

基于最大熵原则的汉语语义角色分类

丁伟伟 常宝宝

北京大学 计算语言学研究所, 北京, 100871

E-mail: {weiwei.ding, chbb}@pku.edu.cn

摘要: 语义角色标注是近些年来兴起的自然语言处理的一个新的研究领域。本文在参考已有工作的基础上, 基于最大熵原则, 对汉语语义角色标注中的一个方面——语义角色分类进行了深入的研究。在提出了一些新的特征之后, 本文还充分利用了语义角色之间的相关性, 使汉语语义角色分类由原来的单点分类的问题转化为序列标注的问题, 从而提高标记的准确率; 此外, 通过对不同特征的单独研究, 我们发现了不同特征取得最优值时的窗口大小差别很大。发现这一现象后, 我们设计了一种基于贪心策略的选择算法, 对不同的特征选择不同的窗口大小, 使得标记结果进一步提高。在综合采用了以上的策略之后, 我们的汉语语义角色分类系统可以达到 95.00% 的准确率, 比前人有较为显著的提升。从而证明了我们的方法是有效的。

关键词: 语义角色分类, 最大熵, 特征, 上下文, 窗口, 贪心策略

Maximum Entropy-based Semantic Role Classification

Ding Weiwei Chang Baobao

Institute of Computational Linguistics, Peking University, Beijing 100871

E-mail: {weiwei.ding, chbb}@pku.edu.cn

Abstract: The semantic role labeling (SRL) is a new research area of natural language process in recent years. In this paper, we made adequate research on the second step of SRL, the semantic role classification (SRC). Besides some new features, we also explore the interdependence of the semantic roles. In other words, the SRC is changed into a sequence labeling problem from a one-point classification problem. Also, a greedy algorithm is designed to select the different windows of the context for different feature templates, since we have noticed that each time for one feature template only, the highest performance can be achieved at different window sizes for different feature templates. Due to all the strategies we have taken, the precision of our SRC system can achieve 95.00%, which has been a significant improvement.

Key words: semantic role classification, maximum entropy, features, context, window, greedy-strategy

1. 引言

语义角色标注(Semantic Role Labeling)指的是分析句子的论元结构, 即标记出句子中某个动词的所有论元。它起始于 Dan Gildea 和 Dan Jurafsky^[1], 他们的实验所用语料是 Berkeley 大学开发的 FrameNet^[2]。在此之后, 语义角色标注这个任务逐渐得到了国际的关注。一方面, 语料不断丰富, 在 FrameNet 之后, 英文 PropBank^[3], 与之相关的 VerbNet^[4]等配套语义词典构建完成; 另一方面, 出现了相关的国际评测, CoNLL 2004^[5]和 CoNLL 2005^[6]都包含了语义角色标注的任务。依据研究方法的不同, 大致可以分为两条道路, 一个是以 Pradhan 等^[7]为代表的基于特征的方法, 另一个是以 Moschiti 等^[8], Zhang Min 等^[9]为代表的基于核函数的方法。中国国内对语义角色标注的关注最早起始于刘挺等^[10], 于江德^[11]等, 不过当时他们的研究重点仍然集中在英文的语义角色标注之上, 实验的语料是 CoNLL-2005 的评测语料, 对汉语的关注不够。

相比较英语上的研究, 中文语义角色标注的工作既开展比较晚。最早进行研究的是 Sun 等^[12], 由于在当时还没有中文方面的专门语料, 所以他们只是人工标记了包含某些动词的一些语料, 并在这些语料上进行研究。后来, 伴随着中文 PropBank^[13]的构建, Xue Nianwen 开始了比

本文得到了国家自然科学基金项目(60303003)和国家社会科学基金项目(06BY048)的资助。

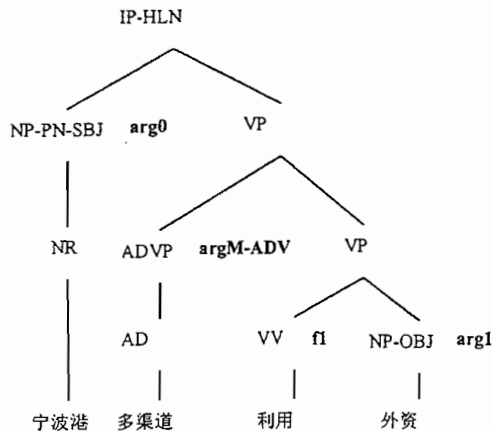
较系统的中文语义角色标注的工作，并得出了一些很有意义的成果，比如：语义角色识别和语义角色分类所采用的特征是有区别的。国内对汉语语义标注的研究主要有刘怀军等^[14]，和吕德新等^[15]。总的来说，与英文上的工作相比，汉语语义角色标注方面的研究比较少。

在目前的研究中，语义角色标注任务通常由两个阶段组成：前一个阶段是挑选出句法树上可能充当动词论元成分 的节点，这是语义角色识别。后一个阶段的任务是对识别出来的节点进行分类，具体判断出是指定动词的哪类论元，这是语义角色分类。本文主要针对汉语语义角色标注第二个阶段的工作——汉语语义角色分类进行研究。

2. 中文 Proposition Bank 简介

中文 Proposition Bank（以下简称中文 PropBank）是宾州大学仿照英文 PropBank 制作的中文语义角色标注语料库。它主要由两个资源构成：1.语义角色标注语料。2.动词框架。其中资源 1 具体标记了动词和其论元成分在中文 TreeBank 中的位置；资源 2 是一个支持性的内容，类似于词典，标记了所有出现在 PropBank 中的动词的子语类框架。图 1 是 PropBank 中的一个例子。

图 1 PropBank 的一个例子



在这个例子中，核心动词是“利用”。“利用”只有一个子语类框架，这个子语类框架包含两个论元成分：“利用（别人或物）的（人或物）”和“被利用的（人或物）”，分别对应原型施事（arg0）和原型受事（arg1）。在图 1 中，“宁波港”是“利用的”，“外资”是“被利用的”。除了原型施事和受事，在这个例子中还有一个论元成分“多渠道”，它是一个副词性的论元成分，表示“利用”的方式，标记为“argM-adv”，其中“argM”是论元标记，“ADV”是一个二级的功能标记。

中文 PropBank 的构建，其理论基础是连接理论。这个理论阐述了语义层面的角色如何实现为语法层面的句子成分，依据这一理论，很自然地会让人想到使用一种类似求逆的过程依据句子结构得出“谓词——论元”结构。无论是语义角色的识别还是分类，都是在句法分析树上进行的，是一个树上节点分类的问题。从某种程度上说，中文 PropBank 这个语料决定了我们的方法论。

3. 语料的预处理

由于 Treebank 的句法标注主要依据的是转换—生成理论，故而在标记中包含了大量由于移位（movement）而造成的空语类（null categories）。空语类的存在，使得移位的句法成分往往和其对应的空语类同时充当某个动词的同一个论元成分。此外，目前的句法分析器在句法分析结果中是不包含空语类的，这使得自动句法分析和人工标注的句法树结构不一致。综合以上两个原因，在我们的工作中，空语类全部被删除了。

既然是语义角色分类，那么首先要解决的是有多少个类的问题。中文 PropBank 标记可以分为两级：一级标记是 arg0-4, argM, 共计 6 个。二级标记是形如 ADV, TMP 这样的功能性标记，共有 16 个。二级标记对 argM 是必需的，对于 arg0-4 是可选的。我们对 PropBank 中的论元标记进行了化简，采用了表 4 中的分类。这样分类的依据是：首先，对于 arg0-arg4 这一类的核心论元，其包含的二级功能标记少，并且区别不大，二级功能标记对核心论元起的作用有限，我们就不再考虑细分了。但是 argM 这类非核心论元，它的内部构成非常庞杂，一致性比较差。比如同样是 argM, argM-MNR 与 argM-TMP 的一致性就很低，所以对 argM 我们从分。

表 4 中的标记，其中前 21 类都比较常见；argM 的功能标记是进一步的细分。主要的有 EXT 程度，FRQ 频率，LOC 地点，MNR 方式，TMP 时间，TPC 话题等²。第 22 类 TBERR 在中文 PropBank 中没有任何说明，为了保证完整性，这一类仍然保留了下来。

4. 特征选择

4.1 基准特征

参考了英文上面的实验和 Xue Nianwen 在中文上的研究^[16-17]，我们使用了以下特征模板作为我们的基准特征。

简单特征

可以分为词特征、词性特征、句法特征三类。其中词特征包括：首词，尾词，中心词，动词。词性特征包括：中心词词性，短语类型。句法特征包括位置，路径。³此外，句法特征中还包括：

动词的框架 动词的父节点及其所有子节点构成的框架

语态 主动或者被动。本文采用了一种较为简单的判别方式，即是否包含“把”、“被”

围绕动词的 NP 从核心动词到最顶层节点之间各层节点周围围绕 NP（名词短语）的情况，比如图 1 中各论元成分的该特征都是（NP（（VNP）））

路径中的 VP 数量 路径中包含的 VP（动词短语）数量

到语态标记词的路径 该论元成分对应节点到语态标记词“把”、“被”的路径

右兄弟节点的短语类型 该论元成分对应节点的右兄弟节点的短语类型

复合特征

动词 + 短语类型，动词 + 中心词

短语类型 + 动词子语类框架简单表达式 动词子语类框架简单表达式与 Xue^[12]中提到的 Frame 一致。

4.2 新特征

尾词的语义类 这里的语义类的信息是取自北京大学计算语言所的资源《现代汉语语义词典》^[19]，如果尾词是名词，则该特征的值是在《现代汉语语义词典》中的语义类，否则为空。

中心词 + 动词子语类框架复杂表达式 动词子语类框架复杂表达式是将动词所有子语类框架都连结起来构成的表达式。例如动词“保持”的子语类框架复杂表达式是：C0_1C0_1_2⁴。

短语类型 + 动词子语类框架复杂表达式

5. 序列标注的观点

提取每个论元成分各自的特征，进行学习标注，这是语义角色标注的传统方法。在传统的方法中，同一动词的不同论元成分之间没有任何联系，这是一种单点分类的观点。这样的处理策

² 更详细的说明请参照中文 PropBank。

³ 由于篇幅限制，这些观其名而知其意的特征，本文就不再详细解释了。

⁴ 子语类框架复杂表达式的内部排列是有顺序的，包含论元数少的框架在前，多的在后。

略好处是简单明了，但是也存在一个很大的问题，就是割裂了“单点”之间的相互关系，具体体现为忽略了同一动词的不同论元之间的相关性。这种相关性在语言学上可以表现为以下两点：

1. 同一类型的论元在一个动词的论元结构中一般只能出现一次。
2. 论元分布有序。例如在非被动句中，主语位置上是原型施事比是原型受事的可能性大得多。

语言学上的理论给我们以启示，我们可以考虑将语义角色标注从一个单点分类的问题转化为一个序列标注的问题，英语上的实验也证实了利用论元相关性改善标记结果是可行的^[20]。例如：

宁波市	多渠道	利用	外资
arg0	argM-ADV	动词	arg1
特征集合 1	特征集合 2		特征集合 3

前人的做法是对各个论元成分，使用各自的特征集合。比如对“宁波市”使用特征集合 1，“外资”使用特征集合 3。而从序列标注的角度来看，“宁波市”、“多渠道”、“利用”、“外资”这四个节点构成了一个序列。由于节点之间存在着相关性，我们就可以利用相关的论元的特征来改善标记结果。比如对于“宁波市”，我们可以同时利用特征集合 1, 2, 3 的信息。我们可以这样理解：特征集合 1 从正面指明了“宁波市”可能是什么论元，而特征集合 2、3 则从反面揭示了“宁波市”不可能是什么论元，因为同种性质的论元在同一个论元结构中一般只出现一次。

为了利用上下文的信息，我们引入了“窗口”的概念。窗口大小[-m, n]表示：将所有的论元成分按照在句子中的先后顺序线性排列，对于其中第 i 个论元，我们用来训练或者用于分类的特征集合是从第 i-m 个到第 i+n 个论元的特征集的并集。

6 特征窗口选择

通过对单个特征的研究，我们可以发现不同的特征在取得最高分类准确率时对应的窗口大小并不一样（详见 7.3.3），这给我们启示，就是是否对不同的特征取不同的窗口可以改善分类结果。仍以图 1 中的句子为例：与之前对特征集设定窗口大小不同，在这里我们细化到具体的每个特征模板，比如对“多渠道”这个论元，“首词”这个模板我们只取首词 2 一个特征集合，“路径”则取路径 1、路径 2、路径 3 三个特征集合。

宁波市	多渠道	利用	外资
arg0	argM-ADV	动词	arg1
首词 1	首词 2		首词 3
路径 1	路径 2		路径 3
.....

我们使用了总共 20 个特征模板。为了简便起见，我们设计了一种贪心策略取寻找最佳的特征窗口设置。贪心策略的具体设计如下：

- 1 所有的特征窗口都设置为 [-1,1]
- 2 For i=0 to 19
- 3 for 特征 i 的窗口设置从[0,0]到[-3,3]
- 4 if(结果变好) 保存特征 i 的这个窗口设置
- 5 End for
- 6 End for

7 数据与实验

7.1 实验数据

本实验所用数据是宾州大学标注的中文 PropBank1.0 (LDC 编号为 LDC2005T23)，

PropBank1.0 标记了 Chinese TreeBank 5.1 的前 250k 语料,共标记了 4865 个动词的 37,183 个论元结构。试验使用如下方式划分语料: 训练集语料 648 个文件 (chtb_081 -- chtb_899), 测试集语料 72 个文件 (chtb_001 -- chtb_041, chtb_900 -- chtb_931), 开发集语料 40 个文件(chtb_041 -- chtb_080)⁵。这个语料的设置与 Xue (2008) 相同, 与 Xue (2005) 不完全相同。

7.2 最大熵分类器

本实验采用 Zhang Le 的最大熵分类器 MaxEnt, 该分类器实现了包含高斯平滑的最大熵算法, 采用 LBFSGS 参数估计方法, 可以很方便地处理多类划分的问题。⁶

实验的参数设置如下: 迭代次数 500, 高斯平滑参数为 15。

7.3 实验结果

7.3.1 单点分类的结果

使用基准特征, 在测试集上可以达到 94.08% 的准确率。加上了我们的新特征, 准确率可以提高到 94.19%。

7.3.2 序列标注的结果

如前所述, 我们将从序列标注的角度审视语义角色分类的任务, 通过改变窗口大小改善分类的结果。表 2 显示的是分类准确率随窗口大小变化的情况。

表 2 不同窗口标记准确率 (开发集上)

[0,0]	[0,1]	[-1,0]	[-1,1]	[-1,2]	[-2,1]	[-2,2]	[-2,3]	[-3,2]	[-3,3]
93.09%	93.36%	93.47%	93.93%	93.09%	93.00%	93.25%	93.59%	93.25%	93.05%

从表 2 中我们可以看到, 在窗口大小为[-1, 1]时语义角色分类取得最高的准确率, 测试集上可以达到 94.69%, 这相对于前人一般的处理策略, 即窗口为[0,0]时的结果, 有很大的提高。

7.3.3 单类特征标记准确率

对于单个特征模板提取的特征, 我们也可以进行序列标注的试验。结果如表 3 所示。

表 3 中各数字代表的特征是: 1, 位置 2, 围绕动词的 NP 3, 语态 4, 到语态标记词的路径 5, 动词的框架 6, 动词 7, 路径中的 VP 数量 8, 尾词的语义类 9, 中心词词性 10, 动词 + 中心词 11, 右兄弟节点的短语类型 12, 首词 13, 中心词 14, 中心词 + 动词子语类框架复杂表达式 15, 尾词 16, 动词 + 短语类型 17, 短语类型 18, 路径 19, 短语类型 + 动词子语类框架复杂表达式 20, 短语类型 + 动词子语类框架简单表达式

表 3 各类特征标记准确率 (开发集上)

	[0,0]	[0,1]	[-1,0]	[-1,1]	[-1,2]	[-2,1]	[-2,2]	[-2,3]	[-3,2]	[-3,3]
1	26.96%	29.01%	30.41%	30.39%	30.39%	32.56%	31.93%	31.54%	31.93%	31.54%
2	30.44%	36.40%	34.93%	38.41%	39.20%	38.23%	38.65%	38.50%	38.43%	38.52%
3	33.12%	47.01%	39.20%	50.06%	50.06%	50.06%	52.16%	51.41%	52.16%	51.41%
4	34.82%	47.98%	40.80%	50.58%	50.67%	50.69%	52.86%	52.22%	52.90%	52.13%
5	36.80%	50.19%	41.88%	53.62%	55.95%	55.00%	56.85%	57.08%	57.06%	57.15%
6	37.91%	52.13%	43.22%	53.99%	55.09%	54.57%	55.41%	55.59%	54.89%	55.29%
7	45.63%	52.99%	47.55%	53.31%	56.18%	53.78%	55.77%	56.02%	56.15%	56.31%
8	50.46%	61.93%	51.61%	63.76%	64.33%	63.36%	63.99%	63.65%	63.67%	63.29%
9	59.04%	61.26%	70.99%	71.19%	71.26%	71.26%	71.28%	71.37%	71.14%	71.19%
10	60.44%	60.80%	63.31%	64.03%	62.90%	64.24%	63.17%	63.02%	62.99%	62.90%
11	60.92%	69.65%	65.61%	70.26%	70.24%	70.40%	70.29%	70.60%	70.38%	70.74%

⁵ 此外还去除了某些 PropBank1.0 中与 TreeBank5.1 中对应不上的例子

⁶ 下载地址是: http://homepages.inf.ed.ac.uk/s0450736/maxent_toolkit.html。

12	65.30%	68.68%	70.47%	72.75%	72.86%	73.36%	73.18%	72.43%	73.27%	72.48%
13	69.32%	71.19%	72.12%	72.91%	72.43%	73.18%	73.00%	72.84%	72.63%	72.57%
14	69.99%	70.42%	72.82%	73.90%	74.24%	73.83%	73.74%	73.85%	73.79%	73.83%
15	70.49%	71.44%	72.66%	73.74%	73.36%	74.10%	73.56%	73.38%	73.45%	73.29%
16	84.24%	84.01%	84.20%	84.06%	83.81%	84.38%	83.97%	84.08%	84.01%	84.17%
17	85.39%	86.07%	85.82%	86.70%	86.61%	87.04%	86.88%	86.84%	86.81%	86.79%
18	85.41%	85.21%	86.18%	85.93%	86.45%	85.64%	86.29%	86.09%	86.09%	85.93%
19	87.88%	88.17%	88.73%	89.30%	89.28%	89.18%	89.23%	89.21%	89.18%	89.16%
20	87.90%	88.19%	88.73%	89.32%	89.23%	89.21%	89.21%	89.16%	89.18%	89.14%

通过上面的试验我们可以发现，不同的特征取得标注最高准确率时对应的窗口大小是不同的，有些特征在窗口较小时效果比较好，有些则随着窗口增大不断提高。

7.3.4 选择特征窗口的结果

通过使用贪心策略进行特征窗口的选择，本系统最终可以将测试集上的标注准确率提高到 95.00%，各特征对应的窗口大小分别是（按照 7.3.3 中的特征顺序）：[-1, 1], [-1, 1], [-1, 1], [-1, 1], [-1, 1], [-1, 1], [-1, 1], [-1, 1], [-2, 1], [-3, 2], [-2, 1], [-1, 1], [0, 0], [0, 0], [-1, 1], [-3, 2], [-1, 1], [-1, 1], [-1, 2], [-2, 3]。我们采用 χ^2 （自由度为 1）显著性检验，测试数据中论元总数为 7714 个，贪心策略进行窗口选择的结果比之前不考虑窗口设置做法（即窗口大小为 [0, 0]）的结果有显著提升 ($p < 0.05$)⁷。表 4 记录了各类论元的分类准确率。

表 4 各类论元标记准确率

	正例	总和	正确率	ARGM-DIR	19	31	61.29%
ARG0	1995	2046	97.51%	ARGM-DIS	75	97	77.32%
ARG1	2333	2428	96.09%	ARGM-EXT	3	8	37.50%
ARG2	202	260	77.69%	ARGM-FRQ	0	0	0.00%
ARG3	16	25	64.00%	ARGM-LOC	286	308	92.86%
ARG4	3	5	60.00%	ARGM-MNR	230	248	92.74%
ARGM-ADV	1440	1490	96.64%	ARGM-PRD	0	0	0.00%
ARGM-ASP	1	1	100.00%	ARGM-PRP	44	46	95.65%
ARGM-BNF	20	23	86.96%	ARGM-TMP	648	675	96.00%
ARGM-CND	8	9	88.89%	ARGM-TPC	5	12	41.67%
ARGM-CRD	0	0	0.00%	TBERR	0	2	0.00%
ARGM-DGR	0	0	0.00%	总计	7328	7714	95.00%

7.3.5 标注准确率综合比较

将前面的所有实验以及前人的实验结果综合起来，比较如表 5⁸：

表 5 实验比较

基准特征	94.08%
所有特征	94.19%
所有特征+[-1,1]窗口	94.69%
所有特征+贪心策略选择窗口	95.00%
Xue(2005)	93.9%
Xue(2008)	94.1%

⁷ 依照 Pradhan 等（2005）的做法

⁸ 实验设置与 Xue（2005）不同，故而可比性不是很大。

8 展望

汉语语义角色标注还有很大的研究空间。本研究只是语义角色标注整个工作的一个组成部分,将来的工作重点将会放在语义角色标注的第一阶段——语义角色识别上面,使其与现有的工作结合起来,从而构建一个完整的汉语语义角色标注系统。我们希望通过汉语语义角色标注系统的建设,为自然语言处理的其他领域,比如对文本自动摘要,机器翻译等领域的研究提供帮助。

参考文献

- [1]. D. Gildea, D. Jurafsky. Automatic labeling of semantic roles[J]. *Computational Linguistics*, 2002,28(3):245-288.
- [2]. F.C. Baker, C.J. Fillmore, and J.B. Lowe. 1998. The Berkeley FrameNet project[A]. In *Proceedings of the 17th international conference on Computational linguistics*[C], pages 86–90, Montreal, Canada.
- [3]. Paul Kingsbury and Martha Palmer. 2002. From TreeBank to PropBank[A]. In *Proceedings of the 3rd International Conference on Language Resources and Evaluation (LREC-2002)*[C], Las Palmas, Spain
- [4]. Karin Kipper, Hoa Trang Dang, and Martha Palmer. 2000. Class-based construction of a verb lexicon[A]. In *Proceedings of the Seventeenth National Conference on Artificial Intelligence and Twelfth Conference on Innovative Applications of Artificial Intelligence(AAAI)* [C], Pages: 691 – 696,
- [5]. Carreras X, Màrques L. Introduction to the conll-2004 shared task: Semantic role labeling[A]. In *Proceedings of CoNLL-2004*[C],Boston, MA, USA, 2004, 89-97.
- [6]. Carreras X, Màrques L. Introduction to the conll-2005 shared task: Semantic role labeling[A]. In *Proceedings of CoNLL-2005*[C], 2005.
- [7]. S. Pradhan, K. Hacioglu, V. Krugler, W. Ward, J.H. Martin, D. Jurafsky. Support vector learning for semantic argument classification[J]. *Machine Learning Journal*, 2005,60(1-3),11-39.
- [8]. Moschitti. A Study on Convolution Kernels for Shallow Statistic Parsing[A]. In *Proceedings of the 42nd Meeting of the Association for Computational Linguistics(ACL'04)*[C], Main Volume, Barcelona, Spain, 2004, 335–342
- [9]. M. Zhang, W. Che, A.T. AW, C.L. Tan, G. Zhou, T. Liu, S. Li, A Grammar-driven Convolution Tree Kernel for Semantic Role Classification[A], in *Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics (ACL '07)*[C], Prague, Czech Republic,
- [10]. 刘挺, 车万翔, 李生, 基于最大熵分类器的语义角色标注[J], 软件学报, Vol. 18, No. 3, 2007, 565-573
- [11]. 于江德, 樊孝忠, 庞文博, 余正涛, 基于条件随机场的语义角色标注[J], 东南大学学报, Vol. 23, No. 3, 2007, 361-364
- [12]. H. Sun, D. Jurafsky. Shallow Semantic Parsing of Chinese[A]. in *Proceedings of the HLT/NAACL* [C], 2004
- [13]. N. Xue, M. Palmer. 2003. Annotating the Propositions in the Penn Chinese Treebank[A]. In *Proceedings of the 2nd SIGHAN Workshop on Chinese Language Processing*[C], Sapporo, Japan.
- [14]. 刘怀军,车万翔,刘挺, 中文语义角色标注的特征工程[J], 中文信息学报, Vol. 21, No. 1, 2007, 79-84
- [15]. 吕德新, 张桂, 蔡东风, 朱江涛[J], 沈阳航空工业学院学报, Vol. 23, No. 1, 2006, 44-46
- [16]. N. Xue, M. Palmer. Automatic semantic role labeling for Chinese verbs[A]. In *19th International Joint Conference on Artificial Intelligence*[C]. *Edinburgh, Scotland* 2005, 1160-1165
- [17]. N. Xue, Semantic Role Labeling of Chinese Predicates[J]. *Computational Linguistics*, 2008, in press
- [18]. M. Collins. Head-Driven Statistical Models for Natural Language Parsing[D]. Pennsylvania University, 1999.
- [19]. 王惠、詹卫东、俞士汶, 现代汉语语义词典规格说明书[J], 汉语语言与计算学报, Volume 13, Number 2, 2003,159-176
- [20]. Z. P. Jiang, J. Li, H. T. Ng. Semantic Argument Classification Exploiting Argument Interdependence[A]. In *19th International Joint Conference on Artificial Intelligence*[C]. *Edinburgh, Scotland* 2005, 1067-1072