


自然言語処理のレシピへの分野適応

森 信介 zelch

京都大学

2011年5月25日



統計的手法による言語処理

▶ 現在主流の手法 (ChaSen, MeCab, ...)

1. コーパスへの^{アノテーション}情報付与
2. 機械学習
3. タスクのテキストの解析

▶ 問題点

- ▶ タスクのテキスト (適応分野) に対する不十分な精度
理由: 学習コーパス (一般分野) との差異
- ▶ 自然言語処理の枠組みに制限されたアノテーション
 - ▶ アノテーション体系の理解困難 (ex. 活用型って何)
 - ▶ 目的には不要なアノテーション (ex. 品詞細分類)


⇒ 辞書追加程度

Pointwise NLP 点予測による言語処理

- ▶ 必要なときに必要なだけの曖昧性解消
- ▶ 部分的アノテーションによる迅速分野適応 Agile Adaptation
- ▶ 推定値を参照しない

1. 単語分割 [LREC 2010, 情処論?]
2. 品詞推定 [ACL 2011, 情処 NL198] きゅーていー
KyTea
3. 読み推定 [LREC 2010]
4. 係り受け解析 [情処 NL201, IJCNLP 2011?] 未公開
5. 述語項構造 実装中
ex.) 上げ (かき-を, ざる-に)

必要なときに必要なだけの曖昧性解消



推定値を参照しない


▶ 点予測による形態素解析



素性は

1. 注目単語
2. その単語境界
3. 前後の文字列

▶ Cf. 系列に基づく形態素解析 (CRF, n-gramモデル)



実験結果

- ▶ 言語資源: 国研の^{コーパス}BCCWJ + UniDic(213,174 語)

出典	用途	文数	文字数
白書・書籍・新聞 (一般分野)	学習	27,338	1,131,317
	テスト	3,038	126,154
医薬品情報 (JAPIC) (適応分野)	テスト	1,236	67,828

- ▶ 結果

形態素解析手法	形態素解析精度	
	一般分野	適応分野
系列予測 (MeCab)	99.23	92.94
点予測 (KyTea)	98.86	93.70

部分的アノテーションによる迅速分野適応


- ▶ 部分的アノテーションコーパスが利用可能
 - ▶ 分野特有の表現のみ情報付与

例) (1) の しし唐/名詞 を加え、ひと炒めし

- ▶ 注目単語の単語境界と品詞のみ
- ▶ 能動学習の活用
- ▶ Cf. フルアノテーションコーパス
 - ▶ 文のすべての単語境界と品詞


例) (/記号 1/数字) /記号 の/助詞 しし唐/名詞
を/助詞 加え/動詞 ひと/接頭辞 炒め/動詞 し/動詞

能動学習 (Active Learning)



- ▶ 東日本大震災の tweet の単語分割 (ANPI_NLP)
 - ▶ 2時間弱の作業 (4 iterations)
 - ▶ 精度: 97.31% $\xrightarrow{+dict}$ 97.32% $\xrightarrow{+AL}$ 97.74%
 - ▶ もう少し時間をかければ 98.5%程度に到達

能動学習の結果




- ▶ ^{KyTea}「点予測+能動学習」は効果的

係り受け解析 [情処 NL201]

係り受け木とは

1. **単語**をノードとし
2. 修飾関係をアークとする
(いまのところラベルなし)
3. 木構造
 - ▶ 部分的アノテーションからの学習
 - ▶ ^{Pointwise}点予測の MST (Maximum Spanning Tree)
 - ▶ まもなく公開
 - ▶ レシピへの適応はまだ




コーパスの諸元

ID	出典	用途	文数	単語数	文字数
EHJ-train	辞書の	学習	11,700	145,925	197,941
EHJ-test	例文	テスト	1,300	16,348	22,207

- ▶ 辞書の例文
- ▶ 品詞なし (KyTea で自動付与)
- ▶ 比較手法
 - ▶ Malt: Nivre ほか (2006) の MaltParser (\approx CaboCha)
 - ▶ MST: McDonald ほか (2005) の MST Parser
 - ▶ PW: 提案手法

フルアノテーションコーパスサイズ v.s. 精度



- ▶ コーパスが大きくなると **PW** の精度が高くなる (11.47[係り受け/文])

レシピテキスト処理の課題

- ▶ 形態素解析の精度向上
 - ▶ 10時間程度の作業 (すでに1時間作業済み)
- ▶ 係り受け解析の精度向上
 - ▶ 50時間程度の作業
- ▶ 固有表現 (特定意味クラスの**単語列**) の抽出
 - ▶ 食材, 調理器具, ...
 - ▶ 様々な言語資源を活用
- ▶ 表記ゆれ
 - ▶ KyTea は読み推定ができるので容易??
 - ▶ JUMAN の代表表記の利用??

まとめ

レシピに強い形態素解析

レシピに強い係り受け解析

表記ゆれ

固有表現

× 述語項構造 (ゼロ代名詞など)

▶ 他にできること

▶ 音声認識, 仮名漢字変換, 読み推定 (音声合成)

▶ 皆さんの要望??

mori.shinsuke.8u@kyoto-u.ac.jp or

zelch

検索