

# 日本語形態素解析の基本設計

坂本義行  
(電子技術総合研究所)

## 概要

本研究は、日英機械翻訳システム<sup>1)</sup>における科学技術文献を対象とした日本語文の形態素解析を行い、分析結果として 日本語構文解析等に必要な情報を辞書システム<sup>2)</sup>より検索し、出力することを目的としている。解析は、辞書駆動型による文字列間の接続関係と文の左端からナエックし、文を単位として、可能な解を全て出力する Multiple-path 方式をとっている。本稿では サンプル文として JICST 文献抄録文について実験を行つてある。そこに出現した文の表現形式を細部にわたり分析し、実用的な解析システムを構築するプロセスの開発をめざしている。

## 1. はじめに

日本語の形態素解析は、その目的、用途によつて、その方法も、自ら異なるものとなるであろう。本研究では、日英機械翻訳システムとして必要な処理形態、言語的な興味といった目的を捨て実用という面から、文献に現われる表記を可能な限り辞書に登録することにより解析の可能性を確めるとともに、処理ソフトウェアと辞書とを明確に区別し、処理手順の簡略化、拡張の容易さをめざした。

日本語構文解析<sup>3)4)</sup>に必要とされる情報は、すべてこの形態素解析レベルで、辞書を引くことにより付与する方式をとつてゐる。

処理手順は、大きく次の 3 つに分かれる。

- 1) 入力テキストの形態化処理
- 2) 形態素の分割
- 3) 形態素解析の出力処理

本研究は、国の科学技術振興調整費による「日英技術文献の連携システムに関する研究」の一部として行つたものである。

研究協力者として、木村睦子(計算機研究室)、山本稔(東洋情報システム)の諸氏、なうじに、本研究の委託を受け、その遂行のために、自然言語処理の専門家から成る言語処理システム作業分科会、さらに処理システム作業グループ(京大)、辞書作業グループ(JICST)を組織し、その審議、指導のもとに研究をすすめている。

## 2. 入力テキストの形態化処理

翻訳の入力文である JICST の抄録文から日本語形態素解析の入力文となる標準形式をつくりだすために以下のようないづれマッピングを行なう。

- 1) 抄録番号、記事番号といった書誌的項目の区分
- 2) 標題、本文、式、図などの区分
- 3) 印刷書式等の内容に直接関係しない部分の区分

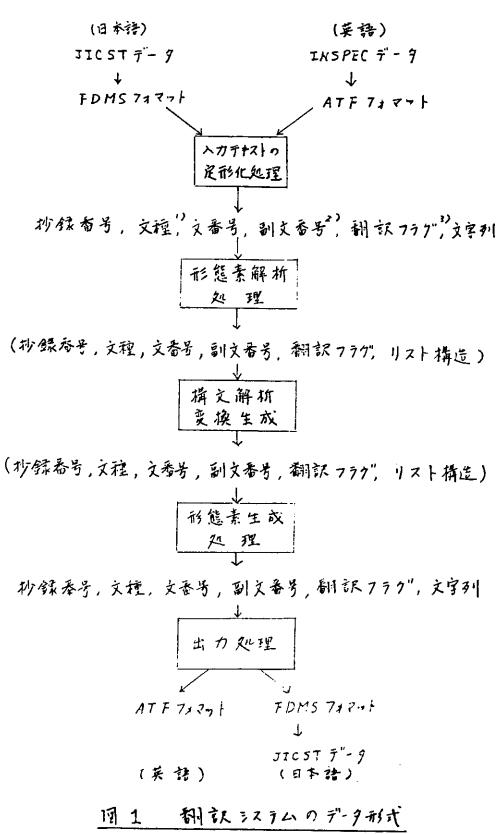
### 2.1 システム中での処理の流れ(図1)

### 2.2 フォーマット情報

フォーマット情報の取扱いを以下の 4 種に分ける。

A 1. 総合システムが管理するもの(翻訳フラグを N I L とする)  
例. @ P9 @, @ AR @

A 2. 総合システム<sup>5)</sup>がすべて管理するもの。フォーマット情報のうち首尾照応するもので、中间に翻訳対象を含むもの。



- 1) 文字列(文)の種類。例: 標題,本文,レイアウト。
- 2) 同一文番号内で複数番号。一文中に「」マーク付けて複数のレコードに分かれられる場合
- 3) 翻訳を必要とするかどうかのフラグ  
T: 翻訳が必要(通常の文)  
NIL: 翻訳が不要(主としてページ構成に用いられる「」マーク)

```

JEF FORM DOCEDT VOL/L07 キニタリスト DATE:83.07.01 TIME:19.27.03 PAGE: 1
タキスト名: 作成日付 83.07.01

項目番号 基本番号
0. 0. 0 1. 1. 0 $PG=50,66,1,5,9,4$BAR=5,5$HS=H12,39
0. 0. 0 1. 3. 0 抄録の機械翻訳システムBHEBこのシステムは JICST
0. 0. 0 1. 4. 0 の抄録を計算により翻訳するものである。本システムの入力は、たとえば、富士通のFDMSのようなフォーマット機能をもったシステムに対する入力であってもよい。
0. 0. 0 1. 5. 0 持ったシステムに対する入力であってもよい。$NLBこのシステ
0. 0. 0 1. 6. 0 ムの特徴は、次のとおりである。
項目番号 基本番号
0. 0. 0 1. 1. 0 E82060001. レイアウト, 0. 10. NIL, "$PG=50,66,1,5,9,4,8"
0. 0. 0 1. 2. 0 E82060001. レイアウト, 0. 20. NIL, "BAR=5,5"
0. 0. 0 1. 3. 0 E82060001. レイアウト, 0. 30. NIL, "$HS=H12,39"
0. 0. 0 1. 4. 0 E82060001. レイアウト, 0. 40. T, "抄録の機械翻訳システム"
0. 0. 0 1. 5. 0 E82060001. レイアウト, 0. 50. NIL, "BHEB"
0. 0. 0 1. 6. 0 E82060001. 本文, 1. 10. T, "このシステムは JICSTの抄録を計算により翻訳するものである。"
0. 0. 0 1. 7. 0 E82060001. 本文, 1. 20. T, "本システムの入力は、たとえば、富士通のFDMSのようなフォーマット機能をもったシステムに対する入力であってもよい。"
0. 0. 0 1. 8. 0 E82060001. レイアウト, 2. 20. NIL, "$NLB"
0. 0. 0 1. 9. 0 E82060001. 本文, 3. 10. T, "このシステムの特徴は、次のとおりである。"

```

フォーマット情報と翻訳対象文を分け別レコードにする。

例: @HS=H12,3 @抄録の機械翻訳  
システム@HE@

B: 形態素解析の時より単語の性質に反映するもの(等価情報)

例: @UH@システム@UE@  
ただし、複数の単語にまたがって指定されている場合は「C」で扱う。

例: CUL@ある種の単語@UE@  
また、単語の一部分だけが指定されている場合は、その単語全体に対して指定したもののみなす。

C: 句読点と同様に一語扱いとして、文法処理に引き渡すもの。

### 3. 形態素の分割

漢字かな混じりの日本文を文節、語あるいはさらに小さな単位に分割する処理方法として、その手順をプログラム化して行う方法と辞書の複数を中心としたプログラムにより行う、大きく分けて2種類の方法がある。前者は「小まわりのきく」方法であり、後者は「辞書」に依存するためプログラムは單純化されるといった特徴を有している。本研究では翻訳に適応する。すなはち英語に訳すに最適であり、改良、拡張が容易な後者の方法である辞書駆動型の解析手順を選んだ。

図2. 定形化処理  
の実例

### 3.1 分割の特徴

- 1) 構成要素一 プログラム、辞書  
接続表等データベース
- 2) 处理方式一 Multiple-path  
方式で 1つ、1)の言語情報により  
形態的に接続可能なあらゆる単位  
語列を作成する。
- 3) 处理単位一 設定した「文」を  
単位にその中の文字列にすべて接  
続可能な場合のみを出力する。

### 3.2 辞書引きの方法

辞書には自立語(複合語を含む)、付

属語、接辞等を見出しお  
し、形態素解析に必要な  
情報として、図1に示す  
ような見出し情報、形態  
素情報が与えられる。

見出しあは用言につい  
ては、終止形で表わされ  
る語尾子数によつて語幹を  
判定可能。異形語はすべ  
て見出しあと同様に扱う。  
分割の可否を判定するに

表1 形態素辞書リスト

見出し語		
	語尾子数	
	漢字部	
	語基	
	読み	

コード	内 容	コード	内 安	コード	内 安
1	名詞	26	助助・まで・並助・と・か	50	上段動詞語幹
2	副詞の名詞(全般類)	27	接続助詞 カラ	51	" "
3	副詞	28	接頭辞	52	" "
4	述語詞	29	五段動詞未然形(～ん)	53	上一段動詞語幹
5	接続詞	30	" "(～う)	54	" "
6	数詞	31	「 」 量体(音韻) 促音便	55	" "
7	サウ、上二下二、カ変、サ変連用	32	" "(音韻) 擬音便	56	" "
8	五段動詞(せり以外)連用	33	動詞・形容詞擬定形	57	" "
9	動詞終止形	34	上一、下一、カ変未然形	58	" "
10	動詞・形容詞連体形	35	サ変未然形 さ	59	" "
11	動詞全形	36	" " セ	60	" "
12	上二、下二語幹基語尾	37	" " し	61	下一段動詞語幹
13	文末語幹	38	形・形容詞未然形 くんで	62	" "
14	終止形 す	39	述形形 カニ	63	" "
15	形容詞連用形 <	40	ナ変語幹	64	" "
16	終止形 <	41	形容詞語幹	65	" "
17	形容動詞連用形 て	42	形容動詞(2方型)語幹	66	" "
18	終止形	43	" (ナ+型) "	67	" "
19	述形	44	五段動詞語幹	68	" "
20	ア、イ、エ	45	" " か行	69	" "
21	ベキ	46	" " 少行	70	" "
22	ト よう 終止形	47	" " 夕行	71	" "
23	格助詞 と	48	" " ト行	0	始末状態
24	" カ カ	49	" " ハ行		
25	" タ カ より へ	50	" " バ行		

表3-1 後接情報

コード	内 容	コード	内 安	コード	内 安
1	名詞	26	ので、のに	51	五段動詞語尾
2	名詞以外の自立語、接頭辞	27	格助詞 カ、タ	52	" "
3	形式名詞	28	" に	53	上一段動詞語尾
4	補助動詞(～に接続形)	29	" カラ	54	" "
5	助敬詞	30	" まで、より	55	" "
6	助動詞 ない	31	" の	56	" "
7	" め	32	助助・と、へで、並助や	57	" "
8	ナ 名詞 セロ	33	と(引用)	58	" "
9	" カロス、セロ	34	助詞 カ	59	" "
10	" カロス、セロ	35	助助詞 カ、タ、ミ、モ、ミ	60	" "
11	" カ	36	副助詞 カ、タ、モ、タ、モ、モ	61	下一段動詞語尾
12	" よう	37	(体言接続)	62	" "
13	" も、まし、つつ、なが	38	少変語幹接続助動詞	63	" "
14	" もの(推定)	39	ナ変語幹	64	" "
15	" た	40	ナ変語尾	65	" "
16	" うい、おうう、なら	41	ナ変語尾	66	" "
17	" だ、でから	42	形容詞語幹	67	" "
18	" べき	43	形容語尾	68	" "
19	" まい	44	五段動詞語尾	69	" "
20	接続助詞 カ、カラ、リハビ、ル	45	" " ハ行	70	" "
21	助動詞 カラビ(括弧)	46	" " バ行	71	" "
22	接続助詞 て	47	" " 夕行	0	終末状態(午後点)
23	" は"	48	" " ト行		
24	" と	49	" " ハ行		
25	" て(た、て、めにこり)	50	" " バ行		

表3-2 前接情報

活用語尾処理は、活用語尾表を用い、その前接情報により判定する。なお語幹を持たない語は、語尾字数により判定し活用処理を行う。(辞書名帳には特殊活用型として記載されており、辞書生成時に見出し等の情報が独立して記憶される。)

### 3.3 分割の手順

#### 3.3.1 辞書による単語抽出

処理は辞書引きから始まる。文字列を左端から一字づつ辞書を引き、1回の操作で最も一致する文字列まで、すべてをスタッフする。スタッフ中の最も一致の文字列に対して、そのつぎの文字列について辞書を引き接続ナエツを行い可能な文字列をスタッフする。活用する語には、活用語尾処理を施す。以上の操作をくり返す。接続不可となつたら、以下の処理を実行する。

#### 3.3.2 特殊記号処理

##### ① 特殊記号の判別方法の特徴

- 文脈(前後の文字の字種や、文字の並びのパターン)によって判別される記号が多い。
- 確定的な判別法はほとんどなく、実際の文例とともに経験的な手法が多い。

##### ② 特殊記号の取り扱いの特徴

- 前の文字と同一の字種と1つ扱う。
- 後の文字と同一の字種と1つ扱う。
- 区切り符号、特殊符号や「つなぎ」の符号等のように独立の符号として取り扱う。

また、翻訳対象の広がりと共に、判別方法の変更の追加等が頻繁に行われ、その取り扱い方法も拡張されることが予想される。

以上の通り、ソフトウェアは機能の追加、変更に柔軟に対応できるようなテーブル駆動型の構造をとった。

##### ③ 特殊記号処理の手順

特殊記号処理は、辞書で引けなくなつた文字列に適用され、特殊記号

処理テーブルにより判別を行う。特殊記号テーブルは、特殊記号、処理適用条件と実行処理からなる。

#### 3.3.3 未知語の処理

辞書になく、特殊記号処理によつても単語抽出ができない場合で、かつ1つ前のスタッフにも、文完成スタッフにも解がれないとき、字種によるスキップ処理を行い、未知語と1つスタッフし、単語がインタを変更する。スキップ位置の決定方法として、未知語の先頭文字が

漢字、

カタカナ、

英文、

ギリシャ文字

指定した特殊記号、であつた場合にその字種が連続する最後の文字の次の文字までスキップする。

#### 3.3.4 バックトラック探索

##### 1) 文完成内のバックトラック

単語抽出に失敗したとき、それ以前にある単語スタッフを探し、単語リストを書き換え、単語がインタを変更し、3.3.1からの処理を繰り返す。

##### 2) 文完成後のバックトラック探索

文末までの処理が完成した後、マルケバスを行つたため、残余の単語スタッフを探索し、スタッフが空にならまで処理を継行する。

#### 3.4 形態素解析の出力処理

##### 3.4.1 辞書項目の付与

分割処理が終了し、文が完成した場合に辞書項目の付与を行つ。

##### 1) 見出し情報

見出しの形(活用語は、その見しの形)、派生語、関連語等表に記述されている情報

##### 2) 形態素情報

活用語には、その活用形を示す

##### 3) 構文・意味情報

##### 4) 依文配情報

## 5) 共起情報

## 6) 備考

以上のすべての情報をLISP-S式にて図3のように付与する。

### 3. 4. 2 日本語構文解析への出力

## 1) 積数の文の出力

分割が異なる解が得られたとき、文を単位として複数の文を出力する。

2) 複数の形態素情報をもつ(PARA)

単位として同一の分割が行われたが複数の形態素情報が得られ形態素解析では判別不能の場合

例

「T」…並列要素  
(PARA) 形容動詞の  
諸尾形

### 3) 連語

連接した文字列間に形態素的結合関係がある。

四

例 「才 / 回」 … 形態要素 才 / 回 (接頭語)  
(MOR COMP) (數) (助數詞)

表3-3 形態素分析接続表(1)

達 88~71；刺角線上 55~1

#### 4) 複合語

辞書に見出として登録されて 113  
文語基情報をもって 113

例

「機械翻訳」…語基要素 (DICCOMP) 翻訳

#### 4. おわりに

本稿では、5ヶ月度行なった基本設計に基き、本年度開発に着手した段階での報告の方針にて、完成されたものではない。今後、実験を重ねて、分割レベルの問題、構文解析へついてターフエイス等、多くの改良、拡張を必要とするところがわかかる。マルチバス方式の収束性の問題がある。それらにつれては、漸次報告する予定である。

## 参考文献

- 1) 長尾真, 「科学技術用機械翻訳アプローチとその概要」。

2) 坂本義行, 「構造を中心とした用言と付属語」。

3) 辻井潤一, 「日本諸構文解析」。

4) 中村順一, 「文法記述用ソフトウェア GRADE」。

5) 卡田光治, 長尾真,  
「機械翻訳統合システムの基本設計」。

以上の川上れも、本会で同時報告されたものである。

\*\*\* INPUT DATA \*\*\* => (E82060003 本文31T システム工学、情報工学、ソフトウェア工学など新しい技術の急速な成長により、IEEおよび電気工学教育の全パターンでの重点が移動した。)

### 図3 形態素解析の出力例