

## コーパス分割を用いた良質な統計量の推定

3 R-7

乾 伸雄, 小谷 善行

東京農工大学工学部情報コミュニケーション工学科

### 1. はじめに

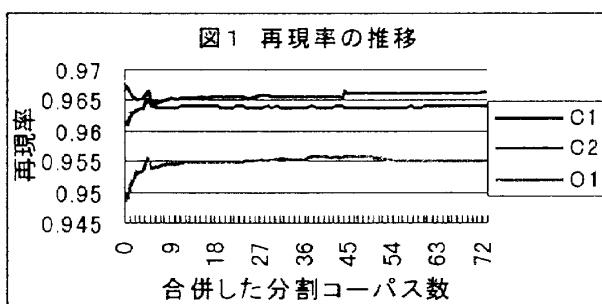
統計的アプローチに基づく自然言語処理においては、質の高い統計量をコーパスから得ることが解析率を向上させる鍵となる。一般にコーパスの規模が拡大すると、そのコーパスに対する解析精度は低下する。これを防ぐために、「コーパス分割法」という新しい手法を導入し、日本語の形態素解析において評価する。

### 2. 学習コーパスの解析率の低下

本稿では、統計量を取得するためのコーパスを「学習データ」、それ以外のコーパスを「評価データ」と呼ぶ。形態素解析には式1を用い、学習データとしてRWCコーパス91年度(約2700万単語、品詞492種類)を使う。図1は、学習データサイズと解析率の関係を示す。学習コーパスを128分割し、おののを分割コーパスと呼ぶ。横軸は、合併された分割コーパス(累積分割コーパス)の数を示す。式(1)は生起確率と文脈確率の積で表されている。C1(39300語)とC2(44781語)は生起確率の算出に使われているデータであり、O1(65409語)は使われていない。また、C1は文脈確率の算出に使われているが、C2、O1は使われていない。

$$(式1) \arg\max P(W_i | P_i) P(P_{i+1} | P_i)$$

$W_i$ : i番目の単語・品詞,  $P_i$ : i番目の品詞



データの規模が大きくなるにつれて、C1の再現率が低下していき、一定の値(約210万語のコーパス、10セットの分割コーパス)に対して、再現率0.964)に収

束した。C2、O1については、ある時点まで再現率が向上するが、やはり収束する。収束した時点で、累積分割コーパスから得られる文脈確率が、一定値になったと考えられるがちであるが、そうではない。これについては、3章で議論する。また、C1、C2とO1との差は、未知語が原因となって発生したものと考えられる。

累積分割コーパス規模が小さいとき、C1の解析精度が下がる理由としては、多品詞処理の問題を指摘できる。規模が小さいときは、C1に含まれる多品詞語をうまく処理できても、大きくなるにつれて、多品詞語を一意的に解釈するような結果しかだせなくなる。実際に、形態素境界の決定率の低下を再現率の低下は大きく上回っている。この意味で、文脈確率は微妙なバランスの上に成り立っているといえる。コーパス規模拡大とともに解析精度が下がる問題を防ぐために、本稿ではコーパス分割法を4章において提案し、5章で評価する。

### 3. 精度の推定

文脈確率がC1に似ているほど、C1に対する再現率は向上すると考えられる。これから、二つの文脈確率のうちで、C1の文脈確率に似ている方が、再現率がより高いことが予想される。このため、文脈確率ベクトルと考え(式2)、二つのベクトル間の非類似度を式3のような尺度で測定した。表1は再現率に対するC1の属する分割コーパスと累積分割コーパスの非類似度の相関係数を示す。

$$(式2) PL_{nm} = (P(pos[1] | pos[m]), P(pos[2] | pos[m]), \dots)$$

$$PL_n = (P(pos[1] | pos[1]), \dots, P(pos[1] | pos[2]), \dots)$$

$PL_{nm}$ : 品詞ごとに、文脈確率をベクトル化

$PL_n$ : 文脈確率全体をひとつにベクトル化

$$(式3) Da_{1,2}(1,n) = \sum_m \text{angle}(PL_{1m}, PL_{nm}) / m$$

$m |PL_{Xm}|=0$  のときは 90 度、無視

$$Da_{3,4}(1,n) = \text{angle}(PL_1, PL_n)$$

$$Dd_{1,2}(1,n) = \sum_m |PL_{1m} - PL_{nm}| / m$$

$m |PL_{Xm}|=0$  のときも計算、無視

$$Dd_{3,4}(1,n) = |PL_1 - PL_n|$$

$|PL_{Xm}|=0$  のときも計算、無視

$\text{angle}(PL_{1m}, PL_{nm})$ : コーパス L1, Ln における品詞mの文脈確率のなす角度

表1から、Da2, Da3, Dd2 の相関が高いので、頻度0の品詞については無視した方がよいことがわかる。本

稿では、この結果に従い、二つの文脈確率の非類似度を Da2 によって、推測する。

表1 文脈確率と再現率の相関係数

Da1	Da2	Da3	Dd1	Dd2	Dd3	Dd4
-0.702	-0.79	-0.792	-0.738	-0.78	-0.748	-0.779

しかし、分割コーパス間の角度については、式(4)が近似的に成り立ち、累積分割コーパスの値は、一定の値に収束しないで振動する。全ての分割コーパスに対し、最も類似した文脈確率を求めることが望まれるが、これを一意的に定めることはできない。このため、本稿では4章で述べる手法を用い、全てのコーパスに似ている文脈確率を求める。

$$(式4) \forall ij Da2(ij) = 18$$

#### 4. コーパス分割法

2, 3章で述べてきたように、精度を向上するためには、どの分割コーパスにも似ている文脈確率をコーパスから推定することが必要である。従来の方法では文脈確率は式5によって計算されるが、個々のコーパスの違いをより反映するために、式6によって文脈確率を計算する。基本的には同じ文脈確率を持つコーパスを重視する(しない)という方針で計算する。freq(pos[i])は品詞 pos[i] の頻度を示し、Px は分割コーパス x についての文脈確率を表す。式5は式6の特殊な場合、つまり全てのコーパスについて品詞の頻度が等しい場合に相当する。

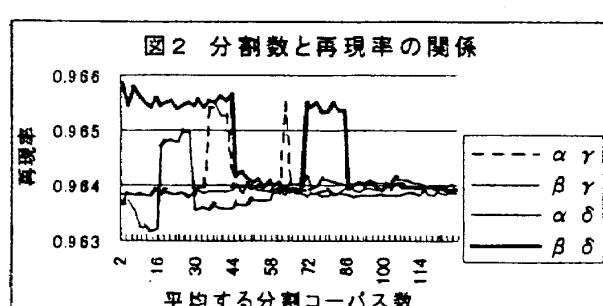
$$(式5) P(pos[i] | pos[j]) = \frac{freq(pos[j]pos[i])}{freq(pos[i])}$$

$$(式6-1) Pz(pos[i] | pos[j]) = \frac{Px(pos[i] | pos[j]) + Py(pos[i] | pos[j])}{2}$$

$$(式6-2) P(pos[i] | pos[j]) = \frac{\sum Px(pos[i] | pos[j])}{k}$$

k : 残りの分割コーパスの数

指定された残りの分割コーパス数になるまで、式6-1によって、二つの分割コーパスの文脈確率を統合し、式6-2によって、平均を求める。式6-2で統合される分割ペアの選択方法として、今回の実験では次の二



つの方法を使う。

方法  $\alpha$ ) 最も類似しない文脈確率を選択

方法  $\beta$ ) 最も類似した分割コーパスを選択

非類似度は次の二つで計算できる。

方法  $\gamma$ ) 分割コーパスを単位として文脈確率を平均

方法  $\delta$ ) 品詞を単位として文脈確率を平均

#### 5. コーパス分割法の評価

図2に L1 に対する再現率を示す。横軸は、式 6-2 を適用する残りの分割コーパス数である。例えば1のときは、式 6-1 だけで文脈確率を求める事になる。

$\beta\delta$ 、つまり、非類似度が最小の組み合わせを品詞単位、累積分割コーパス数が1になるまで行なったとき、最大の再現率 0.6959 を得た。図1と比較すると、通常の手法による再現率の低下を 100%としたとき、約 40% の低下に押されている。 $\alpha\gamma$ において、累積分割数 60 付近で、再現率が瞬間に向上しているが、分割コーパスの組み合わせによって様々な C1 に近い文脈確率を表現できることを示している。しかし、他の文脈確率と比べて、C1 に近い二つの文脈確率の非類似度 Da2 は決して小さくない。そのため、より高精度な非類似度の尺度が必要となる。表2に、C1 を最大にする文脈確率の O1 に対する再現率を示した。評価データに対しても、再現率は向上している。正解率も、再現率と同程度向上することが確認できた。

表2 評価データ O1 に対する再現率

	通常	$\alpha\gamma$	$\beta\gamma$	$\alpha\delta$	$\beta\delta$
再現率	0.9553	0.9569	0.9553	0.9553	0.9568

#### 6. 関連研究

精度を向上するためには、トライグラム、共起関係 [1]、品詞の階層化・低信頼統計量の推定[2]などの手法が考えられている。コーパス分割法はこれらと矛盾なく利用することができ、形態素解析だけではなく、様々な統計的手法への適用が可能である。

#### 7. おわりに

コーパス分割によって、学習コーパスの規模拡大による解析精度の低下を防ぐ方法を提案し、日本語形態素解析における効果を確認した。

謝辞 本研究は文部省科学研究費補助金(09780315)の支援で行われた。

#### 参考文献

[1] 北研二他、音声情報処理、森北出版、1996

[2] 藤本他、枝分かれ構造を持つ同時確率モデルによる形態素解析、情報処理学会論文誌(近刊)