

ボトムアップ構文解析システム BUP の拡張と 日本語文法の試作

田中徳輔，小山晴生，奥村学
(東京工業大学・工学部)

1. はじめに

Prolog は、一階述語論理を基礎とし、パターン・マッチングヒバックトラックの機能を持ててするために、構文解析とは相性がよい。DCG (Definite Clause Grammar) [Pereira80] で記述された文法をほぼ相似で 1 对 1 に対応する Prolog プログラムに変換して実行する手法が、エジンバラ大学で開発されています。この変換されたプログラムを実行することとは、トップダウン、デプスファーストに構文解析を進めることと等価であることが知られています。ところが、この手法を用いるとトップダウンに構文解析が進むため、左再帰的文法規則を扱えない問題があります。そこで、DCG で記述された文法規則に対応する Prolog 節を生成し、それらの実行によりボトムアップ、デプスファーストに構文解析する方法が電子技術総合研究所で開発されました。これを BUP と呼ぶ。[松本他83]

ところで、日本語処理を行なう場合には自動分かち書きの機能は不可欠である。しかし、これまでの BUP システムではこの点が考慮されていません。そこで本論文では、辞書に記述されていました未定義語を含む文の自動分かち書きの機能を付加するため、3 つの方式を検討し、最もと思われる方式を BUP システムに組み入れた。


またこれまでの BUP システムに組み込まれていた高速バージョンの、辞書引きアルゴリズム [松本、清野、田中'83] が、分かち書き、あるいは熟語処理を行なう場合には問題があることを指摘し、その解決策を検討する。

さうに、構文解析木の数を大幅に減らすことができる右方枝分かれの木構造を得た日本語文法規則を開発した。この場合、一つの構文解析木から複数個の意味解析結果を得る機会が非常に多く、Prolog の非決定的プログラム技術を用いると、容易に実現可能であることが示された。

2. 自動分かち書きと構文解析

日本語文は通常分かち書きはなされていない。特に單語ごとの分かち書きは人間が行なっても一定に行なえないとが多い。また、動詞句の中の相を表わす部分など(例: 行かせられたくなかったようだ)を基本要素に分解するには、いずれにせよ自動分かち書きを行なわざるを得ない。

また現在の自然言語処理システムは、基本的には Chomsky 以後の rule (変形規則、文法規則) の集合を使って記述された形式的言語の理



論を基礎にしている。すなわち、これらは人間の言語能力における言語、完全な言語をその主な処理対象としている；しかし、この完全な言語の体系がいかなるものであるかは未解明であり、言語学の大きな問題となる。しかし、現実にシステムで解析される文は、実際の言語運用における言語（自然言語）であるため、ここに多くの問題が発生する。

以上二点から、今回 BUP システムにあらわす種の未定義語を右文の自動分かち書きの機能を付け加え、実験を行なった。

2.1 未定義語と文法規則

一般に未定義語と言。でも多くの種類がある。タイアミスによるもの。固有名詞、専門用語、略語、新しい概念を表す造語。技術語、接頭語。“半径 R”の“R”的ようなラベル、あるいは数字、数式等の特殊記号列。このようなものは辞書に記述されているとは考えにくいものが多く、未定義語として現れることが多いと考えられる。ここでは、例として数字とラベルを取り上げることにする。

ここでは、自動分かち書きを行なった後、あるいは分かち書きを行なひながら、構文解析を行なうことを考えていい。したがって、未定義語に何らかのカテゴリを与え、その役割を文法規則に表現しておくことにする。すなわち、辞書的には未定義であっても、文法規則的には定義された状態にしておく。

さて、数表現は日本語においては次のように形態^{*1}をとることが多いと考えられている。[井佐原 80]

数表現 → (前置助数詞), : 約十年など
数 ,
(概数 表示), : + 整年など
(草位), : kg, 帆など
(程度 名詞), : 以上など

また、この数表現は多くの場合、量と関連する名詞と共に現れる。その代表的な例は次の 2 つと考える。

$np \rightarrow n, number$ 型: 離度 3 をと
 $np \rightarrow number$ 型: 半径が 5cm をと

また、ラベルについても数表現と同じ位置に現れことが多い。また、この場合、2番目の形で固有名詞などの多くが吸収可能であると考えられる。

以上から次の文法規則を組み込んで実験を行なった。

$np \rightarrow (n), unknown.$
 $unknown \rightarrow label, (unit).$
 $unknown \rightarrow number, (unit).$

2.2 自動分かち書きのアルゴリズム

(a) 辞書のみの情報による方法

入力された文字列を parser にわたす前にリストに分解し分かち書きを行なう。この場合、最長一致法と字種の区切れ情報を用いた方がよく知られている。ここで数字については字種情報を用いた。ただし、"円 O₁ と 円 O₂" の "O₁" をどどなど可能性は残した。その他の定義語については最長一致法を用いた。これを用いると失敗する例が有りうるが、使用する情報が辞書のみの場合にはこの種の Heuristics にたよらざるを得ないようである。未定義語に関しては最も短かい切り出しを原則とした。さらに、未定義語の連続は禁止した。これによつて "円 O₁" を "円 O₁ 1" と切り出すことを防いた。

(脚注)

*1 規則の記法については DCG を使用するが、本文中におりて省略可は () で表す。すなわち、

$np \rightarrow (n), unknown.$ は正しくは、 $np \rightarrow (n;()), unknown.$ である。

(b) 構文規則と最長一致法の併用

による方法

(2)の方法の弱点の多くは辞書以外の情報を使つてないことに起因してゐる。現在、我々の BUP システム上の文法体系で利用できるのは構文情報までであるため、(2)にこれを用いることを考へよう。

BUP システムによつて変換されたプログラムで実際にバーチングを行なう場合、入力された文は、goal 節中の辞書引きによつて左から順次カテゴリが決定されていく。そこで、この過程に分かち書きの機能を組み込むことによつて、構文解析と同時に分かち書きを行なう。文法規則の適用とバックトラックに合わせて語の切り出しも同時に進行し、構文解析終了時に分かち書きも終了する。

文法規則によつて未定義語の連続が禁止されてゐるので、(2)で用いた二つの Heuristics は必要ない。

(c) 最長一致法を使用した方法

(b)の方法の弱点は最長一致法を使用したことによるものがめだつ。それは、これを用いたために可能な解釈の一部を捨ててしまうこと、及び、複雑なリストの操作を行なわなければならぬことである。最長一致法では、あるリストで失敗した場合には、そのリストの末尾から一要素を取り出して次の解析を行なうことになる。

例: $[h, a, n, a, w, o, \dots]$... fail
 $[h, a, n, a, w, o]$... fail
 $[h, a, n, a, w]$... fail
 $[h, a, n, a]$... success

(花あまはは鼻)

ところが、Prolog のリスト処理は、先頭に要素を付け加えたり、取りはずしたりすることは容易であるが、末尾でこれを行なおうとすると効率が落ちる。差分リスト操作によつてこれをさしつけた方法もある⁷²が、副作用があるため使用に制限が加わる。

どちらにしても最長一致法を使用しなければ問題はなくなる。そしてこれは構文情報が使用できるため、十分に可能である。

ただし、未定義語部分の切り出しに、最短切り出しヒューリスティクスを用いることは、必要をようである。これを除くと、後に続く定義語も含めた大きな未定義語を切り出して解析することがある。

例: $[h, a, n, k, e, i] [r, n, o, e, n] [n, o]$

羊	径	只	の	円	の
名	詞	未定義語	助詞		

2.3 結果と考察

以上3つにおいて、(2)の辞書のみによる方法はあまり良い方法とは言えないと、(b)については、リスト操作が複雑なため(c)に比べて、よくでも1割は遅くなるようである。(c)は最長一致法を併用せず、Prolog のパターン・マッチングに任されるため、(a), (b)では出てこない解釈も可能でかつ速い。以上から(c)が最もすぐれないと考えられる。

この特徴は以下の通りである。

- ・辞書の情報だけでなく、構文情報も利用している。
- ・数字についてでは字種情報を利用している。
- ・定義語は Prolog のパターン・マッチングによつて切り出されるため可能な解釈のすべてが、語の長さにかかわらずに得られる。
- ・入力文字列中の空白、句読点など明らかなる区切り情報を利用できること。

また、未定義語に関して、

- ・最短切り出しを原則とする。
- ・未定義語の切り出しが起こるのは、文法規則からその存在が予測された時だけである。
- ・定義語で木が作れる場合にはそれを優先する。

最後に、今回のプログラムの弱点は、未定義語の先頭が定義語のスペルと同じになれば、それを場合にセカリ出せないことをあるのを指摘しておく。このような場合、一度解析が完全に失敗するまでは、これを検出することはできないようだと思われる。

以下に成功例をあげておく。

```
?- asse10kowokatte3kowutta.
```

```
400 msec.  
No. 1
```

```
sentence
  |-pp
    |-ap
      |-a -- ase
      |-label
        |-numb -- 10
        |-unit -- ko
    |-p
      |-kp -- wo
  |-sentence
    |-vpt
      |-vp
        |-v -- katta
  |-sentence
    |-pp
      |-ap
        |-label
          |-numb -- 3
        |-unit -- ko
    |-p
      |-kp -- wo
  |-sentence
    |-vp
      |-v -- utta
```

(これは3.で述べる高速化アルゴリズムは使用していない例である。)

3. context を考慮に入れた

辞書引きの高速化

BUPには、解析が進むにつれて行なわれた辞書引きの結果を残しておく、再計算を防ぐ高速化がなされている。ところがこのアルゴリズムは、2.で述べた自動分岐書きを行なう場合や、英熟語などの処理を行なう場合には問題がある。

3.1 従来の高速化辞書引き

アルゴリズムの問題

問題のプログラムの概略を次に示す。

```
dictionary(C, X, Y) :-  
  wf_dict(_, X, _), !, (1-a)  
  wf_dict(C, X, Y), (1-b)  
 dictionary(C, X, Y) :-  
  dict(C, X, Y), (2-a)  
  create_dlist(X, Y, U, V), (2-b)  
  assert(wf_dict(C, U, V)), (2-c)  
  fail. (2-d)  
 dictionary(C, X, Y) :-  
  wf_dict(C, X, Y). (3)
```

dictionary という述語の呼び出しが辞書引きに相当する。X,Yは、入力文字列の差分リスト表現であり、Cは辞書引きの結果得られたカテゴリである。

辞書引きの結果は、具体的には、wf_dictと呼ばれる assertionとして assert されていく。(1-a) でそれがあるかどうか調べる。あれば、(1-b) でそれによ、て結果を返す。カットシンボルがあるため、との他の可能性は追わない。もし、ない場合は辞書本体を調べる(2-a)。さらに、X,Yを、セカリ出し語のみの情報にして(2-b)、U,V^{†3} とし、これらを assert する(2-c)。以下では、これを context なしの wf_dict と呼ぶ。さらに、(2-d) で fail がかかることにより、てこの過程が繰り返され、Xにユニファイ可能なすべての辞書引き結果が wf_dict に assert される。その後、(3) によ、て結果が返された。

(脚注)

*2 bit 1983.5 bitplayer

「リストと差分リスト」上田和紀 参照

*3 例：この石 は 重い。

X = [石, は, 重, い]

Y = [は, 重, い]

U = [石 | R]

V = R

また、以下ではXを context と呼ぶ。

wf-dictは解析中に存在する短語記憶(STM)と考えている。それに対して、dictは辞書本体で、現在はメインメモリ上に存在していながら、大規模化した場合には2次記憶に移り、アクセスに時間がかかるようになると想定されている。

以下に例を示す。例文は、

"花子は花を持つ" (花子も辞書に存在する)

最初の辞書引きでは STM には何もないのに、辞書本体を読みて、STM は次のようになる。

(STM)

・花子
・花

このうち、花は文法的にいずれ失敗するので、やがて花子が選択され、残りのリストは、"は花を持つ"になる。次も、STM にはユニケーション可能なものはないので、同様に、

(STM)

・は
・花子
・花

リストは、"花を持つ"になる。ここで、すでに "花" が STM に存在するため、辞書本体を調べに行く手間は省かれてしまい結果を返す。リストは "を持つ" になる。以下同様に解析がさすむが、これはバックトラックにより、再度辞書引きが行われた場合にも辞書引きの手間を省き高速化がはかられる。

しかし例文が "花を花子は持つ" であると以上のアルゴリズムは不完全になる。最初に、

(STM)

・花

次に、

(STM)

・を
・花

ここで、リストは "花子は持つ" であるから、"花" とユニケーション可能であるため、あらためて辞書本体を読むことはない。そのため "花子" が辞書にある、でもこれは読み出されな

い。同じことは、

I take a bus from that bus stop.
のようを英熟語にあっても生じる。

3.2 完全な高速化経験ミキアルゴリズム

(2) アルゴリズム 1

3.1 で指摘した問題は、文中での單語の現れる位置の追跡を(create_dictにより)無視した結果生じたものである。したがって、文中での單語の現れる位置をも含めたwf-dict(以下ではこれを context付きのwf-dictと呼ぶ)を assert すれば完全性は保たれるようになる。

この方法の欠点は、assert する情報が多くなることである。しかも、同一の切り出し語が異なる場所にあらわれれば別のwf-dictとして assert されるこヒになる。

(b) アルゴリズム 2

(2) で述べた方法の欠点は次のようにして解決できる。例文は、

"花を花子が持つ"
とする。

wf-dictとして assert 可能部は、3.1 で説明した contextなしの wf-dict である。他にその場所で辞書引きが行なわれたことを示すための context が assert される。

最初の辞書引きで

(STM) (wf-dict)

・花

及び、

(STM) (context)

・花を花子は持つ
が assert される。

リストは、"を花子が持つ" になる。

次に、

(STM) (wf-dict)

・を

・花


(context)

・を花子は持つ

・花を花子は持つ

ここでリストは、"花子は持つ"であるから"花"とユニフィケーション可能であるが、contextをすれば、初めての場所での辞書引きであることがわかる。したがって、ユニフィケーション可能なもののうち、最もスペルの長いもの（この場合は"花"しかない）よりさらに長い単語が辞書に隠れていく可能性がある。

このような辞書引きを可能にするためここでは次のような辞書構造を採用する。（5章参照）



この辞書では、スペルの短がり単語から先に読み出される。したがってこれを次々と上側に assert（すなわち asserta）していくければ、最も長い単語が上にくくる。したがって STM内でこのような単語を見つけ出すのは容易である。次にそれを使って、そこから先に辞書を読み進むことができる。

この辞書構造によれば"花"で始まる単語のみの辞書引きが可能になる。

[STM] (wb-dict)

- 花子
 - を
 - 花
- (context)
- 花子は持つ
 - を花子は持つ
 - 花を花子は持つ

以下同様に、解析が進みうる。

"花子が花を持つ"の例では、contextなしのwb-dictによればたため以前と同じ性能が得られるようになっていた。しかしながら、単語ごとの辞書本体へのアクセス回数は減少したが contextごとのアクセス回数は減っていない。

(c) アルゴリズム2 の拡張

上記の辞書は trie 構造をしてい

るので、終端がある、一度終端まで読み切らなければ、その系統の單語については context が新しくなる、ても再び読みに行くのは無意味である。

ここで wb-dict に終端か、非終端かを示す ID を付加する。これにより辞書本体へのアクセス回数が減少する。

3.3 結果と考察

(a) は、assert する切り出し語の後側部分が大きいため、(b) に比較して少くとも 1 割は速度が落ちるようである。使用するメモリも大きい。また冗長な部分が存在する。その点、(b) は何も高速化せず、ただ辞書本体を引きに行く場合と比較して、例文によるとかなり差があるが、3割ぐらり速くなるようである。ただし、木を 2 本、3 本と出していくとやがて、4 本目では (a) と速度が交わらなくなつた。(c) は、現状では、辞書がメイン・メモリ上に存在するため、(b) と大差はない。場合によれば、少し遅くなる。しかしながら、辞書が 2 次記憶に移った場合には、能力を発揮すると考えられる。

実行結果（単位は msec）

例文

hanakotohanawatarouhamotu.
花子と(花)を太郎は持つ。
(鼻)

	(a)	(b)	(c)
第1の木	769	431	423
第2の木	432	371	351
第3の木	772	541	536
第4の木	121	105	104
Total time	2285	1872	1835

4. 左方枝分かれ構造と右方

枝分かれ構造 [井他原, 日中 81]

日本語の構文解析では、埋め込み文をどのようなら構造の構文解析木とするかが問題である。多くの文法学者はこの埋め込み文を左方枝分かれ構造であると述べている。この左方枝分かれ構造は、人間の文理解の過程とうまく対応していることもあり、従来の文法においては自然なものとして受け入れられてくる。それでは、このような構造を得るために文法が、計算機処理の立場からも望ましいと言えるだろうか。これについて考察する。

左方枝分かれ構造を得るために文法規則:

$$\left\{ \begin{array}{l} S \rightarrow PP^*, VP. \\ PP \rightarrow S, PP. \end{array} \right.$$

と右方枝分かれ構造を得るために文法規則:

$$\left\{ \begin{array}{l} S \rightarrow PP, S. \\ S \rightarrow VP. \\ PP \rightarrow VP, PP. \end{array} \right.$$

のこれらを用いて実際に構文解析した結果を表1, 図1に示す。表1のように、左方枝分かれ構造を得るために文法規則では、文が長くなり、埋め込まれる文の数が多くなるほど、得られる構文解析木の数は指数関数的に増加する。構文解析木の数がこのよ




図1 (a)

左方枝分かれ構造の構文解析木




図1 (b)

右方枝分かれ構造の構文解析木

例 文	単語数	左方枝分かれ構造		右方枝分かれ構造	
		構文解析木の数	構文解析に費した時間	構文解析木の数	構文解析に費した時間
花子は川で泳いだ。	6	1	499 msec	1	356 msec
花子は川で泳いでいる少年を見た。	10	3	1122 msec	1	750 msec
花子は池に落ちた犬を助けた少年にアメを上げた。	16	12	4764 msec	1	1614 msec
花子は池に落ちた犬を助けた少年に上げるアメを買へに行った。	19	55	23268 msec	1	2010 msec

表1 得られる構文解析木の数の比較

うに増加すると、構文解析に要する時間が増加するだけでなく、構文解析が終了した後で意味解析を行なう場合には、得られた構文解析木すべてに対して意味解析を施すわけであるから、効率が悪くなる。通常このような点が問題にならないのは、人間が文の意味を理解しつつ、構文解析を行なってからである。従って計算機の場合にも、意味解析・構文解析を並列に実行することが考えられるが、解析の初期には意味情報が不十分であることから、この手法では十分な効果が得られにくくと思われる。

一方、左方枝分かれ構造を得るために文法規則では、表1のような埋め込み文に関しては、得られる構文解析木はただ1つである。

4.1. 左方枝分かれ構造の構文解析木

埋め込み文には、意味的な曖昧さが含まれている場合がある。例えば、「花子は川で泳いでいる少年を見た」という文では、「川で」は「泳いでいる」、「見た」の両方に係りうる。図1(a)がこの例文の構文解析結果であるが、このうち「川で泳いでいる」という関係を表わす(i)と、「川で見た」という関係を表わす(ii)とが、意味的に妥当な構造と言える。

このように左方枝分かれ構造の構文解析木群では、埋め込み文が含みうるすべての意味を、1つ1つの木代表にしておわけである。従ってこのよう文法規則によて得られた個々の構文解析木には、意味的な曖昧さはないと一般に考えられている^{*4}。その代り、複数の構文解析木が得られるという点に意味的な曖昧さが吸収される。

(脚注) *4 しかし、句「花子を紹介した太郎」における「太郎」(紹介した人間、紹介された人間の二通りの解釈が成り立つ)のような例は、実際には多數存在する。

4.2. 右方枝分かれ構造の構文解析 とその意味解析手法

図1(b)が右方枝分かれ構造の構文解析木の例である。右方枝分かれ構造の構文解析木の特徴は、非終端記号 sentence を根とする部分木がすべて、完成了した1つの文の句構造を表わしていることである。例えば、図1(b)の「花子は川で泳いでいる少年を見た」とに対する構文解析木では、

見た

泳いでいる少年を見た

川で泳いでいる少年を見た

花子は川で泳いでいる少年を見た
がそれぞれ非終端記号 sentence によって支配されている。これは、この構文解析木の構造が人間の言語的直観から見ても、さほど奇異ではないことを示している。

左方枝分かれ構造の場合、複数の構文解析木によって意味的な曖昧さは吸収されていたが、右方枝分かれ構造の場合には、基本的には構文解析木を1つに統合せることができるので、構文解析木の相違によって曖昧さは吸収できない。代りに、右方枝分かれ構造の場合には、その1つの構文解析木が、左方枝分かれ構造の複数の構文解析木の持つ意味構造を implicit に内包して、曖昧さを吸収しているのである。

これでは、複数の意味構造を implicit に内包したこの構造の構文解析木上で、どのように意味解析を実行すればよいかどうか。以下でそれを述べることにする。

すでに述べたように、この構造の構文解析木の特徴は、非終端記号 sentence を根とする部分木の各々が、完成了した1つの文の句構造を表わしていることであった。この特徴を最も活かした意味解析の方法としては、図2に示したような、構文解析木の右端の小さな




図3 意味解析

部分木から解析を開始し、その解析結果を用いて、その上の、より大きな部分木について意味解析を繰り返すという方法が考えられる。これはすなわち、文末から文頭へ意味解析を進めていくことを意味する。文中の他の構成要素を規定する力が各語などに比べ強い動詞が後置されていふ日本語では、この意味解析は非常に効率よく行なえるものと思われる。この方法を Prolog で実現するなら、その解析過程において Prolog のバックトラック機能により、1つの構文解析木からでも複数の意味構造を抽出することが可能になる。

例えば、図2では、「川で」の係り先として

「泳いでいる」……(a)

「見た」……(b)

の2通りの可能性が考えられるが、今係り先が(a)の方であるとして解析を進めしていくと、

「川で泳いでいる少年を見た」という意味解析結果が得られる。ここで強制的にバックトラックを掛けると、「川で」の係り先の決定の地點まで自動的に戻り、今度は係り先が(b)の方であるとして解析を進め、

「泳いでいる少年を見た」

という2つの意味解析結果を得ることができる。

計算機処理の立場から左方枝分かれ構造と右方枝分かれ構造の構造解析本と比較してみたが、左方枝分かれ構造は、得られた構文解析木の詮釋との点で問題があり、右方枝分かれ構造と比べて一概に優れているとは言えないとわかった。一方、右方枝分かれ構造では、得られた構文解析木を多く少數に抑えることができ、また、その得られた多くの少數の構文解析木からでし、Prolog のバックトラック機能を用いることで、文の持つすべての意味構造が容易に抽出可能であることがわかった。

そこで今回は、Prolog を用いることの利点を活かして、右方枝分かれ構造を採用し、その文法を試作してみたが、その際、意味解析が比較的容易に行なえるような木構造が得られるよう考慮した。

5. 形態素解析

日本語構文解析システムにおいては、用言に対する形態素解析処理が必ず不可欠である。本構文解析システムでも、三舌らによる形態素解析アロゲラ

「三吉、他」[83]を基に形態素解析を行ふ。ただし、本構文解析システムでは、辞書構造として、辞書へのアクセスが非常に効率よく行なえ、また、将来的には辞書を外部記憶化する時に有用な「Trie」構造(田中、他[83], [Aho, et al. 83])を用いている。図3に「Trie」構造辞書の例を示す。この「Trie」構造辞書を用いた形態素解析処理の例を以下に示す。

ex) .[[ko], [mai]] (乗る)

用ひる文法規則:

```
{ vp → v, aux, {comlink}, ..... ①
  } aux → auxv.
  { aux → auxv, aux, {comlink}.
```

まず、単語("ko")を文字のリスト([k, o])に分解して辞書を見に行く。用吉に明記しては、語幹以外の辞書登録しないので、この辞書検索では語幹のみを取り出す。単語の存在する所まで辞書の文字を達めていき、語幹("k")を切り出した後、語幹("k")の所以記述された「乗る」に関する情報を

[verb, kaken, [], kuru]

ヒ、リストの残り([o])を用いて語尾処理を行なう。語尾処理プログラムは、
gobi(mizen, verb, kaken,_) → [o], ②
のような形で記述されているが、今の場合はこの②が適用され、語尾処理は成功する。単語"ko"についての辞書検索がこれで終了し、"ko"に関する情報をとめて

[v, kaken, mizen, [], verb, kuru] ③

が得られる。"mai"についても同様に辞書検索を行ない、その後、構文解析規則の中に記述された相互承接一口づきムcomlinkにより、"mai"が③の情報を持った動詞と承接可能かどうか調べる。

```
comlink(mai, [_, _, mizen, _, verb, X]) :-  
not(member(X, [aru])).
```

6. 索引

右方枝分かれ構造を得るために文法規則では、埋め込み文に関するでは、得

```
dict([[k, [[v, [[verb, kaken, [], kuru]]]],  
      [a, [[v, [[verb, dan_5, s, kasu]]],  
            [v, [[verb, dan_5, k, kakaku]]]]],  
      [l, [[v, [[verb, jouge_1, [], kiro]]]]],  
      [a, []],  
      [o, []],  
      [b, []],  
      [o, [[v, [[verb, dan_5, r, noboru]]]]],  
      [a, [[auxv, [[adj, 0, [], nai]]]]],  
      [t, []],  
      [o, [[v, [[verb, dan_5, b, tobu]]]]],  
      [a, [[auxv, [[tokushu, 2, [], ta]]]]],  
      [s, [[v, [[verb, ssaken, [], suru]]]]],  
      [u, []],  
      [t, []],  
      [e, [[v, [[verb, jouge_1, [], sateru]]]]],  
      [o, []],  
      [u, [[auxv, [[adjv, 0, [], souda]]]]],  
      [r, []],  
      [e, [[auxv, [[verb, jouge_1, [], reru]]]]]]]]).
```

図3 "Trie" 構造辞書

られる構文解析木は1つであるといふことはすでに述べた。しかし、その右方枝分かれ構造を得るために文法規則でも構文解析木が複数得られることがある。例元句、連体修飾句の係り元と坐名詞句が複数存在する場合である。

ex) 小さな水の粒子の運動

この句を何も制約条件を加えず文脈自由な文法規則で構文解析すると、連体修飾句の係り受けの点で曖昧さが生じ、図4のように構文解析木が5個得られる。そこで、文脈に依存した情報を利用した補強項と呼ぶれるPrologプログラムを文法規則中に書き込み、得られる構文解析木を、(i)のうな、係り受け関係を全て決定しないままの構文解析木1つに絞り込み、係り受け関係の決定は意味解析過程に委ねる。また、(ii)の意味解析過程に分けた係り受け関係の決定は、埋め込み文からの意味構造の抽出と同様に、容易に実現可能である。




図4 補強項なしの文法規則によって得られる構文解析木

```

    |-ap
      |-alink (iii)   |-det -- tiisana (iv)
      |-ap           |-np
      |-det -- tiisana   |-alink
      |-np           |-np
      |-alink
      |-ap           |-alink
      |-a -- mizu   |-a -- mizu
      |-kp -- no    |-kp -- no
      |-ap           |-ap
      |-a -- ryuusi |-a -- ryuusi
      |-kp -- no    |-kp -- no
      |-ap           |-np
      |-a -- undou  |-n -- undou

    |-ap
      |-det -- tiisana (v)
      |-np
      |-alink
      |-ap           |-a -- mizu
      |-kp -- no    |-kp -- no
      |-ap           |-alink
      |-ap           |-a -- ryuusi
      |-kp -- no    |-kp -- no
      |-ap           |-a -- undou

```

図4 (続3)

: houkaiseki ha, kimat ta houkou ni kireini
: wareru seisitu ga aru.

```

812 msec.
No. 1
|-sentence
  |-pp
    |-np
      |-n -- houkaiseki
    |-p
      |-fp -- ba
  |-comma --
  |-sentence
    |-pp
      |-np
        |-vp
          |-v -- kimaru
          |-auxv -- ta
        |-np
          |-n -- houkou
      |-p
        |-kp -- ni
    |-sentence
      |-vpt
        |-vp
          |-adiv -- kireida
    |-sentence
      |-pp
        |-np
          |-vp
            |-v -- wareru
        |-np
          |-a -- seisitu
      |-p
        |-kp -- ga
    |-sentence
      |-vp
        |-v -- aru

```

Total Time = 1634 msec.

number of wf_goal was : 24.
number of wf_dict was : 21.
number of wf_fail_goal was : 49.

図5 解析例

7. 解析例

図5に今回試作した文法を用いて実際の構文解析した例を示す。今回は、日本語文法(水谷, 他 83), (西村, 他 78)のコアとなる部分のみをハイブリッドアントレーニングしたため、文法規則数は約80種類であり、文法体系としてはごく小規模なものでしかない。しかし、この文法によって中学生1年の理科の教科書教科書ページ分の例文が構文解析可能である。また、その例文に対して得られた構文解析木は、どれも数個程度であった。次に構文解析の効率であるが、1単語あたり1つ目の構文解析木を得るまでの時間が約80 msec, 構文解析に要したトータル算時間が約150 msecと、かなりの効率で構文解析が行なえることが示された。

8. おわりに

本研究前半では、構文レベルの情報で未定義語を含む文の解析がどの程度可能か、という問題を検討し、SUPに対して辞書情報、構文情報及び未定義語部分の最短切り出しのHeuristicsを使って、未定義語を含む文の自動分から書きを実現した。また、BUPの高速辞書引きアルゴリズムの不完全性を指摘し、新しいアルゴリズムを提案した。

その結果、Prologが、その強力なunificationとバックトラックの機能ゆえにこの種のプログラムの開発を行なう上で、非常に有効であることが確かめられた。

後半ではまず、左方枝分かれ構造の構文解析木と右方枝分かれ構造の構文解析木を比較検討した結果、右方枝分かれ構造にし、得られる構文解析木を少數に抑制することができたなどの有効な点があることを示した。次に、その右方枝分かれ構造の構文解析木を得る文法規則を試作し、右方枝分かれ構造では、得られる

構文解析木を少段階抑制する二点が可能であることを、実際に確認した。

[謝辞]

本研究の機会を与えていたたいた淵一博士COT研究所長に感謝致します。
また、有益な御討論をしていただいた白中研究室の皆様、電子技術総合研究所推論システム研究室の諸氏、ICOT第二研究室の諸氏に感謝致します。

[参考文献]

Pereira, F. and Warren, D. :
"Definite Clause Grammar for Language Analysis - A Survey of the Formalism and a Comparison with Augmented Transition Networks",
Artificial Intelligence, 13, pp 231-278,
1980

松本裕治, 他 :

"Prologによる達玉判別プログラムアーキテクチャ:
BUP",

Proc. of the Logic Programming Conference '83,
1983

松本裕治, 他 :

"BUPトランслーター—文法規則から構文解析
プログラムの自動生成—",

電子技術総合研究所叢報, 47, 8, 1983

松本裕治, 他 :

"BUPの高速化",
情報処理学会自然言語処理研究会39-7,
1983

Y. Matsumoto and et al. :

"BUP: A Bottom-Up Parser Embedded
in Prolog",

New Generation Computing, 1, 2, 1983

安川秀樹, 田中徳穂 :

"Prologによる形態素処理と熟語処理の
統合",

情報処理学会自然言語処理研究会32-4,
1982

井佐原 洋:

"日本語文法作成の試み",
電子技術総合研究所ルータン情報部推論技術
研究室研究討論会資料, 1980

井佐原洋, 田中徳穂:

"日本語句法文法の構文解析における
諸問題",
情報処理学会自然言語処理研究会 26-4, 1981

水谷静夫, 他 :

"朝倉日本語新講座3 文法と意味 II",
朝倉書店, pp 1-80, 1983

西村想彦, 他 :

"日本語基本文法 — 単文篇 — ",
電子技術総合研究所研究報告, 783,
pp 30-35, 1978

三吉秀夫, 他 :

"Prologによる日本語文節 DCG の生成",
情報処理学会自然言語処理研究会 39-4,
1983

田中徳穂, 他 :

"LISPによる認知心理学言語理解",
東京大学出版会, pp 28-35, 1983

A. V. Aho and et al. :

"data structures and algorithms",
ADDISON-WESLEY, pp 163-169, 1983