

否定句的情感不确定性度量及分类

张志飞^{1,2} 苗夺谦¹ 聂建云² 岳晓冬³

¹(同济大学计算机科学与技术系 上海 201804)

²(加拿大蒙特利尔大学计算机科学与运筹学系 蒙特利尔 H3C 3J7)

³(上海大学计算机工程与科学学院 上海 200444)

(tjzhifei@163.com)

Sentiment Uncertainty Measure and Classification of Negative Sentences

Zhang Zhifei^{1,2}, Miao Duoqian¹, Nie Jianyun², and Yue Xiaodong³

¹(Department of Computer Science and Technology, Tongji University, Shanghai 201804)

²(Department of Computer Science and Operations Research, University of Montreal, Montreal H3C 3J7)

³(School of Computer Engineering and Science, Shanghai University, Shanghai 200444)

Abstract Sentiment classification is a powerful technology for social media big data analysis. It is of great importance to predict the sentiment polarity of a sentence, especially a negative sentence that is often used. The negation words and sentiment words play equally important roles in the sentiment classification of negative sentences. A negation word is important when it modifies a sentiment word; but it can also have sentimental implication on its own. The existing methods only consider the negation words when they modify sentiment words. In this paper, a unified classification model based on decision-theoretic rough sets is proposed to deal with the sentiment classification of negative sentences. First, the sentiment value of each clause in a sentence is calculated by several lexicons and the inter-sentence relations. A novel measure of sentiment uncertainty for a sentence is given based on Kullback-Leibler divergence. Then, the negative sentences are represented in terms of four features (initial polarity, sentiment uncertainty, successive punctuations, and sentence type) and especially two negation-related features: single negation and salient adverb. Finally, a novel attribute reduction algorithm based on the decision correlation degree is used to generate the decision rules for sentiment classification of negative sentences. The experimental results show that this model is effective and the sentiment uncertainty measure is helpful to sentiment classification.

Key words sentiment classification; negative sentences; sentiment uncertainty; decision-theoretic rough sets; attribute reduction

摘要 情感分类是社交媒体大数据分析的有力手段之一。否定句作为一种普遍且特殊的句子现象,其情感分类的研究具有重要的意义。否定词语和情感词语在否定句情感分类中同样重要,已有方法仅仅考虑否定词语修饰情感词语的情况,忽视否定词语本身反映情感的作用。为了统一解决否定词语修饰和不修饰情感词语情况下的分类问题,提出了基于决策粗糙集的否定句情感分类模型。构造词典并结合句际关系计算子句情感值,根据子句情感值提出基于KL散度的句子情感不确定性度量方法;然后融合多个特征,特别是与否定相关的独立否定特征和显著副词特征,用于否定句的特征表示;最后提出基于决策

相关程度的决策正域约简算法,生成否定句情感分类决策规则。实验结果验证了该模型的有效性以及情感不确定性度量对于情感分类的作用。

关键词 情感分类;否定句;情感不确定性;决策粗糙集;属性约简

中图法分类号 TP391

在当今大数据时代,用户习惯于通过社交媒体平台表达社情民意,由此生成海量的非结构化或半结构化文本,如产品评论、股票评论、影视评论等。文本不再局限于描述客观事实,而侧重于表达情感。大数据分析的价值体现在从大数据中获取更准确、更深层次的知识。文本情感作为文本的更深层次的语义知识,在经济、社会以及政治等领域发挥了重要作用^[1]。

文本情感分类是通过分析文本中的立场、观点、情绪、好恶等主观信息,判断文本的感情色彩^[2]。情感分类方法主要有 2 类:1)词典方法。采用情感词典^[3]、句法分析^[4]等;2)机器学习方法。采用最大熵(maximum entropy, ME)^[5]、K 近邻(K-nearest neighbors, KNN)^[6]、朴素贝叶斯(naive Bayes, NB)^[5-6]、支持向量机(support vector machines, SVM)^[5-6]等。

自然语言中的特殊句式对文本情感分类提出了挑战,如否定句、比较句、条件句等。否定指否认现象的存在或者事件的发生,是自然语言中普遍存在的现象,《计算机学报》同一期论文构建的语料库中 15.8% 的句子是否定句^[7]。国内连续 2 届中文倾向性分析评测将否定句的情感分类作为重要任务之一。否定词语对否定句的情感分类具有关键作用,当前方法是考虑情感词语和否定词语在句子内共现^[3,8-9],如对否定修饰的情感极性取反。

例 1. 我不喜欢这款手机。

例 2. 我绝对不购买这款手机。

例 1 中“喜欢”表达褒义,但是被否定词语“不”修饰,则句子表达贬义。例 2 中“不”没有修饰情感词语,则一般认为句子表达中性。然而,否定词语往往表达事与愿违,Zhang 等人^[10]在词典方法的基础上附加规则,将此类否定出现至少 3 次的句子判为贬义,其系统 TJOMS 在第 5 届中文倾向性分析评测的否定句情感分类任务中取得不错的成绩。此外,否定句中出现副词“绝对”,更能体现贬义色彩。因此,需要针对否定句提出情感分类模型,同时解决否定词语修饰和不修饰情感词语情况下的分类问题。

情感分类的难点在于情感的不确定性。粗糙集理论(rough sets, RS)作为知识不确定性分析的有

效工具之一^[11],已经成功应用于文本情感分类。Wang 等人^[12]利用情感倾向强度定义赋权粗糙隶属度,用于篇章的情感分类;Zhang 等人^[13]将 RS, NB 相结合分析具有强语义模糊性词语的情感倾向。经典粗糙集缺乏容错能力,而决策粗糙集(decision-theoretic rough sets, DTRS)则从贝叶斯最小风险决策理论角度定义概率区域^[14]。Zhou 等人^[15]将 DTRS 的思想用于词典方法和机器学习方法的组合,实现一般句子的情感分类;Zhang 和 Wang^[16]利用 DTRS 实现上下文有关的词语情感分类和主题有关的句子情感分类。这些方法旨在分类,忽略了情感不确定性的度量。

情感不确定性的度量对情感分类具有作用。Wu 等人^[17]通过高斯分布度量语料的情感不确定性,度量方法并不适用于句子。而 TJOMS^[10]中人工设定的情感判别规则不够全面。鉴于以上问题,提出基于决策粗糙集的否定句情感分类模型 SCNS-DTRS。在该模型中,给出句子的情感不确定性度量方法,并将其作为情感分类的有效特征之一;融合多个特征,特别是否定相关的特征,构造决策粗糙集分类器,自动生成情感分类决策规则。实验表明 SCNS-DTRS 情感分类模型可以有效地识别否定句的情感极性。

1 否定句的情感分类模型

1.1 基本模型

否定句的情感分类模型如图 1 所示。具体流程依次为:将句子拆分为子句;计算子句情感值;根据子句情感值度量句子情感不确定性,并计算句子初始情感极性;融合多个特征表示否定句;构造决策粗糙集分类器实现否定句的情感分类。流程中各环节采用相同计算步骤分别用于训练和测试。

模型的特殊之处在于:基于 KL 散度计算句子的情感不确定性,并作为否定句表示的特征之一;为否定句表示设计 2 个与否定相关的特征:不修饰情感词语的否定词语的数量、是否出现与情感极性相关的显著副词,加强否定词语本身反映情感的可能性。

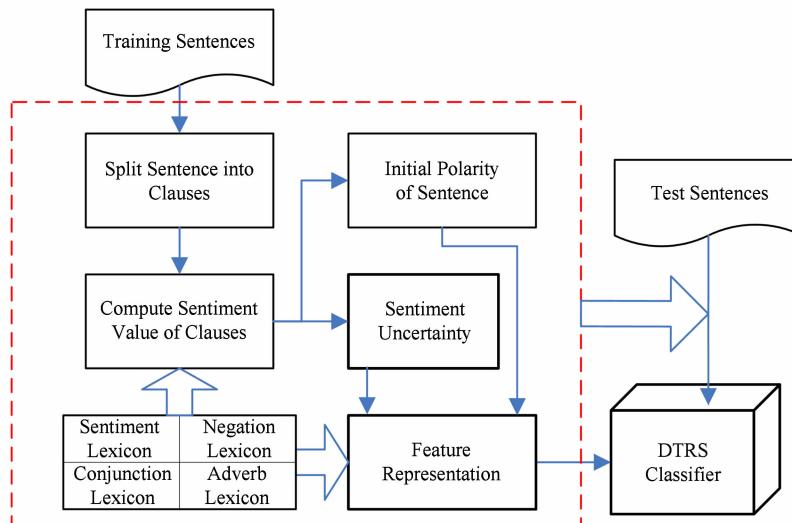


Fig. 1 Model for sentiment classification of negative sentences.

图 1 否定句的情感分类模型

子句情感值的计算采用词典方法。词典包括情感词典、程度词典、否定词典和连词词典^①，其中情感词典最为重要^[18]，程度词典和否定词典用于识别修饰情感词语的成分，连词词典用于识别句际关系。

1.2 词典构建

1) 情感词典

以情感词汇本体^[19]为主要资源，结合 HowNet 情感分析用中文词集^②、中文褒贬义词典^③和学生褒贬义词^④，经过整合、去重、转换和补充得到含有 28 567 个词语的情感词典，每个词语标注词性、极性（1 为褒义词、-1 为贬义词、0 为中性词）、强度（分为 5 档，5 表示强度最大，1 表示强度最小）等信息。结合词语的极性以及强度可以度量词语的情感值。

定义 1. 给定词语 w 的极性 $Polarity(w)$ 以及强度 $Intensity(w)$ ，则词语 w 的情感值 $Sentiment(w)$ 为

$$Sentiment(w) = Polarity(w) \times 0.2 \times Intensity(w), \quad (1)$$

因 $Polarity(w) \in \{-1, 0, 1\}$, $Intensity(w) \in \{1, 2, 3, 4, 5\}$ ，式(1)中的 0.2 使得 $Sentiment(w) \in [-1, 1]$.

2) 程度词典

根据 HowNet 中文程度级别词语整理程度词典，共计 140 个程度词语，如“很”、“非常”，用符号 deg 表示，为每个程度词语设定权重 $Weight(deg)$ 。根据 HowNet 将表达“极其、最”意义的权重设为 5、“很”意义的权重设为 4、“较”意义的权重设为 3、“稍

微、一点”意义的权重设为 2。

定义 2. 给定程度词语 deg 的权重 $Weight(deg)$ ，则程度词语 deg 的程度值为

$$Degree(deg) = 0.25 \times (3 + Weight(deg)), \quad (2)$$

因 $Weight(deg) \in \{2, 3, 4, 5\}$ ，式(2)中的 0.25 和 3 使得 $Degree(deg) \in (1, 2]$ 。

3) 否定词典

HowNet 中的否定词语含有“negation”义项，根据该义项找到否定词语，再添加一些常用的否定词语，如网络用语“木有”，共计 65 个。否定词语用符号 neg 表示，若将否定词语看作特殊的程度词语，有 $Degree(neg) = -1$ 。

4) 连词词典

句子之间的主从关系包括总结(或结果)、让步、转折、假设、目的和条件等，会体现句子情感表达的侧重。从句子情感而言，总结或转折子句的情感最为重要，让步子句的情感相对不重要，而假设、目的和条件子句一般认为不体现情感。从语料中筛选出 60 个连词并标注主从关系，如“但是”表转折。

1.3 子句情感值的计算

假设子句满足 2 个特点：情感极性表达较为单一(由于子句长度较短)；出现多个情感词语时只考虑子句最右侧的情感词语(符合汉语的表达习惯)。

除了情感词语，子句中还可能出现否定词语、程度词语以及连词。对于否定词语 neg ，关键是确定其辖域 $Scope(neg)$ ^[8]。已有的研究表明通过固定窗口

^① <http://tjzhifei.github.io/resources/modifier.zip>

^② <http://www.keenage.com/download/sentiment.rar>

^③ <http://tjzhifei.github.io/resources/bbycd.zip>

^④ <http://nlp.csai.tsinghua.edu.cn/~lj/sentiment.dict.v1.0.zip>

大小的方法检测否定辖域是切实可行的^[20]. 否定可以分为局部否定和长距离否定^[21], 根据语料统计将否定词语划分为局部否定词语和长距离否定词语.

定义 3. 给定局部否定词语 neg , 若 w 是情感词语且 $|Pos(w) - Pos(neg)| \leq W_{local}$, 则 $w \in Scope(neg)$; 给定长距离否定词语 neg , 若 w 是情感词语且 $|Pos(w) - Pos(neg)| \leq W_{longdist}$, 则 $w \in Scope(neg)$. Pos 表示词语在子句中的绝对位置, W_{local} 是局部否定辖域窗口大小, $W_{longdist}$ 是长距离否定辖域窗口大小.

对于程度词语, 同样采用固定窗口大小的方法检测其是否修饰情感词语. 当子句中情感词语、否定词语和程度词语明确后, 其搭配的情感值如表 1 所示(只列出否定词语和程度词语前置的情况).

Table 1 Sentiment Value of Different Collocations

表 1 子句不同搭配的情感值

Collocation	Sentiment Value of Clause cla
w	$Sentiment(cla) = Sentiment(w)$
$deg + w$	$Sentiment(cla) = Degree(deg) \times Sentiment(w)$
$neg + w$	$Sentiment(cla) = -Sentiment(w)$
$neg + neg + w$	$Sentiment(cla) = Sentiment(w)$
$deg + neg + w$	$Sentiment(cla) = -Degree(deg) \times Sentiment(w)$
$neg + deg + w$	$Sentiment(cla) = -Sentiment(w) / Degree(deg)$

由于多种因素, 比如子句含有未登录情感词语, 表 1 中的情感值不一定真正反映子句的情感极性. 因此, 提出结合句际关系的子句情感值计算方法, 见算法 1. 根据连词词典显性表示句际关系, 给出子句标记如表 2 所示. Single-Neg 的优先级低于 Single-Con 和 Single-Adv, Other-Polar 中的其他连词仅指

Table 2 Clause Tags

表 2 子句标记

Tag	Meaning
Single-Polar	Only contain sentiment words
Single-Con	Only contain concessive conjunctions
Single-Adv	Only contain adversative conjunctions
Single-Neg	Only contain negation words
Single-Punc	Only contain punctuations
Con-Polar	Contain sentiment words and concessive conjunctions
Adv-Polar	Contain sentiment words and adversative conjunctions
Other-Polar	Contain sentiment words and other conjunctions
Hope-Polar	Contain words expressing a hope
None	Do not meet the above conditions

目的、假设或条件连词, Hope-Polar 中含有“希望”、“以为”等表示主观愿望的词语.

算法 1. 结合句际关系的子句情感值计算.

输入: 句子 $sent$ 的子句序列 (cla_1, \dots, cla_m) ;

输出: 子句的情感值 $Sentiment'(cla_k)$ ($1 \leq k \leq m$).

```

① for  $k=1$  to  $m$ 
②   if  $Tag(cla_k) = \text{Single-Adv}$ 
③     if  $Tag(cla_{k-1}) = \text{Single-Polar}$ 
④       if  $k=m$  或  $(k < m$  且  $Tag(cla_{k+1}) = \text{None}$ )
⑤          $Sentiment'(cla_k) = -Sentiment(cla_{k-1});$ 
⑥       end if
⑦      $Sentiment'(cla_{k-1}) = 0;$ 
⑧   end if
⑨   else if  $Tag(cla_k) = \text{Single-Con}$ 
⑩     if  $k < m$  且  $Tag(cla_{k+1}) = \text{Single-Polar}$ 
⑪        $Sentiment'(cla_{k+1}) = 0;$ 
⑫     end if
⑬   else if  $Tag(cla_k) = \text{Adv-Polar}$ 
⑭     if  $k > 1$  且  $Tag(cla_{k-1}) = \text{Single-Polar}$ 
⑮        $Sentiment'(cla_{k-1}) = 0;$ 
⑯     end if
⑰   else if  $Tag(cla_k) \in \{\text{Con-Polar}, \text{Other-Polar}, \text{Hope-Polar}\}$ 
⑱      $Sentiment'(cla_k) = 0;$ 
⑲   else
⑳      $Sentiment'(cla_k) = Sentiment(cla_k);$ 
㉑   end if
㉒ end for

```

2 句子的情感不确定性度量

句子的正负情感差异值越小, 则情感不确定性越大; 同时, 句子越长, 则情感不确定性程度越高. 因此, 提出基于 KL 散度的句子情感不确定性度量方法.

定义 4. 给定句子中各个子句的情感值 $Sentiment'(cla_k)$, 则句子的正情感值 S_+ 和负情感值 S_- 分别定义为

$$S_+ = \sum_{k: Sentiment'(cla_k) > 0} Sentiment'(cla_k), \quad (3)$$

$$S_- = \sum_{k: Sentiment'(cla_k) < 0} Sentiment'(cla_k).$$

显然, $S_+ \geq 0, S_- \leq 0$.

定义 5. 给定句子的正情感值 S_+ 和负情感值 S_- , 句子的情感差异值 S_d 定义为

$$S_d = \min\{0.001 + |\tanh(S_+) + \tanh(S_-)|, 0.999\}. \quad (4)$$

因为 $\tanh(S_+) \in [0, 1], \tanh(S_-) \in (-1, 0]$, 有 $S_d \in (0, 1)$, 限定不取 2 个端点值是为了避免 KL 散度取无穷大.

句子越长可能有 2 个影响: 1) 句子的正情感值 S_+ 和负情感值 S_- 的绝对值越大; 2) 句子的情感不确定性程度越高. 为了关联这 2 个影响, 通过双曲正切函数使得 $\tanh(S_+) \rightarrow 1$ 而 $\tanh(S_-) \rightarrow -1$, 因此 $S_d \rightarrow 0$, 则句子情感不确定性最大.

定义 6. 句子 $sent$ 的情感不确定性 (sentiment uncertainty, SU) 度量定义为

$$SU(sent) = e^{-D_{KL}(S_0 \| S_d)} = e^{-S_0 \times \ln \frac{S_0}{S_d} - (1-S_0) \times \ln \frac{1-S_0}{1-S_d}}, \quad (5)$$

其中, S_0 为固定参数, 设为 1 个非常接近于 0 的值. 因为 $D_{KL}(S_0 \| S_d) \geq 0$, 有 $SU(sent) \in (0, 1]$. $SU(sent)=1$ 表示句子的情感最不确定, $SU(sent) \rightarrow 0$ 表示句子的情感最确定.

图 2(a) 以 $S_+ \in [0, 10], S_- \in [-10, 0], S_d \in [-10, 10]$

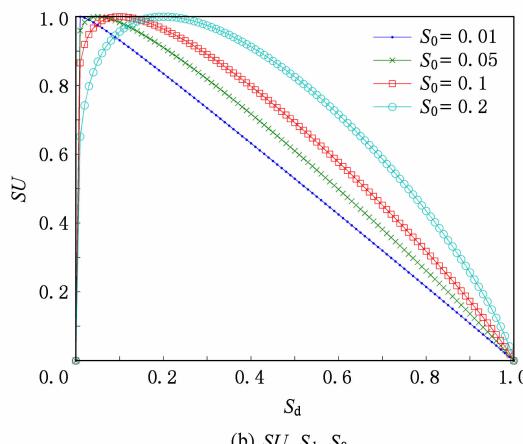
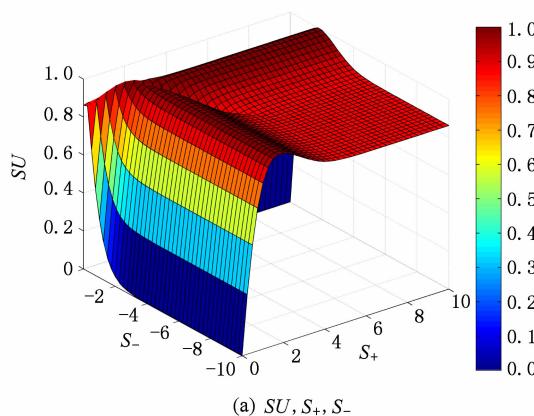


Fig. 2 Sentiment uncertainty measure of a sentence.

图 2 句子的情感不确定性度量

0.05 为例说明 SU, S_+, S_- 的关系. 当 S_+, S_- 的绝对值越近, 即 S_d 越小, SU 则越大; 当 S_+, S_- 的绝对值越远, 即 S_d 越大, SU 则越小.

图 2(b) 以 4 个不同的 S_0 取值为例说明 SU, S_d, S_0 的关系. 将 S_0 设置为区间 $(0, 0.1]$ 内的值更为合理, 如果 S_0 再变大 (如 $S_0=0.2$), 将导致 $S_d \rightarrow 0$ 时的 SU 快速降低 (如 $SU=0.414$), 两者不相符.

3 基于决策粗糙集的否定句情感分类

3.1 否定句的特征表示

设计 6 个特征表示否定句, 其中 1 个为情感不确定性度量特征 SU , 见式(5); 其余 5 个详述如下.

1) 初始情感极性特征

句子的极性绝大多数情况依赖于句子的情感值, 即 $Sentiment(sent) = \sum_{k=1}^m Sentiment'(cla_k)/m$. 根据 $Sentiment(sent)$ 和 0 的大小关系获取初始情感极性特征 (initial polarity, IP), IP 的取值为

$$IP(sent) = \begin{cases} 1, & Sentiment(sent) > 0, \\ 0, & Sentiment(sent) = 0, \\ -1, & Sentiment(sent) < 0. \end{cases} \quad (6)$$

2) 独立否定特征

否定词语本身在一定程度上能够体现情感. 不修饰任何情感词语的否定词语称为独立否定词语.

定义 7. 对于子句 cla_k 中的否定词语 neg , 若 $Scope(neg) = \emptyset$, 则称 neg 为独立否定词语.

表 2 中的子句标记 Single-Neg 说明子句含有独立否定词语. 将句子中的独立否定词语的数量作为独立否定特征 (single negation, SN), SN 的取值近似为

$$SN(sent) = \sum_{k=1}^m 1\{\text{Tag}(cla_k) = \text{Single-Neg}\}, \quad (7)$$

其中, $1\{\cdot\}$ 表示大括号中的式子成立时取 1, 否则取 0.

3) 连续标点特征

用户在发表观点时连续重复使用标点符号, 在一定程度上体现情感, 如“...”可以表达“无语”的意思, “!!!”可以表达“谴责”的意思.

表 2 中的子句标记 Single-Punc 说明句子含有连续的标点. 将句子中标点的连续次数作为连续标点特征 (successive punctuations, SP), SP 的取值近似为

$$SP(sent) = \sum_{k=1}^m 1\{\text{Tag}(cla_k) = \text{Single-Punc}\}. \quad (8)$$

4) 句类特征

句类是根据句子的语气功能划分的句子类型,如陈述句、祈使句、疑问句、感叹句。疑问句或者感叹句在一定程度上也体现情感,特别是负面情感。直接用句末问号或者语气词“吗”标记疑问句,用句末感叹号或者语气词“啊”标记感叹句。

设 Q 表示疑问句, E 表示感叹句, O 表示其他句类, $sent_{last}$ 表示句子 $sent$ 末尾的词语或者标点符号。将句子是否是疑问句或感叹句作为句类特征 (sentence type, ST), ST 的取值为

$$ST(sent) = \begin{cases} Q, & sent_{last} = \text{吗} \text{ 或 } sent_{last} = ?, \\ E, & sent_{last} = \text{啊} \text{ 或 } sent_{last} = !, \\ O, & \text{其他.} \end{cases} \quad (9)$$

5) 显著副词特征

否定句中的一些副词和情感极性存在很大的关联性,称这些副词为显著副词。将句子中是否出现显著副词作为显著副词特征 (salient adverb, SD)。

CHI 特征选择方法表现良好,但是存在忽略负相关和低频倾向缺点。 CDF 特征选择方法则将类间集中度、类内分散度和类内平均频度三者相乘作为特征评价函数^[22],但是未考虑三者的关系及权重。因此,提出加权 CDF (weighted CDF , $WCDF$) 特征选择方法,将类内分散度和类内平均频度联合且弱化相对于类间集中度的权重。

定义 8. 词语 t 对于类别 c 的 $WCDF$ 值定义为

$$WCDF(t, c) = \frac{A_{t,c}}{A_{t,c} + B_{t,c}} \times \left(\frac{A_{t,c}}{A_{t,c} + C_{t,c}} \right)^{\frac{A_{t,c}}{TF_{t,c}}}, \quad (10)$$

其中, $A_{t,c}$ 是属于 c 类且包含 t 的文档频数, $B_{t,c}$ 是不属于 c 类但包含 t 的文档频数, $C_{t,c}$ 是属于 c 类但不包含 t 的文档频数, $TF_{t,c}$ 是 c 类文档中 t 的总次数。 $A_{t,c}=0$, 则 $TF_{t,c}=0$, 定义式(10)为 0。

对于多类问题, 分别计算 t 对于每个类别的 $WCDF$ 值, 然后取最大值作为 t 的 $WCDF$ 值, 即 $WCDF(t) = \max_{\text{所有}c} \{WCDF(t, c)\}$ 。

使用 $WCDF$ 特征选择方法抽取若干显著副词, 其集合记为 SDs 。设 $BoW(sent)$ 表示句子 $sent$ 的词袋, 则显著副词特征 SD 的取值为

$$SD(sent) = \begin{cases} T, & BoW(sent) \wedge SDs \neq \emptyset, \\ F, & BoW(sent) \wedge SDs = \emptyset. \end{cases} \quad (11)$$

3.2 决策粗糙集分类器

将 6 个特征作为条件属性, 句子的最终情感极性作为决策属性, 得到情感句决策表。

定义 9. 情感句决策表形式化为四元组 $SDT = (U, C \cup D, V, f)$, 其中: U 称为论域, 即句子的非空有限集合; $C = \{IP, SU, SN, SP, ST, SD\}$ 称为条件属性集合; $D = \{FP\}$ 称为决策属性集合, 只含有唯一的属性, 即句子的最终情感极性 (final polarity, FP); $V = \bigcup V_a (\forall a \in C \cup D)$, V_a 表示属性 a 的取值集合; $f = \{f_a | f_a : U \rightarrow V_a\}$, f_a 表示属性 a 的信息函数。

设 1 个状态集合 $\Omega = \{X, \neg X\}$ (X 表示褒义状态), 1 个动作集合 $A = \{a_P, a_B, a_N\}$ (分别表示赋予对象褒义、中性和贬义极性), 不同状态下采取不同动作会产生不同的损失, 如表 3 所示, $\lambda_{NN} \neq 0$ 是因为非褒义状态下赋予贬义时存在中性误分的代价。

Table 3 Loss Function in DTRS

表 3 决策损失函数 (u 是单位损失)

Action	State	
	X	$\neg X$
a_P	$\lambda_{PP} = 0$	$\lambda_{PN} = 5u$
a_B	$\lambda_{BP} = 1.5u$	$\lambda_{BN} = 2u$
a_N	$\lambda_{NP} = 3u$	$\lambda_{NN} = u$

决策粗糙集是更具一般性的概率粗糙集模型, 用概率阈值 α 和 $\beta (0 \leq \beta < \alpha \leq 1)$ 定义正域、负域和边界域^[23], 分别为

$$\begin{aligned} POS_B(X) &= \{x \in U | Pr(X | [x]_B) \geq \alpha\}, \\ NEG_B(X) &= \{x \in U | Pr(X | [x]_B) \leq \beta\}, \end{aligned} \quad (12)$$

$$BND_B(X) = \{x \in U | \beta < Pr(X | [x]_B) < \alpha\},$$

其中, $B \subseteq C \cup D$, $Pr(X | [x]_B)$ 表示对象 x 所在等价类 $[x]_B$ 属于状态 X 的概率。根据式(13)计算出 2 个阈值为 $\alpha = 0.67$, $\beta = 0.4$ 。

$$\begin{aligned} \alpha &= \frac{\lambda_{PN} - \lambda_{BN}}{(\lambda_{PN} - \lambda_{BN}) + (\lambda_{BP} - \lambda_{PP})}, \\ \beta &= \frac{\lambda_{BN} - \lambda_{NN}}{(\lambda_{BN} - \lambda_{NN}) + (\lambda_{NP} - \lambda_{BP})}. \end{aligned} \quad (13)$$

设 $Des(x) = \bigwedge_{a \in C} (a = f_a(x))$ 是句子 x 的描述, 其中 $C' \subseteq C$, 则否定句情感的决策粗糙集分类器为

$$h_{SCNS-DTRS}(x) = \begin{cases} 1, & Des(x) \rightarrow x \in POS_C(X), \\ 0, & Des(x) \rightarrow x \in BND_C(X), \\ -1, & Des(x) \rightarrow x \in NEG_C(X). \end{cases} \quad (14)$$

由于决策粗糙集引入了决策类与等价类的概率包含关系, 决策粗糙集的正域随属性变化具有非单调性, 则正域约简中的正域保持性很难成立。Li 等人^[24]以正域全局重要度为启发式信息实现决策正域约简, 没有考虑属性之间的相关性。因此, 将决策

相关程度作为新的启发式信息，并提出基于决策相关程度的决策正域约简算法，详见算法 2。

定义 10. 给定情感句决策表 $SDT = (U, C \cup D, V, f)$ ，条件属性 $a \in C$ 的决策相关程度定义为

$$\rho(a) = \left| \frac{\text{Cov}(a, D)}{\sqrt{\text{Var}(a)} \sqrt{\text{Var}(D)}} \right|, \quad (15)$$

其中， Var 表示方差， Cov 表示协方差。

算法 2. 基于决策相关程度的决策正域约简。

输入：情感句决策表 $SDT = (U, C \cup D, V, f)$ ；

输出：决策正域约简 R 。

- ① $R \leftarrow \emptyset$;
- ② for each $a \in C$
- ③ 根据式(15)计算决策相关程度 $\rho(a)$;
- ④ end for
- ⑤ 对条件属性按照决策相关程度从大到小排序，记作 S ;
- ⑥ while $|POS_R(D)| < |POS_C(D)|$
- ⑦ 取 S 中的第 1 个属性，记作 a ;
- ⑧ $R = R \cup \{a\}$;
- ⑨ $S = S - \{a\}$;
- ⑩ end while
- ⑪ for each $r \in R$
- ⑫ if $|POS_{R-\{r\}}(D)| \geq |POS_R(D)|$
- ⑬ $R = R - \{r\}$;
- ⑭ end if
- ⑮ end for
- ⑯ 返回 R .

4 实验结果与分析

4.1 实验数据

否定句数据集包括：第 5 届中文倾向性分析评测的否定句情感分类任务的语料，记作 COAE，标注汽车和电子产品 2 个领域各 1 200 句，均为否定句；中国科学院计算技术研究所谭松波的中文情感挖掘语料，使用正负类各 2 000 句的书籍和电脑评论，其中否定句占 68.5%，记作 TANC。详细信息如表 4 所示：

Table 4 Data Sets of Negative Sentences

表 4 否定句数据集

Corpus	Domain	Positive	Neutral	Negative	Total
COAE	Digital	382	188	630	2 400
	Car	162	350	688	
TANC	Book	1 542	0	1 475	5 480
	Computer	968	0	1 495	

4.2 实验设置

除否定句的情感分类之外，还有若干实验任务：否定辖域窗口大小的设定；显著副词的抽取；特征的相关性分析及有效性分析。这些任务将以 COAE 语料为例具体说明。

在 COAE 和 TANC 语料上，将 SCNS-DTRS 和 3 类方法的性能进行对比。1) 将否定句作为一般句子处理且不采用 DTRS，如 SO-CAL^[3], ME^[5], KNN^[6], NB^[6], SVM^[6]，其中 SO-CAL 以初始情感极性作为分类结果；2) 将否定句作为一般句子处理且采用 DTRS，如 TWDSC^[15]；3) 直接处理否定句且不采用 DTRS，如 TJOMS^[10]。SCNS-DTRS 则属于直接处理否定句且采用 DTRS 的方法。

采用微平均 F1(Micro-F1)、宏平均 F1(Macro-F1) 和准确率(Accuracy)这 3 个指标评价整体的分类性能。Micro-F1 是合并所有极性类的分类结果再计算 F1 值；Macro-F1 是对每个极性类计算 F1 值再求平均。

4.3 否定辖域窗口大小的设定

COAE 语料中否定词语出现 2 992 次，其中修饰情感词语的达 1 196 次，不修饰情感词语的达 1 796 次(最常用的 4 个依次是“不”、“没有”、“没”、“不是”，累计约占 80%)。统计同一子句中的否定词语和情感词语的距离(平均值 2.84、标准差 1.52)，按照平均距离排序，列出大于平均值的否定词语，如表 5 所示：

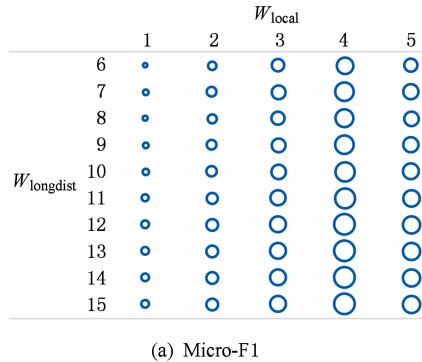
Table 5 Distance Between Negation and Sentiment Words

表 5 否定词语与情感词语的距离分布

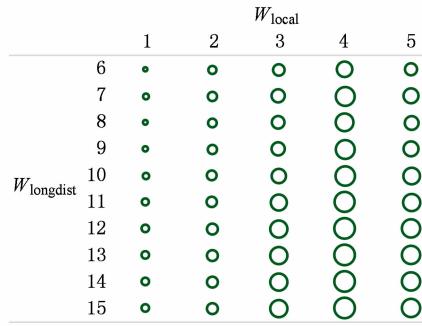
Negation Word	Average Distance	Maximum Distance	Negation Word	Average Distance	Maximum Distance
难道	8.0	8	不会	3.5	10
不像	5.8	7	不能	3.4	14
未	5.4	16	没有	3.3	15
别	4.6	11	并不	3.2	10
不比	4.3	10	不用	3.0	5
未必	4.0	4	尚未	3.0	3
无法	3.6	15	没	2.9	13

根据平均值和标准差计算 95% 单侧置信区间上限为 5.34，因此以窗口大小 5 作为局部否定和长距离否定的界限。从表 5 中选择最大距离大于 5 的词语作为长距离否定词语，如“难道”、“没有”、“没”等。

设局部否定辖域窗口大小 W_{local} 从 1~5、长距离否定辖域窗口大小 $W_{longdist}$ 从 6~15, 两两组合下的 SCNS-DTRS 的分类性能如图 3 所示, 圆的大小代表评价指标的大小。当 $W_{local}=4$ 且 $W_{longdist}$ 为 12, 13, 14 或 15 时, 分类性能最优。因此, 实验设置 $W_{local}=4$, $W_{longdist}=15$ 。



(a) Micro-F1



(b) Macro-F1

Fig. 3 Classification performance with different window sizes for negation scope.

图 3 不同否定辖域窗口大小下的分类性能

4.4 显著副词的抽取

对 COAE 语料(不考虑中性)使用不同特征选择方法抽取显著副词, 同时给出特征评价函数值对应的情感极性, 说明副词与哪种情感极性关联性高。抽取排名前 50 的副词, 如图 4 所示。字体大小代表特征评价函数值, 颜色代表副词关联的极性, 深色(红色)关联贬义, 浅色(绿色)关联褒义。

这些副词与贬义关联的数量明显高于褒义; CDF 选择的副词和 WCDF 选择的副词存在排序的差别, 但是重叠程度很高; CHI 选择的副词效果不好, 如“暂时”、“曾经”, 且副词关联的极性也不合理, 如“很”关联贬义、“居然”关联褒义。

对 50 个副词筛选得到显著副词集合 SDs , 共 12 个:“很”、“太”、“都”、“根本”、“居然”、“竟然”、“非常”、“绝对”、“不够”、“一直”、“至少”、“比较”。

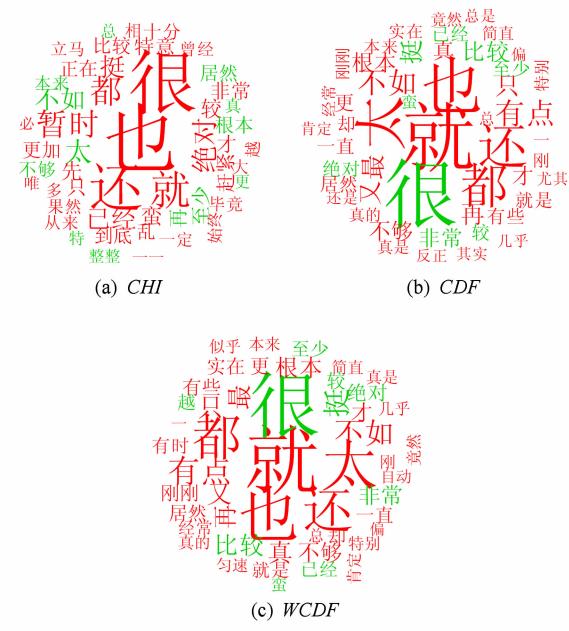


Fig. 4 Salient adverbs with different feature selection methods.

图 4 不同特征选择方法下的显著副词

4.5 特征的相关性分析

在 6 个特征中, SU , SN , SP 是连续值, 需要离散化。 SU : (0, 0.256) 为低, [0.256, 0.768) 为中, [0.768, 1) 为高; SN 或 SP : 0 为无, [1, 3) 为少, [3, ∞) 为多。

图 5 采用相关系数图对特征之间的相关性进行分析。下三角单元格: 斜线(蓝色)表示正相关, 反斜线(红色)表示负相关, 颜色越深则相关性越大, 相关性接近于 0 则基本无色; 上三角单元格: 顺时针(蓝色)填充表示正相关, 逆时针(红色)填充表示负相关, 被填充的饼图面积表示相关性大小, 相关性接近于 0 则基本无填充。

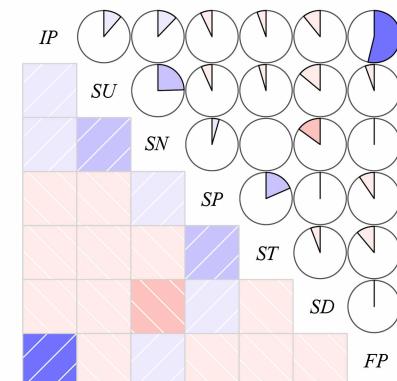


Fig. 5 Correlation coefficients between features.

图 5 特征之间的相关系数

IP, FP 具有很大的正相关性(相关系数是 0.54),说明初始情感极性特征 *IP* 最重要; *SN, SU* 具有较大的正相关性(相关系数是 0.25),说明句子中独立否定越多则识别出情感词语的可能性越小; *SD, SU* 具有较大的负相关性(相关系数是 -0.14),说明句子含有显著副词时倾向于表达贬义色彩,与图 4 的结果一致; *SP, ST* 的相关系数是 0.18,说明连续标点中以出现连续感叹号居多. 条件属性之间的相关性总体不大,说明设计的特征冗余性很小.

4.6 特征的有效性分析

对图 5 中的 6 个条件属性和决策属性 *FP* 的相关系数取绝对值得到决策相关程度,按照大小进行排序并与正域全局重要度比较,如表 6 所示. 两者给出的排序总体接近, *IP, ST, SP* 位列前 3. 不同之处在于:*SU* 的决策相关程度高于 *SD, SN*; *SD, SU* 的正域全局重要程度非常弱. 因此,正域全局重要度不适宜,而决策相关程度作为启发式信息,能够更加突出 *SU* 的作用并提升 *SD* 的作用.

Table 6 Comparison Between Decision Correlation Degree and Positive Region Significance

表 6 决策相关程度和正域全局重要度的对比

Feature	Decision Correlation Degree	Positive Region Significance
<i>IP</i>	0.5381	0.3700
<i>ST</i>	0.1113	0.1317
<i>SP</i>	0.0948	0.0883
<i>SU</i>	0.0552	0.0004
<i>SD</i>	0.0147	0.0004
<i>SN</i>	0.0134	0.0079

图 6 从分类角度说明特征的有效性. 纵坐标从下往上依次为: 考虑全部特征的 SCNS-DTRS 分类

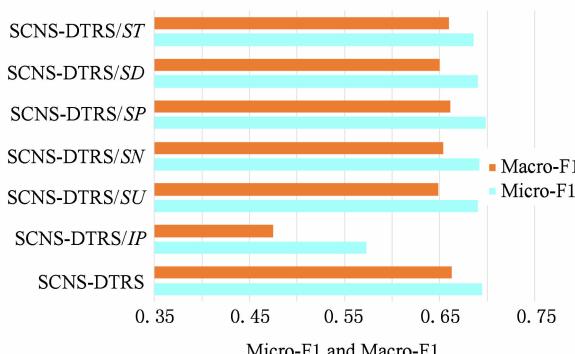


Fig. 6 Comparison of the effect of features in sentiment classification.

图 6 特征对情感分类的有效性对比

性能,只删除特征 *IP, SU, SN, SP, SD, ST* 后的 SCNS-DTRS 分类性能. 分类性能的变化说明,对情感分类作用最大的是 *IP*,与图 5 的分析一致;其次就是 *SU*. 因此,情感不确定性的度量确实能够辅助情感分类.

4.7 否定句情感分类性能的对比

在 COAE 语料上,SCNS-DTRS 生成的情感分类决策规则共计 57 条,列举 6 条如表 7 所示:

Table 7 Decision Rules for Sentiment Classification of Negative Sentences

表 7 否定句的情感分类决策规则

No.	Decision Rule
R1	$IP=0 \wedge SP=\text{多} \rightarrow FP=-1$
R2	$IP=0 \wedge SN=\text{多} \wedge SP=\text{少} \wedge ST=O \rightarrow FP=-1$
R3	$IP=0 \wedge SN=\text{多} \wedge ST=Q \rightarrow FP=0$
R4	$IP=0 \wedge SN=\text{无} \wedge ST=E \wedge SD=T \rightarrow FP=-1$
R5	$IP=1 \wedge SP=\text{少} \wedge ST=Q \rightarrow FP=-1$
R6	$IP=1 \wedge SU=\text{高} \wedge SN=\text{少} \wedge SP=\text{少} \rightarrow FP=-1$

规则 R1: 情感值为 0 的句子若出现很多连续标点,则判定贬义;

规则 R2: 情感值为 0 的非疑问和感叹句若出现很多独立否定和少量连续标点,则判定贬义;

规则 R3: 情感值为 0 的疑问句若出现很多独立否定,则判定中性;

规则 R4: 情感值为 0 的感叹句若不出现独立否定但是出现显著副词,则判定贬义;

规则 R5: 情感值大于 0 的疑问句若出现少量连续标点,则判定贬义,绝大多数属于反问;

规则 R6: 情感不确定性高的句子即使情感值大于 0,若出现少量独立否定和连续标点,则判定贬义,解决句子正负情感绝对值接近时的误分问题.

这些规则是自动生成的,而且通过 *SU, SD* 等特征提高规则的可靠性,如规则 R2, R3 是对 TJOMS 中人工规则的细化.

不同方法在 2 个语料上的情感分类性能如图 7 所示. TWDSC 直接采用文献 [15] 的结果,只有 TANC 语料中电脑领域的准确率. 在 TANC 语料上,SCNS-DTRS 的准确率非常接近 TWDSC,且反映的是书籍和电脑 2 个领域的结果. 从 3 个评价指标上看,与 TJOMS 相比,SCNS-DTRS 的分类性能约提高了 2 个百分点;与 SO-CAL, ME, KNN, NB, SVM 相比,SCNS-DTRS 的优势更为明显. 总之,SCNS-DTRS 对否定句的情感分类是有效的,因为

既包含词典方法(即初始情感极性特征),又包含以情感不确定性、独立否定、显著副词等作为特征的机器学习方法.

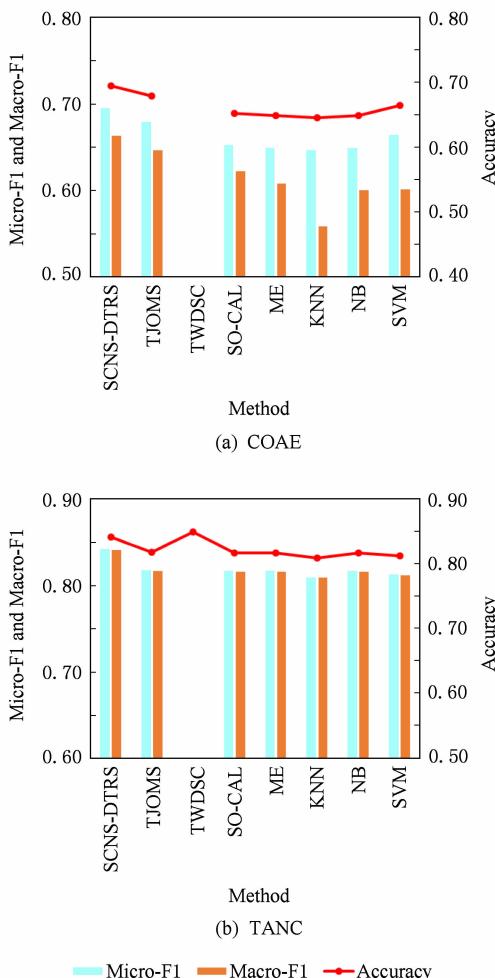


Fig. 7 Comparison of different sentiment classification methods.

图 7 不同情感分类方法的性能对比

5 结 论

将否定词语修饰和不修饰情感词语情况下的否定句情感分类问题纳入统一的模型 SCNS-DTRS. 从不确定性角度出发,提出基于 KL 散度的句子情感不确定性度量方法,并融合多个特征构建基于决策粗糙集的否定句情感分类器. 在 2 个否定句数据集上的实验表明,SCNS-DTRS 在否定句情感分类任务中具有良好的性能. 但是,否定句的特征是人工设计的,而且数量有限. 对于不同类型的句子,特征不仅不同,而且特征的重要程度也不同. 如何自动构造更为有效且数量适宜的特征将作为进一步研究的内容.

参 考 文 献

- [1] Liu B. Sentiment analysis and opinion mining [J]. Synthesis Lectures on Human Language Technologies, 2012, 5(1): 1-167
- [2] Zhao Yanyan, Qin Bing, Liu Ting. Sentiment analysis [J]. Journal of Software, 2010, 21(8): 1834-1848 (in Chinese) (赵妍妍, 秦兵, 刘挺. 文本情感分析[J]. 软件学报, 2010, 21(8): 1834-1848)
- [3] Taboada M, Brooke J, Tofiloski M, et al. Lexicon-based methods for sentiment analysis [J]. Computational Linguistics, 2011, 37(2): 267-307
- [4] Feng Shi, Fu Yongchen, Yang Feng, et al. Blog sentiment orientation analysis based on dependency parsing [J]. Journal of Computer Research and Development, 2012, 49 (11): 2395-2406 (in Chinese) (冯时, 付永陈, 阳锋, 等. 基于依存句法的博文情感倾向分析研究[J]. 计算机研究与发展, 2012, 49(11): 2395-2406)
- [5] Pang B, Lee L, Vaithyanathan S. Thumbs up? Sentiment classification using machine learning techniques [C] //Proc of the 2002 Conf on Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2002: 79-86
- [6] Tan Songbo, Zhang Jin. An empirical study of sentiment analysis for Chinese documents [J]. Expert Systems with Applications, 2008, 34(4): 2622-2629
- [7] Chen Zhancheng, Zou Bowei, Zhu Qiaoming, et al. The construction of Chinese negation and uncertainty identification corpus [G] //LNCS 8229: Proc of the 14th Chinese Lexical Semantics Workshop. Berlin: Springer, 2013: 226-231
- [8] Jia L F, Yu C, Meng W Y. The effect of negation on sentiment analysis and retrieval effectiveness [C] //Proc of the 18th ACM Conf on Information and Knowledge Management. New York: ACM, 2009: 1827-1830
- [9] Zhu X D, Guo H Y, Mohammad S, et al. An empirical study on the effect of negation words on sentiment [C] //Proc of the 52nd Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2014: 304-313
- [10] Zhang Zhifei, Li Yang, Wei Zhihua, et al. Sentiment analysis of Chinese negative sentences [C] //Proc of the 5th Chinese Opinion Analysis Evaluation Workshop. Beijing: Chinese Information Processing Society of China, 2013: 111-120 (in Chinese) (张志飞, 李飚, 卫志华, 等. 中文否定句的情感倾向性分析 [C] //第 5 届中文倾向性分析评测会议. 北京: 中国中文信息学会, 2013: 111-120)
- [11] Pawlak Z, Grzymala-Busse J, Slowinski R, et al. Rough sets [J]. Communications of the ACM, 1995, 38(11): 88-95
- [12] Wang Suge, Li Deyu, Wei Yingjie. A method of text sentiment classification based on weighted rough membership [J]. Journal of Computer Research and Development, 2011, 48(5): 855-861 (in Chinese)

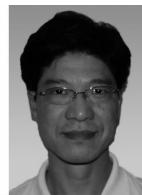
- (王素格, 李德玉, 魏英杰. 基于赋权粗糙隶属度的文本情感分类方法[J]. 计算机研究与发展, 2011, 48(5): 855-861)
- [13] Zhang Zhifei, Miao Duoqian, Yue Xiaodong, et al. Sentiment analysis with words with strong semantic fuzziness [J]. Journal of Chinese Information Processing, 2015, 29(2): 68-78 (in Chinese)
- (张志飞, 苗夺谦, 岳晓冬, 等. 强语义模糊性词语的情感分析[J]. 中文信息学报, 2015, 29(2): 68-78)
- [14] Yao Y Y, Wong S K M. A decision theoretic framework for approximating concepts [J]. International Journal of Man-Machine Studies, 1992, 37(6): 793-809
- [15] Zhou Zhe, Zhao Weibin, Shang Lin. Sentiment analysis with automatically constructed lexicon and three-way decision [G] //LNAI 8818: Proc of the 9th Int Conf on Rough Sets and Knowledge Technology. Berlin: Springer, 2014: 777-788
- [16] Zhang Zhifei, Wang Ruizhi. Applying three-way decisions to sentiment classification with sentiment uncertainty [G] //LNAI 8818: Proc of the 9th Int Conf on Rough Sets and Knowledge Technology. Berlin: Springer, 2014: 720-731
- [17] Wu Yingcai, Wei Furu, Liu Shixia, et al. OpinionSeer: Interactive visualization of hotel customer feedback [J]. IEEE Trans on Visualization and Computer Graphics, 2010, 16(6): 1109-1118
- [18] Rao Yanghui, Li Qing, Liu Wenyin, et al. Progress of generating sentiment lexicons from text in social media [J]. Scientia Sinica Informationis, 2014, 44(7): 825-835 (in Chinese)
- (饶洋辉, 李青, 刘文印, 等. 公众文本之情感词典研究进展 [J]. 中国科学: 信息科学, 2014, 44(7): 825-835)
- [19] Xu Linhong, Lin Hongfei, Pan Yu, et al. Constructing the affective lexicon ontology [J]. Journal of the China Society for Scientific and Technical Information, 2008, 27(2): 180-185 (in Chinese)
- (徐琳宏, 林鸿飞, 潘宇, 等. 情感词汇本体的构造[J]. 情报学报, 2008, 27(2): 180-185)
- [20] Hogenboom A, van Iterson P, Heerschap B, et al. Determining negation scope and strength in sentiment analysis [C] //Proc of the 2011 IEEE Int Conf on Systems, Man, and Cybernetics. Piscataway, NJ: IEEE, 2011: 2589-2594
- [21] Wilson T, Wiebe J, Hoffmann P. Recognizing contextual polarity in phrase-level sentiment analysis [C] //Proc of the 2005 Conf on Human Language Technology and Empirical Methods in Natural Language Processing. Stroudsburg, PA: ACL, 2005: 347-354
- [22] Xiong Zhongyang, Jiang Jian, Zhang Yufang. New feature selection approach (CDF) for text categorization [J]. Journal of Computer Applications, 2009, 29(7): 1755-1757 (in Chinese)
- (熊忠阳, 蒋健, 张玉芳. 新的 CDF 文本分类特征提取方法研究[J]. 计算机应用, 2009, 29(7): 1755-1757)
- [23] Yao Y Y. Three-way decisions with probabilistic rough sets [J]. Information Sciences, 2010, 180(3): 341-353
- [24] Li Huaxiong, Zhou Xianzhong, Zhao Jiabao, et al. Non-monotonic attribute reduction in decision-theoretic rough sets [J]. Fundamenta Informaticae, 2013, 126(4): 415-432



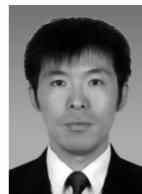
Zhang Zhifei, born in 1986, PhD from Tongji University and postdoctoral fellow in University of Montreal. Student member of China Computer Federation. His main research interests include natural language processing and machine learning.



Miao Duoqian, born in 1964. Professor and PhD supervisor in Tongji University. Distinguished member of China Computer Federation. His main research interests include rough sets, granular computing, and machine learning(dqmiao@tongji.edu.cn).



Nie Jianyun, born in 1963. Professor and PhD supervisor in University of Montreal. His main research interests include information retrieval and natural language processing(nie@iro.umontreal.ca).



Yue Xiaodong, born in 1980. PhD from Tongji University and lecturer in Shanghai University. Member of China Computer Federation. His main research interests include soft computing and data mining (cyswantfly@gmail.com).