

汉语事件句式规范化

邱晗

2014.4.21

Outline

- 背景介绍
 - EC, LC, PA
 - 工作目标
- 工作内容
 - 分类体系
 - EC分类
- 结果统计
 - 数量, Kappa

背景介绍

事件句式（EC）

- 小句组合蕴含了完整的事件，动作，过程，状态，关系等内容
- 能够完整表达该事件的最小结构就是一个事件句式（Event Construction）
- “刚才，这位乘客丢失了一个红色的钱包”
- “乘客-丢失-钱包”

汉语搭配关联对（LC）

- EC: 事件的完整内容→汉语搭配关联对（Lexical Cohesion）：动词同各个名词性成分的搭配关系
- “ZW 乘客-丢失”，“PO 丢失-钱包”
- 动词的搭配特性，深层语义关系
- 问题：部分LC仅反映句法搭配关系，同深层语义之间存在一定的误差
 - “菜刀-切-菜”→“ZW 菜刀-切” ×

谓词论元搭配 (PA)

- 谓词论元 (Predicate Argument) : EC中核心谓语动词和其直接控制的名词性短语
- 控制: 谓词论元之间的语义层面的联系
- 谓词: “丢失”, 论元: “乘客”, “钱包”
- 谓词: “切”, 论元: “菜”
- 施事和受事
 - “丢失”的语义施事为“乘客”, 语义受事为“钱包”,
 - “菜”是“切”的语义受事

PA分类

- 显式PA搭配（Basic-PA, BPA）
 - =LC
 - 前一元PA，例如：“宝宝-睡觉”
 - 后一元PA，例如：“漂着-残骸”
 - 二元PA，例如：“科学家-研究-生物学”
 - 三元PA，例如：“我-借给-他-三本册子”
- 隐含PA搭配（Implicit-PA, IPA）
 - LC存在问题的部分。

假设与目标

- 目标：分析与提取IPA结构，标识EC中的深层语义关系，形成一个更加准确全面的EC描述库
- 原理：BPA和IPA都是来源于EC中→反映出完成的事件内容
- 假设：每个IPA都能够找到其对应的BPA使得两者所反映的事件内容是相同，通过一定的方法将IPA还原成为BPA
- 方法：EC分类进行规范化处理→IPA还原为描述相同事件的BPA

工作内容

分类体系建立(1/3)

基本事件句式(BEC)

- SP(B), SPO(B), SPOO(B), SPOC(B)
- PO(B)
 - 掉了-三颗牙齿
 - ≠SP(B)
- SSP(B)
 - 这次的旅行团-我-带队
- SDP(B), SDPO(B)
 - 我-同他-结婚

分类体系建立(2/3)

派生事件句式(DEC)

- 论元省略(O)
 - $SPO(B) \rightarrow SP(O)$, $SPO(B) \rightarrow PO(O)$, $SDP(B) \rightarrow DP(O)$, $SDPO(B) \rightarrow DPO(O)$,
 $SPOO(B) \rightarrow POO(O)$, $SPOC(B) \rightarrow POC(O)$
- 论元话题化(T)
 - 完全话题化(WT): 核电站-我国-应当大力发展
 - 动宾话题化(POT): 我-作业-早就写完了
 - 同位语话题化(CT): 王晓明-这个人-比较特殊
 - 部分话题化(PT): 敌人-我们-消灭了-三个
 - 省略后的话题化(OT): 大门-打开了
- 谓词被动化(B)
 - 大量毒品-被-销毁
- 论元pp状语化(D)
 - 研究人员-将血清-提取出来
 - 我-将钱包-递给-他

分类体系建立(3/3)

变形句式(TEC)

- 名词中心语(NH)

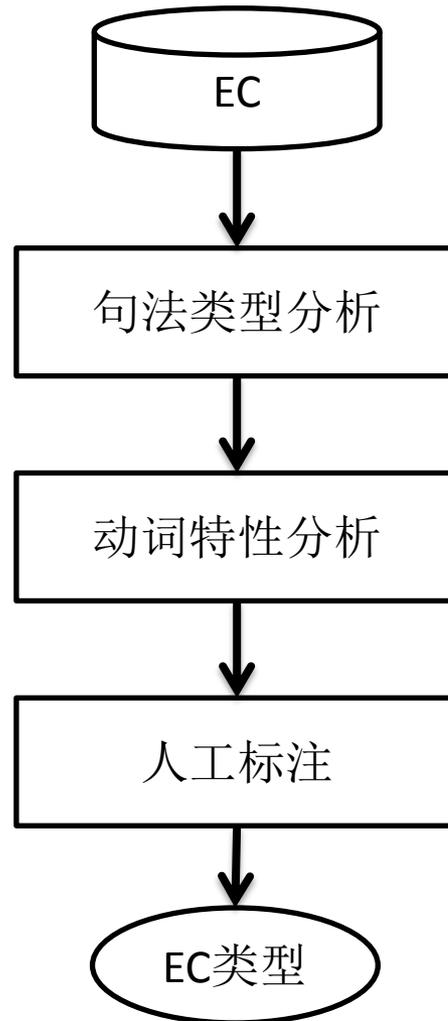
- 附加中心语(EH):传统医学-具有-多样性特点-的-原因, 群众-承受-的-能力

- 论元中心语(AH): 具有-表现力-的-艺术, 出让-的-土地

- 谓词中心语(PH)

- 图书-的-借阅

EC分类处理(1/4)



EC分类处理(2/4)

- 句法类型分析
 - 作业-我-写完了→SSP
 - 菜刀-切-菜→SPO
 - 具有-表现力-的-艺术→PO_H

EC分类处理(3/4)

- 动词特性分析

- BEC和DEC: 动词搭配性质和语义限制

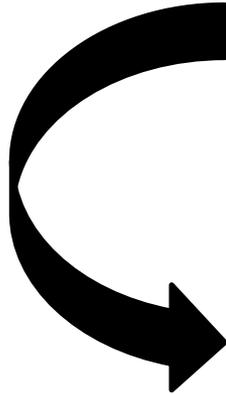
- 自动判断类型: 这件事-我-确实没想到 (二元, 满足语义限制)
 - 需要人工判断: 中国-人口-众多 (一元, 不满足)

- TEC: 动词搭配性质

- 自动方法缩小了所属类型的可能情况, 但是仍需要人工判断
 - HPO(B)→PO_H, PO(O)→PO_H
 - HPO(B)→PO_H, POH(O)→PO_H

EC分类处理(4/4)

- 人工标注



句子情景：来自偏西北方的印欧人种

片段：来自-西北方-的-人种

谓词特性：二元谓词

组合类型：PO_H

选项：1. 人种-来自-西北方

2. 来自-西北方

3. 以上选项均不对

序号= 6018-1

来源语料= CCGBank.ccg

完整推导树=

片段结构推导树= (NP C A-H (NP/NP A C-H (S\NP C H-arg-C ([S\NP]/SP H-arg leaf 来自) (SP C A-H (SP/SP A (S\NP leaf 偏) (SP H leaf 西北方))) ([NP/NP]\[S\NP] H leaf 的)) (NP H leaf 印欧种人))

句法结构类型= PO_H

事件句式类型= ADZ

事件句式标注= [P-vp-Pred(2) 来自] [O-np-Arg2 西北方] 的 [H-np-Arg1 印欧种人]

结果统计

结果统计(1/3)

- TEC数量统计

变形方式 [↵]	变形来源 [↵]	数量统计 [↵]	
EH [↵]	BEC [↵]	1530 [↵]	5826 [↵]
	DEC [↵]	4296 [↵]	
AH [↵]	BEC [↵]	5365 [↵]	6527 [↵]
	DEC [↵]	1162 [↵]	
总计 [↵]		12353 [↵]	

结果统计(2/3)

- 人工标注质量与难度

$$\text{Kappa} = \frac{P_o - P_e}{1 - P_e}$$

P_o ——实际一致率
 P_e ——理论一致率

变形方式	变形来源	Kappa3		Kappa2	
EH	BEC	0.9341	0.8472	0.9603	0.9238
	DEC	0.8034		0.8729	
AH	BEC	0.8817	0.8338	0.9224	0.8974
	DEC	0.7962		0.8236	
总计		0.8396		0.9103	

结果统计(3/3)

- EH>AH
 - EH
 - [S-np-Arg1 轻工业] [P-vp-Pred(1) 发展] 的 [H-np 时代]
 - [S-np-Arg1 企业] [P-vp-Pred(2) 资助] [O-np-Arg2 剧团] 的 [H-np 资金]
 - AH
 - [P-vp-Pred(1) 古老] 的 [H-np-Arg1 恒星]
 - [P-vp-Pred(2) 研究] 的 [H-np-Arg2 恒星]
- BEC>DEC
 - BEC
 - [S-np-Arg1 团体] [P-vp-Pred(2) 深化] [O-np-Arg2 改革] 的 [H-np 思路]
 - [S-np-Arg1 儒家] [P-vp-Pred(2) 提倡] 的 [H-np-Arg2 礼制]
 - DEC
 - [P-vp-Pred(2) 集中] [O-np-Arg2 兵力] 的 [H-np 方法]
 - [P-vp-Pred(2) 挖好] 的 [H-np-Arg2 坑]

参考文献(1/2)

- 石定栩. 汉语句法的灵活性和句法理论. 当代语言学. 第2卷2000年第1期 18-26页 (2000) Adam Meyers. Annotation guidelines for NomBank - noun argument structure for PropBank. Technical report, New York University. (2007).
- Hockenmaier, J., Steedman, M.: CCGbank: A Corpus of CCG Derivations and Dependency Structures Extracted from the Penn Treebank. Computational Linguistics 33(3), 355--396 (2007)
- 宋彦, 黄昌宁, 揭春雨. 中文CCG树库的构建. 孙茂松、陈群秀主编《中国计算语言学研究前沿进展》(CNCCL-2011), 221-227 (2010)
- 周强. 汉语句法树库标注体系. 中文信息学报. 18(4): 1-8. (2004)
- 袁毓林. 汉语配价语法研究[M]. 北京: 商务印书馆, 2010.
- 董振东, 董强. 知网[DB/OL]. [2003].
http://www.keenage.com/zhiwang/c_zhiwang.html. 北大计算语言学研究
研究所. 现代汉语语法信息词典规格说明书[DB/OL]. [2000].
http://icl.pku.edu.cn/icl_groups/syntac-dictn.asp.

参考文献(2/2)

- 陈丽欧. 汉语事件内容分析系统研究与实现[D]. 清华大学: 计算机科学与技术系, 2012.
- 邱晗. 汉语动词CCG范畴人工标注规范[R]. 清华大学: 信息技术研究院语音和语言技术中心, 2011. TCT到CCG bank的自动转换: 设计规范Ver 3.0. 清华大学信息技术研究院语音和语言技术中心技术报告 (2011)
- Steedman M, Baldridge J. Combinatory categorial grammar[J]. Non-Transformational Syntax Oxford: Blackwell, 2011, 181-224.
- J Cohen. A coefficient of agreement for nominal scales[J]. Educational and Psychological Measurement, 1960, 20(1): 37-46.
- S Boxwell, M White. Projecting propbank roles onto the ccgbank[J]. Proceedings of the International Conference on Language Resources and Evaluation, 2008.
- 邱晗, 周强. 自动获取大规模的汉语紧密组合词汇关联对. 《清华大学学报(自然科学版)》 2011年09期

谢谢！