

第4章 文脈自由文法とプッシュダウン・オートマトン

4.1 バッカス・ナウアー記法 (教科書 p.10)

BNF (Backus=Naur Form, _____) は言語の文法を記述するための形式である。まず例で説明する。

例 1

$$\begin{aligned} \text{expr} &\rightarrow \text{expr} \text{ "+" } \text{num} \\ &\quad | \text{expr} \text{ "-" } \text{num} \\ &\quad | \text{num} \\ \text{num} &\rightarrow \text{"0"} \mid \text{"1"} \mid \text{"2"} \mid \text{"3"} \mid \text{"4"} \mid \text{"5"} \mid \text{"6"} \mid \text{"7"} \mid \text{"8"} \mid \text{"9"} \end{aligned}$$

記号の読み方は以下の通りである。

→ 左辺は右辺の形からなる。左辺を右辺の形で書き換える。
| または

ようするに、BNF は書き換え規則の集まりである。BNF の場合、左辺は _____ に限られ、右辺は記号列 (空の場合も含む) である。この規則で *expr* から書き換えられるものを *expr* (すなわち *expression* — 式) とみなす。再帰的である (右辺の記号列の中に、左辺の記号が現れても良い) ところが、正規表現とのだいたいな違いである。BNF で記述される文法を _____ (context-free grammar) と言う。文脈自由文法で生成される言語を文脈自由言語 (context-free language) という。

ついでに英語も覚えよう。

expression	式
number	数

ちなみに、文脈依存文法 (context-sensitive grammar) とは書き換え規則が、次のような形をしている文法である。

$$\alpha A \beta \rightarrow \alpha \gamma \beta$$

ここで A は一つの記号で、 α, β, γ は記号列である。

文脈依存文法は文脈自由文法よりも強い表現力を持つが、プログラミング言語の文法は、通常、文脈自由文法の範囲に収まってしまうので、構文解析で文脈依存文法が必要となることは、ほとんどない。

「 $1 + 2 + 3$ は *expr* である。」 (「*expr* は $1 + 2 + 3$ を _____ (derive)。」ともいう) ことを示すには、次のような列を示せばよい。

$$\begin{aligned}
 expr &\Rightarrow expr + num \Rightarrow expr + 3 \\
 &\Rightarrow expr + num + 3 \Rightarrow expr + 2 + 3 \\
 &\Rightarrow num + 2 + 3 \Rightarrow 1 + 2 + 3
 \end{aligned}$$

このような $\Rightarrow$ の列（導出列）が存在することを、まとめて「 $expr \xRightarrow{*} 1 + 2 + 3$ 」と書く。

ここで記号の意味は次の通りである。

$\Rightarrow$ $\rightarrow$ を記号列（の一部）に適用すること
 $\xRightarrow{*}$ $\Rightarrow$ を 0 回以上適用すること

Q 4.1.1 $expr$ は “7 + 8 - 9” を導出することを示せ。

4.2 用語

(terminal)

実際にプログラム中に現れる記号、これ以上書き換えできない記号
 BNF では引用符に囲んで表す（が、明らかなら省略する）
 さっきの例では 0, 1, +, - など

(non-terminal)

$\rightarrow$ の左辺に現れる記号、書き換えできる記号
 文法上の分類（式・文など）を表す。さっきの例では、 $expr$ と num
 （イプシロン）

空の記号列を表す。

「 $\rightarrow$ 」と「 $|$ 」はメタ記号（meta symbol）という。

「メタ」は「高次の」「超」という意味の接頭辞である。

(production rule)

「非終端記号 $\rightarrow$ 構文記号の列」のかたちのこと

(start symbol)

「プログラム」など、BNF で主に表現したい非終端記号のこと
 （特に断らない限り、BNF の一番上に書かれた非終端記号が開始記号になる。）

習慣として、非終端記号は斜体 (*italic*) や 筆記体 *abc* で、終端記号は太字 (**bold**) や 活字体 abc あるいは引用符囲み (“ ~ ”) で書き分けることが多い。

例 2

$$\begin{aligned}
 expr &\rightarrow term \mid expr + term \mid expr - term \\
 term &\rightarrow factor \mid term * factor \mid term / factor \\
 factor &\rightarrow const \mid var \mid (expr) \\
 const &\rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9 \\
 var &\rightarrow x \mid y \mid z \mid w
 \end{aligned}$$

ついでに英語も覚えよう。

term	項
factor	因子
constant	定数
variable	変数

「1 + 2 * 3 + 4」は *expr* である。

$expr \Rightarrow expr + term \Rightarrow expr + factor \Rightarrow expr + const$
 $\Rightarrow expr + 4 \Rightarrow expr + term + 4 \Rightarrow \dots$


問 4.2.1 上記の導出列の続きを書け。

_____ (parse tree)

導出列を木のかたちにあらわしたもの。
本質的でない書き換え順の違いを無視できる。

_____ (syntax tree)

解析木を圧縮したもの
構文木の節は演算子などである。（解析木の節は
非終端記号である。）



注: 例 2 の BNF は、「*」が「+」より、**結合力が強い**ことなどを表現できている。

問 4.2.2 以下の記号列に対する解析木を書け。

1. 1 + 2 * 3 / 4 （例 2 の BNF で *expr* から）
2. while (i > 0) { n = n * i; i = i - 1; } （教科書 p.14 の BNF で Statement から）

例 3

$expr \rightarrow const \mid expr + expr \mid expr * expr$
 $const \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$

「1 + 2 * 3」の解析木は？

解析木 (1)

解析木 (2)

このような構文規則は _____ (ambiguous) である、という

曖昧 (あいまい、ambiguous)	一つの記号列に対して、解析木が何通りもあること
---------------------	-------------------------

曖昧な文法が役に立たない、というわけではなく、BNFに加えて _____ と _____ を指定して、曖昧でなくすることができる（こともある）。

例

「 $3 - 2 - 1$ 」、 「 $1 + 2 * 3$ 」 など

左結合

同じ優先順位の演算子は左を優先する。ほとんどのプログラミング言語の「+」、 「-」 演算子などは左結合である。

右結合

同じ優先順位の演算子は右を優先する。例えばC言語の「=」 演算子などは右結合である。（「 $x = y = 0$ 」は「 $x = (y = 0)$ 」である。）

非結合

同じ優先順位の演算子が隣りあうとエラーになる。プログラミング言語によっては「<」、 「>」 演算子などは非結合である。その場合、「 $0 < x < 10$ 」は構文エラーになる。（C言語の「<」、 「>」は左結合である。つまり、「 $0 < x < 10$ 」は「 $(0 < x) < 10$ 」の意味になって常に真になる。）

文脈自由言語を構文解析するための手法として LR 構文解析や再帰下降構文解析が知られている。ただ効率よく構文解析できるのは文脈自由言語の一部である。

4.3 プッシュダウン・オートマトン

正規表現に対して有限オートマトンが対応するように、文脈自由文法に対しても（非決定性）プッシュダウン・オートマトンという抽象機械が対応することが知られている。以下では、知られている結果のみを証明なしに述べる。


4.3.1 非決定性プッシュダウン・オートマトン

プッシュダウン・オートマトンとは、入力と状態のほかに _____ を持ち、

- 入力の先頭の記号 (ϵ でも良い) と状態の他に、 _____ も考慮に入れて、次の動作が決まる。

- 次の動作のときに、スタックの操作（一番上の記号をポップして、0 個以上の記号をプッシュする）を伴っても良い。

という点が有限オートマトンと異なる。非決定性プッシュダウン・オートマトンは、入力の先頭とスタックの一番上の記号と状態で次の動作が一意に定まらない（つまり、いくつかの選択肢がある）プッシュダウン・オートマトンである。



Jochgem / CC BY-SA (<https://creativecommons.org/licenses/by-sa/3.0>)

次の事実が知られている。

- 任意の文脈自由文法に対して、それが生成する記号列をちょうど受理する非決定性プッシュダウン・オートマトンを構成することができる。
- 任意の非決定性プッシュダウン・オートマトンに対して、それが受理する記号列を生成する文脈自由文法を構成することができる。

非決定性プッシュダウン・オートマトンをそのままプログラムとして実装しようとすると、効率が良くない。そのため、プログラミング言語の構文解析で非決定性プッシュダウン・オートマトンをそのまま用いることはほとんどない。

文脈自由言語を判定するアルゴリズムは、動的計画法を用いる Cocke-Younger-Kasami 法なども知られている。最悪の場合、記号列の長さの 3 乗に比例する計算時間がかかることが知られている。

4.3.2 決定性プッシュダウン・オートマトン

決定性プッシュダウン・オートマトンは、入力の先頭とスタックのトップの記号と状態で次の動作が一意に定まるプッシュダウン・オートマトンである。有限オートマトンの場合は、非決定性有限オートマトンと決定性有限オートマトンの表現力は同じであった。しかし、非決定性プッシュダウン・オートマトンと決定性プッシュダウン・オートマトンの場合は同じではなく、非決定性のほうが強力である。つまり、非決定性プッシュダウン・オートマトンでは受理できるが、決定性プッシュダウン・オートマトンでは受理できない言語があることが知られている。

また、決定性プッシュダウン・オートマトンにより受理される言語は、 (ただし、 $k \geq 1$) という方法で受理される言語と一致することが知られている。LR 法については後期の「コンパイラ」で触れる。

現在、実用的に効率の良い構文解析法が知られているのは、LR(1) のさらにサブセットになる LALR(1) という構文解析法である。

4.4 （文脈自由言語の）反復補題

文脈自由文法では表現できない言語（記号列の集合）がある。ある言語が文脈自由言語で表せないことを示すためには、次の補題が役に立つ。

文脈自由言語の反復補題 (pumping lemma for context-free languages)



（文脈自由言語の）ポンプの補題ともいう。

文脈自由文法が表現する言語 L に対して、次のような条件を満たす自然数 $p (\geq 1)$ が存在する。


L に属する長さ p 以上の任意の文字列 s は $s = uvwxy$ と書いて、

1. vx の長さは 1 以上である。つまり、 v, x の少なくとも一方は空ではない。
2. vw の長さは p 以下である。
3. すべての $n (\geq 0)$ に対して、 uv^nwx^ny も L に属する。

正確な証明をするためには、文脈自由文法の標準形の議論をしなければいけないので割愛する。概略は以下のような図を見るとわかりやすい。



Generating $uv^0wx^0y^0$



Generating $uv^2wx^2y^2$

Jochen Burghardt / CC BY-SA (<https://creativecommons.org/licenses/by-sa/3.0>)

つまり、 L の記号列がある程度長くなると、解析木の高さも必然的に大きくなり、どこかの経路で同じ非終端記号（上の図の場合は N ）が 2 回現れる。この N から N まで部分をカットしたり（左下の図）、繰り返したり（右下の図）することで得られる記号列もやはり L に属する。

例

$\{a^i b^i c^i \mid i \geq 0\}$ つまり $\{\varepsilon, abc, aabbcc, aaabbbccc, aaaabbbbcccc, \dots\}$ という言語 L は文脈自由文法では表せない。

証明: 文脈自由文法で表せたとして矛盾を導く。 L を文脈自由文法で表せたすると、反復補題により、上のような条件を満たす自然数 $p (\geq 1)$ が存在する。 $s = a^p b^p c^p$ とする。すると、 $s = uvwxy$ と分解したときに vw の長さは p 以下なので、 a と c の両方を含むことはない。すると uwy は L に属するが、例えば、 vw が、 a を含み c を含まないとき、 a と c の出現回数が異なり矛盾する。 a を含まず、 c を含むときも同様である。 vw が b のみからなるときも、 uwy は b の出現回数が異なり矛盾する。

4.5 文脈自由言語の閉包性

次のような事実が知られている。これらもやはり証明なしで紹介する。

文脈自由言語については、正規言語のような閉包性は成り立つとは限らない。つまり、

- 文脈自由言語の補集合は文脈自由言語とは限らない。
- 2 つ以上の文脈自由言語の共通部分は文脈自由言語とは限らない。

また、決定性プッシュダウン・オートマトンで受理できる言語に対しては、ポンプの補題のようなものは存在しない。そのため、ある言語が（文脈自由言語ではあるが）決定性プッシュダウン・オートマトンで受理できないことを示すのは難しい。

