構文法
プログラム言語論

櫻井彰人

プログラムの構文と意味

- 構文 (syntax)
  - プログラムを書くのに用いる記号(達)
- 意味 (semantics)
  - プログラムが実行されるときに発生する行動
- プログラミング言語の実装
  - 構文 → 意味
  - プログラムの構文を機械命令列に変換する。この機械命令列を実行すると、行動の正しい系列が出現するような変換である

Interpreter と Compiler

- 処理(翻訳・実行)方式の違い

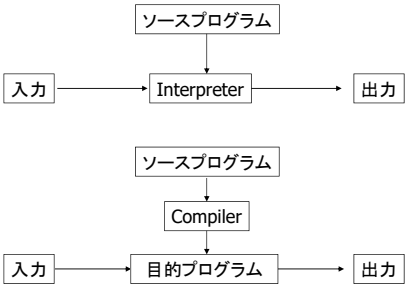

言語と処理(翻訳・実行)方式

- 言語と処理とは、本来、独立な概念のはず
  - すなわち、どの言語にも interpreter があり、compiler があってよい
  - おまけに、多くの場合、compiler があれば interpreter は不要である(interpreter は、実行が遅いため)
  - さらに、compilerを作るのは難しくはない。
- では、interpreter は不要か？
- いや、必要！
  - compile できない(compileしても意味がない)機能をもつ言語がある
    - マクロ機能がこれに相当する。たとえば、LISP
  - compileする時間がもったいない利用環境の言語がある
    - たとえば、JavaScript
  - interactive性を重視する利用環境の言語がある

コンパイルの典型的な流れ

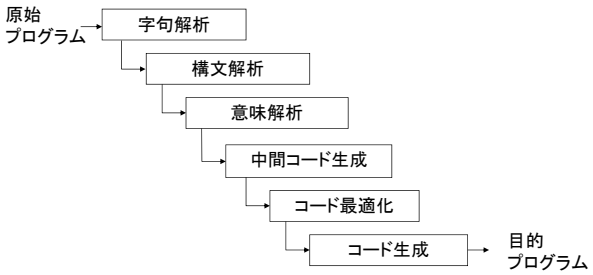

詳細については、コンパイラの本をよむこと

構文を簡単に

- 文法

  e ::= n | e + e | e − e
  n ::= d | nd
  d ::= 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9

- 式

  e → e−e → e−e+e → n−n+n → nd−d+d → dd−d+d
  → ... → 27 − 4 + 3

文法は言語を定める
式は、生成規則を順に適用することによって導出される

ご存じですね？

言語 – 復習 かな？

記号を有限個並べて得られる系列

記号列

制約：文法という

言語

自然言語研究がきっかけ

文法の定義方法

- 「文」は「主部」と「述部」からなる
- 「主部」は「名詞句」と「が」からなる
- 「名詞句」は「名詞」か「修飾句」を一個以上並べたものに「名詞」をつけたもの

- <文> = <主部> <述部>
- <主部> = <名詞句> が

種類が異なることに注意

- <名詞句> = <名詞> | <修飾句並び> <名詞>
- <修飾句並び> = <修飾句> | <修飾句並び> <修飾句>

文法の書き方 (生成方向)

$A \Rightarrow X_1\ X_2 \ldots X_m$

書き換え規則
生成規則
BNF (Backus Naur form,
Backus normal form)

文法の書き方 (解析方向)

$A \Leftarrow X_1\ X_2 \ldots X_m$

解析方向：使用することはまれ

同一記号の書換え

$A \Rightarrow X_1\ X_2 \ldots X_m$

$A \Rightarrow Z_1\ Z_2 \ldots Z_m$

$A \Rightarrow X_1\ X_2 \ldots X_m \mid Z_1\ Z_2 \ldots Z_m$

と記述

文法例1

数 ⇒ 数　数字　|　数字

数字 ⇒ 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9

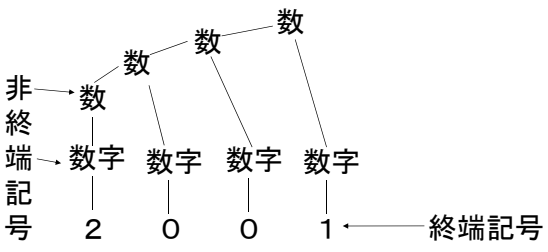

文法例2

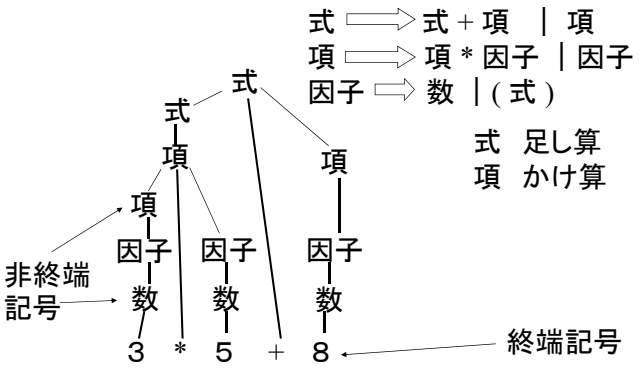

文法例3

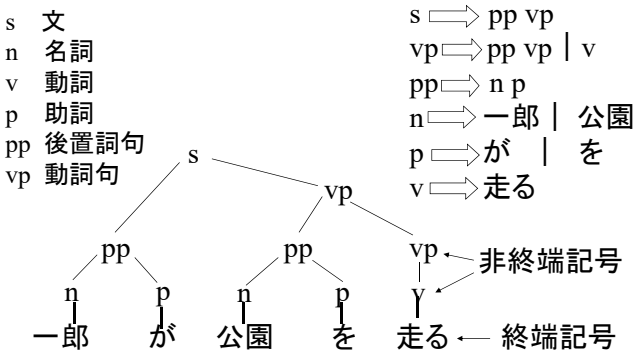

チョムスキー階層

3型 正規文法　　受理:有限状態オートマトン

$A \Rightarrow a$　　$A \Rightarrow a\ B$

2型 文脈自由文法　　受理:プッシュダウン・オートマトン

$A \Rightarrow X_1\ X_2\ \ldots X_m$

1型 文脈依存文法　　受理:線型有界オートマトン

$Z_1Z_2\ldots Z_n \Rightarrow X_1\ X_2\ \ldots X_m \quad n \leqq m$

0型 句構造文法　　受理:チューリング機械

右辺・左辺とも任意

a 終端記号
A,B 非終端記号
X,Z どちらか

有限状態オートマトン

S ⇒ cAd
A ⇒ ab | a

S,A 非終端記号
a,b,c,d 終端記号

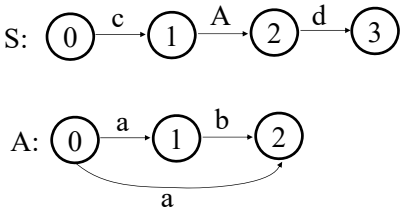

決定性プッシュダウンオートマトン

S ⇒ cSd | cd

S,A 非終端記号
c,d 終端記号

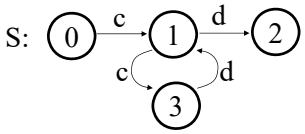

後で、d との対応させるためにcをとっておく

⇩

(一般には)スタック

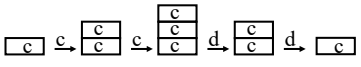

正規文法で記述できない言語の例

S ⇒ (S) S | ε　文脈自由文法では記述可

とか

S ⇒ (S) | ε　文脈自由文法では記述可

((( )))

((( )) ((((( ))))) ()))

文脈自由文法で記述できない言語の例

$L = \{ a^n b^m c^n d^m \mid n,m \geqq 1 \}$　　u^k uのk回並び
aa bbbb cc dddd

$L=\{ wcw \mid w$は$(a|b)^* \}$
aabbcaabb
aacaa

構文解析の手法

- ■ 下向き　　vs. 上向き
  - 文法項目をまとめてより上位の項目に
    - あらゆる纏め方を考える
  - 実際に生成して同じものができるか？
- ■ 深さ優先　　vs. 広さ優先
  - 候補生成の順番：縦方向、横方向
- ■ 最左　　vs. 最右
  - 左端（初め）からか、右端からか
    - 左から2番目、ということも考えられるが

下向き　解析例1

文法
S ⇨ cAd
A ⇨ ab ｜ a

S,A 非終端記号
a,b,c,d 終端記号

入力 cad

S ⇨ cAd ⇨ cabd　失敗
　　⇨ cad　成功

バックトラック

解析例2

下向き＋縦＋最左

s ⇨ pp vp
vp ⇨ pp vp ｜ v
pp ⇨ n p
n ⇨ 一郎 ｜ 公園
p ⇨ が ｜ を
v ⇨ 走る

入力
一郎が公園を走る

s ⇨ pp vp
⇨ n p vp
⇨ 一郎 p vp
⇨ 一郎 が vp
⇨ 一郎 が pp vp
⇨ 一郎 が n p vp
⇨ 一郎 が 一郎 p vp
⇨ 一郎 が 公園 p vp
⇨ 一郎 が 公園 が vp
⇨ 一郎 が 公園 を vp
.....
⇨ 一郎 が 公園 を 走る

上向き型

S ⇨ aABe
A ⇨ Abc ｜ b
B ⇨ d

最右＋深さ優先

入力　abbcde ⇨ aAbcde
⇨ aAde
⇨ aABe
⇨ S

解析例2 – 復習 ここまで かな？

深さ優先＋最右

s ⇨ pp vp
vp ⇨ pp vp ｜ v
pp ⇨ n p
n ⇨ 一郎 ｜ 公園
p ⇨ が ｜ を
v ⇨ 走る

一郎が公園を走る
nが公園を走る
n p　公園を走る
pp 公園を走る
pp n を走る
pp n p 走る

pp pp 走る
pp pp v
pp pp vp
pp s　失敗
pp vp　成功
s

構文解析木

■ 導出過程を表現した木

e → e–e → e–e+e → n–n+n → nd–d+d → dd–d+d
→ … → 27 – 4 + 3

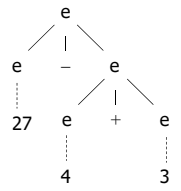

木は、括弧付けされた式を表すと考えられる

構文解析

■ 式が与えられたとき、構文木を作成すること
■ 曖昧性があることもある
- 式　27 – 4 + 3　に二通りの構文解析方法がありうる
- 問題となるのは:　27 – (4 + 3)　≠ (27 – 4) + 3

■ 曖昧性を解消する方法
- 手順で
  - 纏める順序は、* が + より先
  - 3*4 + 2 は (3*4) + 2 と解析
- 結合性(associativity)
  - 等しい優先順序の演算は、左(または右)から括弧でくくる
  - 3 – 4 + 5 は (3 – 4) + 5 と解析

詳細はコンパイラの本等を