

7. 文脈自由言語の性質

- 文脈自由言語の標準形
- 文脈自由言語の反復補題
例) $L = \{ 0^n 1^n 2^n \mid n \geq 0 \}$ は CFL ではない
- 文脈自由言語の閉包性
例) $L_1 = \{ 0^n 1^n 2^m \mid n, m \geq 0 \}$ も $L_2 = \{ 0^m 1^n 2^n \mid n, m \geq 0 \}$
 $L_1 \cap L_2$ は CFL ではない。
- 文脈自由言語の決定問題
 - 所属性問題は効率よく解ける(が、単純ではない)
 - 決定不能な問題がある
 - 与えられた CFG は曖昧か?
 - 与えられた CFL は本質的に曖昧か?
 - 二つの CFL が等しいか?

1/54

7. Property of Context Free Language

Useful from practical viewpoint

- Normal Forms for CFL
- Pumping lemma for CFL
Ex) $L = \{ 0^n 1^n 2^n \mid n \geq 0 \}$ is not CFL.
- Closure property of CFL
Ex) While $L_1 = \{ 0^n 1^n 2^m \mid n, m \geq 0 \}$ and $L_2 = \{ 0^m 1^n 2^n \mid n, m \geq 0 \}$ are CFLs,
 $L_1 \cap L_2$ is not a CFL.
- Decision problems for CFL
 - Membership problem can be solved efficiently (but not so simple...)
 - Undecidable problems
 - Is given CFG ambiguous?
 - Is given CFL inherently ambiguous?
 - Are two CFLs the same language?

2/54

7. 1. 文脈自由言語の標準形

A, B, C : 非終端記号
 a : 終端記号
 α : 0個以上の非終端記号列

➤ 二つの標準形

- チヨムスキー(Chomsky)標準形
 - 次の二つの生成規則しか含まない:
 $A \rightarrow BC$
 $A \rightarrow a$
 - 導出木の形が単純
- グライバッハ(Greibach)標準形
 - 次の生成規則しか含まない: $A \rightarrow a \alpha$
 - 導出の回数=語の長さ

[定理] 任意の CFL L に対して、 $L - \{ \epsilon \}$ を生成する
それぞれの標準形の CFG が存在する。
(実際に構成することができる。)

3/54

7. 1. Normal forms for CFL

A, B, C : Nonterminal
 a : Terminal
 α : 0 or more nonterminals

➤ Two major normal forms

- Chomsky Normal Form
 - consists of the following two types:
 $A \rightarrow BC$
Simple parse tree
- Greibach Normal Form
 - consists of the following type: $A \rightarrow a \alpha$
number of derivations = length of the word

[Theorem] For any CFL L , there are the normal forms that generate $L - \{ \epsilon \}$.
(Constructively proved)

Here we show Chomsky Normal Form

4/54

7. 1. 文脈自由言語の標準形 (Chomsky標準形)

➤ CFG について、有用な手法

- 無用な記号(useless symbol)の除去:
開始記号 $\stackrel{*}{\Rightarrow}$ 終端記号列に無関係な非終端記号や終端記号を除去する
- ϵ -規則(ϵ -production)の除去:
 $A \rightarrow \epsilon$ の形の規則を除去する
- 単位規則(unit production)の除去:
 $A \rightarrow B$ の形の規則を除去する

5/54

7. 1. Normal forms for CFL (Chomsky Normal Form)

➤ Useful techniques for general CFG

- Remove useless symbols:
Remove the symbols which have no relation to any derivation
'Start symbol' $\stackrel{*}{\Rightarrow}$ 'Terminals'
- Remove ϵ -productions:
Remove the production ' $A \rightarrow \epsilon$ '
- Remove unit productions:
Remove the production ' $A \rightarrow B$ '

6/54

7.1.1. 無用な記号(useless symbol)の除去

[定理] CFG $G=(V,T,P,S)$ において、 $L(G)\neq\emptyset$ とする。

1. G が生成的でない記号を含むなら、その記号と、その記号を含む規則を削除する。結果として得られる文法を $G_2=(V_2,T_2,P_2,S)$ とする。
 2. G_2 で到達可能でない記号を除去する。結果として得られる文法を $G_1=(V_1,T_1,P_1,S)$ とする。
- このとき G_1 は無用な記号を含まず、 $L(G)=L(G_1)$ である。

★ $L(G)\neq\emptyset$ より、 G_2, G_1 の開始記号は S のままである。
★生成的でない記号や到達可能でない記号をどうやって見つけるか、という点は後述。

13/54

7.1.1. Remove useless symbols

[Theorem] Let $G=(V,T,P,S)$ be a CFG with $L(G)\neq\emptyset$.

1. Remove all non-generating symbols and the rules containing them if G contains. Let $G_2=(V_2,T_2,P_2,S)$ be the resultant grammar.
2. Remove all non-reachable symbols in G_2 . Let $G_1=(V_1,T_1,P_1,S)$ be the resultant grammar.

Then, G_1 contains no useless symbols and $L(G)=L(G_1)$.

★Since $L(G)\neq\emptyset$, the start symbols of G_2 and G_1 are still S .
★We will consider how can we find those symbols, later.

14/54

7.1.1. 無用な記号(useless symbol)の除去

[定理] CFG $G=(V,T,P,S)$ において、 $L(G)\neq\emptyset$ とする。

1. G から生成的でない記号と、その記号を含む規則を削除する。結果として得られる文法を $G_2=(V_2,T_2,P_2,S)$ とする。
2. G_2 で到達可能でない記号を除去する。結果として得られる文法を $G_1=(V_1,T_1,P_1,S)$ とする。

このとき G_1 は無用な記号を含まず、 $L(G)=L(G_1)$ である。

[証明(概略)]

- ① $V_1 \cup T_1$ の任意の記号 X は生成的で到達可能であることと、
 $L(G)=L(G_1)$ となることを示せばよい。

① X は 1 で除去されなかつたので、 G で生成的。
したがって G_2 でも生成的。よって G_1 でも生成的。
また 2 で除去されなかつたので、 G_2 で到達可能。
したがって G_1 でも到達可能。よって X は G_1 で有用。

15/54

7.1.1. Remove useless symbols

[Theorem] Let $G=(V,T,P,S)$ be a CFG with $L(G)\neq\emptyset$.

1. Remove all non-generating symbols and the rules containing them if G contains. Let $G_2=(V_2,T_2,P_2,S)$ be the resultant grammar.
2. Remove all non-reachable symbols in G_2 . Let $G_1=(V_1,T_1,P_1,S)$ be the resultant grammar.

Then, G_1 contains no useless symbols and $L(G)=L(G_1)$.

[Proof (Sketch)] We show

- ① Any symbol X in $V_1 \cup T_1$ is generating & reachable, and
 $L(G)=L(G_1)$.

① Since X was not removed in step 1, that is generating in G , and hence so is in G_2 . Thus X is generating also in G_1 . Since X was not removed in step 2, that is reachable in G_2 , and hence so is in G_1 . Thus X is useful in G_1 .

16/54

7.1.1. 無用な記号(useless symbol)の除去

[定理] CFG $G=(V,T,P,S)$ において、 $L(G)\neq\emptyset$ とする。

1. G から生成的でない記号と、その記号を含む規則を削除する。結果として得られる文法を $G_2=(V_2,T_2,P_2,S)$ とする。
2. G_2 で到達可能でない記号を除去する。結果として得られる文法を $G_1=(V_1,T_1,P_1,S)$ とする。

このとき G_1 は無用な記号を含まず、 $L(G)=L(G_1)$ である。

[証明(概略)]

- ① $V_1 \cup T_1$ の任意の記号 X は生成的で到達可能であることと、
 $L(G)=L(G_1)$ となることを $L(G) \subseteq L(G_1)$ と $L(G_1) \subseteq L(G)$ で示す。

② $L(G_1) \subseteq L(G)$: 規則を削除しているだけなので、 $L(G_1) \subseteq L(G)$ は自明。
 $L(G) \subseteq L(G_1)$: 任意の $w \in L(G)$ が $w \in L(G_1)$ を満たすことを示す。
仮定より、 $S \xrightarrow{G} w$ となる。この導出途中で現れる記号はすべて生成的かつ到達可能であるので、この導出は G_1 の導出としても有効である。したがって $S \xrightarrow{G_1} w$ であり、 $w \in L(G_1)$ 。

17/54

7.1.1. Remove useless symbols

[Theorem] Let $G=(V,T,P,S)$ be a CFG with $L(G)\neq\emptyset$.

1. Remove all non-generating symbols and the rules containing them if G contains. Let $G_2=(V_2,T_2,P_2,S)$ be the resultant grammar.
2. Remove all non-reachable symbols in G_2 . Let $G_1=(V_1,T_1,P_1,S)$ be the resultant grammar.

Then, G_1 contains no useless symbols and $L(G)=L(G_1)$.

[Proof (Outline)] We show

- ① Any symbol X in $V_1 \cup T_1$ is generating & reachable, and
 $L(G)=L(G_1)$ by proving $L(G) \subseteq L(G_1)$ and $L(G_1) \subseteq L(G)$.

② $L(G_1) \subseteq L(G)$: Since rules are just removed, hence $L(G_1) \subseteq L(G)$ is clear.
 $L(G) \subseteq L(G_1)$: We show any $w \in L(G)$ satisfies $w \in L(G_1)$. By assumption, $S \xrightarrow{G} w$. All symbols appearing on this derivation are generating and reachable. Hence the derivation is also available in G_1 . Hence $S \xrightarrow{G_1} w$, and $w \in L(G_1)$.

18/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.2. [生成的な記号]と[到達可能な記号]の計算方法

1. 生成的記号の計算

- $G=(V,T,P,S)$ に対して、
 - 基礎: T の各要素は生成的(自分を生成するので)。よって生成的記号の集合 GS を T で初期化; $GS := T$
 - 帰納: 規則 $A \rightarrow \alpha$ かつ α 中の記号がすべて生成的なら、 $GS := GS \cup \{A\}$

[定理] 上記のアルゴリズムは正しく生成的な記号を計算する。
3. 2が適用できる限り適用する。

[略証] 生成的な記号だけが GS に加えられること
どの生成的な記号も GS に加えられること 帰納法で

19/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.2. Computation of [generating symbols] & [reachable symbols]

1. Generating symbols:

- For a CFG $G=(V,T,P,S)$,
 - Base: Each element in T is generating (since it generates itself). Hence, the set GS of generating symbols is initialized by T ; $GS := T$
 - Induction: If all symbols in α is generating in a rule $A \rightarrow \alpha$, we update $GS := GS \cup \{\alpha\}$.
Note: It is applied for $\alpha = \epsilon$.
 - Repeat step 2 while it can be applied.

[Theorem] The algorithm surely computes the set of generating symbols.

[Proof (Sketch)] Only generating symbols are added to GS . They can be proved by simple inductions 20/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.2. [生成的な記号]と[到達可能な記号]の計算方法

2. 到達可能な記号の計算

- $G=(V,T,P,S)$ に対して、
 - 基礎: S は自分から自分へ到達可能。よって $RS := \{S\}$ と初期化
 - 帰納: $A \in V \cup T$ で A が到達可能なら、規則 $A \rightarrow \alpha$ であるすべての α 中の記号は到達可能。つまり $RS := RS \cup \{a\}$ for all a in α .

[定理] 上記のアルゴリズムは正しく到達可能な記号を計算する。
3. 2が適用できる限り適用する。

[略証] 到達可能な記号だけが RS に加えられること
どの到達可能な記号も RS に加えられること 帰納法で

21/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.2. Computation of [generating symbols] & [reachable symbols]

2. Reachable symbols:

- For a CFG $G=(V,T,P,S)$,
 - Base: Since S is reachable from S to S , initialize $RS := \{S\}$.
 - Induction: For reachable $A \in V \cup T$, all symbols in α for a rule $A \rightarrow \alpha$ is reachable. Namely,
 $RS := RS \cup \{a\}$ for all a in α .
Note that α can be ϵ .
 - Repeat 2 while it can be applied.

[Theorem] The algorithm surely computes the set of reachable symbols.

[Proof (Sketch)] Only reachable symbols are added to RS . They can be proved by simple inductions 22/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.2. [生成的な記号]と[到達可能な記号]の計算方法

例) $G=(V=\{S,A,B\}, T=\{a,b\}, P, S)$ で

$P: S \rightarrow AB \mid a, A \rightarrow b$

- 生成的記号の計算:
 - a, b は生成的。
 - $A \rightarrow b$ より A は生成的。 $S \rightarrow a$ より S は生成的。
 $\therefore GS = \{S, A, a, b\}$

$G_2 = (\{S, A\}, \{a, b\}, P', S)$ で $P': S \rightarrow a, A \rightarrow b$ となる。

- 到達可能な記号の計算:
 - S は到達無用な記号を含まない文法が得られた。
 - $S \rightarrow a$ より

23/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.2. Computation of [generating symbols] & [reachable symbols]

Ex) For a CFG $G=(V=\{S,A,B\}, T=\{a,b\}, P, S)$ with

$P: S \rightarrow AB \mid a, A \rightarrow b$

- Computation of generating symbols:
 - a and b are generating.
 - $A \rightarrow b$ implies that A is generating. $S \rightarrow a$ implies that S is generating.
 $\therefore GS = \{S, A, a, b\}$

We have $G_2 = (\{S, A\}, \{a, b\}, P', S)$ with $P': S \rightarrow a, A \rightarrow b$.

- Computation of reachable symbols:
 - S is reachable.
 - $S \rightarrow a$ implies that a is reachable. $\therefore RS = \{S, a\}$

We have $G_1 = (\{S\}, \{a\}, P'', S)$ with $P'': S \rightarrow a$.

The grammar G_1 contains no useless symbols. 24/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

目標: 「言語 L が CFL なら、 $L - \{\epsilon\}$ を生成する ϵ -規則を持たない CFG が存在する」ことを示す。

- ϵ -規則は便利だが、本質的ではない。(アルゴリズム的観点からは扱いがけっこう面倒)
- ϵ を含む言語をどうしても表現したいのであれば、標準化した CFG $G = (V, T, P, S)$ に $S \rightarrow \epsilon$ を例外的に追加すればよい。

25/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

Goal: We show 'for any CFL L , there is a CFG that generates the language $L - \{\epsilon\}$, and it has no ϵ -productions.'

- ϵ -production is useful, but it is not essential for languages. (From the algorithmic viewpoint, handling ϵ -production is troublesome.)
- You can add the special rule ' $S \rightarrow \epsilon$ ' to the standardized CFG $G = (V, T, P, S)$ as an exception rule to add ϵ to the language.

26/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

[定義] 変数 A が消去可能(nullable) $\stackrel{\text{def}}{\Leftrightarrow} A \xrightarrow{*} \epsilon$

消去可能な変数を求めるアルゴリズム:

[基礎] $A \rightarrow \epsilon$ が G の規則ならば、 A は消去可能。

[帰納] $B \rightarrow C_1 C_2 \dots C_k$ が G の規則で、すべての C_i が消去可能なら B は消去可能。

[定理] 上記のアルゴリズムは正しく消去可能な記号を計算する。

[略証]

消去可能な記号だけが見つけられること(見つかる順番に関する帰納法) との消去可能な記号も見つかること(導出の長さに関する帰納法)

27/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

[Definition] A nonterminal A is nullable $\stackrel{\text{def}}{\Leftrightarrow} A \xrightarrow{*} \epsilon$

Algorithm for finding nullable rules:

[Base] A is nullable if $A \rightarrow \epsilon$ is a rule of G .

[Induction] B is nullable

if $B \rightarrow C_1 C_2 \dots C_k$ is a rule of G , and all C_i are nullable.

[Theorem] The algorithm surely computes all nullable nonterminals.

[Proof (Sketch)]

Only nullable nonterminals are found (induction for the order of found)
Any nullable nonterminal is found (induction for the number of derivations)

28/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

[定義] 変数 A が消去可能(nullable) $\stackrel{\text{def}}{\Leftrightarrow} A \xrightarrow{*w} \epsilon$

消去可能な変数を求めたあと、 ϵ -規則を含まない文法を構成する:

★ 変数 A が消去可能でも、 $A \xrightarrow{*w} \epsilon$ という規則を残す必要がある

[アイデア] 消去可能な変数 A に対して、例えば $B \rightarrow CAD, A \rightarrow \epsilon$, (A に関する他の規則)

という規則は $B \rightarrow CD, B \rightarrow CAD, (A \rightarrow \epsilon \text{ は削除}), (A \text{ に関する他の規則})$ に書き換える必要がある。

29/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

[Definition] A nonterminal A is nullable $\stackrel{\text{def}}{\Leftrightarrow} A \xrightarrow{*} \epsilon$

After finding all nullable nonterminals, we construct a CFG that contains no ϵ -productions:

★ We have to remain the rule $A \xrightarrow{*w} \epsilon$ even if A is nullable.

[Idea] For a nullable nonterminal A , for example, we have to replace $B \rightarrow CAD, A \rightarrow \epsilon$, (Other rules for A)
by
 $B \rightarrow CD, B \rightarrow CAD, (\text{Remove } A \rightarrow \epsilon), (\text{Other rules for } A)$.

30/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

[定義] 変数 A が消去可能(nullable) $\Leftrightarrow A \xrightarrow{\text{def}} \epsilon$

消去可能な変数を求めたあと、 ϵ -規則を含まない文法を構成する:

- $A \rightarrow X_1 X_2 \dots X_k$ ($k \geq 1$) を P に属する規則とし、 $m \leq k$ 個の X_i が消去可能であったとする。このとき、 2^m 通りの可能な X_i の消去方法を考え、これらの規則をすべて追加する。
- $A \rightarrow \epsilon$ の形の規則はすべて削除する

例) $A \rightarrow WXYZ$
のうち、 X, Z が消去可能なら、
 $A \rightarrow WY$
 $A \rightarrow WXY$
 $A \rightarrow WYZ$
 $A \rightarrow WXYZ$
の4通りの消去方法を適用した規則を追加する。

31/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

[Definition] A nonterminal A is nullable $\Leftrightarrow A \xrightarrow{*} \epsilon$

After finding all nullable nonterminals, we construct a CFG that contains no ϵ -productions as follows:

- Let $A \rightarrow X_1 X_2 \dots X_k$ ($k \geq 1$) be a rule in P such that $m \leq k$ X_i s are nullable. Then, we apply all possible 2^m ways to remove X_i s, and add them as new rules.
- Remove the rule $A \rightarrow \epsilon$.

Ex) For $A \rightarrow WXYZ$, suppose it has two nullable X and Z . Then, we add four possible rules:
 $A \rightarrow WY$
 $A \rightarrow WXY$
 $A \rightarrow WYZ$
 $A \rightarrow WXYZ$

32/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

消去可能な変数を求めたあと、 ϵ -規則を含まない文法を構成する方法:

- $A \rightarrow X_1 X_2 \dots X_k$ ($k \geq 1$) を P に属する規則とし、 $m \leq k$ 個の X_i が消去可能であったとする。このとき、 2^m 通りの可能な X_i の消去方法を考え、これらの規則をすべて追加する。
- $A \rightarrow \epsilon$ の形の規則はすべて削除する

[定理] CFG G から上記のアルゴリズムで ϵ -規則を含まない CFG G_1 を構成すると、 $L(G_1)=L(G)-\{\epsilon\}$ である。

[証明] 省略

33/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

After finding all nullable nonterminals, we construct a CFG that contains no ϵ -productions as follows:

- Let $A \rightarrow X_1 X_2 \dots X_k$ ($k \geq 1$) be a rule in P such that $m \leq k$ X_i s are nullable. Then, we apply all possible 2^m ways to remove X_i s, and add them as new rules.
- Remove the rule $A \rightarrow \epsilon$.

[Theorem] For any given CFG G , construct the CFG G_1 without ϵ -production by the algorithm. Then we have $L(G_1)=L(G)-\{\epsilon\}$.

[Proof] Omitted.

34/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.3. ϵ -規則の除去

例) 規則が

$S \rightarrow AB$

$A \rightarrow aAB \mid \epsilon$

$B \rightarrow bBB \mid \epsilon$

の文法

テキスト改
ス텝1:
消去可能変数を見つける
 $A \rightarrow \epsilon, B \rightarrow \epsilon \dots A, B$
 $S \rightarrow AB \dots S$
 $\therefore S, A, B$ は消去可能変数

ステップ2: 個々の規則の書き換え
Ex.) For the rules modified sample in text
➤ $S \rightarrow AB$
 $S \rightarrow A, S \rightarrow B, S \rightarrow AB$
➤ $A \rightarrow aAB$
 $A \rightarrow a, A \rightarrow aA, A \rightarrow aB, A \rightarrow aAB$
➤ $B \rightarrow bBB$
 $B \rightarrow b, B \rightarrow bB, B \rightarrow bBB$

ステップ3: 最終的な規則
 $S \rightarrow A \mid B \mid AB$
 $A \rightarrow a \mid aA \mid aB \mid aAB$
 $B \rightarrow b \mid bB \mid bBB$

35/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.3. Remove ϵ -productions

Ex.) For the rules modified sample in text

Step 2: Replace rules:
➤ $S \rightarrow AB$
 $S \rightarrow A, S \rightarrow B, S \rightarrow AB$
➤ $A \rightarrow aAB$
 $A \rightarrow a, A \rightarrow aA, A \rightarrow aB, A \rightarrow aAB$
➤ $B \rightarrow bBB$
 $B \rightarrow b, B \rightarrow bB, B \rightarrow bBB$

Step 1:
Find all nullable nonterminals:
 $A \rightarrow \epsilon, B \rightarrow \epsilon \dots A, B$
 $S \rightarrow AB \dots S$
 $\therefore S, A, B$ are nullable.

Step 3: Final rules:
 $S \rightarrow A \mid B \mid AB$
 $A \rightarrow a \mid aA \mid aB \mid aAB$
 $B \rightarrow b \mid bB \mid bBB$

36/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.4. 単位規則の除去

- $A \rightarrow B$ の形の単位規則(unit production)を除去するとき、
- $A \rightarrow B, B \rightarrow C, C \rightarrow A$ といった、循環的なケースがある
 - $A \rightarrow BC, C \rightarrow \epsilon$ なら $A \xrightarrow{*} B$ となりうる
- ので、単に展開して削除するだけではうまくいかないことがある。

[準備] 「単位規則だけを使って $A \xrightarrow{*} B$ となるペア(A,B)」
(単位ペア(unit pair)と呼ぶ)を以下の方法ですべて見つける:

[基礎] どの変数Aについても(A,A)は単位ペア
[帰納] (A,B)が単位ペアのとき、
 $B \rightarrow C$ が単位規則なら(A,C)も単位ペア

37/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.4. Remove unit productions

When we remove unit production $A \rightarrow B$, we have:

- Cyclic case: $A \rightarrow B, B \rightarrow C, C \rightarrow A$
- It can be $A \xrightarrow{*} B$ when $A \rightarrow BC$ and $C \rightarrow \epsilon$

Hence, 'simple expansion and remove' do not work.

[Preparation] We first find all unit pairs, which are pairs (A,B)
such that $A \xrightarrow{*} B$ by only using unit productions:

[Base] (A,A) is a unit pair for any nonterminal.

[Induction] For a unit pair (A,B), if $B \rightarrow C$ is unit production,
(A,C) is also unit pair.

38/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.4. 単位規則の除去

[準備] 「単位規則だけを使って $A \xrightarrow{*} B$ となるペア(A,B)」
(単位ペア(unit pair)と呼ぶ)を以下の方法ですべて見つける:

[基礎] どの変数Aについても(A,A)は単位ペア
[帰納] (A,B)が単位ペアのとき、
 $B \rightarrow C$ が単位規則なら(A,C)も単位ペア

[定理] CFG Gで上記のアルゴリズムですべての単位ペア
を見つけることができる。

[証明] 省略

39/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.4. Remove unit productions

[Preparation] We first find all unit pairs, which are pairs (A,B)
such that $A \xrightarrow{*} B$ by only using unit productions:

[Base] (A,A) is a unit pair for any nonterminal.

[Induction] For a unit pair (A,B), if $B \rightarrow C$ is unit production,
(A,C) is also unit pair.

[Theorem] For any CFG G, the algorithm finds all unit pairs.

[Proof] Omitted.

40/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.4. 単位規則の除去

[単位規則の除去]

1. 単位ペアをすべて見つける
2. すべての
 - 単位ペア(A,B)
 - 単位規則ではない規則 $B \rightarrow \alpha$ に対して、規則 $A \rightarrow \alpha$ を追加する
3. 単位規則を削除する

[定理] CFG Gから上記のアルゴリズムで単位規則を含ま
ないCFG G_1 を構成すると、 $L(G_1)=L(G)$ である。

[証明] 省略

41/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.4. Remove unit productions

[Remove unit productions]

1. Find all unit pairs
2. For all possible
 - unit pair (A,B)
 - non-unit production $B \rightarrow \alpha$add the rule $A \rightarrow \alpha$.
3. Remove all unit productions.

[Theorem] Let G_1 be the CFG obtained from a CFG G by
the algorithm. Then, we have $L(G_1)=L(G)$.

[Proof] Omitted

42/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.4. 単位規則の除去

例) 規則が

$$\begin{aligned} I &\rightarrow a \mid (E) \\ F &\rightarrow F \times I \mid I \\ E &\rightarrow E + F \mid F \end{aligned}$$

の文法(スタート記号はE)

ステップ1:
単位ペアを見つける
 $F \rightarrow I, E \rightarrow F \dots (F,I), (E,F)$
さらに(E,I)も
 $\therefore (F,I), (E,F), (E,I)$ が単位ペア

ステップ2: 追加すべき規則
 $\triangleright (F,I)$ より
 $F \rightarrow a \mid (E)$
 $\triangleright (E,F)$ より
 $E \rightarrow F \times I$
 $\triangleright (E,I)$ より
 $E \rightarrow a \mid (E)$

ステップ3: 最終的な規則
 $I \rightarrow a \mid (E)$
 $F \rightarrow F \times I \mid a \mid (E)$
 $E \rightarrow E + F \mid F \times I \mid a \mid (E)$

43/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.4. Remove unit productions

Ex) For a grammar with rules

$$\begin{aligned} I &\rightarrow a \mid (E) \\ F &\rightarrow F \times I \mid I \\ E &\rightarrow E + F \mid F \end{aligned}$$

(start symbol; E)

Step 2: rules should be added
 $\triangleright (F,I)$ implies
 $F \rightarrow a \mid (E)$
 $\triangleright (E,F)$ implies
 $E \rightarrow F \times I$
 $\triangleright (E,I)$ implies
 $E \rightarrow a \mid (E)$

Step 1:
Find all unit pairs
 $F \rightarrow I, E \rightarrow F \dots (F,I), (E,F)$
and (E,I) is.
 $\therefore (F,I), (E,F), (E,I)$ are unit pairs.

Step 3: Final rules
 $I \rightarrow a \mid (E)$
 $F \rightarrow F \times I \mid a \mid (E)$
 $E \rightarrow E + F \mid F \times I \mid a \mid (E)$

44/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.1～7.1.4. まとめ

[単純化アルゴリズムまとめ]

- ε -規則を削除する
- 単位規則を削除する
- 無用な記号を除く

という順番で変換を適用すると、以下の定理が得られる。

[定理] CFG G が ε 以外の語を少なくとも1つ生成するとする。このとき上記のアルゴリズムを適用して作成した CFG G_1 は、 $L(G_1)=L(G)-\{\varepsilon\}$ であり、 ε -規則と単位規則は持たず、無用な記号も持たない。

[証明] 省略(適用順序は大切であることに注意)

45/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.1～7.1.4. Summary

[Outline of Simplify Algorithm]

Perform the following operations in the following ordering,

- Remove ε -productions
- Remove unit productions
- Remove useless symbols

we have the following theorem.

[Theorem] Let G be a CFG that generates at least one word except ε . Then, the CFG G_1 obtained from G by the algorithm satisfies (1) $L(G_1)=L(G)-\{\varepsilon\}$, (2) no ε -productions, (3) no unit productions, and (4) no useless symbols.

[Proof] Omitted (Note that the ordering is crucial.)

46/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.5. Chomsky 標準形

1. チヨムスキーチー(Chomsky)標準形

- 次の二つの生成規則しか含まない: $\begin{cases} A \rightarrow BC \\ A \rightarrow a \end{cases}$

7.1.1.～7.1.4.のまとめ: 単純化した CFG G は
 $A \rightarrow \varepsilon$ と $A \rightarrow B$ の形の規則は含まない

単純化した CFG $G=(V,T,P,S)$ の規則 P は

- $A \rightarrow a$ OK
- $A \rightarrow X_1X_2\dots X_k$ $\left\{ \begin{array}{l} X_i \in V \cup T \\ k \geq 2 \end{array} \right.$

の形の規則のみを含む。
これをChomskyの標準形に変換する。

47/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.5. Chomsky Normal Form

A,B,C : Nonterminals
 a : terminal
 α : 0 or more nonterminals

1. Chomsky Normal Form

- consists of the following two types: $\begin{cases} A \rightarrow BC \\ A \rightarrow a \end{cases}$

7.1.1.～7.1.4. Summary: Simplified CFG G has no rules with form $A \rightarrow \varepsilon$ and $A \rightarrow B$

Simplified CFG $G=(V,T,P,S)$ has the set of rules P , which has just two types of rules:

- $A \rightarrow a$ OK
- $A \rightarrow X_1X_2\dots X_k$ $\left\{ \begin{array}{l} X_i \in V \cup T \\ k \geq 2 \end{array} \right.$

We modify them to Chomsky Normal Form.

48/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.5. Chomsky 標準形

- 1. チョムスキーチー(Chomsky)標準形**
 - 次の二つの生成規則しか含まない:
$$(2) A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \cup T \\ k \geq 2 \end{cases}$$

[手順1] X_i が終端記号 a なら、新たな非終端記号 X'_i を導入し、
 $A \rightarrow X_1 X_2 \dots X_{i-1} X'_i X_{i+1} \dots X_k$
 $X'_i \rightarrow a$ OK

とする。この処理をすべての X_i に適用してラベルをつけると…

$$(2') A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \\ k \geq 2 \end{cases}$$

となる。

49/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.5. Chomsky Normal Form

- 1. Chomsky Normal Form**
 - consists of the following two types:
$$(2) A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \cup T \\ k \geq 2 \end{cases}$$

[Step 1] If X_i is a terminal a , make a new nonterminal X'_i , and add
 $A \rightarrow X_1 X_2 \dots X_{i-1} X'_i X_{i+1} \dots X_k$
 $X'_i \rightarrow a$ OK

After applying the step to all X_i , relabel them, and we have…

$$(2') A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \\ k \geq 2 \end{cases}$$

k=2 is also OK

50/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.5. Chomsky 標準形

- 1. チョムスキーチー(Chomsky)標準形**
 - 次の二つの生成規則しか含まない:
$$(2') A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \\ k \geq 3 \end{cases}$$

[手順2] 新たな非終端記号 Y_1, Y_2, \dots, Y_{k-2} を導入し、
 $A \rightarrow X_1 Y_1$
 $Y_1 \rightarrow X_2 Y_2, Y_2 \rightarrow X_3 Y_3, \dots, Y_{k-3} \rightarrow X_{k-2} Y_{k-2}$
 $Y_{k-2} \rightarrow X_{k-1} X_k$ OK

とする。

これですべて Chomsky の標準形のどちらかのタイプに変換できた。

51/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.5. Chomsky Normal Form

- 1. Chomsky Normal Form**
 - consists of the following two types:
$$(2') A \rightarrow X_1 X_2 \dots X_k \begin{cases} X_i \in V \\ k \geq 3 \end{cases}$$

[Step 2] Make new nonterminals Y_1, Y_2, \dots, Y_{k-2} , and rewrite
 $A \rightarrow X_1 Y_1$
 $Y_1 \rightarrow X_2 Y_2, Y_2 \rightarrow X_3 Y_3, \dots, Y_{k-3} \rightarrow X_{k-2} Y_{k-2}$
 $Y_{k-2} \rightarrow X_{k-1} X_k$ OK

Now all rules are one of two types in Chomsky Normal Form.

52/54

7.1. 文脈自由言語の標準形 (Chomsky標準形)

7.1.5. Chomsky 標準形

- 1. チョムスキーチー(Chomsky)標準形**
 - 次の二つの生成規則しか含まない:
$$\begin{cases} A \rightarrow BC \\ A \rightarrow a \end{cases}$$

[まとめ] 任意の CFL L に対して、 $L - \{\epsilon\}$ を生成する Chomsky 標準形の CFG が存在する。

$L(G)=L$ を満たす任意の CFG G から実際に構成できる。

[おまけ] 任意の CFL L に対して、 $L - \{\epsilon\}$ を生成する Greibach 標準形の CFG が存在する。
 (同様に構成的に示すことができる。)

53/54

7.1. Normal forms for CFL (Chomsky Normal Form)

7.1.5. Chomsky Normal Form

- 1. Chomsky Normal Form**
 - consists of the following two types:
$$\begin{cases} A \rightarrow BC \\ A \rightarrow a \end{cases}$$

[Summary] For any CFL L , there exists a CFG of Chomsky Normal Form that generates $L - \{\epsilon\}$.

And we can surely construct from any G with $L(G)=L$.

[Note] For any CFL L , there exists a CFG of Greibach Normal Form that generates $L - \{\epsilon\}$.
 (Similar constructive proof is given.)

54/54