

形式言語理論

Formal Language Theory

13. 句構造文法とChomsky階層




本日の内容

- Chomsky階層
- 句構造文法
- 文脈依存文法
- Turing機械
- 線形有界オートマトン
- 各言語族の閉性

Chomsky 階層

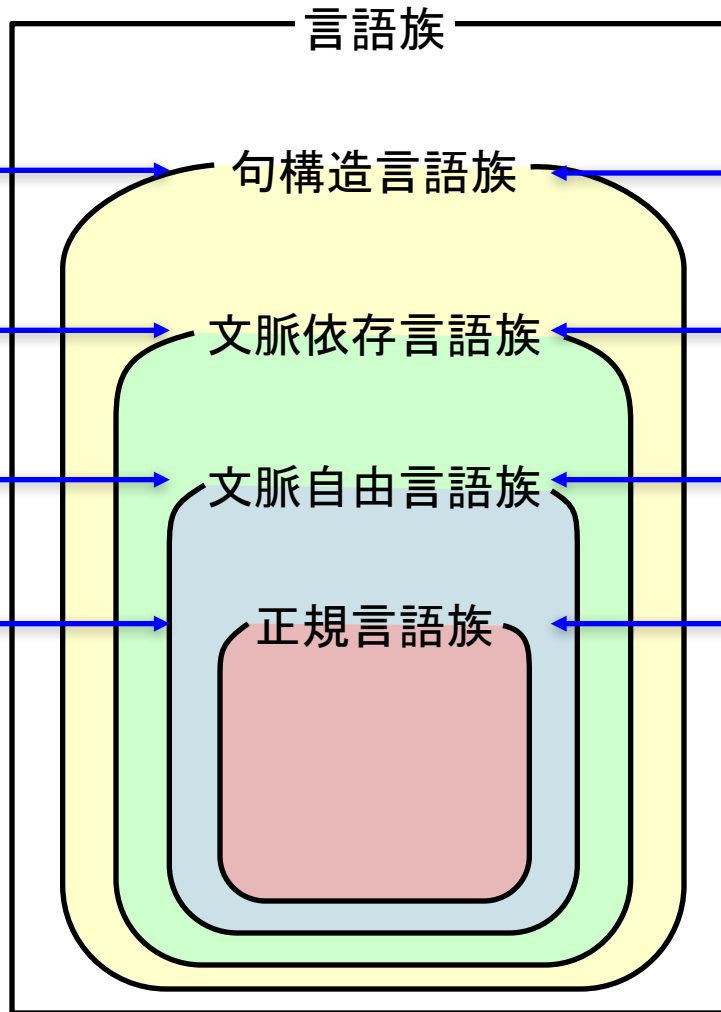
Avram Noam Chomsky (1928-)

- 合衆国の哲学者，言語哲学者，言語学者，認知科学者，論理学者.
- 「現代言語学の父」



Chomsky階層

対応する形式文法



対応する計算モデル

句構造文法



句構造言語族



Turing機械

文脈依存文法



文脈依存言語族



線形有界オートマトン

文脈自由文法



文脈自由言語族



プッシュダウンオートマトン

正規文法



正規言語族



有限オートマトン

句構造文法

句構造文法 (phrase-structure grammar; PSG)

【定義】 句構造文法とは、次のような4つ組 $G = (N, \Sigma, P, S)$ をいう。

- N は非終端記号の空でない有限集合。
- Σ は終端記号の空でない有限集合。
- $S \in N$ は開始記号。
- P は以下の形式をした生成規則の有限集合
$$\alpha \rightarrow \beta \quad (\alpha \in (N \cup \Sigma)^* N (N \cup \Sigma)^*, \beta \in (N \cup \Sigma)^*)$$

左辺 α は少なくとも1個の非終端記号を含む

文脈自由文法は句構造文法の特別な場合である

句構造文法における導出

【定義】 PSG $G = (N, \Sigma, P, S)$ に対し, $(N \cup \Sigma)^*$ 上の2項関係 \Rightarrow_G を次で定義する.

$$\delta \Rightarrow_G \delta'$$

\Leftrightarrow

$$\begin{aligned} \exists \gamma_1, \exists \gamma_2 \in (N \cup \Sigma)^*, \exists \alpha \rightarrow \beta \in P, \\ \delta = \gamma_1 \alpha \gamma_2 \wedge \delta' = \gamma_1 \beta \gamma_2 \end{aligned}$$

$$\delta = \begin{array}{|c|c|c|} \hline \gamma_1 & \alpha & \gamma_2 \\ \hline \end{array}$$

$$\delta' = \begin{array}{|c|c|c|} \hline \gamma_1 & \beta & \gamma_2 \\ \hline \end{array}$$

例 句構造文法

$$G_1 = (N, \Sigma, P, S)$$

$$N = \{S, A, B, C\}$$

$$\Sigma = \{a\}$$

$$P = \{$$

$$S \rightarrow BAB,$$

$$BA \rightarrow BC,$$

$$CA \rightarrow AAC,$$

$$CB \rightarrow AAB,$$

$$A \rightarrow a,$$

$$B \rightarrow \varepsilon$$

$$\}$$

$$L(G_1) = \{a^{2^n} \mid n \geq 0\} = \{a^1, a^2, a^4, a^8, \dots\}$$

$$S \Rightarrow BAB$$

$$\vdots$$

$$\underline{BAB} \Rightarrow \underline{BCB} \Rightarrow BAAB$$

$$\Rightarrow^* BAAB$$

$$\vdots$$

$$\underline{BAAB} \Rightarrow \underline{BCAB} \Rightarrow \underline{BAACB} \Rightarrow BAAAAB$$

$$\Rightarrow^* BAAAAB$$

$$\vdots$$

$$\Rightarrow^* BAAAAAAAAAAB$$

$$\Rightarrow^* aaaaaaaaaa$$

例 句構造文法

$$G_2 = (N, \Sigma, P, S)$$

$$N = \{S, A, B, C, D, E\}$$

$$\Sigma = \{0, 1\}$$

$$P = \{$$

$$S \rightarrow ABC,$$

$$AB \rightarrow 0AD \mid 1AE,$$

$$DC \rightarrow B0C, \quad EC \rightarrow B1C,$$

$$D0 \rightarrow 0D, \quad D1 \rightarrow 1D,$$

$$E0 \rightarrow 0E, \quad E1 \rightarrow 1E,$$

$$AB \rightarrow \varepsilon, \quad C \rightarrow \varepsilon,$$

$$0B \rightarrow B0, \quad 1B \rightarrow B1$$

$$\}$$

$$L(G_2) = \{uu \mid u \in \{0,1\}^*\}$$

$$S \Rightarrow^* uABuC \Rightarrow^* uu$$

$u=x0$ とする.

$$S \Rightarrow^* xABxC$$

$$\Rightarrow x0ADxC$$

$$\Rightarrow^* x0AxD C$$

$$\Rightarrow x0AxB0C$$

$$\Rightarrow^* x0ABx0C$$

$$= uABuC$$

$u=x1$ とする.

$$S \Rightarrow^* xABxC$$

$$\Rightarrow x1AExC$$

$$\Rightarrow^* x1AxEC$$

$$\Rightarrow x1Ax B1C$$

$$\Rightarrow^* x1ABx1C$$

$$= uABuC$$

句構造文法の生成する言語

- 文脈自由文法の場合と同様，以下のように定める。

【定義】 PSG $G = (N, \Sigma, P, S)$ と文字列 $w \in \Sigma^*$ に対して， G が w を生成するとは， $S \xRightarrow[G]{*} w$ であるときをいう。

【定義】 PSG $G = (N, \Sigma, P, S)$ によって生成される Σ 上の文字列全体の集合を $L(G)$ で表わし， G の生成する言語とよぶ。すなわち，

$$L(G) = \{ w \in \Sigma^* \mid S \xRightarrow[G]{*} w \}$$

である。

句構造言語

【定義】 言語 $L \subseteq \Sigma^*$ が句構造言語であるとは, $L = L(G)$ となる句構造文法 G が存在するときをいう.

0型文法, 消去付き文脈依存文法

【定義】 句構造文法 $G = (N, \Sigma, P, S)$ が**0型**であるとは, すべての生成規則が次の形式であるときをいう.

$$\alpha \rightarrow \beta \quad (\alpha \in N^+, \beta \in (N \cup \Sigma)^*)$$

【定義】 句構造文法 $G = (N, \Sigma, P, S)$ が**消去付文脈依存文法**であるとは, すべての生成規則が次の形式であるときをいう.

$$\alpha A \beta \rightarrow \alpha \gamma \beta \quad (A \in N, \gamma \in (N \cup \Sigma)^*, \alpha, \beta \in (N \cup \Sigma)^*)$$

句構造言語

【定理7.1】 任意の言語 $L \subseteq \Sigma^*$ に対し, 次の①②③は等価である.

- ① $L=L(G)$ となる句構造文法 G が存在する.
- ② $L=L(G)$ となる0型文法 G が存在する.
- ③ $L=L(G)$ となる消去付文脈依存文法 G が存在する.

文脈依存文法

文脈依存文法(context-sensitive grammar; CSG)

【定義】句構造文法 $G = (N, \Sigma, P, S)$ が**文脈依存文法**であるとは, P の生成規則が次のいずれかの形式であるときをいう.

(1) $S \rightarrow \varepsilon$

(2) $\alpha A \beta \rightarrow \alpha \gamma \beta$ ($A \in N, \gamma \in (N \cup \Sigma)^+, \alpha, \beta \in (N \cup \Sigma)^*$)

- 文脈自由文法における生成規則 $A \rightarrow \gamma$ と異なり, 記号 A が**左右の文脈** α, β の中にあるときのみ書き換えが行われる.

例 文脈依存文法

$$G_3 = (N, \Sigma, P, S)$$

$$N = \{S, A, B, C\}$$

$$\Sigma = \{a, b, c\}$$

$$P = \{$$

$$S \rightarrow aSBC \mid aBC,$$

$$CB \rightarrow AB,$$

$$AB \rightarrow AC,$$

$$AC \rightarrow BC,$$

$$aB \rightarrow ab, bB \rightarrow bb,$$

$$bC \rightarrow bc, cC \rightarrow cc$$

$$\}$$

$$L(G_3) = \{a^n b^n c^n \mid n > 0\}$$

$$S \Rightarrow^* a^n (BC)^n$$

$$\vdots$$

$$\Rightarrow^* a^n B^n C^n$$

$$\vdots$$

$$\Rightarrow^* a^n b^n C^n$$

$$\vdots$$

$$\Rightarrow^* a^n b^n c^n$$

$$\begin{aligned} & (BC)^n \\ &= B(CB)^{n-1}C \\ &\Rightarrow^* B(BC)^{n-1}C \\ &\Rightarrow^* B(B^{n-1}C^{n-1})C \\ &= B^n C^n \end{aligned}$$

$$\begin{aligned} & aB^n \\ &= aB^{n-1}B \\ &\Rightarrow^* ab^{n-1}B \\ &\Rightarrow^* ab^{n-1}b \\ &= ab^n \end{aligned}$$

$$\begin{aligned} & bC^n \\ &= bC^{n-1}C \\ &\Rightarrow^* bc^{n-1}C \\ &\Rightarrow^* bc^{n-1}c \\ &= bc^n \end{aligned}$$

文脈依存言語

【定義】 言語 $L \subseteq \Sigma^*$ が **文脈依存言語** であるとは,
 $L=L(G)$ となる文脈依存文法 G が存在するときをいう.

単調文法

【定義】句構造文法 $G = (N, \Sigma, P, S)$ が**単調文法**であるとは、任意の生成規則 $\alpha \rightarrow \beta$ が次のいずれかを満たすときをいう。

- (1) $|\alpha| \leq |\beta|$
- (2) $\alpha = S, \beta = \varepsilon$

例 単調文法

$$\begin{aligned} G_4 &= (N, \Sigma, P, S) \\ N &= \{S, A, B, C\} \\ \Sigma &= \{a, b, c\} \\ P &= \{ \\ &\quad S \rightarrow aSBC, S \rightarrow aBC, \\ &\quad \mathbf{CB \rightarrow BC}, \\ &\quad aB \rightarrow ab, bB \rightarrow bb, \\ &\quad bC \rightarrow bc, cC \rightarrow cc \\ &\quad \} \end{aligned}$$

$$L(G_4) = \{a^n b^n c^n \mid n > 0\}$$

G_3 の生成規則

$CB \rightarrow AB, AB \rightarrow AC, AC \rightarrow BC$
の代わりに

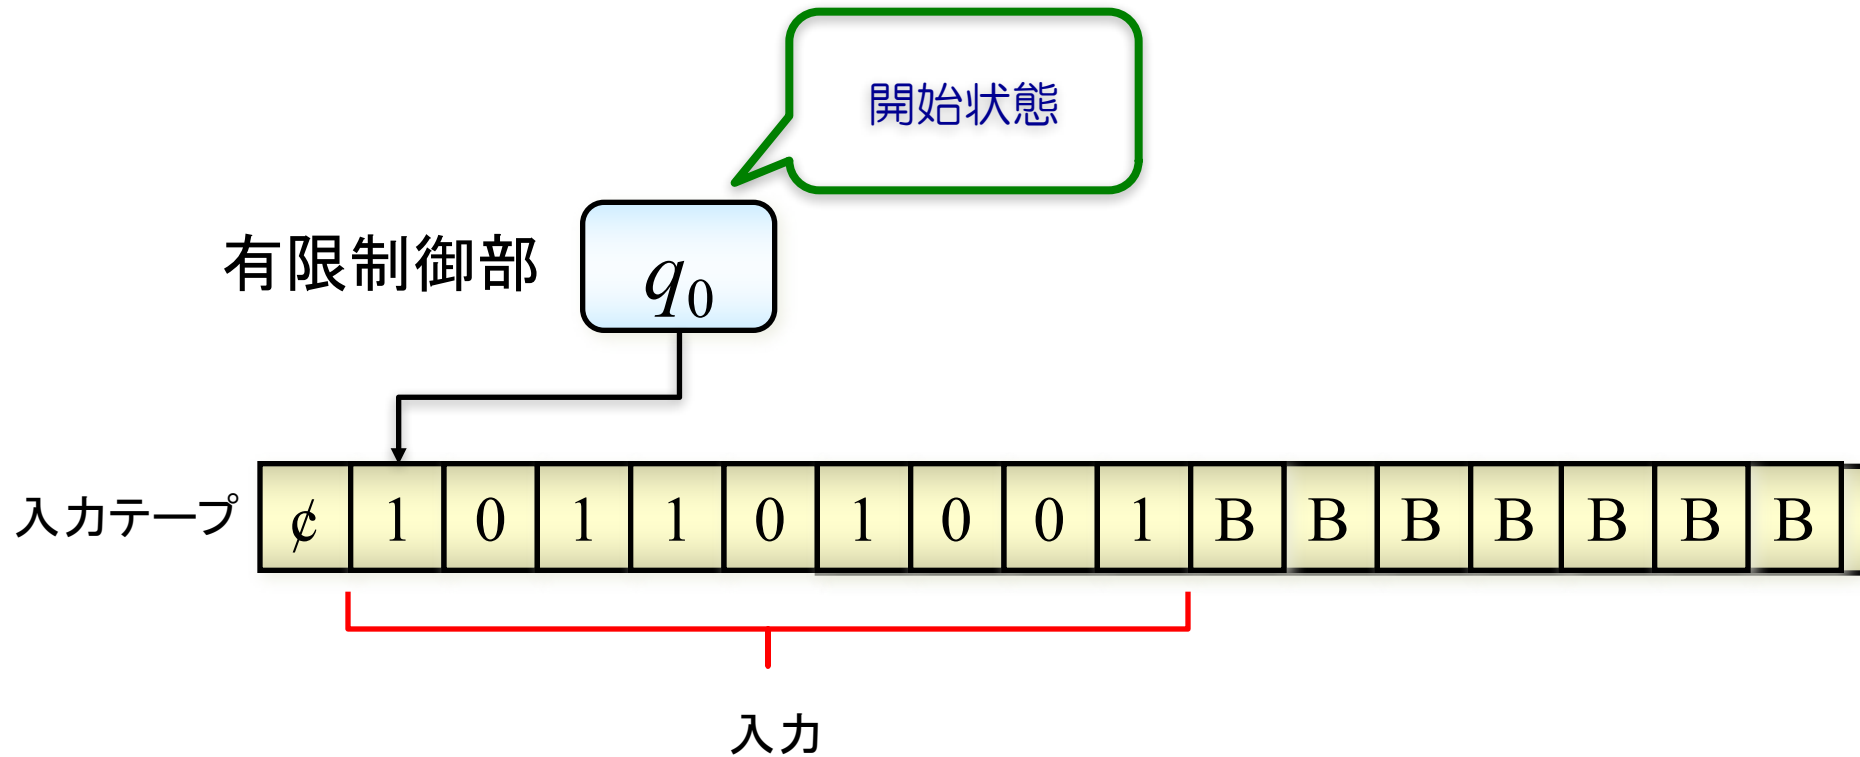
文脈依存言語

【定理7.2】 任意の言語 $L \subseteq \Sigma^*$ に対し, 次の①②は等価である.


- ① $L=L(G)$ となる文脈依存文法 G が存在する.
- ② $L=L(G)$ となる単調文法 G が存在する.

Turing機械

計算開始時のTuring機械




Turing機械の動作の1ステップ



$$\delta(p, 1) \ni (q, 0, R)$$

- 状態を q に変更
- ヘッド位置の記号を0に書き換え
- ヘッドを右へ移動



Turing機械の停止と入力文字列の受理

- 有限オートマトンやプッシュダウンオートマトンは、入力を読み切ったら停止するが、Turing機械のテープヘッドは左右に動くため「入力を読み切る」ということがない。
- Turing機械 M の状態を p , テープヘッド位置の記号を a とするとき, $\delta(p, a) = \emptyset$ ならば M は停止する。
 - 永遠に停止しないことも！
- Turing機械 M が停止したとき受理状態であれば, M は w を受理するという。

非決定性Turing機械の形式的定義

【定義】非決定性Turing機械は次のような6つ組 $M = (Q, \Sigma, \Gamma, \delta, q_0, F)$ である.

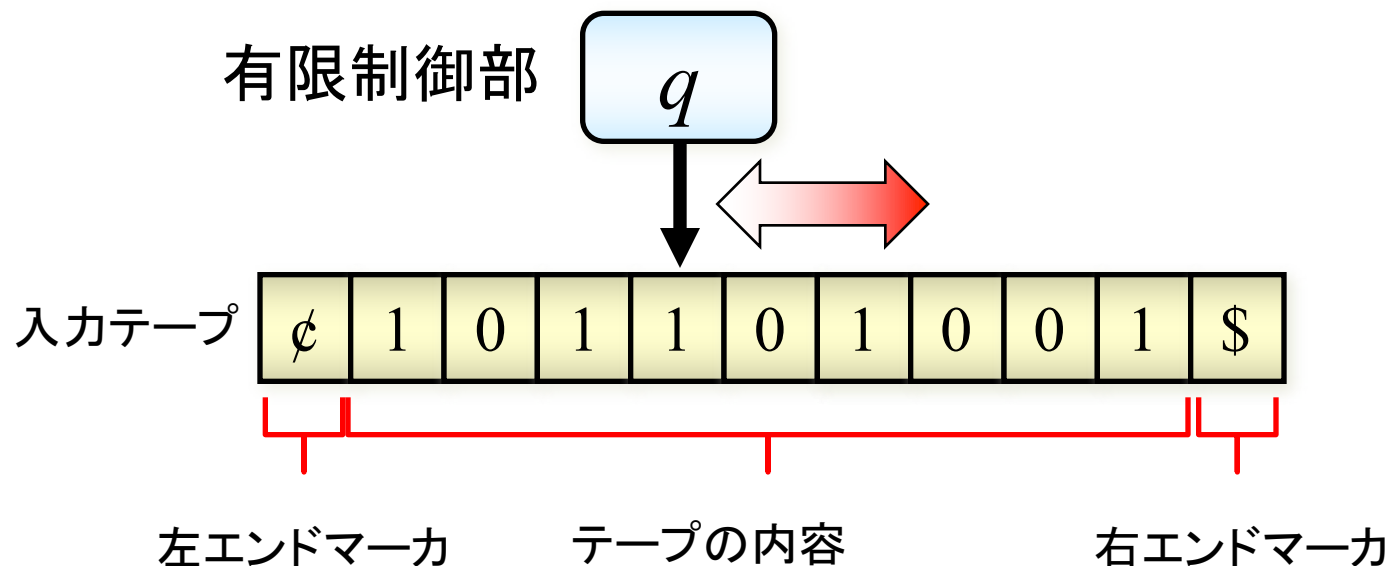
- Q は状態の空でない有限集合.
- Σ は記号の空でない有限集合で, $\Sigma \cap \{B, \epsilon\} = \emptyset$.
- Γ は記号の空でない有限集合で, $\Sigma \cup \{B, \epsilon\} \subseteq \Gamma$.
- $\delta: Q \times \Gamma \rightarrow \mathcal{P}(Q \times \Gamma \times \{L, R\})$ は次を満たす状態遷移関数:
任意の $p \in Q$ に対して,
 - ◆ $\delta(p, a) \subseteq Q \times (\Gamma - \{\epsilon\}) \times \{L, R\}$ ($a \in \Gamma - \{\epsilon\}$)
 - ◆ $\delta(p, \epsilon) \subseteq Q \times \{\epsilon\} \times \{R\}$
- $q_0 \in Q$ は開始状態.
- $F \subseteq Q$ は受理状態の集合.

$$\mathcal{P}(S) = 2^S = \{X \mid X \subseteq S\}$$

線形有界オートマトン

線形有界オートマトンとは？

- Turing機械との違い:
 - テープの左端と右端に, それぞれ, ϵ , $\$$ が置かれ, 入力はそれらに挟まれて与えられる.
 - テープヘッドは, テープの左端(右端)を越えて左へ(右へ)動くことはできない.



線形有界オートマトンの形式的定義

【定義】 線形有界オートマトンは次を満たす非決定性 Turing 機械 $M = (Q, \Sigma, \Gamma, \delta, q_0, F)$ である.

- $\Sigma \cap \{\epsilon, \$\} = \emptyset, \Sigma \cup \{\epsilon, \$\} \subseteq \Gamma.$
- $\delta: Q \times \Gamma \rightarrow Q \times \Gamma \times \{L, R\}$ は次を満たす状態遷移関数:
任意の $p \in Q$ に対して,
 - ◆ $\delta(p, a) \subseteq Q \times (\Gamma - \{\epsilon, \$\}) \times \{L, R\} \quad (a \in \Gamma - \{\epsilon, \$\})$
 - ◆ $\delta(p, \epsilon) \subseteq Q \times \{\epsilon\} \times \{R\}$
 - ◆ $\delta(p, \$) \subseteq Q \times \{\$\} \times \{L\}$

各言語族の閉性

閉性

- 和集合, 連接, Kleene閉包, 積集合, 補集合の各演算に関する閉性は, 次のようになる.

言語族	和集合	連接	Kleene閉包	積集合	補集合
句構造言語族	○	○	○	○	×
文脈依存言語族	○	○	○	○	○
文脈自由言語族	○	○	○	×	×
正規言語族	○	○	○	○	○