

単語対応の導入

内山将夫@NICT
mutiyama@nict.go.jp

パラレルコーパスからの情報抽出

- 単語対応 (Word alignment) の抽出 (これ)
- 句対応 (Phrase alignment) の抽出
- 翻訳規則の抽出

単語対応 (Word Alignment) とはなにか

たくさんの対訳文対が，パラレルコーパスとして与えられたとき，各対訳文対において，日本語のどの単語が，英語のどの単語に対応しているかを同定する．

単語対応は，そもそも良く定義できない問題である．つまり，対訳文が与えられたとき，どの単語とどの単語が対応するかは，人間がみても良くわからないのが普通である．

しかし，今のところ，単語対応を求めることは，コーパスベースの翻訳にとって，本質的な問題である．

単語対応の例

- 「今日」「は」「良い」「天気」「だ」
- 「It」「is」「fine」「today」

において

- 「今日」と「today」は対応する．
- 「良い」「天気」と「fine」は対応する．

その他の「は」「だ」や「It」「is」は，どう判断したら良いだろうか？

課題

適当な対訳文 10 文について，単語対応を求めること．

単語対応の確率モデル (Brown et al. 1993)

$P(f|e)$ = フランス語の文 f が英語の文 e から生成される確率

この $P(f|e)$ を, 英単語と仏単語の対応確率から求めたい. まず, e と f は, それぞれ l, m 個の単語からなる.

$$\mathbf{e} = e_1 e_2 \dots e_i \dots e_l = e_1^l \quad (1)$$

$$\mathbf{f} = f_1 f_2 \dots f_j \dots f_m = f_1^m \quad (2)$$

次に, 各仏単語 f_j が, ただ一つの英単語に対応すると
して, その英単語の位置を a_j とする.

$$\mathbf{a} = a_1 a_2 \dots a_j \dots a_m = a_1^m \quad (3)$$

このとき, f_j に対応する英単語は, e_{a_j} である. もし, f_j に対応する英単語がない場合には, $a_j = 0$ とする. この f_j は, NULL 単語から生成されたと考える. したがって, $a_j \in \{0, 1, \dots, l\}$ である. ある対応,

	f_1	f_2	f_3	f_4	f_5
NULL					X
e_1		X			
e_2	X		X		
e_3				X	

において, $f_1 \rightarrow e_2, f_2 \rightarrow e_1, f_3 \rightarrow e_2, f_4 \rightarrow e_3, f_5 \rightarrow \text{NULL}(e_0)$ より $a_1 = 2, a_2 = 1, a_3 = 2, a_4 = 3, a_5 = 0$ である.

ある生成モデル (IBM-Model 1,2 の原型)

$$\begin{aligned} P(\mathbf{f}|\mathbf{e}) &= \sum_{\mathbf{a}} P(\mathbf{f}, \mathbf{a}|\mathbf{e}) \\ P(\mathbf{f}, \mathbf{a}|\mathbf{e}) &= \text{仏文 } \mathbf{f} \text{ と対応 } \mathbf{a} \text{ が英文 } \mathbf{e} \text{ から生成される確率} \\ &= P(m|\mathbf{e}) \prod_{j=1}^m P(a_j | a_1^{j-1}, f_1^{j-1}, m, \mathbf{e}) \\ &\quad P(f_j | a_1^j, f_1^{j-1}, m, \mathbf{e}) \end{aligned}$$

$P(m|\mathbf{e})$ = 英文 \mathbf{e} が m 単語の仏文になる確率

$P(a_j | a_1^{j-1}, f_1^{j-1}, m, \mathbf{e})$ = 仏文が f_1^{j-1} まで生成され, それぞれが, a_1^{j-1} の位置の英単語につながっているとき, j 番目の仏語が a_j 番目の英単語につながる確率

$P(f_j | a_1^j, f_1^{j-1}, m, \mathbf{e})$ = 上述の条件に加えて, j 番目の仏語が a_j 番目の単語につながるときに, j 番目の仏単語が f_j である確率

これは, 確率の式を厳密に展開したものであることに注意する. 上述の式を簡単化したものが IBM Model 1,2 である. 別の形の式展開をすると IBM Model 3,4,5 となる.