

# 1 R-8 ニュース原稿データベースからの表現パターンの抽出

浦谷 則好

NHK 放送技術研究所

## 1. はじめに

機械翻訳等の自然言語処理にとって慣用表現や定型表現が重要な役割を果たすことは、疑うべきもない。しかし、慣用表現を手で収集するのは容易ではない。そこで、コーパスからコンピュータを用いて機械的に慣用表現を抽出することが考えられている<sup>1)~6)</sup>。機械的に慣用表現を抽出するためには何らかの基準が必要となる。過去の研究では相互情報量や仕事量などの基準が使われているが、どのような基準が慣用表現を抽出するのに適しているかは明らかでない。

我々は3つの基準を設定して表現パターン（慣用表現や定型表現）を抽出する実験を実施した。ここでは、3つの基準と抽出結果と傾向について報告する。

## 2. 表現パターンの自動抽出

ある文字列（長さ  $n$ ）が1つの表現パターンをなしているか否かは、直感的に「その文字列の先頭か最後尾の1字を取ったパターンの頻度が元のパターンからあまり増加しない」、および「その文字列の前後に1字を加えたパターンの頻度は（最大のもので）大きく減少する」ことを確認することで決定することができる。しかし、どの程度の変化をもって表現パターンの大きさを決定すれば良いかは明らかでない。Churchらは相互情報量<sup>1)</sup>を、北らは仕事量<sup>2)</sup>を、長尾らは直前、直後にくる文字種の数<sup>3)</sup>を、新納は条件付き確率の変移<sup>6)</sup>を抽出の基準に用いている。

われわれは以下に示す3つの基準を設定して、抽出実験を行なった。

### An Automatic Extraction of Expressions from News Manuscript Database

Noriyoshi URATANI

NHK Science and Technical Research Laboratories

1-10-11 Kinuta, Setagaya-ku, Tokyo 157, Japan

### ●仕事量基準

$$n \times f_a$$

### ●平均情報量基準

$$\log (N / f_a) / I_n$$

### ●エントロピー基準

$$\log (N / f_a) / H_n$$

ここで、

$a$  : 長さ  $n$  の文字列 (例えば  $defgh$ )

$f_a$  : 文字列  $a$  の頻度

$A_n$  : 長さ  $n$  の文字列全体の集合

$N$  :  $A_n$  に含まれる文字列の頻度の総和

$f_n$  :  $A_n$  に含まれる文字列の頻度の平均

$I_n$  :  $A_n$  中で平均頻度を持つ文字列の情報量  
 $= -\log_2 (f_n / N)$

$H_n$  :  $A_n$  のエントロピー ( $= -\sum p \log p$ )

である。「仕事量基準」は北らのものと酷似しているが、 $n-1$  でなく  $n$  を用いているところが異なっている。(北らの基準では、1字長のパターンと2字長のパターンの優位を計ることができない。また、重要度を定義するにはこの方が自然であると考え。)

これらの基準を用いて、各々の文字列をそれより1だけ長いもの、および1だけ短いものと比較し、優位と判断された方を残すことによって表現パターンを抽出する。例えば、

$\beta$  :  $a$  を部分列とみて含む長さ  $n+1$  の文字列  
 (例えば  $defghi$  あるいは  $cdefgh$ )

$\gamma$  :  $a$  の先頭の1字を除いた文字列 (例えば  $efgh$ )

$\delta$  :  $a$  の最後の1字を除いた文字列 (例えば  $defg$ )

とした時、「仕事量基準」では

$$\max (f_\gamma, f_\delta) \times (n-1) < f_a \times n$$

$$\max (f_\beta) \times (n+1) < f_a \times n$$

のときに  $a$  を表現パターンと認定するわけである。(「平均情報量基準」や「エントロピー基準」でも同様であるが、不等号の向きは反対になる。)

## 3. 実験

NHKのニュース原稿データベースを対象にして2. で述べた基準を用いて表現パターンの抽出を行なった。用いたデータは1992年7月から1993年7月分の約1年分のニュース文(本文のみで1110万文字)である。文字列の単純頻度は長尾の方法<sup>5)</sup>で求めた。表現パターンの抽出結果を図1~図3に示す。“S!”は文頭を表す記号で1字として扱っている。これを見ると仕事量基準では短いパターンが抽出される傾向があり、エントロピー基準では比較的長いパターンが抽出される。平均情報量基準は2つの中間に位置しているように思われる。

## 4. おわりに

抽出されたパターンは3つの基準それぞれに特徴を有している。我々の目的は日英機械翻訳のための表現パターン(つまりは翻訳ユニット)を探ることにある。実験結果から、こうした目的にはエントロピー基準が合致しているように思われる。今後、さらに実験と検討を加えて、日英機械翻訳システムの改善に利用していく予定である。

表1 仕事量基準で抽出されたパターン

仕事量	頻度	表現パターン
484380	484380	の
320183	320183	、
299345	59869	ました。S!
263361	263361	に
240718	120359	。S!
218431	218431	と
214180	107090	した
213325	213325	を
197914	197914	で
184302	30717	ています。S!
182450	182450	が
179476	89738	てい
166410	55470	す。S!
162040	81020	して
123046	61523	は、
93098	46549	こと
92178	46089	って
86902	43451	する
84002	42001	から
82491	27497	ている

表2 平均情報量基準で抽出されたパターン

頻度	表現パターン
59869	ました。S!
30717	ています。S!
55470	す。S!
484380	の
89738	てい
81020	して
61523	は、
18336	について
24091	。S!こ
21987	ること
263361	に
43451	する
42001	から
18051	きょう
17921	という
33935	など
6798	によりますと
14024	ことに
213325	を
8713	アメリカ

表3 エントロピー基準で抽出されたパターン

頻度	表現パターン
59869	ました。S!
30717	ています。S!
18336	について
17665	です。S!
4403	ということです。S!
6798	によりますと
6017	ということ
3045	ことにしています。S!
27497	ている
2894	ことになりました。S!
3781	ました。S!また
3172	を示しました。S!
3585	たものです。S!
2543	と話しています。S!
484380	の
2428	」と述べました。S!
5827	す。S!この
21987	ること
21587	として
2982	」と話していま

## 参考文献

- 1) Church, K.W. and Hanks, P.: Word Association Norms, Mutual Information, and Lexicography, ACL-89 (1989)
- 2) 浦谷則好ほか: AP電経済ニュースからの定型パターンの抽出, 情処42全大6E-4, (1991)
- 3) 加藤直人, 相沢輝昭: 外電ニュースの定型文抽出とその英日機械翻訳, 情処研資N93-2, (1993)
- 4) 北 研二ほか: 仕事量基準を用いたコーパスからの定型表現の自動抽出, 情処論vol.34, No.9, (1993)
- 5) 長尾眞, 森信介: 大規模日本語テキストのnグラム統計の作り方と語句の自動抽出, 情処研資N96-1, (1993)
- 6) 新納浩幸: 文字列と後続文字との接合割合の変化を利用した定型的文末表現の自動抽出, 情処研資NL104-6, (1994)