


5. 文脈自由文法と言語(2): (テキスト5.2)

5.2. 構文木

導出のプロセスは木構造
で表現されることが多い。

例) $P \Rightarrow (P) \Rightarrow (P+P)$
 $\Rightarrow (a+P) \Rightarrow (a+(P))$
 $\Rightarrow a+(P+P)$
 $\Rightarrow (a+(a+P))$
 $\Rightarrow (a+(a+a))$

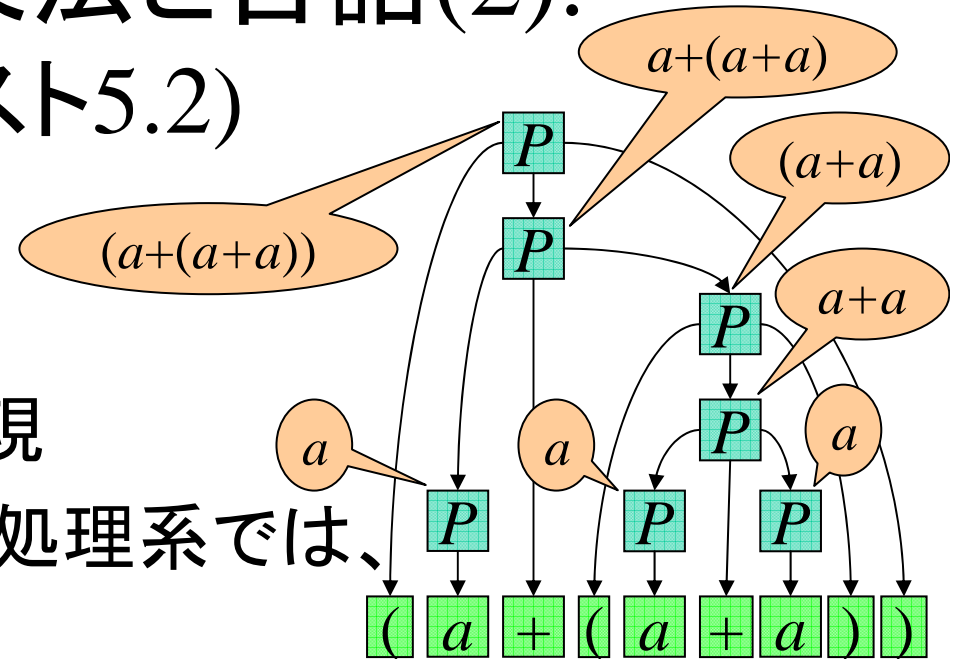
構文木



5. 文脈自由文法と言語(2): (テキスト5.2)

5.2. 構文木

- 「語」の導出過程を表現
- コンパイラなどの言語処理系では、
 - 式
 - 命令列



などの構造を表現する標準的なデータ構造

✓ 与えられた語に対する構文木の構成

は言語処理系では必須の機能

5. 文脈自由文法と言語(2): (テキスト5.2)

5.2. 構文木

- ▶ **曖昧な文法** = 語に対する構文木が
複数個存在する文法

⇒ プログラミング言語では許されない

⇒ 自然言語処理でも大きな問題

例) Time flies like an arrow.

「時は矢のように飛ぶ」のか？

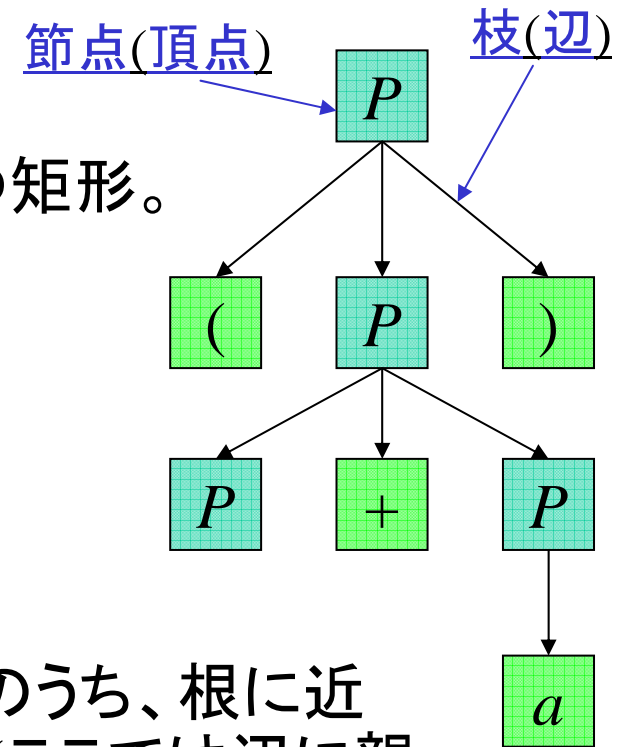
「時蠅は矢を好む」のか？



文脈自由文
法の曖昧さ

5.2.* 木

- 節点(頂点): 点。ここではラベルを持つ矩形。
- 枝(辺): 二つの点を結ぶ線。
- 木: 頂点が辺で結ばれたもので、閉路がないもの。
- 根: 木の特定の1頂点。
(習慣的に)一番上に描く。
- 親子関係: 辺で結ばれた二つの頂点のうち、根に近いほうを親、そうでない方を子という。(ここでは辺に親から子へ方向をつける)
- 葉: 1つの辺にしかつながない頂点
- 先祖/子孫:
 - 1. 頂点 v は頂点 v の先祖かつ子孫
 - 2. 頂点 v の子孫の子供は v の子孫
 - 3. 頂点 v の先祖の親は v の先祖
- 子供は左の子と右の子は区別される。(順序つき木)



5.2.1. 構文木の構成



文法 $G=(V,T,P,S)$ に対して、 G の構文木とは、以下の条件を満たす木:

1. 葉でない頂点には V (非終端記号)がラベル
2. 葉のラベルは次のどれか一つ
 1. T の要素(導出が終わっている頂点)
 2. V の要素(まだ導出途中の頂点)
 3. ε (その葉が親の唯一の子供のとき)
3. 葉でない頂点のラベルが A で、子のラベルが左から

$$X_1, X_2, \dots, X_k$$

なら、 G は以下の生成規則を持つ

$$A \rightarrow X_1 X_2 \dots X_k$$



5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.1. 構文木の構成

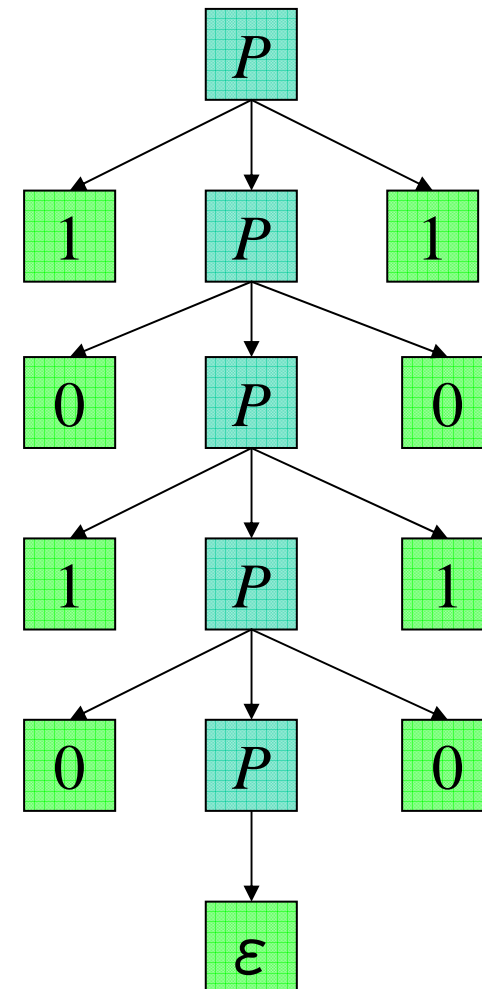
例)

$$G_p = \{\{P\}, \{0,1\}, A, P\}$$
$$A: P \rightarrow \varepsilon \mid 0 \mid 1 \mid 0P0 \mid 1P1$$

10100101の導出

$$P \Rightarrow 1P1 \Rightarrow 10P01 \Rightarrow 101P101$$
$$\Rightarrow 1010P0101 \Rightarrow 10100101$$

10100101の構文木



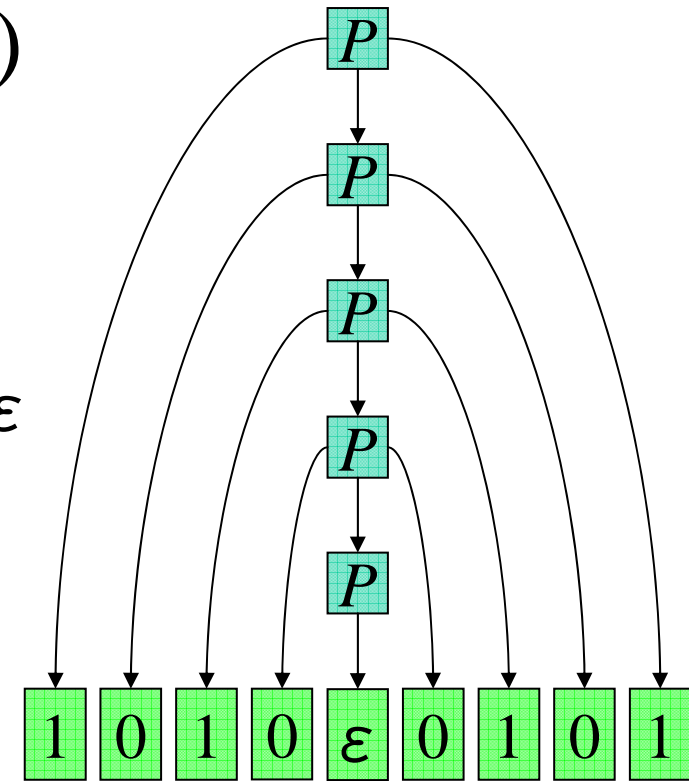
5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.2. 構文木の成果

構文木が

1. 根のラベルが出発記号
2. 葉のラベルがすべて終端記号か ε のとき、葉のラベルを左から並べた文字列を構文木の**成果**と言う。

(c.f. $a\varepsilon = \varepsilon a = a$)



[観測] 文法 G によって**導出される語**の集合
= 文法 G の構文木の**成果である語**の集合

↓
10100101

5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.3. 推論・導出・構文木

- 再帰的推論

文字列(語=終端記号列)から出発記号(非終端記号)

- 導出(最左導出と最右導出)

出発記号(非終端記号)から文字列(語)

- 構文木

5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.3. 推論・導出・構文木

文法 $G=(V,T,P,S)$ について以下はすべて同値:

1. 終端記号列 w から変数 S が再帰的に推論
できる


2. $S \xRightarrow{*} w$

3. $S \xRightarrow[*]{左} w$

4. $S \xRightarrow[*]{右} w$

- $3 \rightarrow 2, 4 \rightarrow 2$ は自明
- $5 \rightarrow 3, 5 \rightarrow 4$ は対称

$1 \rightarrow 5, 5 \rightarrow 3, 2 \rightarrow 1$ を示す。



5. S を根とし、 w を成果とする構文木が存在。


5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.4. 再帰的推論から構文木へ(1→5)

[定理] CFG $G=(V,T,P,S)$ に対し、再帰的推論で語 w が変数 S の言語に属しているなら、 S を根として、 w を成果とする構文木が存在する。

[証明] w が S の言語に属していることを示す導出のステップ数に関する帰納法。

[基礎] w が S から1ステップで導出できる場合生成規則 $S \rightarrow w$ が P に入っている。
したがって構文木が存在。



5.2.4. 再帰的推論から構文木へ(1→5)

[定理] CFG $G=(V,T,P,S)$ に対し、再帰的推論で語 w が変数 S の言語に属しているなら、 S を根として、 w を成果とする構文木が存在する。

[証明] w が S の言語に属していることを示す導出のステップ数に関する帰納法。

[帰納] w が S から $n+1$ ステップ($n > 1$)で導出できる場合

[帰納法の仮定] G において語 x が変数 B の言語に属していて、かつ x が B から n ステップ以下で導出できるなら、 B を根として、 x を成果とする構文木が存在。

5.2.4. 再帰的推論から構文木へ(1→5)

[証明] w が S の言語に属していることを示す導出のステップ数に関する帰納法。

[帰納] w が S から $n+1$ ステップ($n > 1$)で導出できる場合

[帰納法の仮定] G において語 x が変数 B の言語に属していて、かつ x が B から n ステップ以下で導出できるなら、 B を根として、 x を成果とする構文木が存在。

w は S から $n+1$ ステップで導出できるので、 P は生成規則

$$S \rightarrow X_1 X_2 \dots X_k$$

をもち、かつ

$$X_i \xRightarrow{*} w_i$$

X_i から w_i の導出は高々 n ステップ
($X_i = w_i$ もありえる)

$$w = w_1 w_2 \dots w_k$$

を満たす文字列 w_1, w_2, \dots, w_k が存在する。

5.2.4. 再帰的推論から構文木へ(1→5)

[帰納] w が S から $n+1$ ステップ($n > 1$)で導出できる場合

[帰納法の仮定] G において語 x が変数 B の言語に属して、かつ x が B から n ステップ以下で導出できるなら、 B を根として、 x を成果とする構文木が存在。


w は S から $n+1$ ステップで導出できるので、 P は規則

$S \rightarrow X_1 X_2 \dots X_k$ をもち、かつ

$X_i \xRightarrow{*} w_i$ (n ステップ以下で導出できる)

$$w = w_1 w_2 \dots w_k$$

を満たす文字列 w_1, w_2, \dots, w_k が存在する。



G において語 w_i は変数 X_i の言語に属し、かつ n ステップ以下で導出できるので、帰納法の仮定より、 X_i を根として w_i を成果とする構文木が存在する。

5.2.4. 再帰的推論から構文木へ(1→5)

[帰納] w が S から $n+1$ ステップ ($n > 1$) で導出できる場合

w は S から $n+1$ ステップで導出できるので、 P は生成規則

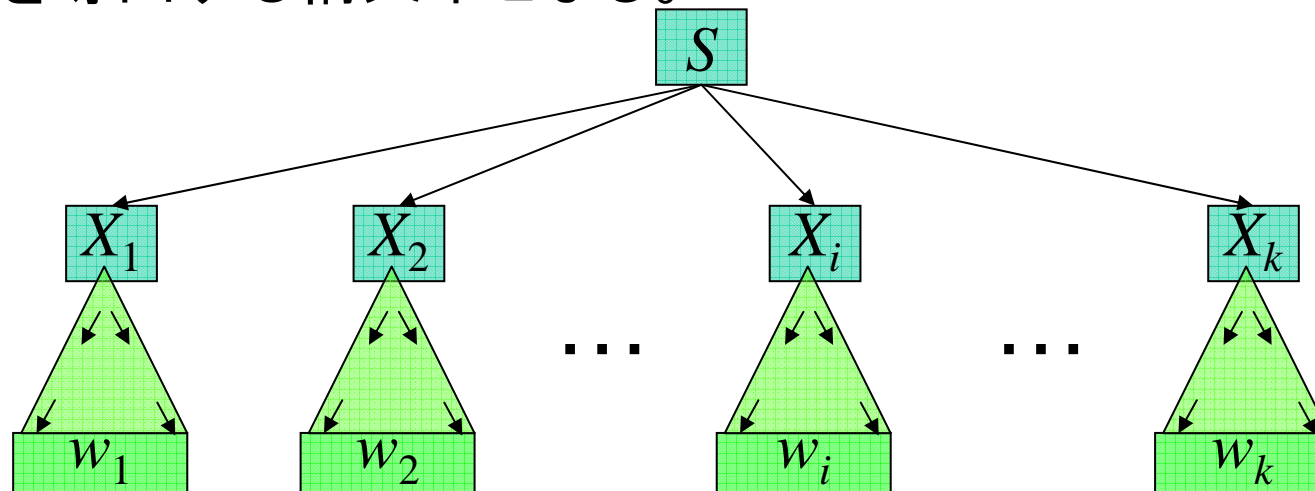
$$S \rightarrow X_1 X_2 \dots X_k$$

をもち、かつ

$$X_i \Rightarrow^* w_i, w = w_1 w_2 \dots w_k$$

を満たす文字列 w_1, w_2, \dots, w_k が存在する。

帰納法の仮定より、 X_i を根として w_i を成果とする構文木が存在する。これらの構文木から以下の構文木を構成すると、 S から w を導出する構文木となる。



5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.5. 構文木から最左導出へ(5→3)

直感的には...


構文木を左優先で
探索する
ことに対応する。

例) $P \Rightarrow (P) \Rightarrow (P+P)$
 $\Rightarrow (a+P) \Rightarrow (a+(P))$
 $\Rightarrow a+(P+P)$
 $\Rightarrow (a+(a+P))$
 $\Rightarrow (a+(a+a))$

終端記号(葉)
はそこで終わり

非終端記号
は左優先で

根から
スタート



5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.5. 構文木から最左導出へ(5→3)

[定理] CFG $G=(V,T,P,S)$ に対し、変数 S を根とし、 w を成果とする構文木があれば、 G の最左導出 $S \xrightarrow[\text{左}]{*} w$ が存在する。

[略証] 木の高さ i についての帰納法で証明する。

(木の高さ = 各葉から根までの辺の個数の最大値)

木の高さが0のときは根しかないので、これは構文木ではない。したがって意味のある木の高さの最小値は1。

[基礎] $i=1$ のとき: $S \rightarrow w$ が規則に入っている。

これは最左導出。

5.2.5. 構文木から最左導出へ(5→3)

[定理] CFG $G=(V,T,P,S)$ に対し、変数 S を根とし、 w を成果とする構文木があれば、 G の最左導出 $S \xRightarrow{*}_{\text{左}} w$ が存在する。

[略証] 木の高さ i についての帰納法で証明する。

[帰納] $i \geq 2$ 以上のとき:

- 根のラベルを S とし、 S の子供のラベルを左から X_1, X_2, \dots, X_k とする。
- 帰納法の仮定から、各 X_i の成果 w_i に対して、最左導出 $X_i \xRightarrow{*}_{\text{左}} w_i$ が存在する。
- $w = w_1 w_2 \dots w_k$ である。

導出 $S \xRightarrow{*}_{\text{左}} X_1 X_2 \dots X_k$ から、


最左導出

$$S \xRightarrow{*}_{\text{左}} w_1 w_2 \dots w_k$$

が構成できることを示す。具体的には $j=1, 2, \dots, k$ について、

$$S \xRightarrow{*}_{\text{左}} w_1 w_2 \dots w_j X_{j+1} \dots X_k$$

であることを j に関する帰納法で示す。(以下省略)



5. 文脈自由文法と言語(2): (テキスト5.2)

5.2.6. 導出から再帰的推論へ(2→1)

[定理] CFG $G=(V,T,P,S)$ に対して、導出 $S \xRightarrow{*} w$ があれば、 w が S の言語に属することが再帰的推論によって確かめられる。

[略証] 導出 $S \xRightarrow{*} w$ の長さに関する帰納法による。

[基礎] 長さが 1 のとき: $S \rightarrow w$ が生成規則に入っている。

したがって1ステップの再帰的推論により確認できる。

[帰納] 導出 $S \xRightarrow{*} w$ の長さが $n+1$ とし、長さ n 以下のすべての導出が再帰的推論によって確かめられるとする。

導出は生成規則 $S \rightarrow X_1 X_2 \dots X_k$ により

$$S \Rightarrow X_1 X_2 \dots X_k \xRightarrow{*} w$$

という形で表現できる。

5.2.6. 導出から再帰的推論へ(2→1)

[定理] CFG $G=(V,T,P,S)$ に対して、導出 $S \xRightarrow{*} w$ があれば、 w が S の言語に属することが再帰的推論によって確かめられる。

[略証] 導出 $S \xRightarrow{*} w$ の長さに関する帰納法による。

[帰納] 導出 $S \xRightarrow{*} w$ の長さが $n+1$ とし、長さ n 以下のすべての導出が再帰的推論によって確かめられるとする。

導出は生成規則 $S \rightarrow X_1 X_2 \dots X_k$ により

$$S \Rightarrow X_1 X_2 \dots X_k \xRightarrow{*} w$$

という形で表現できる。さらに

$$\gg X_i \xRightarrow{*} w_i \quad (1 \leq i \leq k)$$

$$\gg w = w_1 w_2 \dots w_k$$

であり、帰納法の仮定から、すべての導出 $X_i \xRightarrow{*} w_i$ は再帰的推論によって確かめられる。したがって $S \rightarrow X_1 X_2 \dots X_k$ とこれらの推論から、 w が S の言語に属することが推論によって確かめられる。