

文章编号:0253-2778(2016)3-0253-06

一种基于框架语义的专项新闻检索方法研究

谢兴生¹, 周邦定¹, 熊 焰²

(1. 中国科学技术大学信息科学技术学院自动化系, 安徽 合肥 230027;
2. 中国科学技术大学计算机科学院, 安徽 合肥 230027)

摘要:提出了一种专项新闻语义框架以及借助该框架识别来自动检索、分类客户负面新闻的方法。与传统基于词的语义框架不同, 负面新闻事件语义框架针对每个单一语境负面新闻事件子类来定义语义框架。通过构建框架知识库、领域词汇本体库及与框架关联的样本句子库, 融合利用依存语法、词性标记技术和植入任务型代价的对数线性分类建模技术, 实现了负面事件语义框架的自动识别。测试表明, 该方法实用、高效, 对知识库中已预定义的负面事件新闻类识别, 在准确率、召回率和处理效率上都有很好的表现。

关键词:语义框架; 词性标注; 依存语法; 专项新闻

中图分类号: TP311 **文献标识码:** A doi:10.3969/j.issn.0253-2778.2016.03.011

引用格式: XIE Xingsheng, ZHOU Bangding, XIONG Yan. Research on an automatic retrieval method for special topic news based on semantic frame[J]. Journal of University of Science and Technology of China, 2016, 46(3):253-258.

谢兴生, 周邦定, 熊 焰. 一种基于框架语义的专项新闻检索方法研究[J]. 中国科学技术大学学报, 2016, 46(3):253-258.

Research on an automatic retrieval method for special topic news based on semantic frame

XIE Xingsheng¹, ZHOU Bangding¹, XIONG Yan²

(1. Department of Automation, University of Science & Technology of China, Hefei 230027, China;
2. Department of Computer Science and technology, University of Science and Technology of China, Hefei 230027, China)

Abstract: A novel negative news retrieving semantic frame (NNFrame) and its identification were presented. Different from traditional semantic FrameNets, which were defined based on word-sense disambiguation, NNFrames were defined on each subcategory of negative news with a single semantic context. By constructing the NNFrame knowledge base, domain ontology repository, and a collection of annotated example sentences for each NNFrame, that a method is described for identifying NNFrame by a task-specific extended conditional log-likelihood model, which takes dependency-syntax structure representations, and the part of speech tags as input. This approach is practical, efficient, and can achieve state-of-the-art results on precision/recall metrics for identification and classification of negative news whose subcategories are pre-defined in the NNFrame knowledge base.

Key words: semantic frame; part of speech; dependency-syntax; special topic news

收稿日期:2015-01-29;修回日期:2016-02-25

作者简介:谢兴生(通讯作者),男,1965年生,博士/副教授,研究方向:智能信息处理、人工智能与模式识别。Email:xshxie@ustc.edu.cn

0 引言

客户或自己的负面新闻对银行、保险、风险投资类机构的管理决策有重要参考价值。现有通用搜索引擎一般都不提供负面新闻筛选功能，而人工筛选效率低、工作量大，不能满足信息需求。

负面专项新闻是一种情感倾向文本。目前，倾向文本识别目标大多集中在舆情评论，主要方法有两大类：一类是基于情感词构造分类器法^[1]，这类方法实现简单，但因未考虑情感词出现位置和语境，准确性不高；另一类是语义分析法，对句子做语义分析并结合情感词典来识别。早期全功能自然语言处理（natural language processing, NLP）句子理解、语法和语义模板等由于语义界限过泛，难以应用^[2-3]。近年来，以确定谓词及其关联成份识别为主要任务的语义角色标注（part OF speech, POS）技术，由于其针对性强，并具有较好实用性，已成为 NLP 研究的一个热点^[4]。出现了 FrameNet^[5]、PropBank^[6-7]、CFrameNet^[8] 等一些影响较大的开源语义标注工程。

为绕过语义过泛、难以界定问题，Fillmore 最早提出了语义框架概念：将一组语义相近的谓词归为一类，共享相同的语义场景。由 Bake 等主持的 FrameNet 1.3 资源项目^[5]以单词义定义框架，限定每个框架可共享的语义角色，并提供了一套示例标注语料库。PropBank 在 Penn Treebank 标注语料库的基础上，增加一层语义角色标注资源库^[6]。PropBank 目标词只定义了动词，但词汇覆盖面远大于 FrameNet 1.3。目前，基于语义框架的 POS 标注，已被广泛用于信息抽取、文本摘要生成和文本分类^[9]。

本文在传统基于词的语义框架基础上，提出了一种负面新闻检索语义框架（negative news frame, NNFrame）。它针对每个负面新闻子类定义语义框架。通过构建框架知识库、领域词汇本体库，及与框架关联的样本句库，融合利用依存语法、词性标记及植入任务型代价惩罚函数的最大软间隔对数线性分类建模技术，实现了 NNFrame 的自动识别。

1 负面新闻识别方法

1.1 关键句群提取

对新闻类网页，首先要去除所有 html 标签，提取内容文本；然后根据中文标点，结合主题关键词，

提取关键句群。令 $M_1 = (x_1 \cdots x_n)$ 为句子码字集， x_k 是其第 k 个码字分量； $M_2 = (q_1 \cdots q_m)$ 为查询式 q 对应的码字集， q_j 为其第 j 个码字分量，句子文本与查询关键词集相似度计算采用汉明距离^[1,3]：

$$\text{sim}(M_1, M_2) = 1 - (\sum_{k=1}^n x_k \oplus y_k) / n \quad (1)$$

1.2 依存语法分析

依存语法是一种浅层语法，侧重描述句子中词之间的依存关系，将支配词和从属词联系起来^[10-12]。由于其结点数少，且可标注词性，具有表示简洁、准确性好等特点，常用作语义分析的基础。依存语法中引入了有向图、语法树等概念，其形式定义如下：

定义 1.1 节点词。可作为句中某种确定成分（主/谓/宾/定/状/补）的简单词语或词组。

定义 1.2 依存边。若句中两节点词 g 与 d 之间存在依存关系，其中 g 是支配词， d 是依存词，则 g 与 d 间构成一依存对，用一条由 d 指向 g 的有向边 l 表示，记为 $g \xrightarrow{l} d$ 。

定义 1.3 依存图。句子 x 的依存图是一个 $\langle x, E \rangle$ 对， $E \in x \times x \times L$ 对应形为 $\langle g, d, l \rangle$ 的传递依存边集。

定义 1.4 依存树。是满足投影性约束，即独根结点、单父节点、无交叉边的无环句子依存图。

图 1 是一简单的句子依存图标注示例。依存语法表示技术及产品现已相对成熟^[11]。本文用依存语法分析作为预测模型输入。

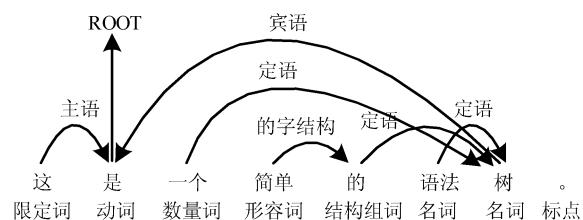


图 1 依存语法树示例

Fig. 1 A simple example of dependency syntax tree

1.3 负面新闻语义框架

与现有针对单语义定义框架法不同，本文针对单语境负面新闻子类，定义粗粒度事件级语义框架。

定义 1.5 NNFrame。这是一个 $\langle f_i, \text{frameName}, \text{coreTokens}^0, \text{roleTokens}^0, \text{sampleSentences}, \text{parameters} \rangle$ 六元组，分别表示框架标识、名称、核心根词集、角色根词集、样本句集和参数集。

允许有多个核心词,作为触发某框架目标词;角色词是与核心词共现的、作为句子中其他语法成份的词。框架核心词、角色词都只列出它们的本体根词(上标0)。样本句集是一组绑定到框架的例句,它们将作为框架分类模型训练的正样本。参数集是可动态更新的框架分类模型特征权重参数。图2给出了一个典型的NNFrame语义框架定义示例。

标识	# # #
框架名	亏损
核心词	<亏>, <损>, <负> (根词集)
角色根词集	<p><负面. 程度>/形 副, 例: 严重, 惨, 巨额, 不利, 加剧, 净, ...</p> <p><发生>/动, 例: 开始, 出现, 导致, 陷入, 存在, ...</p> <p><增强>/动词, 例: 增, 升高, 上升, 逾, 超, ...</p> <p><时间段>/名, 例: 年, 季, 长期, ...</p> <p><时间. 持续>/动, 例: 继续, 连续, 累计, 再, ...</p> <p><经营范围>/名 形, 例: 行业, 主业, 项目, 结构, 全线, 局部, 板块, ...</p> <p><经营类>/名 动, 例: 营业, 运营, 财政, 投资, ...</p> <p><资本类>/名 形, 例: 股权, 股票, 资产, 资金, 流动, 固定, 现金, ...</p> <p><警告语>/名 形 动, 例: 风险, 警告, ...</p> <p><数量>/量词, 例: 额度, 元, 千, 万, 亿, ...</p>
样本句集	<p>1) 产能过剩玻璃企业亏损严重 2) 东方航空以64.6亿元的累计亏损位居“累亏公司”榜首 3) 北京城建四公司被指改制前虚增利润, 巨亏7.7亿 4) 2012年第一季度, 航运板块亏损50.6亿元, 经营性现金流水平连续3个季度为负 5) 据北京会计师事务所审计结果, 截至2008年底, 城建四公司已有近8亿元亏空.....</p>

图2 NNFrame语义框架定义示例

Fig. 2 A typical example of NNFrame definition

已定义NNFrame集合构成了本文的框架知识库(NNFrameBases),与其配套的工作库还有领域词本体库、样本句库和模型参数库。

1.4 NNFrame识别

有了与负面新闻分类对应的框架知识库,负面新闻识别就可转化为框架识别问题。识别任务包括利用目标词激发框架,获取候选框架子集,再利用分类器从候选集中识别目标框架。

1.4.1 NNFrame分类器

本文采用对数线性模型构建NNFrame分

类器。

若 $x \in t$ 表示源自一个句子语境的输入词序列, $y \in F_s$ 表示某个预定义NNFrame框架, F_s 是候选框架子集,函数 $f: X \times F \rightarrow \mathbb{R}^d$ 是映射不同 x 对 y 识别贡献分值的 d 维特征向量, w 是与特征向量各分量对应的权重参数,基于特征得分的、并进行指数化和规范化的框架 y 出现条件概率算式为

$$p(y | x, w) = \frac{\exp(w^T \cdot f(x, y))}{\sum_{y' \in F_s} \exp(w^T \cdot f(x, y'))} \quad (2)$$

给定 n 个样本训练集 $\{(x^{(i)}, y^{(i)})\}_{i=1}^n$,基于如下的条件对数似然(conditional log-likelihood, CLL)优化目标函数来训练模型参数 w ^[13].

$$\min_w \sum_{i=1}^n \left\{ -w^T f(x^{(i)}, y^{(i)}) + \log \sum_{y' \in F_s} \exp(w^T f(x^{(i)}, y')) \right\} + \frac{\lambda}{2} \|w\|^2 \quad (3)$$

式中,第一项表征模型参数拟合训练样本的拟合度,而第二项中 $\|w\|^2 = \sum_k w_k^2$ 为 L_2 范数正则项,用以惩罚过大或过拟合的参数值,并可加快解收敛速度。 λ 是决定这两个项相对重要性的超参数,本文通过样本交叉验证法来确定。

Gimpel等^[14]提出了一种在CLL中植入任务型代价函数的、可有效提高精度的最大软间隔(softmax-margin, SMM)增强模型,其修正的目标函数为:

$$\min_w \left\{ \frac{\lambda}{2} \|w\|^2 + \sum_{i=1}^n \left\{ -w^T f(x^{(i)}, y^{(i)}) + \log \sum_{y' \in F_s} \exp(w^T f(x^{(i)}, y')) + \text{cost}(y^{(i)}, y') \right\} \right\} \quad (4)$$

式中, $\text{cost}(y^{(i)}, y)$ 表示因 $y^{(i)}$ 值被误分为 $y' | y' \in F_s \setminus y^{(i)}$ 应加的惩罚性代价函数。对非负的 cost ,SMM是CLL和最小风险目标函数的凸上界^[14]。

本文针对每个框架构建一个分类器,以句子库中属于框架的样本句子为正样本候选集,句库中的其他句子则作为负样本候选集。

1.4.2 NNFrame分类器特征选取方法

每个 $f_k(x, y) (k = 1, \dots, d)$ 对应 d 维空间表达句子语境的一个特征。这里,标签 y 对应一个候选框架, x 可以是句子中谓词或谓词依存链上的一个节点词或节点词的词性。每个特征函数是二元指示函数。若某个 x 与 y 共现,则函数取1,否则取0。本

文分类模型共选用了约 30 个二元特征,表 1 中给出了其中部分特征.

表 1 一些可用于框架识别的特征
Tab. 1 Some features which are used
by NNFrame's frame recognition

输入 x	描述
$t_0 = \text{句子谓词}$	谓词对应的根词是否属于框架 y $\text{ontology}(t_0) \in y. \text{predTokes}^\circ?$
第 1 左依存词 t_{l1} $= \text{left_dep}(t_0)$	$\text{ontology}(t_{l1}) \in y. \text{roleTokes}^\circ?$
$\text{POS}(t_{l1})$	$\text{ontology}(t_{l1}) \in y. \text{roleTokes}^\circ \wedge$ 词性与对应 $y. \text{roleTokes}^\circ$ 相同?
第 2 左依存词 t_{l2} $= \text{left_dep}(t_0 t_1)$	$\text{ontology}(t_{l2}) \in y. \text{roleTokes}^\circ$
$\text{POS}(t_{l2})$	$\text{ontology}(t_{l2}) \in y. \text{roleTokes}^\circ \wedge$ 词性与对应 $y. \text{roleTokes}^\circ$ 相同?
...	...
第 1 右依存词 t_{r1} $= \text{right_dep}(t_0)$	$\text{ontology}(t_{r1}) \in y. \text{roleTokes}^\circ$
...	...
$\text{subj}(t_0)$	$\text{subj}(t_0) \text{ like } \%y. \text{roleTokes}^\circ\%$ 主语相似?
...	...

1.4.3 NNFrame 识别算法

算法 1.1 NNFrame 识别主算法

```
Input: 目标文本;
function IDENTIFY_NNFRAME_MAIN( $T$ )
begin
从目标文本  $T$  提取含标题句的关键句群  $S$ ;
并标识标题句, 及出现在首段、末段句子;
置候选框架集  $F_s \leftarrow \emptyset$ 
for each sentence  $s \in S$  do
    // 调用 NNFrame 识别算法
     $f = \text{IDENTIFY_NNFRAME}(s)$ ;
    if ( $f. id$  非空) then
         $F_s = F_s \oplus f$ 
        if  $s$  是标题句 then
             $F_s(f. id). score += 2.0$  ;
        elseif  $s$  是首段或末段句子 then
             $F_s(f. id). score += 1.5$  ;
        else
             $F_s(f. id). score += 1.0$  ;
    endif
endfor
```

```
endif
将非空  $f. id$  得分更新到  $?S$  ;
end if;
end for;
if  $F_s$  非空 then
    目标文本  $T$  判为负面新闻;
    以得分最高的  $f. name$  为  $T$  的子类别;
end if
end begin;
```

算法 1.2 NNFrame 识别算法

```
Input: 目标句子  $s$ ;
// 调用依存语法分析工具包 API;
// 获取句子  $s$  的谓词/依存词/词性;
function IDENTIFY_NNFRAME( $s$ )
begin
    predTokens = getPredTokens( $s$ );
    初始化候选框架集  $F_s \leftarrow \emptyset$ 
    for each  $pt \in \text{predTokens}$  do
         $f = \text{find_NNFrameBy_PredToken}(\text{ontology}(pt))$ ;
         $F_s = F_s \oplus f$ 
    end for;
    for each  $f \in F_s$  do
        features[] = computeFeature( $f, s$ );
        // 利用公式(2)计算  $f$  的条件概率;
         $f. p = \text{LOGLINEARMODEL\_P}($ 
         $F_s, f. paras, \text{features}[])$ ;
         $F_s(f). p = \max\{f. p, F_s(f). p\}$ ;
    end for;
    return  $f$  with  $\max f. p$  in  $F_s$ ;
end begin;
```

2 算法时间复杂度

本文调用的依存句法分析包采用基于转换算法, 并使用了贪婪策略, 单句子依存解析的时间复杂度为 $O(L^2)$, L 是句子长度^[16]. 运用式(2)进行单句子框架识别计算的时间复杂度是 $O(m^2 d)$, m 是框架库中框架的总数, d 是特征维度, 考虑依存解析的单句子测试时间复杂度为 $O(m^2 d L^2)$. 基于随机梯度下降法训练 CLL, 单样本对权重更新算式为

$$\mathbf{w}_j = \mathbf{w}_j + \delta \{f_j(x, y) - E'_y \sim p(y' | x; \mathbf{w})[f_j(x, y')]\} \quad (5)$$

式中, δ 是学习率, 计算 f_j 特征期望及学习率相关梯度的时间复杂度近似为 $O(m^2 d)$, n 个样本点训练的总时间复杂度为 $O(m^2 dnL^2)$.

3 实验及结果

本文实验语料取自某商业银行 2012 年度针对

其贷款客户人工收集的1 832条负面风险新闻。在对这些负面新闻进行归类及特征研究的基础上,人工选取了其中比较典型或有代表性的1 626则新闻,对其中典型句子进行标识;然后预定义了68个NNFrame框架,并自动采集这1 626则新闻文本中被标识的典型情感句子到句子库,共采集了8 852条情感句子,对每个句子标识所属框架。

对数线性建模采用LIBSVM工具包的对数线性建模工具^[15-16],依存语法分析采用FudanNLP开源项目工具包。用句子库中的3 488条新闻情感句子作为训练集,分别对每个NNFrame进行训练,并将训练结果参数存入框架知识库关联表中。

对应分类效果测试,将8 852条情感例句中去掉3 488条样本例句后,剩下的5 364条,加上本文还另外利用百度新闻搜索引擎,搜索与国内前100强民营企业相关的新闻情感句子近2 508条,共7 872条例句,作为测试样本集,调用本文负面新闻算法进行识别实验,并计算查准率、召回率和F-Score指标^[4]。

3.1 代价函数

本文SMM训练采用任务型代价函数,对给定输入x,正确类别是y,预测分类是 \hat{y} ,分别定义精度错误事件 $A_j = \{y_j = O \wedge \hat{y} \neq O\}$ 、召回错误事件 $B_j = \{y_j \neq O \wedge \hat{y} = O\}$ 和其他预测错误事件 $C_j = \{y_j \neq O \wedge \hat{y} \neq O \wedge \hat{y} \neq y\}$,采用如下的代价函数形式:

$$\text{cost}(y, \hat{y}) = \sum_{k=1}^{m=|\mathcal{Y}|} \alpha I[A_j] + \beta I[B_j] + \gamma I[C_j] \quad (6)$$

式中, $I[\cdot]$ 为频度比,通过选择不同系数 $\alpha / \beta / \gamma$,可对不同类错误施加不同惩罚,本文简单取 $\gamma = 5$, $\beta = 10 - \alpha$,对同组训练/测试样本做多次循环/测试训练:初次训练 $\alpha = 0$,其后每次用前次结果计算代价。当 F_1 表征的精度提高很小或循环次数超过指定次数时,停止迭代。

3.2 结果分析

超参数 λ 对模型精度有一定影响。表2给出了本文采用多重交叉验证确定最优 λ 值后的实验结果。从表2可看出,本文方法识别精度可达90%左右,测试精度接近训练精度,模型泛化能力很强。但测试的召回率明显低于训练的召回率。人工分析漏检样本,发现有相当比例都是因为没有可触发的框

架类。这说明框架知识库、领域本体库的完备性对本文方法有重要影响。

从表2还可看出,植入任务型代价惩罚函数(SMM模型)优于传统的CLL的训练模型,可在不显著增加训练时间和模型复杂度情况下,提高模型训练和测试的精度。图3进一步给出采用相同样本/测试集和最优超参数SMM时,不同任务代价惩罚系数组合对模型的影响。

表2 CLL与SMM模型的实验结果对比

Tab. 2 Comparison of experimental results for CLL and SMM

模型	训练			测试		
	精度	召回率	F1	精度	召回率	F1
CLL	93.38	88.46	90.85	83.47	77.56	80.41
SMM $\alpha = 5$	94.52	89.58	92.03	85.87	80.16	82.92

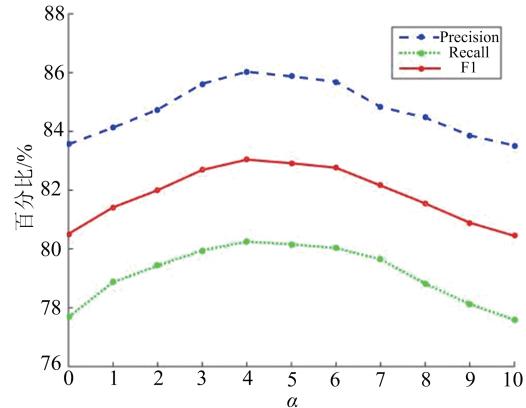


图3 不同代价惩罚系数组合对模型训练精度影响
($\gamma = 5$; $\beta = 10 - \alpha$)

Fig. 3 Impact on the accuracy of model training by combination of cost factors

从图3可看到,通过不同代价惩罚系数组合,可有限度地提高并平衡模型的精度和召回率。

4 结论

通过将负面新闻进行分类,并对每个子类定义语义框架,然后借助框架识别来自动检索、分类负面新闻的方法,具有很好的准确性和识别率。但框架知识库、样本句库、领域本体词库的完备性对本文方法应用效果有重要影响。另外,样本句库中,负样本明显多于正样本,目前实验只是简单随机选择了一定比例的负样本。如何更合理选取训练/测试样本还有待深入研究。

参考文献(References)

- [1] 林政, 谭松波, 程学旗. 基于情感关键句抽取的情感分类研究[J]. 计算机研究与发展, 2012, 49(11): 2376-2382.
LIN Z, TAN S B, CHENG X Q. Sentiment classification analysis based on extraction of sentiment key sentence[J]. Journal of Computer Research and Development, 2012, 49(11): 2376-2382.
- [2] 刘永丹, 曾海泉, 李荣陆, 等. 基于语义分析的倾向性文本过滤[J]. 通信学报, 2004, 25(7): 78-85.
LIU Y D, ZENG H Q, LI R L, et al. Polarity text filtering based on semantic analysis [J]. Journal of China Institute of Communications, 2004, 25 (7): 78-85.
- [3] 苏金树, 张博锋, 徐昕. 基于机器学习的文本分类技术研究进展[J]. 软件学报, 2006, 9(1): 1848-1859.
SU J S, ZHANG B F, XU X. Advances in machine learning based text categorization [J]. Journal of Software, 2006, 9(1): 1848-1859.
- [4] DAS D. Statistical models for frame-semantic parsing [C]// Proceedings of Frame Semantics in NLP: A Workshop in Honor of Chuck Fillmore. Baltimore, USA: ACL Press, 2014:26-29.
- [5] BAKER C F, FILLMORE C J, LOWE J B. The Berkeley FrameNet project[C]// Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics and 17th International Conference on Computational Linguistics, Montréal, Canada: ACM Press, 1998: 86-90.
- [6] PALMER M, GILDEA D, KINGSBURY P. The proposition bank: An annotated corpus of semantic roles[J]. Computational Linguistics, 2005, 31(1): 71-105.
- [7] BAKER C, ELLSWORTH M, ERK K. SemEval-2007 task 19: Frame semantic structure extraction [C]// Proceedings of the 4th International Workshop on Semantic Evaluations. Prague, Czech Republic: ACM Press, 2007: 99-104.
- [8] 牛之贤, 白鹏洲, 段富. 基于框架语义标注的自由文
本信息抽取研究[J]. 计算机工程与应用, 2008, 44 (25): 143-145.
NIU Z X, BAI P Z, DUAN F. Free text information extraction based on frame semantic tagging [J]. Computer Engineering and Application, 2008, 44(25): 143-145.
- [9] HAN L F, WONG D F, CHAO L S, et al. A study of Chinese word segmentation based on the characteristics of Chinese[A]// Lecture Notes in Computer Science, 2013, 8105(1): 111-118.
- [10] PUNYAKANOK V, ROTH D, YIH W T. The importance of syntactic parsing and inference in semantic role labeling[J]. Computational Linguistics, 2008, 34(2): 257-287.
- [11] QIU X P, ZHANG Q, HUANG X J. FudanNLP: A toolkit for Chinese natural language processing[C]// Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics. Sofia, Bulgaria: IEEE Press, 2013: 49-54.
- [12] NIVRE J. Non-projective dependency parsing in expected linear time [C]// Proceedings of the 4th International Joint Conference Natural Language Processing of the AFNLP. Singapore: ACM Press, 2009: 351-359.
- [13] COLLINS M. Log-linear models[EB/OL]. <http://www.cs.columbia.edu/~mcollins/loglinear.pdf>, 2014.
- [14] GIMPEL K, SMITH N A. Softmax-margin CRFs: Training log-linear models with cost functions[C]// HLT'10: The 2010 Annual Conference on Human Language Technologies. Los Angeles, USA: ACM Press, 2010: 733-736.
- [15] CHANG C C, LIN C J. LIBSVM: a library for support vector machines[J]. ACM Transactions on Intelligence Systems and Technology, 2011, 2 (3): (No. 27)1-27.
- [16] FAN R E, CHANG K W, HSIEH C J, et al. LIBLINEAR: A library for large linear classification [J]. Journal of Machine Learning Research, 2010, 9 (12): 1871-1874.