

階層ベイズ言語モデルと条件付確率場の統合による半教師あり形態素解析

2012年6月15日 統計数理研究所
オープンハウス

持橋 大地 数理・推論研究系 准教授

鈴木潤、藤野昭典 NTTコミュニケーション科学基礎研究所 (共同研究)

形態素解析 = 文字列を単語に分けること

統研はいかがですか → 統研はいかがですか
世界杯賽場地已准备停当 → 世界杯賽場地已准备停当
特にアジア圏では、自然言語処理に不可欠

現在の問題点 “正しい”テキストしか解析できない

何て言うんでしょうねその当時はそう思っていたっていうことを全部ドラマにしちゃうっていうところそういうところとか面白く凄く見てたんですけど最初の方は凄くまともで緋色の研究とか四人の署名とかそういうのから始まってたんですけどそれはもうとにかく原作に沿っててこういうこれこれホームズってこれっていうのが見たくて私はずっと見てます見てましたで凄く… CSJ日本語話し言葉コーパス (国立国語研究所)

对@mo小颖 说:星期五吃饭～！6点啊 [乐乐] 新浪微博
快下班了。。。。。可是我的时间才刚刚开始！ (中国語版Twitter)
注册口碑卡~\(\geq \nabla \leq)/~啦啦啦
亲爱的，现在的我很成熟，我知道你对我意味着什么，我要好好珍惜你，我不要在错过一个值得我爱一生的女孩。
快艺考了。中西上戏，最差也要山艺铜。
哈哈哈.....天真不嘛～可耐不嘛！雕塑课.....明显是摆拍的--

教師なし形態素解析

何か方法はないのか？

- 生の文字列だから、完全に自動的に「単語」を学習
- 階層-階層Pitman-Yor過程(NPYLM) + Blocked MCMC


- 1 神戸では異人館 街の二十棟が破損した。
- 2 神戸では異人館 街の二十棟が破損した。
- 10 神戸では異人館 街の二十棟が破損した。
- 50 神戸では異人館 街の二十棟が破損した。
- 100 神戸では異人館 街の二十棟が破損した。
- 200 神戸では異人館 街の二十棟が破損した。
- 限界: 低頻度語, 人間の基準に弱い
 - 阪急桂駅”, “首都グロズヌイ”
 - “歌う”→“歌う”, “静かな”→“静かな”

半教師あり学習: JESS-CM


$$p(\mathbf{y}|\mathbf{x}; \Lambda, \Theta) \propto p_{\text{DISC}}(\mathbf{y}|\mathbf{x}; \Lambda) p_{\text{GEN}}(\mathbf{y}, \mathbf{x}; \Theta)^{\lambda}$$

- joint probability model embedding style semi-supervised conditional model (Suzuki+ACL2008, ACL2009)
- 現在世界最高性能の半教師あり学習

NPYLM=semi-Markov モデル



semi-Markov→Markov変換



実験

「しょこたんブログ」の解析例

四つとも全部この川柳 wwwwww お茶 wwwwww イトカ
ワユス wwwwww イトカワユス wwwwww (^ω^)(^ω^)(^ω^)
深夜までお疲れさマミタス(° ω °)ギャル曾根たん！最近よ
く一緒になるのと楽屋に遊びにきてくれるのでいろいろ
おしゃべりしてタノシス！(^ω^)今日もいろいろ話したおね

新浪微博の解析結果

呻～？半个钟前发的围脖昨不见了咧～只是感慨了一下
今天的归途特顺嘛~~(╯︵╰)b
好饿啊....走！妈妈带你出去吃饭去～.....((((ゞ(o =
^エ^)o ツ 嘘^o (=^ω^=)m
學校學生超愛牠的！！！[哈哈]

SIGHAN Bakeoff 2005 データセット MSRでの結果	Model	CRF	NPYCRF	+辞書
	Token F値	97.4	97.5	97.5
	OOV 再現率	83.5	84.1	82.1
	IV 再現率	98.5	98.6	98.8

論文

持橋, 鈴木, 藤野: 「ベイズ階層言語モデルと条件付確率場の統合による半教師あり形態素解析」, NLP2011, 2011.3.