

アルゴリズムとデータ構造III

2回目: 10月15日

文脈自由文法, CYK法

授業資料 <http://ir.cs.yamanashi.ac.jp/~ysuzuki/algorithm3/index.html>

授業の予定(中間試験まで)

1	10/01	スタック（後置記法で書かれた式の計算）
2	10/15	文脈自由文法, 構文解析, CYK法
3	10/22	構文解析 CYK法
4	10/29	構文解析 CYK法
5	11/12	構文解析(チャート法), グラフ(ダイクストラ法)
6	11/	構文解析(チャート法), グラフ(ダイクストラ法, DPマッチング)
7	11/	グラフ(DPマッチング, A*アルゴリズム)
8	11/19	グラフ(A * アルゴリズム), 前半のまとめ
9	11/26	中間試験

10/08, 11/05の代わりの補講日は後日相談

授業の予定(中間試験以降)

10	12/03	全文検索アルゴリズム(simple search, KMP)
11	12/10	全文検索アルゴリズム(BM, Aho-Corasick)
12	12/17	全文検索アルゴリズム(Aho-Corasick), データ圧縮
13	01/07	暗号(黄金虫, 踊る人形) 符号化(モールス信号, Zipfの法則, ハフマン符号)テキスト圧縮
14	01/14	テキスト圧縮(zip), 音声圧縮(ADPCM, MP3, CELP), 画像圧縮(JPEG)
15	01/21	期末試験

7 2 3 + - を計算してみよう (アセンブリ言語でプログラミング)

数式(7 2 3 + -)をメモリ(データ領域)に書き込まれている

1. データ領域から1文字読み込む

1. 数字(アスキーコード: 30H~39H)なら

1. 数値に変換し、数値をスタックにプッシュ

2. 演算子なら

1. 一旦スタックにプッシュし、ポップする。

2. スタックからポップし、数値をAレジスタに取り込む

3. スタックからポップし、数値をBレジスタ(キュムレータ)に取り込む

4. 演算子が+なら

1. A + B を計算し、Aレジスタに計算結果を格納

5. 演算子が-なら

1. A - B を計算し、Aレジスタに計算結果を格納

6. Aレジスタの内容をスタックにプッシュ

2. データ領域すべてを読み終えるまで続ける。

簡単な計算の例 7 2 3 + -

; 後置記法 7 2 3 + - の計算

ORG 8000H ;

LD HL, DATA ; 数式の先頭番地を指定

LOOP:

LD A, (HL)

CP 00H

JP Z, OWARI ; 数式を全部読み込んだら終わ

り

LD E, (HL)

LD D, 0H

LD A, (HL)

INC HL

CP 2BH

JP Z, LOOPA ; +なら加算処理へ

CP 2DH

JP Z, LOOPS ; -なら減算処理へ

LD A, E

SUB 30H ; 数字なら数値に変換

; Aレジスタの内容をスタックヘプッシュ

STPUSH: LD E, A

LD D, 0H

PUSH DE ; 読み込んだ数値をスタックヘプッ

シユ

JP LOOP ; つぎの文字読み込みへ

; 加算

LOOPA:

PUSH DE ; 演算子をスタックヘプッシュ

POP DE ; 演算子をスタックからポップ

POP DE ; 数値をスタックからポップ

LD B, E ; スタックトップの値をBレジスタへ

POP DE ; 数値をスタックからポップ

LD A, E ; スタックトップの値をAレジスタへ

ADD A, B ; 加算(A <= A + B)

JP STPUSH

; 減算

LOOPS:

PUSH DE ; 演算子をスタックヘプッシュ

POP DE ; 演算子をスタックからポップ

POP DE ; 数値をスタックからポップ

LD B, E ; スタックトップの値をBレジスタへ

POP DE ; 数値をスタックからポップ

LD A, E ; スタックトップの値をAレジスタへ

SUB B ; 減算(A <= A - B)

JP STPUSH

;

OWARI: HALT

; 入力データ

DATA:

DEFB 37H ;7

DEFB 32H ;2

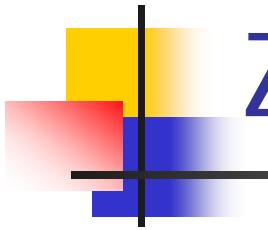
DEFB 33H ;3

DEFB 2BH ;+

DEFB 2DH ;-

DEFB 00H ;END

END



Z80 シミュレータ

- Z80シミュレータ for Win32

- <http://www.game3rd.com/soft/z80edit/index.htm>

(スタックを含めた)メモリの様子

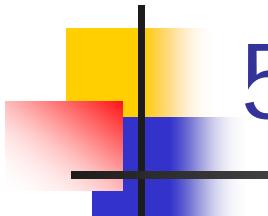


4.5.3 オートマトンと計算理論

オートマトンの受理する言語クラス

オートマトン	受理言語型	言語クラス
チューリング機械	第0型言語	句構造言語(PSL)
線形拘束チューリング機械	第1型言語	文脈依存言語(CSL)
プッシュダウンオートマトン	第2型言語	文脈自由言語(CFL)
有限オートマトン	第3型言語	正規言語(RL)

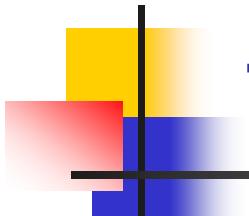
$RL \subset CFL \subset CSL \subset PSL$ (チョムスキイの言語階層)
(\subset は包含関係を表す)



「形式言語と有限オートマトン入門」

5 形式言語理論入門

- 5.1 形式言語理論
- **5.2 文脈自由文法**
- 5.3 線形文法と正規言語
- 5.4 形式言語のクラス階層とオートマトン
- 5.5 言語処理への応用

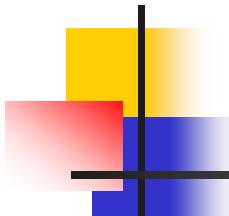


形式文法Gの定義

- $G = (N, T, P, S)$
 - N: 非終端記号の集合
 - T: 終端記号の集合
 - P: プロダクション
 - S: 開始記号

5.2 文脈自由文法

- 文脈自由文法(CFG: Context Free Grammar)
 - 文脈自由プロダクションのみから構成される
 - 文脈自由プロダクション
 - $\alpha \rightarrow \beta$
 - ただし, $\alpha \in N$, $\beta \in V^*$
 - N : 非終端記号の集合, T : 終端記号の集合, V : N と T の直和
 - 左辺が変数1つ
- 文脈依存文法(CSG: Context Sensitive Grammar)
 - 文脈依存プロダクションを含むプロダクションから構成される
 - 文脈依存プロダクション
 - $u\alpha v \rightarrow u\beta v$ ただし, $\alpha \in N$, $u, v \in V^*$, $\beta \in V^+$
 - N : 非終端記号の集合, T : 終端記号の集合, V : N と T の直和
 - $u=v=\varepsilon$ のとき($\alpha \rightarrow \beta$)文脈自由プロダクションとなる



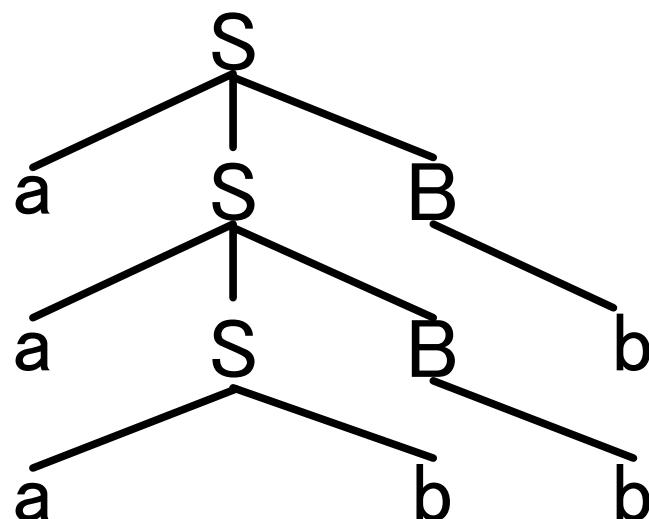
文脈自由文法の例(例題5.9)

- CFG $G = (N, T, P, S)$
 - N (非終端記号) = {B, S}
 - T (終端記号) = {a, b}
 - P :
 - $S \rightarrow aSB \mid ab$
 - $B \rightarrow b$
 - S : S
- 語 aaabbb の導出過程
- $L(G)$ はどのような言語か

例題5.9の解答例

- CFG $G = (N, T, P, S)$
 - $N = \{B, S\}$
 - $T = \{a, b\}$
 - $P: S \rightarrow aSB \mid ab, B \rightarrow b$
 - $S: S$

- $S \Rightarrow aSB \Rightarrow aaSB \Rightarrow aaabBB \Rightarrow aaabbbB \Rightarrow aaabb$
- $L(G): a^n b^n$
- 正規表現では表せない
- プッシュダウンオートマトンでは表現可能
- 構文木



練習問題1

例題5.10 文脈依存文法の例

- CSG $G = (N, T, P, S)$
- $N = \{A, B, S\}$
- $T = \{a, b\}$
- $P: S \rightarrow aSBA \mid abA, AB \rightarrow BA, bB \rightarrow bb, bA \rightarrow ba, aA \rightarrow aa$
- $S: S$

- 語 $aabbaa$ の導出過程
- $L(G)$ はどのような言語か

練習問題1 解答

例題5.10 aabbaa

- CSG $G = (N, T, P, S)$
- $N = \{A, B, S\}$
- $T = \{a, b\}$
- $P: S \rightarrow aSBA \mid abA, AB \rightarrow BA, bB \rightarrow bb, bA \rightarrow ba, aA \rightarrow aa$
- $S: S$

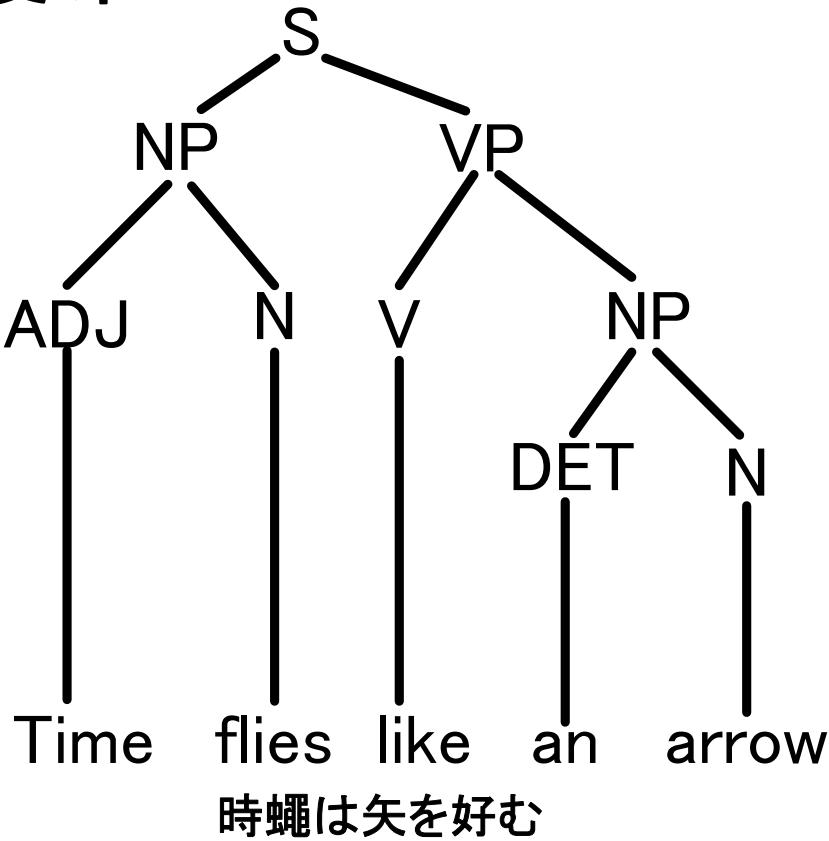
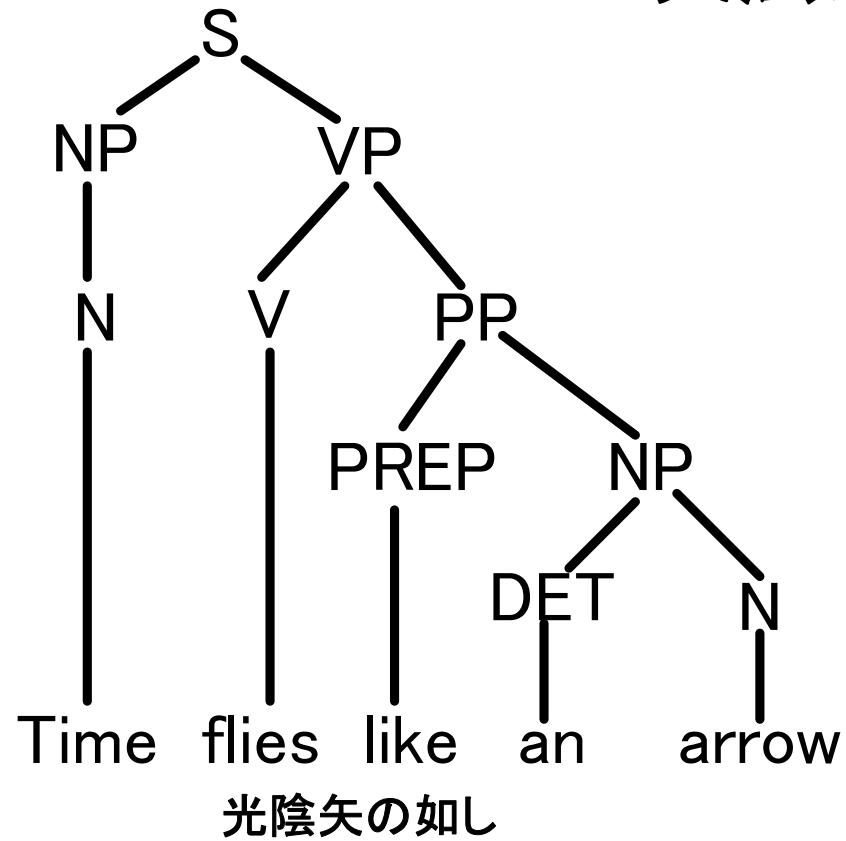
- 語 aabbaa の導出過程
- $S \Rightarrow aSBA \Rightarrow aab\textcolor{blue}{A}BA \Rightarrow aab\textcolor{blue}{B}AA \Rightarrow aab\textcolor{blue}{b}AA$
- $\Rightarrow aab\textcolor{blue}{b}A \Rightarrow aabb\textcolor{blue}{aa}$
- $L(G)$ はどのような言語か
- $L(G): a^n b^n a^n$

構文木(導出木)

- Time flies like an arrow.

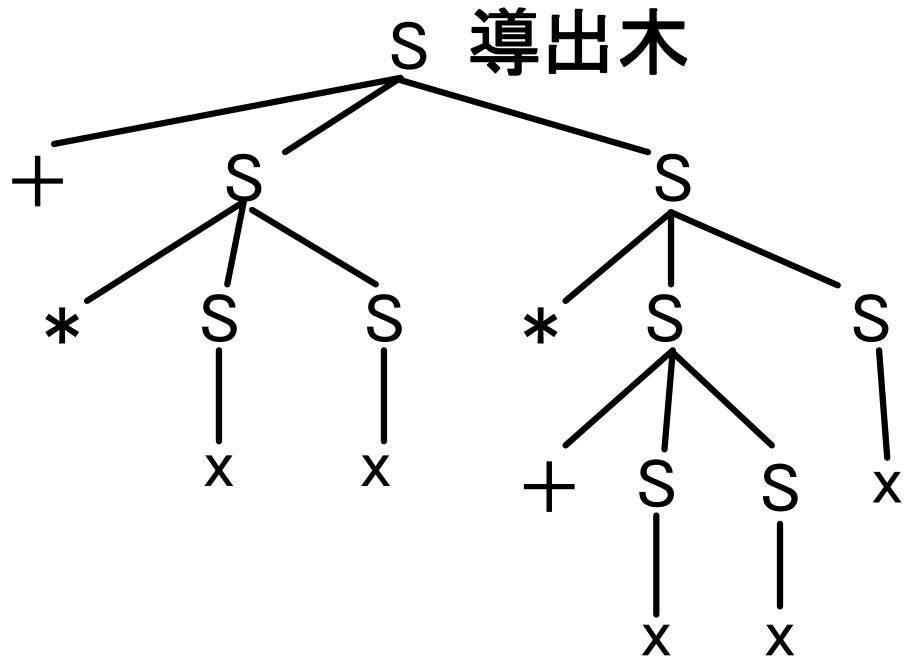
2種類の導出木
→ 文法が曖昧

S → NP VP
NP → N | DET N | ADJ N
VP → V PP | V NP
PP → PREP NP
N → Time | arrow | flies
V → flies | like
PREP → like
DET → an
ADJ → Time



例題5.11

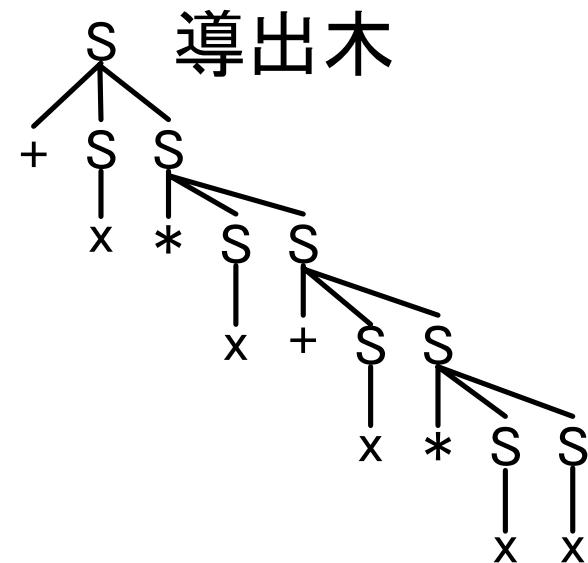
- 問題:
- 文法 $N = \{S\}, T = \{x, +, *\}, P = \{S \rightarrow +SS | *SS | x\}, S = S$
- 語 $w = +^*xx^* + xxx$ を導出せよ
- 語 w の導出木



- 解答例
- 導出:
 $S \Rightarrow +SS \Rightarrow +^*SSS \Rightarrow +^*xSS \Rightarrow +^*xxS \Rightarrow +^*xx^*SS \Rightarrow +^*xx$
 $* + SSS \Rightarrow +^*xx^* + xxx$

例題5.12 ①

- 問題
- 文法 $N = \{S\}, T = \{x, +, *\}, P = \{S \rightarrow +SS | *SS | x\}$
- 中置記法 $x + x^* (x + x^* x)$



- 解答例
- 前置記法 $+x^*x + x^*xx$
- $S \Rightarrow +SS \Rightarrow +xS \Rightarrow +x^*SS \Rightarrow +x^*xS \Rightarrow +x^*x + SS$
 $\Rightarrow +x^*x + xS \Rightarrow +x^*x + x^*SS \Rightarrow +x^*x + x^*xS \Rightarrow +x^*x + x^*xx$

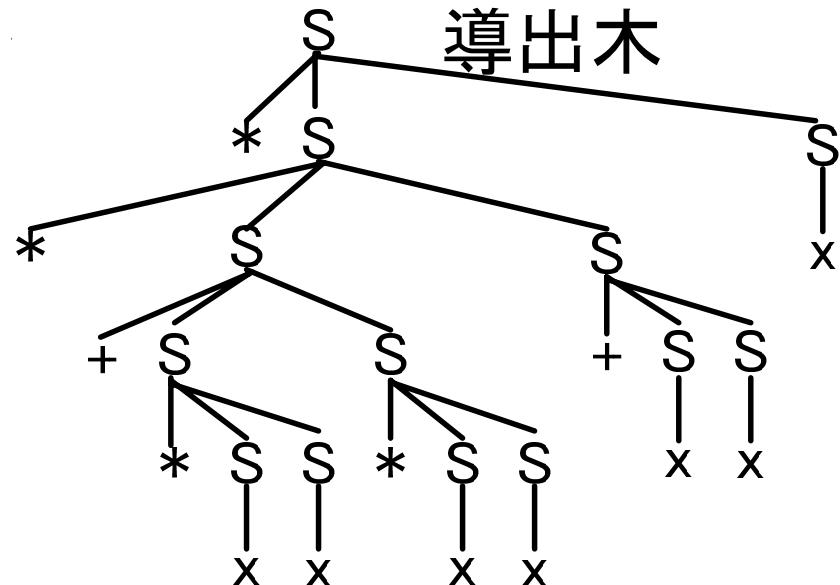
練習問題2 例題5.12 ②

- 問題
- 文法 $N = \{S\}, T = \{x, +, *\}, P = \{S \rightarrow +SS | *SS | x\}$
- 中置記法 $(x^*x + x^*x)^*(x+x)^*x$

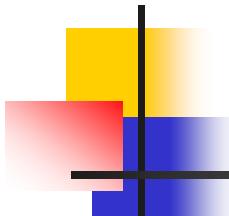
- 前置記法
- 最左導出
- 構文木

練習問題2 例題5.12 ②の解答例

- 問題
- 文法 $N = \{S\}, T = \{x, +, *\}, P = \{S \rightarrow +SS | *SS | x\}$
- 中置記法 $(x^*x+x^*x)^*(x+x)^*$



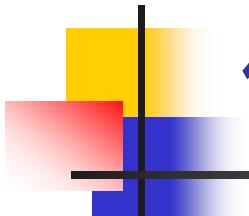
- 解答例
- 前置記法 $**+^*xx^*xx+xxx$
- $S \Rightarrow *SS \Rightarrow **SSS \Rightarrow **+SSSS \Rightarrow **+^*SSSSS$
 $\Rightarrow **+^*xSSSS \Rightarrow **+^*xxSSS \Rightarrow **+^*xx^*SSSS$
 $\Rightarrow **+^*xx^*xSSS \Rightarrow **+^*xx^*xxSS \Rightarrow **+^*xx^*xx+SSS$
- $\Rightarrow **+^*xx^*xx+xxx$



文脈自由文法の曖昧性

- どのような導出を行っても同じ導出木が得られる
- ⇒文法Gは曖昧でない

- 複数の異なった導出木が構成できるような語を含む
- ⇒文法Gは曖昧である



例題5.26

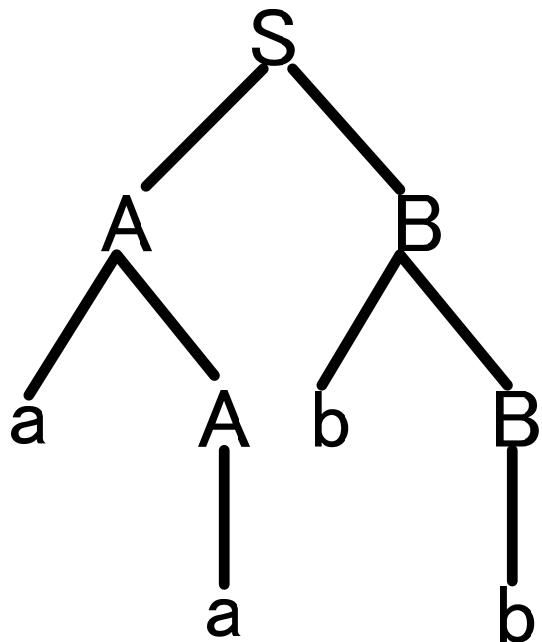
- 文法 $G=(N, T, P, S)$ において,
 $N=\{S, A, B\}$, $T=\{a, b\}$,
- $P: S \rightarrow AB | aAB, \quad A \rightarrow aA | a, \quad B \rightarrow bB | b$
- この文法が曖昧であることを示せ

例題5.26 解答例

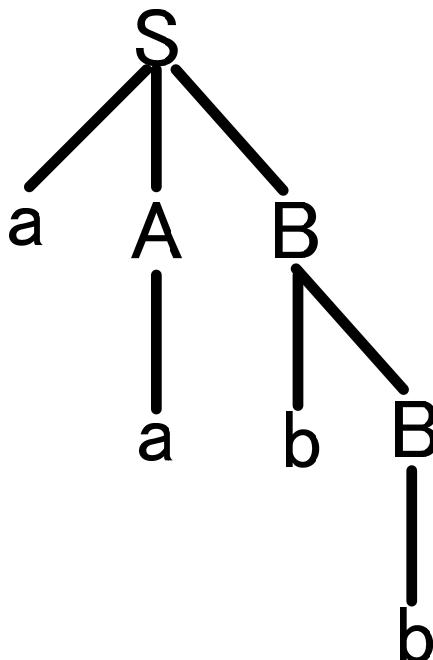
同一文字列に対して2種類の導出木が構成可能→曖昧である

- 1. $S \rightarrow AB \rightarrow aAB \rightarrow aA bB \rightarrow aabB \rightarrow aabb$
- 2. $S \rightarrow aAB \rightarrow aaB \rightarrow aabB \rightarrow aab b$

1.



2.



$$\begin{array}{ll} P: & S \rightarrow AB \mid aAB \\ & A \rightarrow aA \mid a \\ & B \rightarrow bB \mid b \end{array}$$

練習問題3

例題5.27

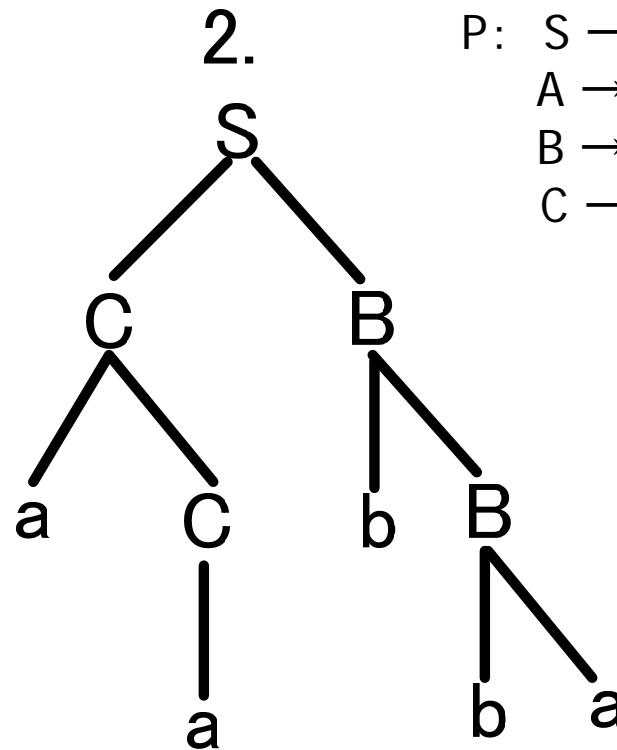
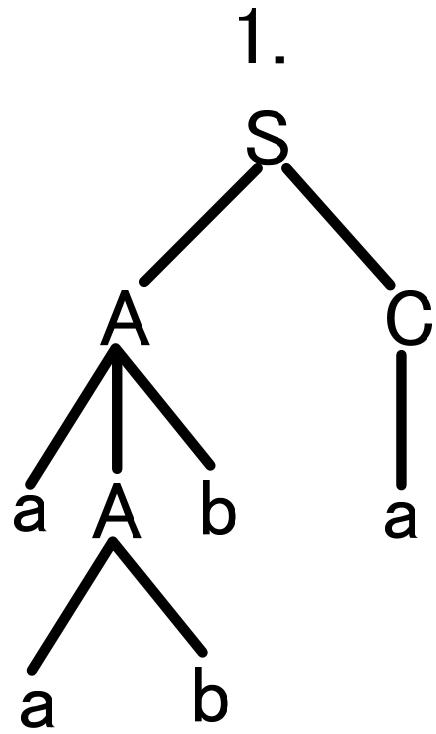
- 文法 $G=(N,T,P,S)$ において,
- $N=\{S,A,B,C\}$, $T=\{a,b\}$,
- $P:$ $S \rightarrow AC|CB$, $A \rightarrow aA|a$, $A \rightarrow aAb|ab$, $B \rightarrow bB|ba$
- $C \rightarrow aC|a$

- この文法が曖昧であることを, $aabba$ の導出木を構成して示せ

練習問題3 例題5.27 解答例

同一文字列に対して2種類の導出木が構成可能 → 疑問である

- 1. $S \rightarrow AC \rightarrow aAbC \rightarrow aAb a \rightarrow aabba$
- 2. $S \rightarrow CB \rightarrow aCB \rightarrow aCbB \rightarrow aabB \rightarrow aabba$



P: $S \rightarrow AC \mid CB$
 $A \rightarrow aA \mid a, A \rightarrow aAb \mid ab$
 $B \rightarrow bB \mid ba$
 $C \rightarrow aC \mid a$

CFGの構文図式

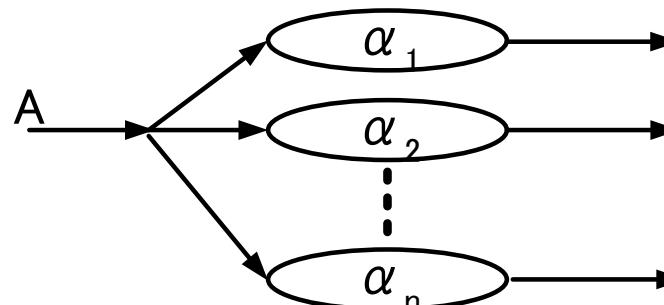
文脈自由プロダクション

$$A \rightarrow \alpha$$

構文図式



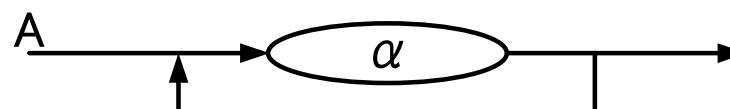
$$A \rightarrow \alpha_1 | \alpha_2 | \cdots | \alpha_n$$



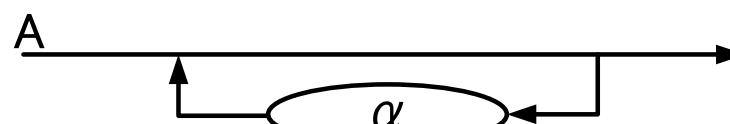
$$A \rightarrow \alpha_1 \alpha_2 \cdots \alpha_n$$



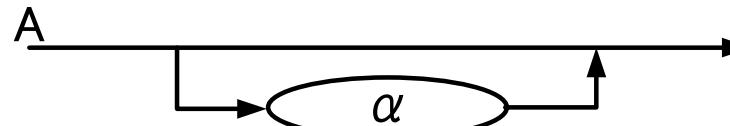
$$A \rightarrow \alpha | \alpha A |$$

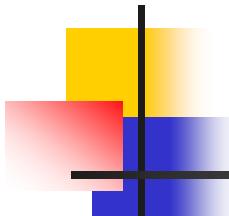


$$A \rightarrow \varepsilon | \alpha | \alpha A |$$



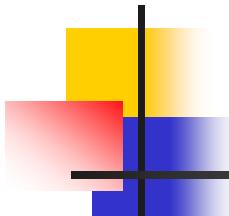
$$A \rightarrow \varepsilon | \alpha$$





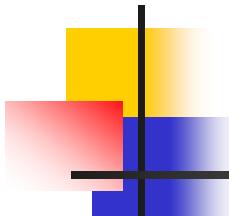
構文解析 CYK法

- 文脈自由文法で生成された文から自動的に構文木を生成する。



構文解析とは(Wikipediaより)

- ある文章の文法的な関係を説明すること(*parse*)。計算機科学の世界では、構文解析は字句解析(*Lexical Analysis*)とともに、おもにプログラミング言語などの形式言語の解析に使用される。また、自然言語処理に応用されることもある。
- コンパイラにおいて構文解析を行う機構を構文解析器(Parser)と呼ぶ。
- 構文解析は入力テキストを通常、木構造のデータ構造に変換し、その後の処理に適した形にする。字句解析によって入力文字列から字句を取り出し、それらを構文解析器の入力として、構文木や抽象構文木のようなデータ構造を生成する。

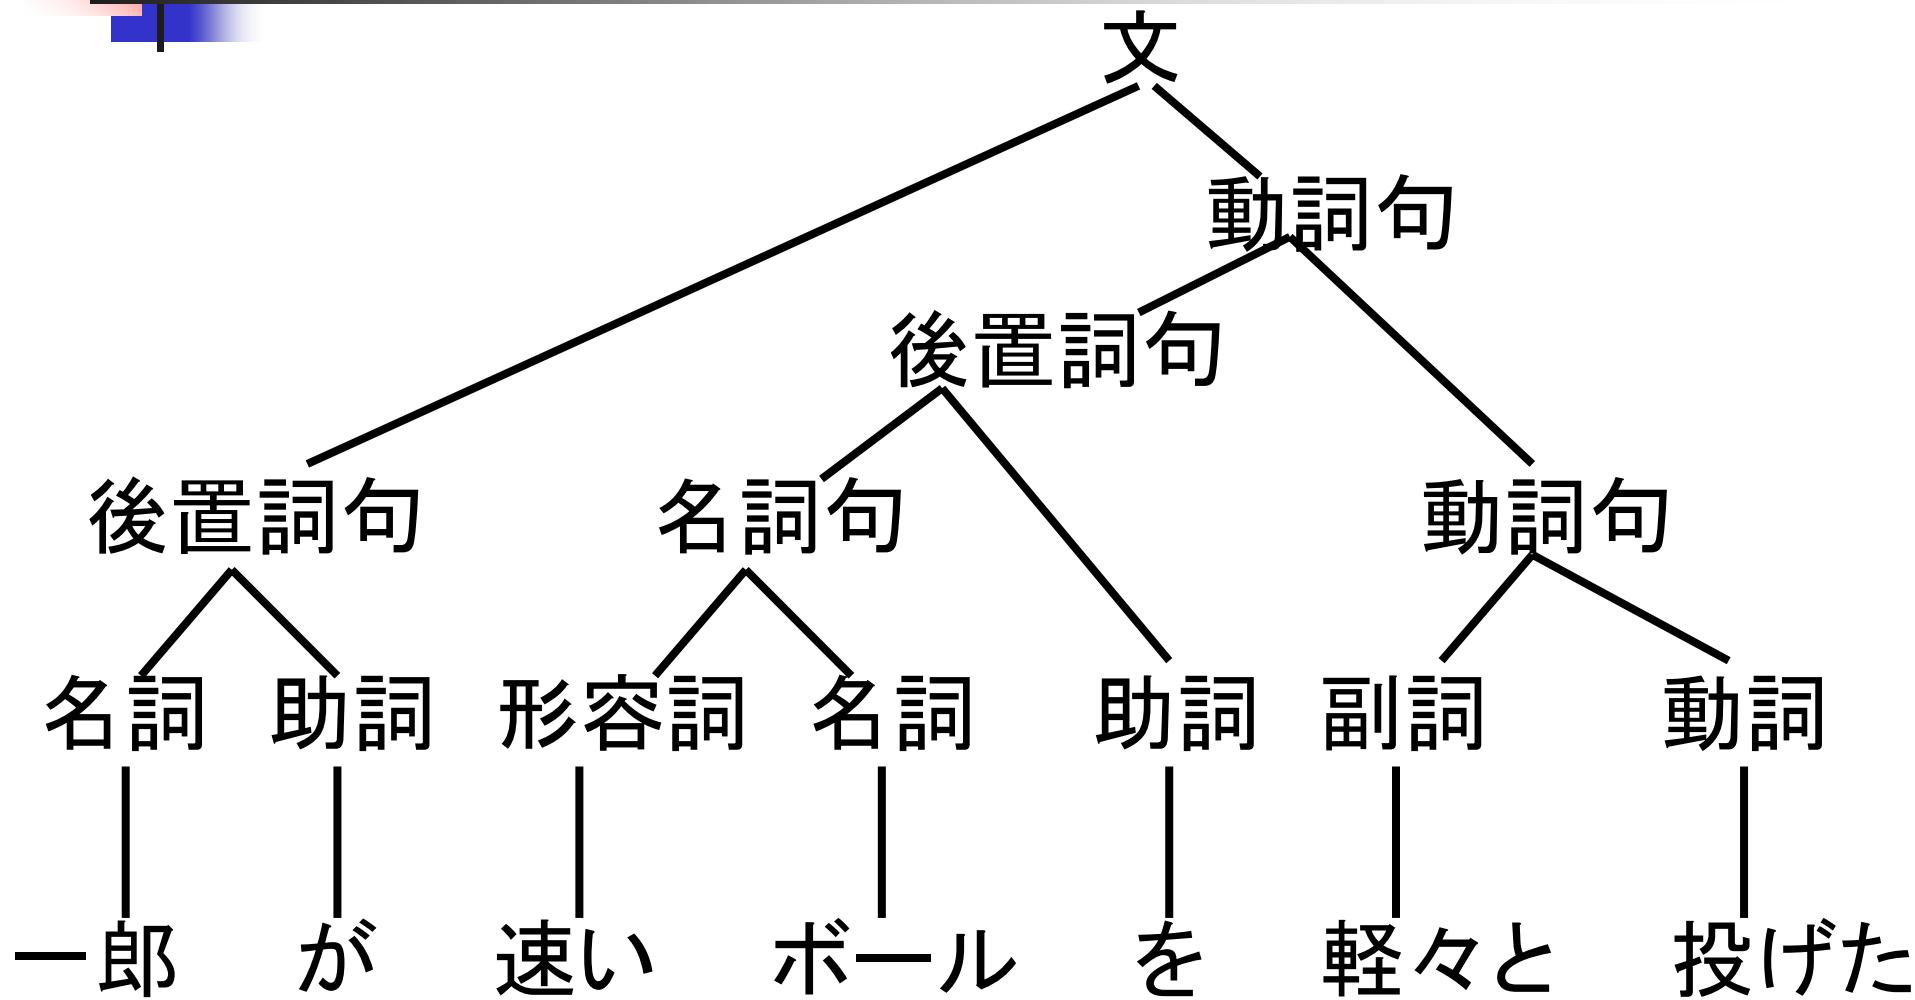


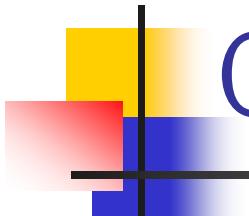
構文解析

- 入力文(記号列)が与えられたとき, 文法によってその文を解析し, その構造を明らかにする
- 代表的な構文解析アルゴリズム
 - CYK法
 - チャート法
 - アーリー法
 - LR法

構文木

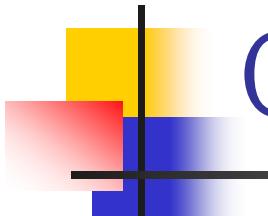
(一郎が速いボールを軽々と投げた)





CYK(Cocke-Younger-Kasami)法

- ボトムアップアルゴリズム
- 扱える文法
 - チョムスキーの標準形
 - $A \rightarrow BC$
 - $A \rightarrow a$
- CYK表
 - 構文解析の途中経過を保持するための表



CYKアルゴリズム

- チョムスキーの標準形で表される文脈自由文法を対象とした構文解析法
- チョムスキーの標準形
 - $A \rightarrow BC$ ($A, B, C \in V_n$)
 - $A \rightarrow a$ ($A \in V_n, a \in V_t$)

$X \rightarrow aB$ はチョムスキーの標準形ではないが

$X \rightarrow AB, A \rightarrow a$ に分解できる

$X \rightarrow ABC$ はチョムスキーの標準形ではないが

$X \rightarrow AY, Y \rightarrow BC$ に分解できる