 即:

$$\exists A_i^* \in \{A_i^+, A_i^-\}, U_{ik}^T(A_i^*, A_j^\pm) \geq U_{ik}^T(A_i^\pm, A_j^\pm)$$

$$\exists A_j^* \in \{A_j^+, A_j^-\}, U_{jk}^T(A_i^\pm, A_j^*) \geq U_{jk}^T(A_i^\pm, A_j^\pm) \quad (12)$$

此时用户 j 采取 A_j^+ 和 A_j^- 的期望回报分别为:

$$\begin{aligned} E_{jk}^T(\cdot, A_j^+) &= p_{ijk}^T U_{jk}^T(A_i^+, A_j^+) + (1 - p_{ijk}^T) U_{jk}^T(A_i^-, A_j^+) \\ E_{jk}^T(\cdot, A_j^-) &= p_{ijk}^T U_{jk}^T(A_i^+, A_j^-) + (1 - p_{ijk}^T) U_{jk}^T(A_i^-, A_j^-) \end{aligned} \quad (13)$$

基于混合纳什均衡理论^[6], 当用户 j 积极评论的期望回报同消极评论的期望回报一致时, 即 $E_{jk}^T(\cdot, A_j^+)$ 和 $E_{jk}^T(\cdot, A_j^-)$ 相等时, 求解得到的 p_i 是用户 i 的占优策略:

$$P_{ijk}^T = \frac{U_{jk}^T(A_i^-, A_j^-) - U_{jk}^T(A_i^-, A_j^+)}{U_{jk}^T(A_i^-, A_j^-) + U_{jk}^T(A_i^+, A_j^+) - U_{jk}^T(A_i^-, A_j^+) - U_{jk}^T(A_i^+, A_j^-)} \quad (14)$$

上述规则给出了约束条件由强到弱的 3 种情况, 综合这 3 种情况, 得到计算任意用户的策略选择概率计算过程.

给定包含 m 条评论的文本集合 $C = \{c_1, c_2, \dots, c_m\}$, 预测任意两个交互用户基于话题 T 的情感. 首先需要根据式(4)计算这 m 条评论文本的情感值; 然后基于交互双方在话题 T 下的历史评论情感计算其效用函数集合; 最后根据三种情境选择相应规则计算用户占优策略的选择概率. 上述过程的时间复杂度主要来自于评论文本的情感值计算. 设 n 为特征词个数, 情感演化预测算法基于整个数据集的时间复杂度为 $O(mn)$, 保证了预测算法的时间是可以接受的.

4 实验分析

本文以天涯论坛国际观察板块的在线评论为数据来源, 首先设计了一种高效的网页分析工具来实时抽取板块内帖子页面所包含的“主题-评论-用户”信息. 由于天涯论坛中的评论存在上下文引用现象, 我们在抽取过程中删除相应引用文本, 将剩余信息抽象为两张关系表: (1)主题表, 用于存储主题信息; (2)评论表, 用于存储评论信息. 在 2010 年 1 月到 2013 年 12 月时间段内, 我们共抽取到 133605 个主题、5174799 条评论和 376796 个注册用户.

4.1 评论情感计算有效性

利用 ICTCLAS 对评论样本分词, 得到 1524906 个不同词汇. 为了降低情感计算的复杂性, 选择 Top- n 个高频词形成特征词汇集 $F^{(n)}$, 定义 $F^{(n)}$ 的累积分布函数 $\text{cdf}(n)$:

$$\begin{aligned} \text{cdf}(n) &= \sum_{i=1}^m f(n, i) / m, \\ f(n, i) &= \begin{cases} 1, & \exists f_l \in F^{(n)}, f_l \in c_i \\ 0, & \text{otherwise} \end{cases} \end{aligned} \quad (15)$$




图3 累积分布函数

$\text{cdf}(n)$ 表示包含 $F^{(n)}$ 中至少一个词汇的评论占评论集的比率. 图 3 给出了 $\text{cdf}(n)$ 随参数 n 的变化曲线, 观察可知, 随着 n 的增大, $\text{cdf}(n)$ 快速向 100% 收敛, 说明少量的特征词汇可以较完整的描述评论样本. 实验设 $n = 533$, 此时, $\text{cdf}(533) = 0.95$, 表示数据集中有约 95% 的评论样本可以由这 533 个特征表示, 剩余 5% 的评论样本被视为离群点.

根据第 2 节提出的方法, 学习获得 533 个特征词汇的情感值. 图 4 展示了规格化之后的特征词汇情感值分布, 可见大部分词汇呈现出清晰的极性, 少部分词汇表现为中性(0.5 左右), 最终获得 270 个积极词汇和 263 个消极词汇.

获得特征词汇情感值后, 根据式(4)可以计算所有评论的情感值, 由于评论数量巨大, 难以逐一手工标注其真实情感值. 为了验证评论情感分类的准确性, 我们采用一种间接的评价方法^[11]: 首先, 对评论按照其情感




图4 特征词汇规格化情感值

80.4%，说明其预测用户情感演化的总体表现良好。




图5 情感演化总体预测结果

值降序排列,选取序列中前 $x\%$ 和后 $x\%$ 评论分别标记为正/负样本构建测试集;然后利用不同分类算法在测试集上进行 10 折交叉验证,计算出分类评估指标.如果不同分类算法都在测试集评论上表现出优良的性能,则间接验证了本文提出的评论情感计算方法的有效性,即能够准确地标注评论情感.

表 1 样本分类结果

$x\%$	SVM			J48			Naïve Bayes		
	P	R	$F1$	P	R	$F1$	P	R	$F1$
5%	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
10%	1.00	1.00	1.00	1.00	1.00	1.00	0.98	0.97	0.96
15%	0.98	0.97	0.97	0.99	0.99	0.99	0.95	0.94	0.94

表 1 给出了 x 分别为 5、10 和 15 时由 3 种分类算法,支持向量机(SVM)、决策树(J48)、朴素贝叶斯(Naïve Bayes)的 10 折交叉验证结果.其中, P 为准确率, R 为召回率, $F1$ 为 F-measure 指标.实验中,样本的初始标签是根据情感值给定的.当 $x = 5$ 时,分类结果接近完美,各个指标达到了 100%;当 $x = 15$ 时,正/负样本的特征表示趋近,分类准确率有所下降.上述实验间接验证了情感计算的有效性.

4.2 情感演化预测算法准确性

我们随机地选择讨论深度 $d > 10$ 的 1000 个用户对建立相应的测试集验证情感演化预测算法的准确性.基于用户 i 和 j ,在主题 T 下交互的测试集构建如下:首先计算他们第 $k (2 \leq k \leq d)$ 次交互的效用值 ($U_{ik}^T(A_i^\pm, \cdot)$ 和 $U_{jk}^T(\cdot, A_j^\pm)$);然后根据实际情感值 (E_{jk}^T 和 E_{jk}^T) 将双方在第 k 次交互的评论标记为正/负样本构建测试集.实验中,共标记生成了 59622 个测试样本,平均每个测试集包含 59.6 个样本.最后,利用算法 1 在每个测试集上进行验证,计算出分类评估 $F1$ 指标.图 5 给出了算法 1 在每个测试集上预测结果(实验中,惩罚因子 ξ 设置为 0.1).其中 x 坐标和 y 坐标分别表示用户 i 和 j 的标识符,每个数据点表示算法 1 在相应测试集上的分类预测结果.算法在测试集上的平均 $F1$ 指标达到

我们进一步研究预测算法对数据集中一个特定讨论实例的预测性能.我们选择两个用户在某个话题下的 74 条评论.根据双方历史交互行为,预测他们距离当前最近的 72 次交互的情感态度.实验结果如图 6 所示,在该讨论实例上预测的准确率 $P = 84.7\%$ 、召回率 $R = 69.2\%$ 、 $F1$ 值为 76.2%.从图 6 还可以观察到,在双方交互过程的前期,预测精度不高,这是由预测可参考的历史评论情感信息不足造成的;随着双方历史交互信息的不断累积,效用函数的计算更加合理,预测精度会有所提高.

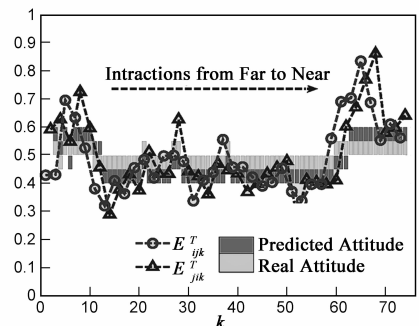


图6 讨论实例情感预测

5 总结

本文研究社会网络中在线评论的情感计算和情感演化问题.首先提出了情感计算框架,需要极少量的人工标注,就可准确地计算评论的情感倾向.然后将情感计算和博弈论相结合提出情感演化预测算法,以混合纳什均衡策略作为预测结果.在大规模评论数据集上,验证了情感计算框架的有效性和情感演化预测算法的准确性.实验表明,我们的情感计算框架可以准确的计算在线评论的情感强度.

参考文献

- [1] 赵妍妍,秦兵,刘挺.文本情感分析[J].软件学报,2010,21(8):1834-1848.
Zhao Y Y, Qin B, Liu T. Sentiment analysis[J]. Journal of

- Software, 2010, 21(8): 1834 – 1848. (in Chinese).
- [2] Hatzivassiloglou V, McKeown K R. Predicting the semantic orientation of adjectives[A]. Proceedings of the 35th ACL[C]. Stroudsburg: ACL, 1997. 174 – 181.
- [3] Turney P D, Littman M L. Measuring praise and criticism: Inference of semantic orientation from association[J]. ACM Transactions on Information Systems, 2003, 21(4): 315 – 346.
- [4] Hu M, Liu B. Mining and summarizing customer reviews[A]. Proceedings of the 10th KDD[C]. New York: ACM, 2004. 168 – 177.
- [5] Pang B, Lillian L, Shivakumar V. Thumbs up?: sentiment classification using machine learning techniques[A]. Proceedings of the EMNLP[C]. Stroudsburg: ACL, 2002. 79 – 86.
- [6] Galik M, Rank S. Modelling emotional trajectories of individuals in an online chat[A]. Proceedings of the 10th MATES[C]. Berlin: Springer-Verlag, 2012. 96 – 105.
- [7] Li T M H, Chau M, Wong P W C, et al. A hybrid system for online detection of emotional distress[A]. Proceedings of PAISI 2012[C]. Berlin: Springer-Verlag, 2012. 73 – 80.
- [8] Myerson R B. Game Theory: Analysis of Conflict[M]. Cambridge: Harvard University Press, 2013.
- [9] Haythornthwaite C. Social network analysis: An approach and technique for the study of information exchange[J]. Library & Information Science Research, 1996, 18(4): 323 – 342.

- [10] Yee N. The psychology of massively multi-user online role-playing games: Motivations, emotional investment, relationships and problematic usage[J]. Avatars at Work and Play, 2006, 34: 187 – 207.
- [11] Mukherjee A, Kumar A, Liu B, et al. Spotting opinion spammers using behavioral footprints[A]. Proceedings of the 19th KDD[C]. New York: ACM, 2013. 632 – 640.

作者简介



卜 湛 男, 1987 年 6 月出生, 安徽铜陵人. 2009 年和 2014 年分别在西安科技大学和南京航空航天大学获工学学士和工学博士学位. 现为南京财经大学江苏省电子商务重点实验室讲师, 主要研究领域为社会网络计算、web 挖掘.

E-mail: buzhan@nuaa.edu.cn



伍之昂(通信作者) 男, 1982 年 9 月出生, 江苏宜兴人. 2004 年和 2009 年分别在南京邮电大学和东南大学获工学学士和工学博士学位. 现为南京财经大学江苏省电子商务重点实验室副教授, 主要研究领域为推荐系统、云计算和数据挖掘.

E-mail: zawu@seu.edu.cn