

Vorlesungsmitschrift zur Vorlesung Theoretische Informatik vom 14.07.2000

Von Matr.-Nr.: 702100

5.1.2. Chomsky-Normalform

kontextfreier Fall: $A \rightarrow w, w \in (N \cup T)^*, A \subseteq N$

- \Rightarrow Chomsky-Normalform:
1. ϵ -Regeln vermeiden, soweit möglich
 2. Rechte-Seiten vereinfachen
 - $|w| \leq 2$
 - $|w| = 2, w \in N \bullet N$
 - $|w| \geq 1, w \in T$

Def. E: Eine kontextfreie Grammatik $G = (N, T, P, \sigma)$ heisst Chomsky-Normalform wenn gilt:

- Falls $\epsilon \in L(G)$, so gibt es die Regeln $\sigma \rightarrow \epsilon$ und σ kommt auf keiner rechten Seite einer Produktion vor
- Für alle $\alpha \rightarrow \beta \in P$ gilt: $\alpha \in N, \beta \in N \bullet N \cup T$

Bemerkung: Ableitungsbäume von kontextfreien Grammatiken in Chomsky-Normalformen sind binäre Bäume

Satz F: Zu jeder kontextfreien Grammatik G existiert eine äquivalente (sprachenerzeugende) Grammatik G' in Chomsky-Normalform

Beweis:

Idee: Effektive Konstruktion in mehreren Schritten:

- Entfernen von ϵ -Regeln
- Terminalzeichen aus rechten Seiten entfernen
- Entfernen von Kettenregeln
- Verkürzen der rechten Seite auf Länge 2

Sei $G = (N, T, P, \sigma)$ gegeben

Schritt 1: Entfernen der ϵ -Regeln

Bilde $M_1 := \{A \mid A \in P\} \subseteq N$

$M_{i+1} = M_i \cup \{B \mid \exists B \rightarrow u \in P \text{ mit } u \in M_i^*\} \subseteq N$ für $i=1, \dots, n$

$[X \in M_{i+1} \Rightarrow X \xrightarrow{i+1} \epsilon]$

Es gibt: $M_1 \subseteq M_2 \subseteq \dots \subseteq N$

Das heisst, die Folge der M_i ist nach oben beschränkt.

Dann gibt es ein $k \in N$ mit $M_k = M_{k+1} = \dots = M_{k+r}$ für alle $r \in N$

Behauptung: $A \in M_k \Leftrightarrow A \rightarrow^* \varepsilon$ bezüglich G

“ \Rightarrow ”: $A \in M_k \Rightarrow A \in M_{k-1}$ oder $\exists u \in M_{k-1}^*$ mit $A \rightarrow u \in P$

Hierdurch folgt mit vollständiger Induktion bezüglich k dass $A \rightarrow^* \varepsilon$

“ \Leftarrow ”: Es gelte $A \rightarrow^* \varepsilon$. Betrachten des Ableitungsbaum.

Falls es ein „selbsteinbettendes“ B gibt ($B \rightarrow^* B$), dann lasse man den schraffierten Teil weg. Es entsteht eine kürzere Ableitung $A \rightarrow^* \varepsilon$.

Eliminiere so alle selbsteinbettende Nonterminale. Der entstehende Ableitungsbaum kann höchstens Höhe $|N|$ haben.

$A \in M_{|N|} = M_k \Rightarrow$ Behauptung

Man bilde nun $Q_1 := P$

$$Q_{i+1} := \{ A \rightarrow A_1 \dots A_{j-1} A_{j+1} \dots A_m \mid A \rightarrow A_1 \dots A_{j-1} A_j A_{j+1} \dots A_m \in Q_i \text{ und } A_j \in M_k \}$$

Man entferne also schrittweise die Nonterminale aus der rechten Seite, die nach ε ableitbar sind.

Da die rechten Seiten immer kürzer werden, gibt es ein $q \in \mathbb{N}$, so dass $Q_q = \emptyset$ und $Q_{q-1} \neq \emptyset$.

$q-1$

Sei $P_1' = \bigcup_{i=1}^{q-1} Q_i \setminus \{ A \rightarrow \varepsilon \mid \exists i \text{ mit } A \rightarrow \varepsilon \in Q_i \}$ (P_1' ist ohne ε -Regeln)

Beispiel: Gilt $A \rightarrow^* \varepsilon$, so nimmt man zur vorhandenen Regel $B \rightarrow uAv$ die Regel $B \rightarrow uv$

Sei $G_1' = (N, T, P, \sigma)$ und es gilt $L(G_1') = L(G) \setminus \{\varepsilon\}$.

Setze man für ein Zeichen: $\sigma \notin N: N_1 := N \cup \{\sigma'\}$

$$\text{Bilde } P_1 = \begin{cases} P_1' \cup \{\sigma' \rightarrow \sigma\}, & \text{falls } \varepsilon \notin L(G) \\ P_1' \cup \{\sigma' \rightarrow \sigma, \sigma \rightarrow \varepsilon\}, & \text{falls } \varepsilon \in L(G) \end{cases} \text{ [1. Anstrich in Def. E]}$$

Schritt 2: Terminalzeichen aus rechten Seiten entfernen

[z.B. $A \rightarrow wxw', ww' \in (N \cup T)^*, x \in T \Rightarrow A \rightarrow wXw' \quad X \rightarrow x$]

Sei $T' := \{t' \mid t \in T\}$ eine zu T gleichmächtige Menge.

Setze $N_2 := N_1 \cup T'$ und mit $h := (N \cup T)^* \rightarrow (N \cup T')^*$ Homomorphismus

$$\text{mit } h(a) = \begin{cases} a, & a \in N \\ a', & a' \in T' \end{cases}$$

Bilde $P_2' = \{A \rightarrow h(a) \mid A \rightarrow u \in P_1\} \cup \{t' \rightarrow t \mid t \in T\}$

Für $G_2' = (N_2, T, P_2', \sigma')$ gilt $L(G_2') = L(G_1')$

$[A \rightarrow u \in P_2' \Rightarrow u \in T \text{ oder } u \in N_2^+]$

Schritt 3: Entfernen der Kettenregeln

[z.B. $A \rightarrow B, B \rightarrow C, C \rightarrow D, wxw', ww' \in (N \cup T)^*, x \in T$

$X \rightarrow wAw'$

$X \rightarrow wBw'$

$X \rightarrow wCw'$

$X \rightarrow wDw'$]

Vorgehen: Man entfernt diese Regeln, indem man sie wie in Schritt 1 in vorhergehende Regeln hineinzieht.

Für jedes $A \in N_2$ bilde

$$M_1(A) = \{A\}$$

$$M_{i+1}(A) = M_i(A) \cup \{ B \in N_2 \mid \exists C \in M_i(A) \text{ mit } C \rightarrow B \in P_2' \} \subseteq N$$

Also gilt: $\exists k$ mit $M_k(A) = M_{k+1}(A) = M_{k+r}(A) \ (\forall r \in \mathbb{N})$

Und es folgt: $B \in M_k(A) \Leftrightarrow A \xrightarrow{sk-1} B$ bezüglich G_2'

[Bemerkung: Man kann ein einheitliches k für alle $A \in N_2$ wählen, da $k \subseteq |N_2|$ wegen $M_1(A) \subseteq M_2(A) \subseteq \dots \subseteq N_2$]

Konstruiere $G_2 = (N_2, T, P_2, \sigma')$ mit

$$P_2 = \{ A \rightarrow C_1 \dots C_r \mid \exists A \rightarrow B_1 \dots B_r \in P_2', r \geq 2, B_i \in N_2 \text{ für } i = 1, \dots, r$$

und für alle $i = 1, \dots, r$ gilt: $C_i \in M_k(B_i) \}$

$$\cup \{ \sigma' \rightarrow u \mid \exists A \rightarrow u \in P_2' \text{ mit } |u| \geq 2 \text{ und } A \in M_k(\sigma') \}$$

$$\cup \{ \sigma' \rightarrow t \mid t' \in M_k(\sigma'), t \in T \}$$

$$\cup \{ \sigma' \rightarrow \varepsilon \mid \text{für } \sigma \rightarrow \varepsilon \in P_2' \}$$

gilt: $L(G_2) = L(G_2') = L(G_1)$ [ohne Beweis]

Schritt 4: Verkürzung der rechten Seiten auf die Länge ≤ 2

[z.B. $A \rightarrow BCDE \Rightarrow A \rightarrow BB', B' \rightarrow CC', C' \rightarrow DE$]

Für jede Regel $A \rightarrow B_1 \dots B_r, r \geq 3, A, B_1, \dots, B_r \in N_2$ füge $r-2$ neue Nonterminals $A_1 \dots A_{r-2}$ hinzu und ersetze die Regel $A \rightarrow B_1 \dots B_r$ durch

$$A \rightarrow B_1 A_1$$

$$A_1 \rightarrow B_2 A_2$$

\vdots

\vdots

$$A_{r-3} \rightarrow B_{r-2} A_{r-2}$$

$$A_{r-2} \rightarrow B_{r-1} B_r$$

Beachte: Je Regel in P_2 neue Zeilen $A_1 \dots A_{r-2}$ N'' neue Nichtterminalmenge, P' neue Produktionsmenge

$$P' = P_2 \setminus \{ A \rightarrow u \mid |u| \geq 3, A \rightarrow u \in P_2 \}$$

$$\cup \{ A \rightarrow B_1 A_1, \dots, A_{r-2} \rightarrow B_{r-1} B_r \mid A \rightarrow B_1, \dots, B_r \in P_2, r \geq 3 \}$$

Setze $N' := N'' \setminus \{ A \mid A \text{ tritt in } P_2 \text{ nirgends auf} \}$

$G' = (N', T, P', \sigma')$ ist in Chomsky-Normalform und es gilt:

$$L(G) = L(G')$$

Beispiel: $G = (N, T, P, \sigma)$ mit

$$N = \{A, B, S\}, T = \{a, b, c\}$$

$$P = \{ S \rightarrow AB, A \rightarrow ab, A \rightarrow aAb, B \rightarrow c, B \rightarrow cB \}$$

Schritt 1: keine ε -Regeln

Schritt 2: Terminalzeichen aus rechten Seiten entfernen

$$T' = \{a', b', c'\}, N_2 = N \cup T'$$

$$P_2' = \{ S \rightarrow AB, A \rightarrow a'b', A \rightarrow a'Ab', B \rightarrow c', B \rightarrow c'B,$$

$$a' \rightarrow a, b' \rightarrow b, c' \rightarrow c \}$$

Schritt 3: Kettenregeln entfernen



$$M_1(B) = \{B\}, M_2(B) = \{B\} \cup \{ X \in N_2 \mid \exists C \in M_1(B) \text{ mit } C \rightarrow X \in P_2' \}$$

Schritt 4: rechte Seite verkürzen $N' = N_2 \cup \{C_1\}$

$\Rightarrow P' = \{ S \rightarrow AB, A \rightarrow a'b_1', A \rightarrow a'C_1, C_1 \rightarrow Ab', B \rightarrow c, B \rightarrow c'B, a' \rightarrow a, b' \rightarrow b, c' \rightarrow c \}$

Pumping-Lemma für kontextfreie Sprachen

Idee: $A \rightarrow BC$



reguläre Sprache: $uv^i w$

Satz F: Zu jeder kontextfreien Sprache $C \subseteq T^*$ existiert eine Zahl $n \in \mathbb{N}$, so dass für alle Wörter $z \in L$ mit $|z| \geq n$ gilt:

Es gibt eine Zerlegung $z = uvwxy$ mit $u, v, w, x, y \in T^*$ und

- (i) $vx \neq \varepsilon$
- (ii) $|vwx| \leq n$
- (iii) für alle $i \in \mathbb{N}_0$ gilt: $uv^iwx^iy \in L$