生成規則・生成文法

生成規則を与えることでも
言語を定めることが出来る

⟶ **生成文法 (generative grammar)**

生成規則による "文法に適っている" 語の生成

- 初期変数を書く
- 今ある文字列中の或る変数を
  生成規則のどれかで書換える
- 変数がなくなったら終わり

文脈自由文法 (context-free grammar)

文脈が全て空列 ε

即ち、規則が全て $A \to w$ ($A \in V$) の形

文脈自由文法の形式的定義

- V ： **有限集合 (変数の集合)**
- Σ ： **有限集合 (終端記号の集合)**
  ここに $V \cap \Sigma = \emptyset$
- R ： **有限集合** $\subset V \times (V \cup \Sigma)^*$ **(規則の集合)**
- $S \in V$ ： **開始変数**

$(A, w) \in R$ **が生成規則** $A \to w$ **を表す**

例：言語 $A = \{a^n b^n | n \geq 0\}$ は
正規言語ではないが文脈自由言語である：

- $S \to aSb | \varepsilon$

従って、

文脈自由言語は正規言語より真に広い!!

さて、正規言語を計算するモデルが
有限オートマトンであった

文脈自由言語を計算するモデル
$\cdots$ **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

(非決定性) 有限オートマトンに
プッシュダウンスタックを取り付けたもの

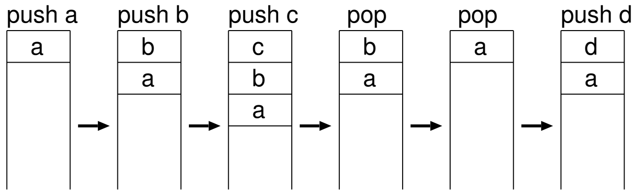

無限 (非有界) の情報を保持できるが、
読み書きは先頭だけ

$\cdots$ LIFO (Last In First Out)

プッシュダウンオートマトンの形式的定義

$$M = (Q, \Sigma, \Gamma, \delta, s, F)$$

- Q : **有限集合** $\cdots$ **状態の集合**
- Σ : **有限集合** $\cdots$ **alphabet**
- Γ : **有限集合** $\cdots$ **stack alphabet**
  $\Sigma_\varepsilon := \Sigma \cup \{\varepsilon\}$, $\Gamma_\varepsilon := \Gamma \cup \{\varepsilon\}$ **と置く**
- $\delta : Q \times \Sigma_\varepsilon \times \Gamma_\varepsilon \longrightarrow \mathcal{P}(Q \times \Gamma_\varepsilon)$
  : 遷移関数 (非決定的) $\cdots$ **可能な遷移先全体**
- $s \in Q$ $\cdots$ **初期状態**
- $F \subset Q$ $\cdots$ **受理状態の集合**

$$\delta : Q \times \Sigma_\varepsilon \times \Gamma_\varepsilon \longrightarrow \mathcal{P}(Q \times \Gamma_\varepsilon)$$

- $(r, y) \in \delta(q, a, x)$ **とは、**
  「入力 a を読んだとき、
  状態 q でスタックの先頭が x なら、
  スタックの先頭を y に書換えて、
  状態 r に移って良い」
  ということ (`pop; push y`**)**

- $x = y$ **は書き換え無し**
- $x = \varepsilon$ **は push のみ**
- $y = \varepsilon$ **は pop のみ**
- $a = \varepsilon$ **は入力を読まずに遷移**

スタックマシン

このように

記憶場所としてプッシュダウンスタックを備えた計算モデルや仮想機械・処理系を

一般にスタックマシンという

例：

- 逆ポーランド電卓
- PostScript

構文解析木

生成規則の適用過程を木で表したもの

$G = (V, \Sigma, R, E)$

- $V = \{E, T, F\}$
- $\Sigma = \{a, +, \times, \ (\, ,\,)\ \}$
- R :
  - $\star\ E \longrightarrow T \mid T + E$
  - $\star\ T \longrightarrow F \mid F \times T$
  - $\star\ F \longrightarrow a \mid (E)$

(a + a) x a

定理：

L：**正規言語**

L **が或る有限オートマトンで認識される**

定理：

L：**文脈自由言語**

L **が或るプッシュダウンオートマトンで認識される**

本質的な違いは？

文脈自由言語は再帰 (recursion) を記述できる

文脈自由言語と再帰

- $S \rightarrow aSb|\varepsilon$

```
S(){
  either
    "";
  or
    { "a"; S() ; "b"; }
}

main(){
  S();
}
```

再帰：関数 S() **の中で、自分自身を呼び出す**

計算機での関数呼出・再帰の実現

関数呼出は原理的には次の仕組みで行なっている

- **現在の実行番地 (戻る場所) を覚えておく**
- **関数を実行する**
- **関数を実行し終えたら、**
  覚えていた実行番地に戻って呼出側の実行再開

再帰呼出では呼出す度に覚えておく番地が増える

$\longrightarrow$ **スタックに積んで覚えておく**
(関数呼出の際に番地を push、戻ったら pop)

正規言語における再帰

正規表現： $(aa)^*$

- $S \rightarrow aaS | \varepsilon$

```
S(){
  either
    "";
  or
    { "aa"; S() ; }
}

main(){
  S();
}
```

$\longrightarrow$ **末尾再帰の除去**

```
main(){
  loop {
    "aa";
  }
}
```

繰返しで記述可能
(再帰は不要)

正規言語・文脈自由言語と再帰

- 正規言語は繰返しを記述できる
- 文脈自由言語は再帰を記述できる
- 再帰の実装にはスタックを要す
- 正規言語の生成規則は次の形に出来る
  - $\star\ X \longrightarrow xY\ (X, Y \in V, x \in \Sigma)$
  - $\star\ X \longrightarrow x\ (X \in V, x \in \Sigma_\varepsilon)$

  特に、末尾再帰であり再帰の除去可能

文脈自由言語の Pumping Lemma

文脈自由言語 A **に対し、**

$\exists n \in \mathbb{N}:$

$\forall w \in A, |w| \geq n:$

$\exists u, v, x, y, z \in \Sigma^* : w = uvxyz$

(1) $vy \neq \varepsilon$ **(即ち** $v \neq \varepsilon$ **または** $y \neq \varepsilon$**)**

(2) $|vxy| \leq n$

(3) $\forall k \geq 0 : uv^kxy^kz \in A$

文脈自由言語の例

回文全体の成す言語は文脈自由

- $S \to aSa|bSb|a|b|\varepsilon$

問：回文全体の成す言語を認識する プッシュダウンオートマトンを構成せよ

プッシュダウンオートマトンでは認識できない言語の例

同じ文字列 2 回の繰返しから成る文字列全体

$$A = \{ww | w \in \Sigma^*\}$$

入力を読み直せないのが弱点

$\longrightarrow$ **より強力な計算モデルが必要**

一つの方法としては、

入力を覚えておくために
プッシュダウンスタックをもう一つ
使えることにする

実際これで真により強い計算モデルが得られる

しかし、通常はこれと同等な
次のような計算モデルを考える
· · · チューリングマシン

チューリングマシン

- 有限個の内部状態を持つ
- 入力データはテープ上に一区画一文字づつ書き込まれて与えられる
- データを読み書きするヘッドがテープ上を動く
- 遷移関数は次の形：
  内部状態とヘッドが今いる場所の文字とによって、その場所の文字を書き換え、次の内部状態に移り、ヘッドを左か右かに動かす
- 受理状態または拒否状態に達したら停止するが、停止しないこともある