

POPSによる構文解析とChart Parsing について

平川秀樹 古川康一

(財団法人 新世代コンピュータ技術開発機構)

1. はじめに

我々は、PrologのOR並列処理実行モデルに基づいた処理系POPS(Or-Parallel Optimizing Prolog System)をConcurrent Prolog上にimplementした[Hirakawa 83]。POPSモデルは、次の様な特徴を持っていた。

- (1) PrologのAND-relationについてはserialに、OR-relationについてはParallelに実行する。
- (2) multiprocessingとmessageの伝達によりOR並列処理を実現している。
- (3) graph reduction mechanismを導入し、同一計算の重複を避ける。

POPSは、OR並列度が高く同一計算の多い計算分野に特に有用である。この例として自然言語の構文解析が挙げられ、POPSによる構文解析は、他のPrologベースの構文解析システム([Pereira 80], [Matsumoto 83], etc)に散在する次の様な問題点を解決していた。

- (1) 計算の重複 : backtrackingは同じ計算を何度も繰り返し実行し、解析する文の長さに対して指数オーダーの時間を要するという効率の悪さを持っている。
- (2) derivation cycle : 自然言語は、本質的にrecursiveな構造を有し、構文規則もそれを反映してcycleを含む規則となることが多い。この様な規則をProlog流のtop down and depth firstのstrategyで解釈すれば、infinite loopに陥り、計算は終了しない。
- (3) ε規則の処理 : 自然言語では単語の省略等は頻繁に行なわれるが、これはCFG規則ではε規則に対応する。ε規則を自然な形で記述したい。

これらは、POPSによる構文解析の質的な議論であった。本報告では、POPSによる構文解析の量的な面に関する考察を行ない、従来のCFG parsing algorithmとの関係について述べる。2節では、POPSの計算モデルを示し、3節では、POPSによるDFG parsingの時間オーダーに関する考察を行なう。4節では、Earley's parsing algorithm, Chart parsing およびEarley DeductionとPOPSのモデルとの関係について考察する。

2. POPS

本節ではPOPSの計算モデルを示す。

2.1 対象言語およびそのInterpretation

POPSが対象とする言語は、Pure Prologであり、一般に次の

形式をしたDefinite Clauseの集合である。

- (a) $H \leftarrow G_1, G_2, \dots, G_n \quad (n \geq 1)$
- (b) $H \leftarrow \text{true}.$

H および $G_i (1 \leq i \leq n)$ は、Prologで言うリテラルであり、trueは恒真を表す特殊なリテラルである。Prologと同様に、(b)において ' $\leftarrow \text{true}$ ' は省略して記述してよい。また、Pure Prologでは、実行制御オペレータのカットや'not'等のevaluable predicateは含まれない。POPSでは、Pure Prologを、subgoalのAND結合についてはserialに、OR結合についてはparallelに実行する。すなわち上記の(a), (b)をそのままプログラムとすれば、 $G_i, G_j (i < j)$ では G_i が計算(証明)されるまで G_j は計算されないが、(a), (b)は同時に計算される。

2.2 構成要素

POPSは図1に示すように、プロセス、チャンネル、ボード、およびホーンデータベース(HDB)の4つの要素から構成される。




図1 POPSの構成




図2 プロセス/チャンネル

プロセスは、計算の実行主体であり、任意個数存在できる。プロセスは、計算途中のclauseに対応し、例えば $H \leftarrow G_1, G_2$ といったclauseを内部に持っている。この際計算の環境は、clauseの変数に実際の値がinstantiatedされているという形式で保持されている。プロセスには activeプロセスとwaiting processの2種があり、waiting プロセスは他のプロセスからデータを受取るまでwaitしている。チャンネルはプロセス間の通信路

であり、計算過程で動的に生成される。チャンネルを通して送られるデータをメッセージと呼ぶ。メッセージの伝達方向は一方向とし、メッセージの送り手となるプロセスをgenerator、受け手となるプロセスをconsumerと呼ぶ。この区別は相対的なものであり、1つのプロセスが同時にgenerator およびconsumerの2役を兼ねる事ができる。また、1つのgenerator プロセスは、1つのチャンネルを用いて複数のconsumerプロセスにメッセージを同時に送ることが可能である(図2)。また、逆に1つのconsumerが複数のgenerator と接続可能である。ボードは、プロセスからアクセスされる記憶領域であり、その時点で計算が進行しているsubgoal すべてとそのsubgoal に対する計算結果(メッセージ)が送り出されてくるchannel を保存する役割を持っている。例えば、subgoal a(x)が呼び出されると、それに対し1つのチャンネルC が生成されa(x)とC が1組となりボードに登録される。このチャンネルC からはsubgoal a(x)に対する解、たとえばa(1), a(2), ..., が送られてくることになる。このchannel とsubgoal (term)を1組としたデータをチャンネルヘッドペアと呼ぶこととする。チャンネルヘッドペアは次の様に記述する。

Channel+Head

HDB は、Pure Prolog のclauseの集合であり、プロセスによってアクセスされる。

2.3 実行メカニズム

POPSでは、複数のプロセスがメッセージの交換を行ないながら計算が進行する。本節では、プロセスのより詳細な説明を行ない、簡単な例を示し、POPSの実行メカニズムを示す。なお、簡単のために、全ての述語は引数を持たないこととする。

プロセスは、'Status', 'Head', 'Goals', 'Input-Channel' および 'Output-Channel' の5つの要素によって規定される。これを図式的に次の様に示す。

process(Status, Head, Goals, Input-Channel, Output-Channel)

'Status'は、プロセスの状態を表わし、'active'または'waiting'のいずれかとなる。activeプロセスは、それ自身で計算を進めるが、waiting プロセスはメッセージを受けるまで何もしない。Headは1つの述語 (term) であり、最終的にこのプロセスが計算すべきものを表わす。Goals は、 ϕ , trueまたは述語の列であり、Headを計算するために計算すべき述語を示している。例えば、HDB に 'a $\leftarrow$ b, c' があれば、

process(Status, a, (b, c), Input-Channel, Output-Channel)

というプロセスが存在して良い。さらに、述語bの計算が終了していれば、

process(Status, a, (c), Input-Channel, Output-Channel)

というプロセスが存在して良い。Channel は、既に述べたように、他のプロセスとメッセージの送受を行なうためのもので、プロセスは、Input-Channel に対してはconsumer, Output-Channel に対してはgenerator となっている。

次にプロセスの動作の定義を示す。

(A) activeプロセス

Activeプロセスの動作は大別してderivation, terminationのいずれかである。Derivationはprologの推論規則の展開が進む場合で、動作の後にそのactiveプロセスは存続する。これに対し、termination は推論が恒真 (true) にたどりついた場合または推論規則の適用が不可能 (fail) になった場合で、いずれの場合もその時点でプロセスは消滅する。

derivation時の動作

process(active, H, G, I, O) において

R が ϕ でもtrueでもなく、G がP または(P, ...) の場合、P がHDB 中に定義された述語である場合
チャンネルヘッドペアI+P に関してボードへの参照/登録^{*1}を行なう。

参照であった場合には、
プロセスの状態をwaiting に変える。

登録であった場合には、
P に関してHDB よりselection ^{*2}を行ないクローズの集合S を得る。S の全要素に対してactiveなプロセスを生成し、その各プロセスとチャンネルI で接続する。(各プロセスがproducer)
プロセスの状態をwaiting に変える。

^{*1} ボードへの参照/登録 : ボードはチャンネルヘッドペア C1+H1, C2+H2, ..., Cn+Hn を保存している。これに対し、C+H を参照/登録するとは、H=Hi (1 $\leq$ i $\leq$ n) であればC=Ciとし(参照)、そうでなければボードにC+Hを追加する(登録)ことである。

^{*2} selection : P に関するselection とは、HDB 中でHeadがP とunify できる全てのclauseを取り出すことである。

termination 時の動作

termination には、success termination とfailure termination の2つの場合がある。success termination は導出がtrueに到達した場合であり、failure termination は、HDB に対するselection が失敗した場合であり、Prologのfail

に相当する。

success termination

R が ϕ または、trueである場合、H をチャンネルO に送信し、プロセス自身は消滅する。

failure termination

プロセス自身が消滅する。

(B) waiting プロセス

Channel I よりメッセージH(term)を受信した場合、waiting プロセスのGoals G のコピーG' (形式はP'または(P', P1..))となる)を作り、その先頭要素(P')とH unify する。(計算結果の伝達)そしてR'より先頭要素を除いたものをNewGとする。ただし、R'がP'だけの時はNewGはtrueとする。そして次のactiveなプロセスを生成する。

```
process(active, H, NewG, I', 0)
```

・I'は新たなチャンネル

waiting プロセス自身はそのまま存続する。

この計算メカニズムの全体の停止条件は、存在するプロセスが全てwaiting になる事であり、これをdeadlock terminationと呼ぶ。Concurrent Prolog によるimplementationでは、Cycle freeのプログラムの実行の場合、全てのプロセスが消滅して終了する。

3. POPSによる構文解析

Prologの処理系であるPOPSにより構文解析を行なう場合には、DEC10 Prologに組みこまれているDCG(Definite Clause Grammar)を利用している。すなわち、DCG トランスレータによりCFGの文法をPrologのプログラムに変換し、そのプログラムを実行することにより構文解析が行なわれる。DCG トランスレータは、次に示すように文法の各カテゴリにcontinuationのための2つの変数を自動的に付加する。

```
DCG      s --> np, vp.
```

```
Prolog    s(X0, X) :- np(X0, X1), vp(X1, X).
```

各変数は入力文のある位置を示すポイントと考えられ、例えば [john, walks] という文の解析が終了した時点では次の様な値が各変数に代入されている。

```
s([john, walks], []) :-  
    np([john, walks], [walks]), vp([walks], []).
```

以降の説明では、簡単のため、listの代わりに入力文の位置を数字で示す。すなわち、上記の例は次の様に示される。

```
s(0, 2) :- np(0, 1), vp(1, 2).
```

一般に、構文解析中に現われる全てのリテラルはa(I, J)となる。

3.1 時間オーダ計算の概要

本節では、POPSによる構文解析における計算時間のオーダに関する考察を行なう。POPS自体はparallel parsingモデルとなっているためprocessor の個数等により実際の計算時間は変化する。ここでは、[Harison 78], [Aho 72] に見られる様に単一processor を仮定し、入力stringの長さに関する計算量のオー

ダを示す。また、parsing そのものについても、入力stringが文法で受理可能かを判定する場合と可能な全ての解(parsing tree)を求める場合では、当然、必要な計算量が異なる。POPSは後者の全解を求めるアルゴリズムであるが、POPSのprocess 動作を少し手直しすることで前者のアルゴリズムに変更が可能である。全解版をtype1、受理版をtype2 のPOPSと呼ぶ事とする。以下では、次の 3つの場合の計算時間に関する考察を行なう。

Case1 type1 POPSによるあいまい性のない文法 (unambiguous grammar)によるparsing

Case2 type2 POPSによるあいまい性のある文法(ambiguous grammar) によるparsing

Case3 type1 POPSによりあいまい性のある文法によるparsing

ここで、あいまい性のない文法とは、S をrootとする2つの導出木T1とT2においてfr(T1)=fr(T2) ならばT1=T2が成立する文法を言う。ここでfr(T) とはT のleavesの連接 (concatenation)である。次に、parsing 時間オーダの証明の手続きを示す。

- (1) type1, type2 のPOPSプロセスのアルゴリズムを示し、アルゴリズム中の各オペレーションの時間オーダを示す。
- (2) 1つのプロセスの入力列に依存する部分の計算コストのオーダを示す。
- (3) parsing 全体で生成されるプロセス数の入力列長に関するオーダを示し、(2) と組み合わせることで全体のオーダを示す。

3.2 プロセスコスト

POPSのプロセスの動作については、既に2で述べたが、ここでは、Type1, type2 POPSの動作を形式的に示し、各オペレーションのコストおよびプロセスコストを示す。

次に各プロセスの動作を形式的に示す。

active process

```
if terminated(Clause) then  
    if type1 then  
        send_message(Head, OutChannel)  
    else  
        if is_new_message(Message, OutChannel)  
            send_message(Head, OutChannel)  
    else begin  
        board_access(Head+Channel, Result);  
        if Result == notyet  
            begin clauses(Body _Top, NewGoals);  
                create_new_processes(NewGoals, OutChannel)  
            wait  
        end
```

waiting process

if receive(Message)

then do

create_new __process(Clause, Message, OutChannel);

active動作中のif type1 then ~elseの部分は、type1 POPSとtype2POPSの定義をマージして記述している。各オペレーションの意味は以下の通りである。

terminated: ClauseがHead $\leftarrow$ trueの形式かを判定する。

send_message: HeadをOutChannelに導出する。

is_new __message: Messageが既にOutChannelに送られたかをチェックする。

board __access: 2で述べたBoardに対する参照/登録を行なう。

==: 右辺と左辺が等しいかをチェックする

clauses: データベースにより展開可能な規則のcollectionを取り出す

create_new __process: New Goals(Clauseのcollection)の各々の要素に対応するactive processを生成する。

wait: 状態をwaitingに変える

receive: messageを受けた時trueとなる

create_new __process: Messageを受け新たなclauseを生成し、active processを生成する。

いま、与えられた文法を固定して考えると、上記の各オペレーションの入力string長に対する計算時間は次のようになる。

constant: terminated, sendmessage, clauses, create_new __processes, receive, create_new __process

また、case1(type1 POPS, unambiguous grammar), case2 (type2 POPS, ambiguous grammar)において

$O(n)$: board __access, is_new __message

board accessのオーダ

文法(DCGプログラム)中の全てのリテラルは、 $a(I, J)$ の形式をしている。また、ボードに登録されているHeadの第1引数は、 $0 < i < n$ (n は入力string長)のいずれかの値を取る。このため、ボードを次の様に構成する事が可能である。

Board = { [0 C11+H12, ..., C1p+H1q],
[1 C21+H21, ..., C2q+H2q],
:
[n Cn1+Hn1, ..., Cnm+Hnm] }

ここで、リスト[...]の個数は $n+1$, 各リストに含まれるチャンネルヘッドペアの個数は最大で文法カテゴリ数となる。ボードへの参照/登録の手続きは次のようになる。

(1) 参照/登録しようとするリテラルの第1引数に応じて

リストの1つを取り出す。 $= \Rightarrow O(n)$

(2) リストをサーチし、参照あるいは登録する $\Rightarrow$ constant

以上により、ボードへの参照/登録オペレーションは $O(n)$ となる。

is_new __message

is_new __messageはあるメッセージが既に出力チャンネルに送出されたかをチェックする。出力チャンネルは、ボード中のチャンネルヘッドペアのチャンネルに対応し、その中のメッセージは $a(i, j)$ の形式をしている。ここで、 i は、ヘッドの第1引数と同じであるため、 $0 < i < n$ を満たす特定の数である。このためチャンネルに送られるmessageの総数は最大 $n+1$ 個となりis_new __messageの計算時間は $O(n)$ となる。

3.3 type1 POPSとunambiguous grammar

ここでは、type1のPOPSによりunambiguousな文法で構文解析する場合について考察する。各オペレーションのコストは既に示したため、全パージング過程で生成されるプロセスの個数を求める。各プロセスは必ずactiveプロセスとして生成されるが、プロセスの保持しているclauseの形式に応じて2つのtypeに分けて考える。1つは、clauseのボディ部分がtrueであるt-typeプロセス(terminate)他は、ボディ部分が1つ以上のsubgoal列となっているn-typeプロセス(non-terminate)である。

t-type $n(2, 3) \leftarrow \text{true}$
n-type $s(\phi, X) \leftarrow \text{np}(\phi, Y), \text{vp}(Y, X),$

t-typeプロセスのコストは、プロセスジェネレーション(constant), メッセージ送信(constant)の和であるので、 $O(\text{constant})$ である。また、n-typeプロセスについてはボードアクセスが $O(n)$ となっている。よってprocessコストは、次の通り。

t-type $O(\text{constant})$
n-type $O(n)$

次に、parsing全体における、n-typeプロセス、t-typeプロセスの個数のオーダを求める。

(1) n-typeプロセス

n-typeプロセスは次の様なclauseに対応する。

$a(i, J) \leftarrow b(k, L), \text{rests}, 0 < i, k < n, J, \text{are variables}$


ここで、n-typeプロセスが生成された時点では、 i および k は実際のある値に決まっており、1つのt-typeプロセスはボード中の1つのチャンネルヘッドペアにチャンネルを介して接続している。逆に、1つのチャンネルヘッドペア、 $b(k, L) + \text{Channel}$, を考えると、それはunambiguous grammarの場合には、あるヘッド a に関して1個のn-typeプロセスと接続可能である。^{*3} いっぽう、3.2で示した様に、ボードには $O(n)$ のチャンネルヘッドペアが存在する。よって、全parsing過程を通して生成されるt-ty

peプロセスの個数は $O(n)$ となる。

*3 : unambiguous grammar を用いた、type1 POPSによる parsing 過程において、ある1つの文法規則 $a \rightarrow m, b, n$. (b は empty production でない) から導出された $a(i, K) \leftarrow b(j, L), n(L, K)$. を clause として持つプロセスが存在した場合、 $a(i, K) \leftarrow b(j, L), n(L, K)$. where $i \neq j$ を clause として持つプロセスは存在しない。

[概略証明]

今、 $a(i, K) \leftarrow b(j, L), n(L, K)$, $a(i, K) \leftarrow b(j, L), n(L, K)$. $i \neq j$ を持つプロセスが存在すると仮定する。nonterminal m に関する parse は終了しているため、 $m(i, j)$, $m(i, j)$ が同時に成立している。 $i \neq j$ および unambiguous grammar の定義により、 $m(i, j)$ に対応する parse tree は、 $m(i, j)$ の parse tree の subtree となっている。



これが成立するのは、 $K=j$, すなわち b が empty production の場合だけである。よって上記2つのプロセスが同時に存在することは無い。

(2) t-typeプロセス

t-typeプロセスは、 $a(k, J) \leftarrow \text{true}$ の形式の clause を持ち、次の2つの場合に生成される。(ここで k は固定している)

- (a) clause として $x(i, j) \rightarrow a(k, L)$, rests. を持つ active プロセスが derive されて生成される。
- (b) clause として $a(i, j) \rightarrow x(k, L)$. の形式を持つ waiting プロセスがメッセージを受けて生成する。

今、文法を固定しているため、 a に関する unit clause は constant order であり、 a を body に含む文法数も constant order である。 a を body に含む規則1つに関して言えば、上記(a)の $0 < i < n$ により高々、 n 個の t-type プロセスを生成するのみである。よって(a)によるプロセス数は $O(n)$ となる。(b)では、 a を head として持つ文法は Constant order であり、その各々に対して(b)の i が $0 < i < n$ であるため、やはり生成されるプロセス数は $O(n)$ である。よって k を固定して時 $a(k, j)$ に対してプロセス数は $O(n)$ である。今 k は、 $0 < k < n$ より全体としては t-type プ

ロセス数は、 $O(n^2)$ となる。

以上より、type1 POPS による unambiguous grammar の Total の計算時間オーダは、次のようになる。

$$\begin{aligned} & n\text{-type process cost} \times n\text{-type process 数} + \\ & t\text{-type process cost} \times t\text{-type process 数} = \\ & O(n) \times O(n) + O(\text{constant}) \times O(n^2) = \\ & O(n^2) \end{aligned}$$

3.4 type2 POPS と ambiguous grammar

ここでは、入力列が文法で受理可能か否かを判定する type2 の POPS について考察する。

t-type プロセスのコストは、プロセスジェネレーション (constant), 新しいメッセージか否かのチェック ($O(n)$), メッセージ送信 (constant) の和であるので、 $O(n)$ である。また、n-type プロセスについてはボードアクセスが $O(n)$ となっている。

$$\begin{aligned} n\text{-type process cost} & O(n) \\ t\text{-type process cost} & O(n) \end{aligned}$$

次に、parsing 全体における、t-type プロセス、n-type プロセスの個数のオーダを求める。

(1) n-type プロセス数

n-type プロセスは次の様な clause に対応する。

$$a(i, j) \leftarrow b(k, L), \text{ rests. } 0 < i, k < n, j, L \text{ are variables}$$

ここで、n-type プロセスが生成された時点では、 i および k は実際のある値に決まっており、1つの n-type プロセスはボード中の1つのチャンネルヘッドペアにチャンネルを介して接続している。逆に、1つのチャンネルヘッドペア、 $b(k, L) + \text{Channel}$, を考えると、 $0 < i < n$ であるため、それはあるヘッド a に関して最大 n 個の n-type プロセスと接続可能である。よって、1つのチャンネルヘッドペアに対して $O(n)$ の n-type プロセスが存在しう。一方、3.2で示した様に、ボードには $O(n)$ のチャンネルヘッドペアが存在する。よって、全 parsing 過程を通して生成される t-type プロセスの個数は $O(n) \times O(n) = O(n^2)$ となる。

(2) t-type プロセス数

t-type プロセスに関しては、3.3 (2) と同じ議論が成立し、次のようになる。

$$t\text{-type プロセス数 } O(n^2)$$

以上により、parsing 全体のコストは、

$$\begin{aligned} & t\text{-type プロセス数} \times t\text{-type プロセスコスト} + \\ & n\text{-type プロセス数} \times n\text{-type プロセスコスト} = \\ & O(n^2) \times O(n) + O(n^2) \times O(n) = \\ & O(n^3) \end{aligned}$$

3.5 type1 POPS, ambiguous grammar

type1 POPSは、可能なparsing treeを全て出力するシステムである。通常、入力長 n に対する解の総数は組み合わせ的な増加をし、それに供ないprocess 数も組み合わせ的に増加する。よって、アルゴリズムの時間オーダも組み合わせ的に増加する。次に示す文法は、入力長 n に対し、 n のカタラン数個の解を持つ。

$S \rightarrow S, S$

$S \rightarrow a.$

この様な場合には、1つの解に対する計算時間をアルゴリズムの良さの尺度に求める事が、妥当であるように考えられるが、例えば、次に示すような文法を考える。

$S \rightarrow E, b. \quad E \rightarrow E, E. \quad G \rightarrow a, G.$

$S \rightarrow G, c. \quad E \rightarrow a. \quad G \rightarrow a.$

この文法は、 $a^n b$ 又は $a^n c$ の入力stringを解析可能である。両者のparsing には、共に組み合わせ的時間オーダがかかるが、 $a^n b$ については解は $n-1$ カタラン数個、 $a^n c$ については1つのみ存在する。よって、一概には1つの解に対する計算時間を評価する事はできないと思える。むしろ、計算時間のパラメタに文法のサイズ、その他の要素を考慮する必要があると思われる。type1 POPSのアルゴリズムについて言えば、type2 POPSが入力列に対し $O(n^3)$ でparsing が可能である点を考慮して、効率的には問題の無いものであると言える。また、POPSはモデル自体が並列性を有し、並列プロセッサ上にimplement が容易であるという特性を持っている。現在、POPSは、Concurrent Prolog[Shapiro 83]上にimplement されておりConcurrent Prologの並列処理マシン上で実行する事を想定している。

4. Earley's Algorithm, Chart Parsing and POPS

本節では、POPSによる構文解析 (DCG プログラムの実行) と他の構文解析アルゴリズムによる構文解析の関係について述べ

$E \rightarrow E \cdot E$	$E \rightarrow E \cdot + E$	$E \rightarrow E \cdot + + E$	$E \rightarrow E \cdot + + + E$	$E \rightarrow E \cdot + + + + E$	$E \rightarrow E \cdot + + + + + E$
$E \rightarrow + E \cdot E$	$E \rightarrow + E \cdot + E$		$E \rightarrow + E \cdot + + E$		$E \rightarrow + E \cdot + + + E$
$E \rightarrow + + \cdot E$	$E \rightarrow + + \cdot + E$		$E \rightarrow + + \cdot + + E$		$E \rightarrow + + \cdot + + + E$
		$E \rightarrow + + + \cdot E$	$E \rightarrow + + + \cdot + E$	$E \rightarrow + + + \cdot + + E$	$E \rightarrow + + + \cdot + + + E$
		$E \rightarrow + + + + \cdot E$	$E \rightarrow + + + + \cdot + E$	$E \rightarrow + + + + \cdot + + E$	$E \rightarrow + + + + \cdot + + + E$
				$E \rightarrow + + + + + \cdot E$	$E \rightarrow + + + + + \cdot + E$
				$E \rightarrow + + + + + \cdot + + E$	$E \rightarrow + + + + + \cdot + + + E$
				$E \rightarrow + + + + + \cdot + + + + E$	$E \rightarrow + + + + + \cdot + + + + + E$

図3 文法 $E \rightarrow a \mid E+E \mid E \cdot E$. 入力 "a+a+a"

る。

4.1 Earley's Algorithm と POPS

CFG の "Good practical algorithm" の1つにEarley's algorithmがある。Earley's Algorithmは、長さ n の入力stringに対して $(n+1) \times (n+1)$ の recognition matrixを生成する。recognition matrixは、図3に示すように文法規則に1つのメタシンボル・を加えたものを要素として持ち、全てのparsing を含んでいる。この場合、全てのparsing とは、全てのparsing treeの生成 (POPSの場合) を意味するのではなく、recognition matrixより、あるアルゴリズムにより全parsing treeが生成されるということを意味している。

次にbit vector版のEarley's algorithmを示す。

```

begin
  t<0> = [ predict({s})
           0
           :
           0 ]
  for j := 1 to n do
    begin
      scanner:
        t<j> := t<j-1> * {a<j>};
      computer:
        for k:= j-1 down to 0 do
          t<j> := t<j> U (t<k> * t<k,j>);
      predictor:
        t<j,j> := predict(U t<i,j> where 0 < i < j)
    end
  end
end

```

アルゴリズムの詳細は文献[Harrison 78] 参照することとし、ここでは、ポイントのみを述べる。次は、アルゴリズム中の基本オペレーションである。

predict nonterminal symbolの集合に対し、文法規則による展開を行なう。(Topdown 予測)

ex. $S \rightarrow A, B. \quad A \rightarrow a. \quad A \rightarrow D, E.$ において

$\text{predict}(\{S\}) = \{S \rightarrow \cdot A B, A \rightarrow \cdot a, A \rightarrow \cdot D E\}$

scanner Topdown 予測されているterminal symbol と入力シンボルとの照合を行なう。

ex. 前例 $A \rightarrow \cdot a$ の予測に対しa が入力stringにあった場合に、 $A \rightarrow a \cdot$ を recognition matrixに追加する。

computer scanner で認識されたnonterminal symbolに対し、そのnonterminal symbolを予測しているrecognition matrix中の要素より新たな要素を生成し、追加する。この計算は可能な限りくり返し適用される。(Bottom Up) の木

の成長に対応)

ex. $A \rightarrow a \cdot$ および $S \rightarrow \cdot A, C$ より $S \rightarrow A \cdot C$ を生成

Earley's algorithmとPOPSを比較すると、次に示す対応関係がある。

Earley	POPS
predict	active processにおける子プロセスの生成 (規則の展開)
scanner	active processにおけるterminated clause の処理
computer	子プロセスからのmessage 送受およびwaiting process における新プロセスの生成

Earley's algorithmにおけるrecognition matrixの要素は、そのままPOPSのプロセスに対応させることが可能である。このようにEarley's algorithmとPOPSによる構文解析は、parsingの動作としては等価であることが示される。基本的な違いは、Earley's algorithmがrecognition matrixを、POPSは全parsing 結果を出力するように動作する点にある。このため、入力stringの認識のみを行なうtype2 POPSはambiguous な文法に関して $O(n^3)$ でparsing することと、Earley's algorithmが $O(n^3)$ でrecognition matrixを作成することは等価なことと見ることができる。

4.2 Earley DeductionとPOPS

Earley Deduction proof procedure schema は、Earley's algorithmに基づいている。Earley Deductionは、program とstate とよばれる2つのdefinite clause の集合に対して適用される。program は入力stringに対応するinput clauses の集合であり、deduction の過程で固定されている。state はderived clauseの集合であり、deduction の仮定で追加されてゆく。各derived clauseは、selected negative literal を持つ。推論規則は、新たなderived clauseを追加することにより、current state を新たなstate にmap する働きをし、instantiation とreduction の2種類がある。instantiation は、Earley's algorithmのpredict オペレーションに対応し、あるclauseのselectedリテラルとnon-unitclauseの正リテラルとを (もし可能なら) unification した結果をcurrent state に追加する。reduction は、current state 中のclauseのselectedリテラルに対し、program およびcurrent state 中のunitclauseをunify し、derivationを行なった結果をcurrent state に追加する操作である。但し、deriveされた結果が既にcurrent state にあるclauseにsubsume される場合は追加を行わない。reduction は、Earleyのscanner, compute オペレーションに対応する。

Earley DeductionとPOPSは、次のように対応づけられる。

Earley Deduction

POPS

instantiation	active processにおけるclauses, create-new-processオペレーション
reduction	message の送受, waiting process による新active processの生成
subsume check	Board への参照/登録

このことから、POPSは、次のような特徴を持つEarley Deduction処理系と見做すことができる。

- (1) multi process, message passing を計算の基礎とし、並列性をexplicitに表現している。
- (2) channel の接続の概念により、Earley Deductionのreduction 時のstate のサーチの手間の最適化が行なわれている。
- (3) POPSのプロセスは、Earley Deductionのstate の要素に対応するが、POPSではプロセス自体は順次消滅し、Board のみが残る。
- (4) Earley Deductionではclauseのsubsumption が必要であるが、POPSではselectedリテラルのequivalence を check するだけである。
- (5) Earley Deduction では、selectedリテラルはsubgoal の任意の1つであるが、POPSでは先頭のsubgoal と固定している。(AND=serialなinterpretation)

以上のように、基本的にPOPSとEarley Deductionは同等と見做せるが、POPSのモデルにchannel の概念が入っていることにより、Earley Deduction では行なえない処理が可能となる。これについては5節で簡単に触れる。

4.3 Chart parsingとPOPS

Chart parsing は、Chart と呼ばれるデータ構造をbookkeeping に使用することを特徴とした、CFG のparsing algorithm




図4

のための一般的なワク組みである。parserの状態は、有向グラフであるchartとして表現される。chart中のノードは入力のpositionを表現し、1つのedgeは、文法規則の1つの適用に対応している。ここでは、詳細は[Kay 80], [Winograd 83], [Hirakawa 83]を参照することとする。[Pereira 83]によれば、Earley's Parsing Algorithmは、Chart parsingの1つの例と見る事が可能である。また、同文献によれば、parsingをdeduction (ex. Earley Deduction)と見る立場から次の事が言える。

(1) chart parsingは、chartのノードを特殊なargumentとしたproof procedureである。

(2) proof procedureは、拡張されたCFG (gap処理、dependency処理)のワク組みを提供する。

すでに述べた様にPOPSとEarley Deductionは同等であり、上記のPereiraの議論は、そのままChart parsingとPOPSについて言える事である。最後に本節をまとめると図4に示すような包含関係となる。

5. ディスカッション

POPSは、messageの伝達路としてchannelを使用しており、常にmessageのsenderに送出可能としている。これは、channelが無制限長のバッファ(unbounded buffer)となっていると言い換える事ができる。POPSのchannelの性質を有限長バッファ(bounded buffer)に置き換え、プロセスの動作に多少の変更を加えるとシステムの動作をコントロールする事が可能となる。すなわち無限長バッファはeagerな実行を、有限長バッファはlazyな実行をする。Earley DeductionとPOPSの動作は基本的には等価であるが、POPSモデルは上記の様な柔軟性を含む点が特徴の1つと言える。eagerおよびlazyな実行については、別紙において報告する予定である。

3節では、POPSによる構文解析の時間計算に焦点をあてて考察を行なったが、Prologの処理系としての効率という点では十分なものではない。例えば、Boardへの参照/登録は計算のsharingおよびoccur-checkのために行なわれるが、同一計算が全くなく、無限loopに陥るような事がないプログラムに対してはBoardは無意味であり、処理効率を下げるだけである。通常のProlog programmingでは、同一計算が多数現われる事は少なく、無限loopの管理はプログラムが行なう。このため、Board-less POPSの方が望ましい場合が多い。Board-less POPSについては、上記のeager, lazyの議論と共にConcurrent Prologにおけるenumerationの取扱いの問題と位置づけて研究していく予定である。

6. おわりに

本報告では、POPSによる構文解析に焦点をあて、CFG parsingを行なった場合の時間のオーダを示し、他のアルゴリズム等との比較を行なった。その結果、POPSによる構文解析は、入力

stringの長さに関してEarley's parsing algorithmと同じ時間オーダで解析することが判明した。

【謝辞】

本研究の機会を下さり、ご指導いただいた淵一博ICOT研究所長に感謝いたします。また、アルゴリズムの解析に助言をいただいた近藤研究員、時間計算等に関して討論いただいた、柴山研究員、坂井研究員、富士通国際研究所の横森研究員に感謝いたします。また、本論文の作成に協力して下さった藤田嬢ならびに中川嬢に感謝いたします。

【参考文献】

- [Pereira 80] Pereira, F and Warren, D.H.: "Definite Clause Grammar for Language Analysis", A.I. 13, (1980)
- [Pereira 83] Pereira, F and Warren, D.H.: "Parsing as Deduction", SRI Technical Note 295, 1983
- [Matsumoto 83] Matsumoto, Y. et. al.: "BUP: A Bottom Up Parser embedded in Prolog", New Generation Computing vol2
- [Kay 80] Kay, M.: "Algorithm Schemata and Data Structures in Syntactic Processing", Xerox Tec. Rep., 1980
- [Shapiro 83] Shapiro, E.Y.: "A Subset of Concurrent Prolog and Its Interpreter", ICOT Tec. Rep. TR-003, 1983
- [Hirakawa 83] Hirakawa, H.: "Chart Parsing in Concurrent Prolog", ICOT Technical Report TR008, 1983
- [Hirakawa 83] Hirakawa, H. R. Onai and K. Furukawa: "Implementing POPS in Concurrent Prolog", ICOT Technical Report TR020, 1983
- [Winograd 83] Winograd, T.: "Language as a Cognitive Process", Addison-Wesley Pub., 1983
- [Harrison 78] H.A. Harrison: "Introduction to Formal Language Theory", Addison Wesley pub., 1978
- [Aho 72] A.V. Aho and J.D. Ullman: "The Theory of Parsing, Translation and Compiling", Prentice-Hall Inc., 1972