

## Die Chomsky-Normalform (CNF) für kontextfreie Grammatiken

Def: Eine kontextfreie Grammatik  $G = (\Sigma, V, P, S)$  ist in Chomsky-Normalform, wenn alle Regeln folgende Gestalt haben:

$$A \rightarrow BC, \quad A, B, C \in V$$

$$A \rightarrow a \quad A \in V, a \in \Sigma$$

Ausnahme: Die Regel  $S \rightarrow \varepsilon$  ist erlaubt, aber dann darf  $S$  auf keiner rechten Seite vorkommen.

Bsp.  $S \rightarrow SS | ST | \emptyset$   
 $T \rightarrow TS | SS | \emptyset$

~~$T \rightarrow SOT1$~~      ~~$S \rightarrow TTTT$~~   
 $S \rightarrow T$      ~~$T \rightarrow \varepsilon$~~   
 ↑                    ↑                    ↑  
 $\Sigma$  und  $V$  gemischt    zu kurz    zu lang

SATZ: Zu jeder kontextfreien Grammatik  $G$  gibt es eine äquivalente Grammatik  $G'$  in CNF.

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

Folgerung: Jede kontextfreie Sprache ist auch eine kontextsensitive Sprache.

Beweis: Transformation von  $G \rightsquigarrow G'$

Schritt ①: Trennung von Variablen und Terminalsymbolen


- Füge für jedes  $a \in \Sigma$  eine neue Variable  $V_a$  hinzu

- Ersetze auf den rechten Seiten jedes  $a \in \Sigma$  durch  $V_a$
- Füge die Regeln  $V_a \rightarrow a$  für alle  $a \in \Sigma$  hinzu

Bsp:  $T \rightarrow SOT1 \rightsquigarrow T \rightarrow SV_0TV_1$   $V_1 \rightarrow 1$   
 $V_0 \rightarrow 0$


Schritt (2): Behandlung zu längeren Regeln

Bsp:  $T \rightarrow STUSS \rightsquigarrow T \rightarrow SW_1$



neue Variablen

$W_1 \rightarrow TW_2$   
 $W_2 \rightarrow UW_3$   
 $W_3 \rightarrow SS$



Für jede rechte Seite mit Länge  $k \geq 3$   
 führe  $k-2$  neue Variablen und  $k-1$  neue  
 Regeln ein, die die ursprünglichen Regeln ersetzen.

Schritt (3): Elimination der  $\epsilon$ -Regeln

3a. Bestimme die Menge  $V_\epsilon := \{A \in V \mid A \xRightarrow{*} \epsilon\}$

3b. Vereinfachung der Regeln mit Variablen  $\in V_\epsilon$  auf der rechten Seite

IDEA:  $S \xrightarrow{\epsilon} TU$  und  $U \xRightarrow{*} \epsilon$  :

füge die Regel  $S \rightarrow T$  hinzu

(3a.)  $V_0 := \{A \in V \mid A \rightarrow \epsilon \in P\}$

Wenn  $A \rightarrow BC$  und  $B, C \in V_0 \Rightarrow$  Füge  $A$  zu  $V_0$  hinzu

Wenn  $A \rightarrow B$ , und  $B \in V_0 \Rightarrow$  Füge  $A$  zu  $V_0$  hinzu

Wiederhole, bis sich  $V_0$  nicht mehr ändert.

Am Ende ist  $V_0 = V_\epsilon$ .


- 3b) Wenn  $A \rightarrow BC$  und  $C \in V_\epsilon \Rightarrow$  zusätzliche Regel  $A \rightarrow B$   
 Wenn  $A \rightarrow BC$  und  $B \in V_\epsilon \Rightarrow$  zusätzliche Regel  $A \rightarrow C$   
 Entferne alle Regeln der Form  $A \rightarrow \epsilon$ .

$G$  vor Schritt 3b,  $G'$  nach Schritt 3b

Behauptung:  $\forall A \in V \forall w \in \Sigma^*: A \xrightarrow{G'}^* w \Leftrightarrow A \xrightarrow{G}^* w$  und  $w \neq \epsilon$

Beweis: „ $\Rightarrow$ “ ✓

„ $\Leftarrow$ “



Betrachte den Ableitungsbaum für  $w$  in  $G$

Entferne alle Teilbäume, die nur  $\epsilon$ -Blätter enthalten

Es entsteht ein Ableitungsbaum für  $w$  in  $G'$

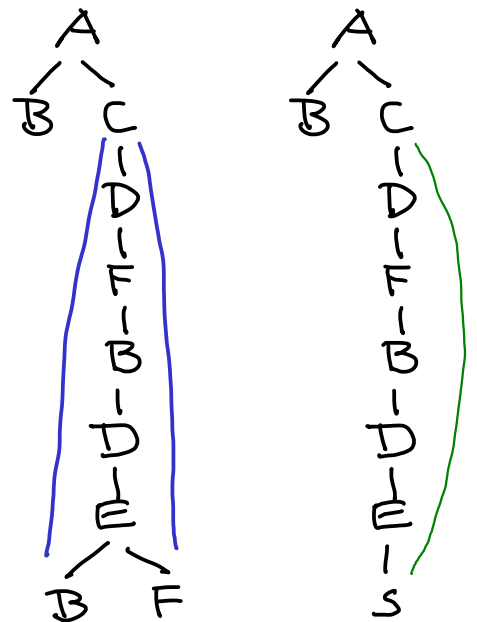
□

Wenn  $\epsilon \in L(G)$  ist:

Verwende ein neues Startsymbol  $\bar{S}$

zusätzliche Regeln  $\bar{S} \rightarrow \epsilon \mid S$

- Terminalregeln  $A \rightarrow a, a \in \Sigma'$  ✓
- Paarregeln  $A \rightarrow BC$  ✓
- Einheitsregeln  $A \rightarrow B, B \in V$  ✗



Schritt 4. Elimination der Einheitsregeln

Wenn  $A \xrightarrow{*} B$  und  $B \rightarrow CD$ ,

füge Regel  $A \rightarrow CD$  hinzu

Wenn  $A \xrightarrow{*} B$  und  $B \rightarrow a$  ( $a \in \Sigma'$ ),

füge Regel  $A \rightarrow a$  hinzu

Lass alle Einheitsregeln weg.  $\rightarrow$  neue Grammatik  $G'$   
Behauptung  $L(G) = L(G')$  " $\cong$ "  $\checkmark$

" $\subseteq$ " Auf jede maximale Kette  $A_1 \rightarrow A_2 \rightarrow \dots \rightarrow A_k$  von Einheitsregeln im Ableitungsbaum muss eine Paare Regel  $A_k \rightarrow BC$  oder Terminalregel  $A_k \rightarrow a$  folgen.

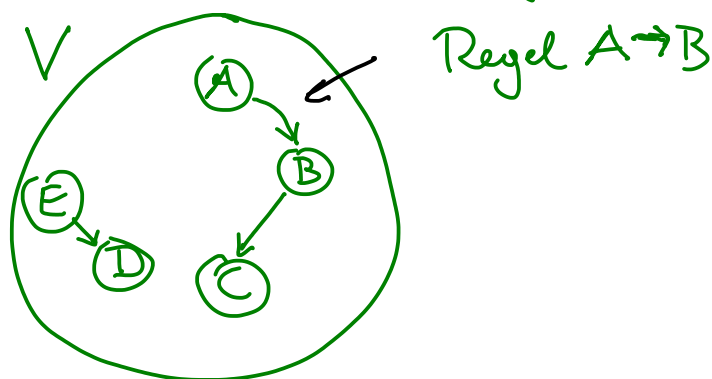
Die Anwendung der Einheitsregeln in der Kette wird durch die neue Regel  $A_1 \rightarrow BC$  bzw.  $A_1 \rightarrow a$  ersetzt.

$\rightarrow$  Ableitungsbaum ohne Einheitsregeln

Nun ist die Grammatik in CNF. □

\* Finden aller Paare  $A \Rightarrow^* B$  :

Erreichbarkeitsproblem im "Graphen der Einheitsregeln"



Beispiel 1.

$S \rightarrow aAa \mid bBb$

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

$A \rightarrow C \mid a$

$B \rightarrow C \mid b$

$C \rightarrow CD \mid \epsilon$

$D \rightarrow A \mid B \mid ab$

Schritt ①: Trennen von Variablen und Terminalsymbolen

$$\begin{array}{l} S \rightarrow V_a A V_a \mid V_b B V_b \\ A \rightarrow C \mid V_a \\ B \rightarrow C \mid V_b \\ C \rightarrow CD \mid \varepsilon \\ D \rightarrow A \mid B \mid V_a V_b \end{array} \quad \begin{array}{l} V_a \rightarrow a \\ V_b \rightarrow b \end{array}$$

Schritt ②: Behandlung zu langer Regeln

$$\begin{array}{l} S \rightarrow V_a E \mid V_b F \\ A \rightarrow C \mid V_a \\ B \rightarrow C \mid V_b \\ C \rightarrow CD \mid \varepsilon \\ D \rightarrow A \mid B \mid V_a V_b \end{array} \quad \begin{array}{l} V_a \rightarrow a \\ V_b \rightarrow b \\ E \rightarrow A V_a \\ F \rightarrow B V_b \end{array}$$

### Schritt ③: Elimination der $\epsilon$ -Regeln


$$\begin{array}{l|l}
 S \rightarrow V_a E & V_b F \\
 A \rightarrow C & V_a \\
 B \rightarrow C & V_b \\
 C \rightarrow \underline{CD} & \cancel{A} \mid C \mid D \\
 D \rightarrow A \mid B & V_a V_b
 \end{array}
 \quad
 \begin{array}{l}
 V_a \rightarrow \epsilon \\
 V_b \rightarrow b \\
 E \rightarrow A V_a \mid V_a \\
 F \rightarrow B V_b \mid V_b
 \end{array}$$

③a) Bestimme die Menge  $V_\epsilon := \{A \in V \mid A \xRightarrow{*} \epsilon\}$

③b) Zusätzliche Regeln

### Schritt ④: Elimination der Einheitsregeln

$$\begin{array}{l|l}
 \checkmark S \rightarrow V_a E & V_b F \\
 A \rightarrow \cancel{C} \mid V_a \mid a \mid b \mid CD \mid V_a V_b & \checkmark V_a \rightarrow \epsilon \\
 B \rightarrow \cancel{C} \mid V_b \mid a \mid b \mid CD \mid V_a V_b & \checkmark V_b \rightarrow b \\
 \checkmark C \rightarrow CD & \checkmark E \rightarrow A V_a \mid \cancel{V_a} \mid a \\
 \checkmark D \rightarrow \cancel{A} \mid B & \checkmark F \rightarrow B V_b \mid \cancel{V_b} \mid b
 \end{array}$$




Wenn  $A \xRightarrow{*} B$  und  $B \rightarrow a$ ,  
 Füge Regel  $A \rightarrow a$  hinzu

Wenn  $A \xRightarrow{*} B$  und  $B \rightarrow CD$ ,  
 Füge Regel  $A \rightarrow CD$  hinzu


# Beispiel 2: eindeutige Grammatik für arithmetische Ausdrücke

„Ausdruck“  $A \rightarrow T \mid A + T$   
 „Term“  $T \rightarrow F \mid T * F$   
 „Faktor“  $F \rightarrow Z \mid (A)$   
 „Zahl“  $Z \rightarrow 1 \mid 2 \mid 3$

Jeder Ausdruck ist die Summe von 1 oder mehr Termen, durch „+“ verbunden.



Jeder Term ist das Produkt von 1 oder mehr Faktoren, durch „\*“ verbunden.



$A \rightarrow F \mid AB \mid 1 \mid 2 \mid 3 \mid V_c D \mid TC$ ,  $B \rightarrow V_+ T$

$T \rightarrow F \mid TC \mid 1 \mid 2 \mid 3 \mid V_c D$ ,  $C \rightarrow V_* F$

$F \rightarrow Z \mid V_c D \mid 1 \mid 2 \mid 3$ ,  $D \rightarrow AV$

$Z \rightarrow 1 \mid 2 \mid 3$

$V_+ \rightarrow +$   $V_* \rightarrow *$

$V_c \rightarrow ($   $V_s \rightarrow )$

