

# 機械翻訳に対するロングマン辞書データベースの応用

長尾 真 中村 順一 畑崎 香一郎 藤田 公一  
(京大・工)

1. はじめに 自然言語処理を行う場合、処理のために必要な情報を貯めておく処理用辞書をどのようにして作成するかは、重要な問題である。自然言語の解析アルゴリズムや生成アルゴリズムの研究が盛んに行われていて、これらのアルゴリズムを多量の文に対して適用しようとした場合、最大のネックは、これらのアルゴリズムが使用する、個々の単語についての情報、即ち、処理用辞書の見出し語が少なすぎるという点にある。見出し語の個数という点では、通常の中型辞書程度で十分であろう（専門用語、固有名詞を除く）。計算機による辞書引きが可能な通常辞書として、新コンサイス英和辞典<sup>1)</sup>、Longman Dictionary of Contemporary English (LDOCE)<sup>2)</sup>などがある。本来、これらの辞書は、人間のために作られたものである。このため、計算機による自然言語処理のために必要な情報を十分に含んでいないわけではない。しかし、LDOCEには、比較的多くの情報が含まれている。そこで、LDOCEをオンラインで英文の解析、日英機械翻訳における誤語選択、英文生成に利用する実験を行った。本報告では、LDOCEに含まれている、自然言語処理のための情報について紹介し、これを用いた実験結果について述べる。

2. Longman Dictionary of Contemporary English (LDOCE) LDOCE は、イギリスの Longman 社から発行されている英和辞書である。これには、自然言語処理にとって、次の 4 つの便利な点がある。

(1) この辞書は、計算機を利用して作成されたものである。このため、印刷物としてだけでなく、磁気テープの形でも入手可能である。この磁気テープには、図もしくは絵の部分を除く、印刷に必要なすべての情報が校正済みのデータとして含まれている。そこで、オンラインによる利用が容易である。

(2) 単語 (Head Word (HW)) に対して、その HW が用いられる統語的な環境の記述がコード化されて与えられている。このコードは、Grammatical Code (GC) と呼ばれている。GC は、従来の「他動詞」や「自動詞」の区別を細分化したものである。GC は、各 HW の各定義 (語義) 每に与えられている。

(3) 単語に対して Box Code (BC) が与えられている。このコードには、名詞に対する意味的制限が意味マークとして含まれている。なお、この BC は、印刷物中には表わされていない。<sup>3)</sup>

(4) HW の定義が、約 2000 単語に制限された単語 (Controlled Word) により記述されている。このため、定義自体を計算機により処理し、利用できる可能性がある。<sup>4)</sup>

以上の 4 点の中で、(2) と (3) との特徴が計算機による自然言語処理にとって重要である。

2.1. Grammatical Code (GC) GC は、HW がある定義で用いられる場合の統語的な環境の記述をコード化したものである。GC は、動詞、形容詞、副詞と名詞に対して与えられている。GC の種類の数を表 1 に示す。GC は、アル

ファベットと数字の組み合いで表現されている。たとえば、表1. GCの種類

*They considered him their enemy.*

という文中で用いられる動詞"consider"の定義に対しては、"X1"というGCが与えられている。ここで"X"は、 $Vt + O + C$ の形で用いられることを表わしている。また"1"は、動詞の後に1個以上(この場合は2個)の名詞句(NP)が現われることを表わしている。即ち、"X1"は、 $Vt + O + C$ の形で用いられ、OとCは共にNPであることを示している。動詞に関するGCの一覧を表2に示す。

動詞	31種
形容詞	15種
副詞	7種
名詞	23種
	計 76種

表2 Grammatical Code 一覧(動詞)

動詞コード	文型例	例文	GC
I	Vi	He <u>lived</u> to be 90.	I3
L	Vi C	She <u>became</u> famous.	L7
T	Vt O	I <u>hoped</u> clean the window.	T2
D	Vt IO DO	He <u>warned</u> her (that) he would come.	D5
X	Vt O C	They <u>considered</u> him their enemy.	X1
V	Vt O NP	to <u>have</u> a house built.	V8

このように、LDOCEのGCは、表層格フレームを記述したものであると言える。即ち、浅いレベルの解析と生成に必要な情報、言い換えれば、CFIG程度の情報を含んでいた。また、表2以外に形態素処理レベルのコ

数字コード	説明
0	V(動詞が何も伴う必要がない)
1	V + NP (+ NP)
2	V + Vinf
3	x + TO-V
4	V + Ving
5	x + THAT-clause
6	x + WH-clause
7	V + Adj
8	V + Ved
9	V + Adv, N + 叙述的語句, Adj + 叙述的語句

ドも含まれている。そこで、GCを用いて形態素処理を行うこともできる。なお、GCは、格フレームについての意味レベルの記述を含んでいない。そこで、GCだけを用いて表層レベルと深層レベルの記述(たとえば深層格フレーム)との間の変換を一般的に行うことできなない。

## 2.2. Box Code (BC)

LDOCE

の磁気テープ版には、Box Code (BC)と呼ばれるコードが単語の各語義に対して与えられてい。

BCは10個のフィールドから成り立っている。名詞・形容詞・動詞のBCでは、このうち3つのフィールドがそれを各語義に対する意味的制限を与えている。3つのフィールドは、box1, box2, illus<sup>+</sup>と呼ばれる。これらのフィールドの意味マーカの意味は品詞によって異なり、次のようになっている。

### (a) 名詞

名詞の場合には、box1のみが与えられる。box1は単語がその語義の意味で使われた場合の意味マーカを表わしている。

### (b) 形容詞

形容詞の場合も、box1のみが与えられる。box1はその形容詞によって修飾され得る名詞の意味マーカを表わしている。

### (c) 動詞

box1は、動詞の主語となり得るもののが意味マーカを表わしている。

+ illus<sup>+</sup>が意味的制限を表わすのは、その単語がD又はXのGCを持つときのみで、その他の場合は辞書中のマレーラーに開く情報を表わしている。

box 2 は、その動詞の GC が T, V, X のいずれかの場合は、その動詞の目的語、GC が D の場合は直接目的語、GC が L の場合は名詞補語に、それなり得るものとの意味マーカを表わしている。

illus は、その動詞の GC が D の場合はその動詞の間接目的語、GC が X の場合は名詞補語に、それなり得るものとの意味マーカを表わしている。他の他の GC を持つ動詞に対しては、box 3 は与えられなし。

次に意味マーカについて述べる。意味マーカはアルファベット 26 文字と 1 行の数字によって表わされている（表 3）。これらの意味マーカは階層構造を持ち、それは木の形になるが、その木は唯一ではない。つまり、木のあるノード（ある意味マーカ）に注目すると、そのノードが根ノードでなければ親ノードは 1 つ以上存在する。例えば、C (concrete) を根とする意味マーカ木は図 1 のようになる。すなわち、各意味マーカは木の終端ノードに対応するいくつかの意味マーカ（基本意味マーカと呼ぶ）をもののか、その組み合せを表わしている。その基本意味マーカは表 3 の記号で言えば、B, D, F, G, J, L, M, N, P, T である。

表 3. LDOCE 意味マーカ

A	Animal (not human) - sex unspecified
B	Female animal
C	Concrete (not abstract) - animate or inanimate
D	Male animal
E	Solid or liquid (not gas)
F	Female human
G	Gas
H	Human - sex unspecified
I	Inanimate (not abstract) - solid, liquid or gas unspecified
J	Movable (solid)
K	Male (animal or human)
L	Liquid
M	Male human
N	Not movable
O	Animal or human - sex unspecified
P	Plant
Q	Animate (plant, animal or human)
R	Female (animate or human)
S	Solid - movable or not movable unspecified
T	Abstract
U	Collective and animal or human
V	Plant or animal (not human)
W	Not animate (abstract or inanimate)
X	Not concrete or animal (abstract or human)
Y	Abstract or animate
Z	UNMARKED (no semantic restriction)
1	Human or solid
2	Abstract or solid

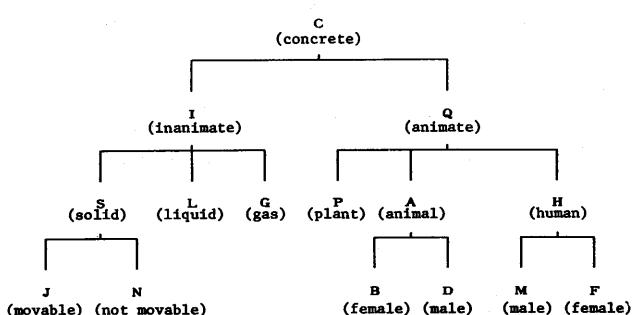


図 1 意味マーカの階層構造の例

### 3. LDOCE データベース

Longman 社から提供された磁気テープには基本的には出版されていなかった印刷物を作成するためのものである。データは、各項目（たとえば、見出し語、要綴語、品詞など）毎に可変長レコードの形で貯えられている。このため、各項目を切り出さ必要はない。

LDOCE のデータを効率よく、かつ柔軟に検索するため、磁気テープのデータを図 2 に示す形で直接アクセス装置上に貯え、利用している。<sup>2)</sup>

ITEMS には、辞書の各項目と TEXTS 中のエントリー（辞書のひとつつの見出し語に対する項目の集合）とを対応づけるための情報が含まれている。これには、見出し語（辞書の見出し語ではなく、検索のためのキーとなる見出し語。要綴語は別のレコードとして貯えている。また字体シフトコードなどは含まれていない。）と ITEMS へのポインタとか貯えられている。LDOCE の情報を単語をキーとして検索することは、HDTBL,

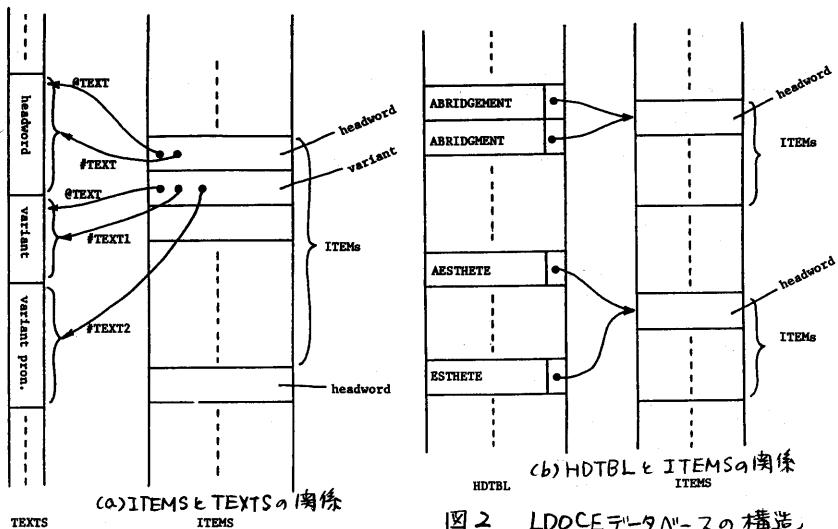
ITEMS, TEXTS をこの順序でたどることにより可能である。

LDOCEの構造データは、2で述べたように各項目毎に区別されている。しかし、項目内のデータは、ほぼ印刷物そのままの文字列の形で表わされている。

このため、原データをそのまま利用することは容易ではない。たとえば、異綴語は、"generalize, -ise"のように完全な形で書かれていらない場合がある。そこで、異綴語を復元して HDTBL に登録している。また、GC は、"[L1, 7]"のように、"[L1; L7]"を省略して表わされている場合がある。そこで、GC を定型化するプログラムを用意してある。

LDOCE データベースを検査するプログラムは PL/I で書かれている。また、LISP プログラムから LDOCE データベースを利用するためにインターフェースプログラムも作成した。これらのプログラムは、任意の単語（語尾変化しても、不規則変化形でも LDOCE 中に含まれる単語であればよい。）を与えれば、その GC や BC, 活用形などの情報を返すものである。なお、これらのプログラムは、用いたプログラムと LDOCE データベースの容量を表 4 に示す。

図 2 LDOCE データベースの構造



	Records	Space(KB)
HDTBL (Headword Table)	53,468	2,470
ITEMS	264,138	3,952
TEXTS	—	9,880
Total	—	16,302

表 4 LDOCE データベースの容量

#### 4. LDOCE をオンラインで用いた英文の解析

4.1. 解析の方法 2で述べたように、LDOCE の GC は、CFG 程度の情報をかなり詳しく表わしていると考へることができる。たとえば、V2 ("see"など) には、NP の目的語と INFL(不定詞句) の目的補語を支配することを示している。そこで、V2 に対して、

$$VP \rightarrow V_V2 \quad NP \quad INFL$$

という書き換え規則 (RR) を用いることができる。

このことから、GC を直接、非終端記号として扱う CFG-RR を作り、CFG パーサーを用いて英文の統語的解析を行った。解析の流れを図 3 に示す。実験に用いた RR の一部を図 4 に示す。

この CFG-RR は、以下に示す範囲の言語現象を扱うものである。これらは、LDOCE の GCだけを用いて、CFG パーサーで解析することが適当であると考えられる範囲の言

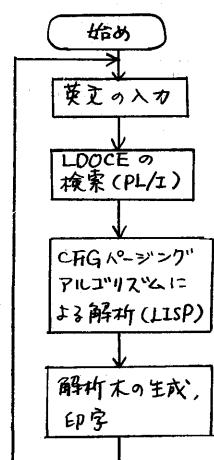


図 3 解析の流れ

語現象である。

(1) 単語の品詞のあいまいさの統語的な解消

(2) 肯定文(疑問文, 命令文は扱わない)

(3) 反身文, 使役文(これらは, 統語的には base-generated であるとして扱う)

(4) 関係詞節(gap は RR 中に直接記述)

(5) 動詞の必須格としての前置詞句(動詞の任意格としての前置詞句は扱わない。\*)

(6) 名詞の修飾句としての前置詞句

(7) 動詞の必須格としての副詞句(動詞の任意格としての副詞句は扱わない。)

(8) That 節における That の省略

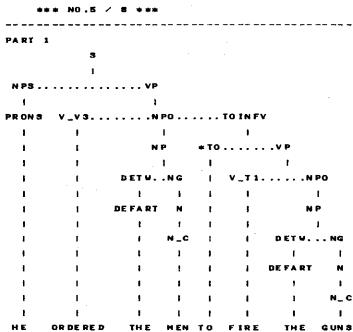
(9) 関係詞節の関係詞の省略は扱わない。

(10) 名詞句, 文等の接続詞による接続と, これによる名詞句などの省略は扱わない。

なお, RR は全部で 211 個ある。

4.2. 実験結果 解析結果の例を図 5, 図 6 に示す。実験の結果, LDOCE の GC を用いて統語的な解析を行うと, 次の利点があることがわかつた。

(1) 統語的な違いにより, 意味のあいまいさを解消できる場合がある。



たとえば, "order(v)" には, 次の 6 個の定義が与えられている。

(i) to give an order;

command (T5c; T5b; V3)

(ii) to give an order that (something) should be done or made (T1)

\*) 必須格, 任意格の区別は, LDOCE の GC では区別には從 He ordered the men to fire the guns. している。即ち, GC により記述されてる前置詞句, 副詞句は必須格とし, それ以外は任意格として。

図 5 解析結果の例

```

V_14    ---> V_VVI
V_14    ---> V_VVI
V_18    ---> V_VVI
V_18    ---> V_VVI
V_L1    ---> V_VVI
V_L1    ---> V_VVI
V_L3    ---> V_VVI
V_L3    ---> V_VVI
V_L4    ---> V_VVI
V_L4    ---> V_VVI
V_L6A   ---> V_VVI
V_L6A   ---> V_VVI
V_L7    ---> V_VVI
V_L7    ---> V_VVI
V_L9    ---> V_VVI
V_L9    ---> V_VVI
VP      ---> V_VIO
VP      ---> V_T1
VP      ---> V_T1
ADJR   ---> ADJ_B5 THATC
ADJR   ---> ADJ_B9 TOINFY
ADJF   ---> ADJ_F8 WHP
ADJF   ---> ADJ_F8A WHC
ADJF   ---> ADJ_F8A DTHATC
ADJF   ---> ADJ_F8E DTHATC
ADJF   ---> ADJ_F8E DTHATC
DIHATC ---> THAT S
NG      ---> N_N_E
NG      ---> N_N_A
NG      ---> N_N
NN      ---> N_U6B WHP
NN      ---> N_U6A WHC
NN      ---> N_U6S DTHATC
NN      ---> N_U9S TOINFY
NN      ---> N_P6B WHP
NN      ---> N_P3 TOINFY
NN      ---> N_C6 WHP
NN      ---> N_C6 UHC
NN      ---> N_C6A WHC
NN      ---> N_C6C DTHATC
NN      ---> N_C6S TOINFY
NP      ---> DEFART_N_DJ_GU
NP      ---> DEFART_NDJ_P
NP      ---> N_RS THATC
NP      ---> N_RS TOINFY
NP      ---> N_RS PRON
NP      ---> DEFART_N_R
NP      ---> INDEFART_N_S
NP      ---> DETW_NN
NP      ---> NG_PRON
NP      ---> PRE_NG
NP      ---> DETW_NG
NP      ---> PRE_NPO
NP      ---> ADV_ADJW
NP      ---> WHWS VP
RELC   ---> S
  
```

```

P13 = NP
  
```

```

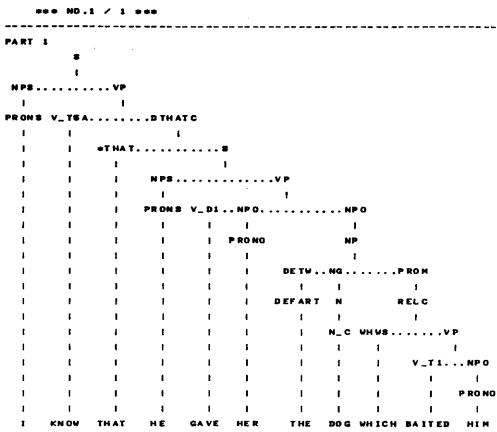
NP      ---> DEFART_N_RS TOINFY
NP      ---> DEFART_N_R PRON
NP      ---> INDEFART_N_SS THATC
NP      ---> INDEFART_N_S PRON
NP      ---> DETW_PRIM_NN
NP      ---> PRE_NG_PRON
NP      ---> DETW_NG_PRON
NP      ---> DETW_PRIM_NG
RELC   ---> WHWP_N_VP
RELC   ---> WHWD_N_VP
VP      ---> V_D6B_NPO_WHP
VP      ---> V_D6A_NPO_WHC
VP      ---> V_D6A_NPO_DTHATC
VP      ---> V_D6_NPO_THATC
VP      ---> V_D1_NPO_NPO
VP      ---> V_V6_NPO_PASTPP
VP      ---> V_V4_NPO_PRESPP
VP      ---> V_V3_TOINFY
VP      ---> V_V2_NPO_INF
VP      ---> V_X9_NPO_ADV
VP      ---> V_X7_NPO_ADV_F
VP      ---> V_X7_NPO_ADJ_F
VP      ---> V_X7_NPO_ADJ_B
VP      ---> V_X1_NPO_NPS
WHC    ---> WHWD_NG_VP
WHC    ---> WHWD_NPS_VP_O
WHP    ---> WHWP_NG_TOINFY
NP      ---> DETW_PRIM_NG_PRON
RELC   ---> WHWD_NG_NPS_VP_O
WHC    ---> WHWP_NG_NPS_VP_O
WHP    ---> WHWP_NPS_TOINFY
  
```

図 6 実験に用いた CFG-RR (一部)

\*) 必須格, 任意格の区別は, LDOCE の GC では区別には從

He ordered the men to fire the guns. している。即ち, GC により記述されてる前置詞句,

副詞句は必須格とし, それ以外は任意格として。



I know that he gave her the dog  
which baited him.

図6 解析結果の例

1=2=3。

(2) 比較的複雑な文でも、統語的にあいまいでない場合がある。  
GC を用いた T=R R の左边は比較的長い(1個へ4個)。このため、一見統語的に複雑と思える文でも、あいまいでなしに解析でき場合がある(図6参照)。

(3) 語彙が豊富 LDOCE の HW は約 50,000 ある。そこで、専門用語と有名詞などを除けば、通常使用されている、ほぼすべての単語が含まれている。このため、どのような単語を用いても、一応統語的な解析が可能である。

しかし、以下の問題点があることも明らかになつた。

(1) 語彙が豊富すぎるため、品詞レベルのあいまいさが生じる場合がある。  
現在は、特殊な使われ方をする場合の GC や品詞も、通常の使用法と同じに扱つてある。このため、"Time flies like an arrow." における問題と同様の問題を生じることが多い。

(2) 数の一一致、活用型の一致を扱つてこないため、誤った解析が得出する場合がある。  
これは、CFG パーサーを用いてこなしたための問題である。

5. 日英機械翻訳システムへの LDOCE 意味マークの応用

日本語中間表現システムでは、トランスファ過程で日本語表現から英語表現への変換が行われている。その際に、日本語の単語に対して英語の適切な単語を選択すること、すなわち、記語選択が行われる。この記語選択は LDOCE の意味マークを利用するこことを試みた。

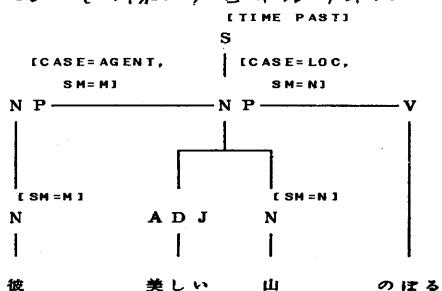


図7 日本語中間表現

- (iii) to command (someone or something) to go (to or from the stated place) (X9)
- (iv) (of a doctor) to advise (something) as necessary (D1(for); T1)
- (v) to ask for (something) to be brought, made, etc., in return for payment (D1(for); T1; I $\emptyset$ )
- (vi) to arrange, direct (X9; T5)

ここで、次の文を考へる。

/He ordered the men to fire the guns.

この文で "order" は V3 (動詞) のあとに NP と where 不定詞がくさりとして用いられている(図5参照)。このため、この "order" は (i) の意味で用いられていることが、統語的な解析だけで明らか

トランスファの対象となる日本語中間表現(JIR)は、基本的には句構造表現をとり、文法カテゴリを表わす各コードには格マーカー・意味マーカー・時制・法などの情報が付加されている(図7)。特に、記語選択をこなすための前提として、JIR 中の名詞・名詞句にはその意味マーカーが解析段階で与えられると仮定する。

かつ、その意味マーカは LDOCE 意味マーカの体系に従うものとする。

LDOCE 意味マーカで説語選択が行えるのは、名詞・形容詞・動詞に対してであるので、以下では図7の JIR を例にとって話を進めてゆく。

JIR 中の日本語単語には、変換辞書によつていくつかの英語表現が与えられる。例えば、「ぼる」という日本語単語を知英辞典で引くと、「rise」、「go up」、「climb」、「mount」、「ascend」、「reach」、「amount to」、「come to」といった英語表現を得ることができ。ところ

で、LDOCE では、例えば、「climb」に対する

では 6 個の語義がある(図8)。LDOCE では GC が単語の語義に対して与えられていくために、1つの単語でも語義が異なれば複数の GC を持つ場合がある。かつて、トランプアでは、この GC によって構造変換の規則が選ばれる。従って、1つの単語でも、語義が異なれば別々の英語表現と見なさねばならない。すなわち、「ぼる」に対しては計 48 個の英語表現が与えられることになる。ところがこの中には、「climb」の語義 6 や「mount」の「馬に乗る」という語義のように、明らかに「ぼる」に対応する英語表現ではないものも含まれている。理想的に言えば、このような明らかに意味の違う英語表現は意味マーカを調べることにより、排除されるべきである。しかし、LDOCE の意味マーカがそれほど細分化されておらず強力なチェックは出来ないことに、動詞の場合にはそれ自身に意味マーカは付いておらず、動詞の格要素の意味マーカのチェックにより動詞の選択を行ふとするために、明らかに意味の違う英語表現が選択されることがある。今回の実験では、ある日本語単語の説語として挙げられる英語表現の集合から、最も適切なものを選択することを目的とし、そのために明らかに意味の違う英語表現はあらかじめ人間の手によって除いておく。その結果、図7の JIR の各日本語単語には図10に挙げられている英語表現が、変換辞書によって与えられることになる。

#### 説語選択の手続き

(a) 名詞 名詞の場合には、JIR の名詞に付けられていく意味マーカ(例えば、「山」には「N」がつけられていく。)を包含する意味マーカを box1 に持つ説語が選択される。

(b) 形容詞 形容詞の場合には、それが修飾する名詞(「美しい」の場合には「山」による。)に付けられていく意味マーカを包含する意味マーカを box1 に持つ説語が選択される。

(c) 動詞 動詞の場合には、各々の動詞によって深層格要素(動作主・経験者・場所など)と表層格要素(主語・目的語・補語など)の対応が異なる。また、JIR では格要素に深層格マーカが付けられていく。従って、これらの対応(例えば、SUBJ=AGENT, DOBJ=LOC)を変換辞書の動詞の各説語に与えておく。この対

climb  
1 to go esp. from a lower to a higher position up,  
over, or through, esp. by using the hands and feet  
2 to go esp. from a lower to a higher position up  
or over (esp. mountains) as a sport  
3 to rise to a higher point; go higher  
4 to slope upwards  
5 (esp. of a plant) to grow upwards, esp. along a  
supporting surface  
6 to get into or out of clothing usu. with haste or  
some effort

図8 climb<sup>1</sup>の語義(LDOCE)

CAVERB  
<<(S = 2S  
LINE HAVING  
OPTIONAL (NP : CASE IS SUBJ :  
\*) = SSUBJ  
OPTIONAL (NP : CASE IS DOBJ :  
\*) = SDOBJ  
OPTIONAL (NP : CASE IS IOBJ :  
\*) = SIOBJ  
OPTIONAL (NP : CASE IS COMP :  
\*) = SCOMP  
EXIST  
\*  
ANYTHINGS >  
>  
(BOX-CHECK-V SSUBJ SDOBJ SIOBJ SCOMP BOXCODE>>>

図9 説語選択のルールの例

応に従って、JIR中より主語、目的語等を取り出し、それぞれ動詞のbox1、box2等との包含関係をチェックする。そしてすべての格要素について、意味マーカの包含関係が満たされた記語が選択される。そしてこれらの手続きにおけるJIRの扱いはすべて本構造のマッケンジ・パターンによって記述される。動詞の場合を例にとると図9のルールにより格要素を取り出し、意味マーカのチェック関数を起動することが指示される。

意味マーカの包含関係については、基本的には、記語のBC中の意味マーク(M<sub>1</sub>)かJIR中の名詞・名詞句の意味マーカ(M<sub>2</sub>)を包含すれば、包含関係が満たされるとする。包含するとは、意味マーカの階層構造の不(例えば図1)でM<sub>1</sub>がM<sub>2</sub>より根の方に向にあるか、又は、M<sub>1</sub>とM<sub>2</sub>が同じであるということである。しかしこれでは

包含するかしないかの2値しか得られないため、包含関係を満足する記語間の優劣がつけられないのである。そこで、次のように2つの意味マーカの距離を定義し、これにより意味マーカの包含関係の評価値を算出する。ただし、M<sub>1</sub>がM<sub>2</sub>を包含するとき。

$$\text{意味マーカ } M_1 \text{ と } M_2 \text{ の距離} = \{ M_1 \text{ を構成する基本意味マーカの数} \} - \{ M_2 \text{ を構成する基本意味マーカの数} \}$$

意味マーカM<sub>1</sub>とM<sub>2</sub>の包含関係の評価値 = Const1 × [ - {M<sub>1</sub>とM<sub>2</sub>の距離} ] + Const2

以上の手続きを図のJIRに対して行うと、図10の結果が得られる。SCOREで示されるのが上で述べた評価値であるが、ここでConst1=1, Const2=31とした。また、動詞Tの「3」の場合には、主語と目的語のそれぞれの意味マーカの包含関係の評価値の平均をその記語の評価値としている。この結果から、例ええばTの「3」に対しては climb<sup>1</sup>の語義2が最も適切であるとされる。

6 まとめ 自然言語処理を行う場合、個々の単語についての情報を貯えていく処理用辞書を十分に用意することは、重要な課題である。本報告では、処理用の辞書として、計算機による検索が可能な通常辞書LDOCEを用いた英文の解析、日英機械翻訳における記語選択の実験について述べた。解析の実験の結果、LDOCEのGCを用いたCFG-RRにより、浅いレベルの解析が可能であることがわかった。今後は、意味マーカをあいまいさの解消に用いる実験と、LDOCEを用いた、深いレベルの解析の可能性の検討を行う予定である。また、記語選択の実験の結果、LDOCE意味マーカによって、記語をT=1つ選ぶことはできなくても、多くの記語の候補をより少數に絞り込むことは可能であることがわかった。これに加えて、GCにより統語構造のチェック等を行えば、記語の候補をさらに絞ることが可能である。

- 参考文献
- 1) 長尾真 et al., 英和辞書データベースの作成ヒビの応用, 情報全大, 55年度, 1031-32
  - 2) Nagao, M. et al., The Data Structure of LDOCE Database, Internal report, Kyoto Univ, 1981
  - 3) Procter, P., Computer Codes for the Definition Space other than Subject field, Letter to Editors of STUDOC, Longman Group Ltd, 1974.
  - 4) Michiels, A., Retrieving and Using Semantic Information, Report to Longman Ltd, Université de Liège, 1980.

(NOOOOOO3 /KARE)		P.O.S.	BOXCODE	SCORE
WORD		(pron)	(K NIL NIL)	30.00
(HE 1 1)				
(ADJ00005 /UTSUKUSHII)				
WORD		P.O.S.	BOXCODE	SCORE
(BEAUTIFUL 1 1)	(adj)	(Z NIL NIL)	21.00	
(FINE 3 1)	(adj)	(Z NIL NIL)	21.00	
(PICTUREQUE 3 1)	(adj)	(Z NIL NIL)	21.00	
(GOOD-LOOKING 1 1)	(adj)	(H NIL NIL)	FAILURE	
(LOVELY 1 1)	(adj)	(Q NIL NIL)	FAILURE	
(NOOOOO6 /YAMA)				
WORD		P.O.S.	BOXCODE	SCORE
(MOUNTAIN 1 1)	(n)	(IN NIL NIL)	31.00	
(CROWN 1 2)	(n)	(IN NIL NIL)	31.00	
(SPECULATION 1 1)	(n)	(T NIL NIL)	FAILURE	
(CLIMAX 1 2)	(n)	(T NIL NIL)	FAILURE	
(PEAK 2 6)	(n)	(T NIL NIL)	FAILURE	
(NOOOOO7 /NOBORU)				
WORD		P.O.S.	BOXCODE	SCORE
(CLIMB 1 2)	(v)	(H NIL N)	30.50	
(CLIMB 1 1)	(v)	(D NIL S)	29.00	
(MOUNT 2 2)	(v)	(D NIL S)	29.00	
(ASCEND 1 1)	(v)	(Z NIL Z)	21.00	
(AMOUNT TO 1 1)	NIL	(Z NIL Z)	21.00	
(COME TO 1 2)	(V PREP)	(Y NIL T)	FAILURE	
(REACH 1 4)	(v)	(IN NIL N)	FAILURE	
(ASCEND 1 2)	(v)	(J NIL N)	FAILURE	
(CLIMB 1 6)	(v)	(P NIL NIL)	FAILURE	
(CLIMB 1 4)	(v)	(S NIL NIL)	FAILURE	
(CLIMB 1 3)	(v)	(J NIL NIL)	FAILURE	
(GO UP 1 1)	(V ADV)	(T NIL NIL)	FAILURE	
(RISE 1 1)	(v)	(J NIL NIL)	FAILURE	

WORD: 記語の候補  
P.O.S.: 品詞  
BOXCODE: BC中の意味マーク。左からbox1, illus, box2。  
SCORE: 意味マークの包含関係をチェックした結果の評価値。  
'FAILURE'は意味マークの包含関係が満たされなかつてことである。

図10 意味マークによる記語選択の結果

包含するかしないかの2値しか得られないため、包含関係を満足する記語間の優劣がつけられないのである。そこで、次のように2つの意味マークの距離を定義し、これにより意味マークの包含関係の評価値を算出する。ただし、M<sub>1</sub>がM<sub>2</sub>を包含するとき。