

## 5b

**Die Chomsky-Normalform**

Prof. Dr. Jasmin Blanchette

Lehr- und Forschungseinheit für  
Theoretische Informatik und Theorembeweisen

Stand: 4. April 2024

Basiert auf Folien von PD Dr. David Sabel



Zusammenfassung:

- ▶ **Kontextfreie Sprachen** (*context-free languages*, CFLs) werden von **kontextfreien Grammatiken** (*context-free grammars*, CFGs) erzeugt.
- ▶ Das sind die **Typ 2-Sprachen** bzw. die **Typ 2-Grammatiken**.
- ▶ Bedingung: Alle linken Seiten der Produktionen bestehen aus genau einer Variablen, d.h. die Produktionen sind von der Form  $A \rightarrow r$ .

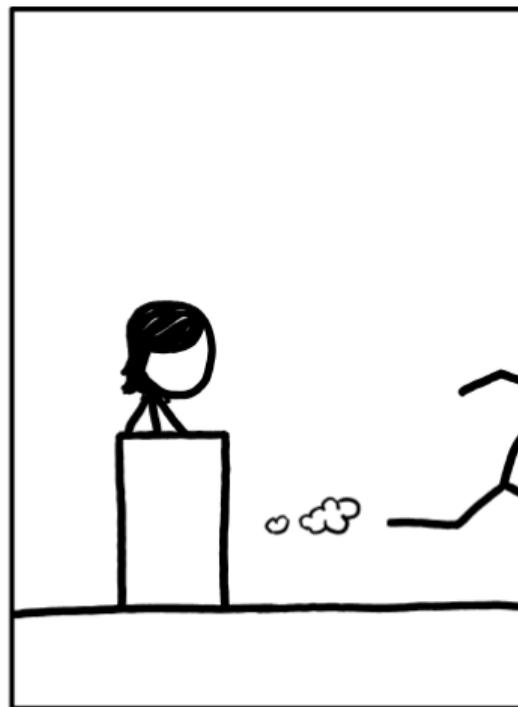
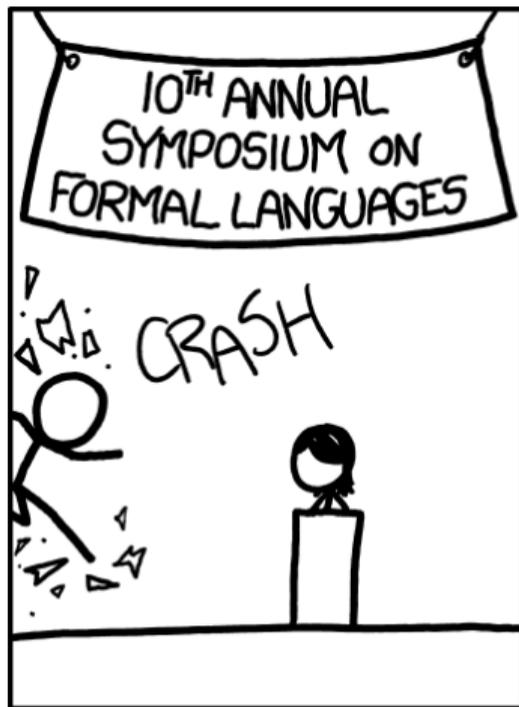
# Kontextfreie Sprachen

---

Zusammenfassung:

- ▶ **Kontextfreie Sprachen** (*context-free languages, CFLs*) werden von **kontextfreien Grammatiken** (*context-free grammars, CFGs*) erzeugt.
- ▶ Das sind die **Typ 2-Sprachen** bzw. die **Typ 2-Grammatiken**.
- ▶ Bedingung: Alle linken Seiten der Produktionen bestehen aus genau einer Variablen, d.h. die Produktionen sind von der Form  $A \rightarrow r$ .

Kontextfreie Sprachen sind insbesondere nützlich um Sprachen mit Klammerungen zu beschreiben, z.B. Programmiersprachen.



[xkcd.com/1090/](http://xkcd.com/1090/)

# Beispiele für kontextfreie Sprachen

---

Die CFG  $G_1 = (\{S, T\}, \{a, b\}, P_1, S)$  mit

$$P_1 := \{S \rightarrow \varepsilon \mid T, \\ T \rightarrow aTb \mid ab\}$$

erzeugt die Sprache  $\{a^j b^j \mid j \in \mathbb{N}\}$ , die daher kontextfrei ist.

## Beispiele für kontextfreie Sprachen

Die CFG  $G_1 = (\{S, T\}, \{a, b\}, P_1, S)$  mit

$$P_1 := \{S \rightarrow \varepsilon \mid T, \\ T \rightarrow aTb \mid ab\}$$

erzeugt die Sprache  $\{a^j b^j \mid j \in \mathbb{N}\}$ , die daher kontextfrei ist.

Die CFG  $G_2 = (\{E, M, A, Z, R\}, \{+, *, (, )\} \cup \{0, \dots, 9\}, P_2, E)$  mit

$$P_2 := \{E \rightarrow M \mid E + M, \\ M \rightarrow A \mid M * A, \\ A \rightarrow Z \mid (E), \\ Z \rightarrow 1R \mid \dots \mid 9R, \\ R \rightarrow 0R \mid \dots \mid 9R \mid \varepsilon\}$$

erzeugt einfache **arithmetische Ausdrücke** nach der „Punkt vor Strich“-Regel.

# Normalformen von Grammatiken

---

- ▶ **Normalformen** fordern eine spezielle Form der Produktionen.
- ▶ Sie sind nützlich, wenn man Grammatiken analysiert oder Algorithmen auf Grammatiken formuliert: Man muss dann nur diese Form (statt aller erlaubten) von Produktionen betrachten.
- ▶ Wir betrachten zwei Normalformen:  
die **Chomsky-Normalform** und die **Greibach-Normalform**.

# Die Chomsky-Normalform

---

## Definition

Eine CFG  $G = (V, \Sigma, P, S)$  ist in **Chomsky-Normalform**, wenn für jede Produktion  $A \rightarrow w \in P$  gilt:  $w = a \in \Sigma$  oder  $w = BC$  mit  $B, C \in V$ .

# Die Chomsky-Normalform

## Definition

Eine CFG  $G = (V, \Sigma, P, S)$  ist in **Chomsky-Normalform**, wenn für jede Produktion  $A \rightarrow w \in P$  gilt:  $w = a \in \Sigma$  oder  $w = BC$  mit  $B, C \in V$ .

Beispiele:

- ▶ Die CFG  $G_0 = (\{A\}, \{(\,), [, ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$  ist **nicht** in Chomsky-Normalform. Nur die Produktion  $A \rightarrow AA$  passt zum vorgeschriebenen Format.

# Die Chomsky-Normalform

## Definition

Eine CFG  $G = (V, \Sigma, P, S)$  ist in **Chomsky-Normalform**, wenn für jede Produktion  $A \rightarrow w \in P$  gilt:  $w = a \in \Sigma$  oder  $w = BC$  mit  $B, C \in V$ .

Beispiele:

- ▶ Die CFG  $G_0 = (\{A\}, \{(\,), [, ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$  ist **nicht** in Chomsky-Normalform. Nur die Produktion  $A \rightarrow AA$  passt zum vorgeschriebenen Format.
- ▶ Die CFG  $G = (\{A, B, C, D, E, F, G\}, \{(\,), [, ]\}, P, A)$  mit

$$P := \{A \rightarrow BF \mid BC \mid DG \mid DE \mid AA, \\ B \rightarrow (, C \rightarrow ), D \rightarrow [, E \rightarrow ], F \rightarrow AC, G \rightarrow AE\}$$

ist in Chomsky-Normalform, und erzeugt dieselbe Sprache wie  $G_0$ .

# Eigenschaften der Chomsky-Normalform

---

Für CFG  $G$  in Chomsky-Normalform gilt, dass Ableitungen eines Worts  $w \in L(G)$  immer genau aus  $2 \cdot |w| - 1$  Ableitungsschritten bestehen.

Zudem sind die dazugehörigen Syntaxbäume immer **Binärbäume** (Bäume, wobei jeder Knoten 0 oder 2 Kinder hat), bis auf die letzte Schicht, die Produktionen  $A \rightarrow a$  anwendet.

# Eigenschaften der Chomsky-Normalform

Für CFG  $G$  in Chomsky-Normalform gilt, dass Ableitungen eines Worts  $w \in L(G)$  immer genau aus  $2 \cdot |w| - 1$  Ableitungsschritten bestehen.

Zudem sind die dazugehörigen Syntaxbäume immer Binärbäume (Bäume, wobei jeder Knoten 0 oder 2 Kinder hat), bis auf die letzte Schicht, die Produktionen  $A \rightarrow a$  anwendet.

Sei die CFG  $G' = (\{A, B, C, D, E, F, G\}, \{(\cdot), [, ]\}, P, A)$  mit

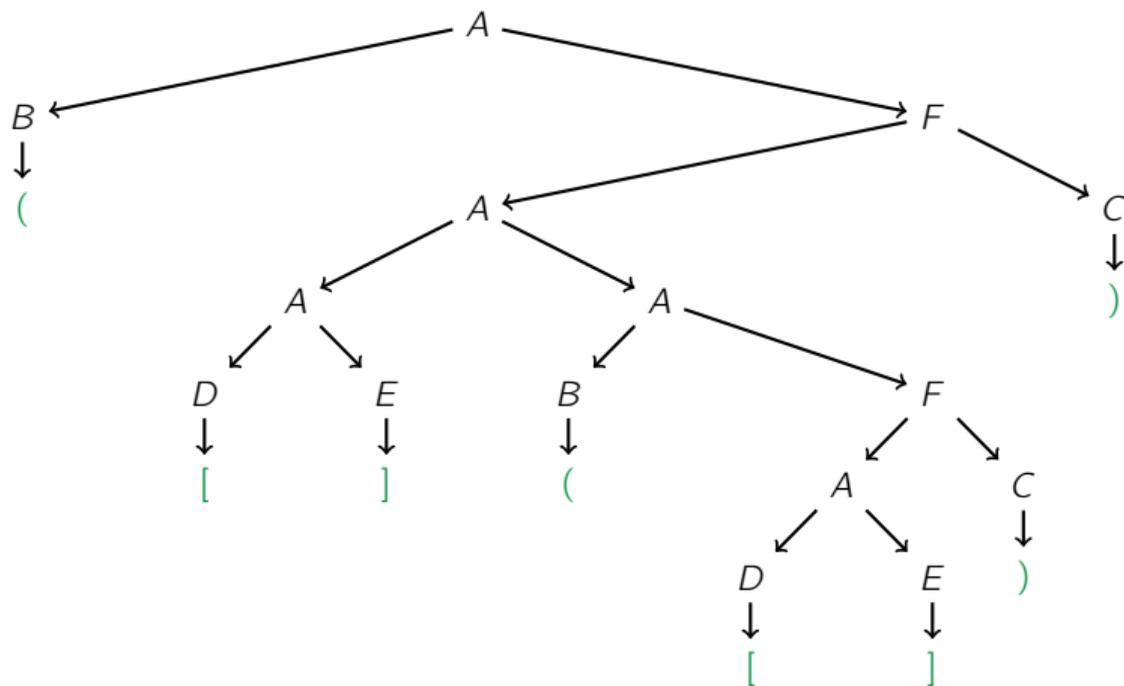
$$P := \{A \rightarrow BF \mid BC \mid DG \mid DE \mid AA, \\ B \rightarrow (\cdot, C \rightarrow \cdot), D \rightarrow [\cdot, E \rightarrow \cdot], F \rightarrow AC, G \rightarrow AE\}$$

Ableitung von  $(\cdot(\cdot(\cdot)))$ :

$$\begin{aligned} A &\Rightarrow BF \Rightarrow (F \Rightarrow (AC \Rightarrow (AAC \Rightarrow (DEAC \Rightarrow ([EAC \\ &\Rightarrow (\cdot AC \Rightarrow (\cdot BFC \Rightarrow (\cdot (FC \Rightarrow (\cdot (ACC \Rightarrow (\cdot (DECC \\ &\Rightarrow (\cdot ([ECC \Rightarrow (\cdot (\cdot CC \Rightarrow (\cdot (\cdot)C \Rightarrow (\cdot (\cdot) \end{aligned}$$

# Eigenschaften der Chomsky-Normalform

Der Syntaxbaum zur vorherigen Ableitung:



# Herstellen der Chomsky-Normalform

---

## Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

# Herstellen der Chomsky-Normalform

## Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

Grundgedanke der Prozedur:

1. Entferne  $\varepsilon$ -Produktionen (wie in früherer Vorlesung).
2. Entferne Produktionen von der Form  $A \rightarrow B$  („Entfernen von Einheitsproduktionen“).
3. Ersetze alle Terminale  $a$  in rechten Seiten, die nicht nur aus  $a$  bestehen durch neue Variablen  $A$  und füge Produktionen  $A \rightarrow a$  hinzu.
4. Zerlege alle Produktionen von der Form  $A \rightarrow B_1 \cdots B_m$  mit  $m > 2$  in mehrere:  
 $A \rightarrow B_1 C_1, C_1 \rightarrow B_2 C_2, \dots, C_{m-2} \rightarrow B_{m-1} B_m$ .

## Beispiel für die Herstellung der Chomsky-Normalform

---

0. Eingabe: CFG  $G_0 = (\{A\}, \{(\ , ), [\ , ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$ .

## Beispiel für die Herstellung der Chomsky-Normalform

---

0. Eingabe: CFG  $G_0 = (\{A\}, \{(\ , ), [\ , ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$ .
1. Es gibt keine  $\varepsilon$ -Produktionen zu entfernen.

## Beispiel für die Herstellung der Chomsky-Normalform

---

0. Eingabe: CFG  $G_0 = (\{A\}, \{(\ , ), [\ , ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$ .
1. Es gibt keine  $\varepsilon$ -Produktionen zu entfernen.
2. Es gibt keine Einheitsproduktionen zu entfernen.

## Beispiel für die Herstellung der Chomsky-Normalform

0. Eingabe: CFG  $G_0 = (\{A\}, \{(\ , \ ), [\ , ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$ .
1. Es gibt keine  $\varepsilon$ -Produktionen zu entfernen.
2. Es gibt keine Einheitsproduktionen zu entfernen.
3. Das Ersetzen von Terminale CFG führt zu  $G_3 = (\{A\}, \{(\ , \ ), [\ , ]\}, P_3, A)$  mit

$$P_3 := \{A \rightarrow BAC \mid BC \mid DAE \mid DE \mid AA\} \\ B \rightarrow (, C \rightarrow ), D \rightarrow [, E \rightarrow ]\}$$

## Beispiel für die Herstellung der Chomsky-Normalform

0. Eingabe: CFG  $G_0 = (\{A\}, \{(\ , \ ), [\ , ]\}, \{A \rightarrow (A) \mid () \mid [A] \mid [] \mid AA\}, A)$ .
1. Es gibt keine  $\varepsilon$ -Produktionen zu entfernen.
2. Es gibt keine Einheitsproduktionen zu entfernen.
3. Das Ersetzen von Terminale CFG führt zu  $G_3 = (\{A\}, \{(\ , \ ), [\ , ]\}, P_3, A)$  mit

$$P_3 := \{A \rightarrow BAC \mid BC \mid DAE \mid DE \mid AA\} \\ B \rightarrow (, C \rightarrow ), D \rightarrow [, E \rightarrow ]\}$$

4. Die Zerlegung von langen rechten Seiten führt zu  $G = (\{A, B, C, D, E, F, G\}, \{(\ , \ ), [\ , ]\}, P, A)$  mit

$$P := \{A \rightarrow BF \mid BC \mid DG \mid DE \mid AA, \\ B \rightarrow (, C \rightarrow ), D \rightarrow [, E \rightarrow ], F \rightarrow AC, G \rightarrow AE\}$$

# Entfernen von Einheitsproduktionen

---

Intuitiv ist klar, dass  $A \rightarrow B$  entfernt werden kann:  
Wenn erst  $A \rightarrow B$ , dann  $B \rightarrow w$  angewendet wird,  
kann man auch gleich  $A \rightarrow w$  anwenden.

# Entfernen von Einheitsproduktionen

---

Intuitiv ist klar, dass  $A \rightarrow B$  entfernt werden kann:  
Wenn erst  $A \rightarrow B$ , dann  $B \rightarrow w$  angewendet wird,  
kann man auch gleich  $A \rightarrow w$  anwenden.

Algorithmisch zu beachten:

- ▶ Eliminiere in der richtigen Reihenfolge: Wenn  $A \rightarrow B$  und  $B \rightarrow C$ , dann ist Ersetzen von  $A \rightarrow B$  durch  $A \rightarrow C$  nicht zielführend.
- ▶ Zyklen  $A_1 \rightarrow A_2, A_2 \rightarrow A_3, \dots, A_n \rightarrow A_1$  müssen vorher entfernt werden.

# Algorithmus 5: Entfernen von Einheitsproduktionen

**Eingabe:** Eine CFG  $G = (V, \Sigma, P, S)$

**Beginn**

Erzeuge gerichteten Graph  $D = (V, E)$ , mit  $(A, B) \in E$  für jede Einheitsproduktion  $A \rightarrow B \in P$ ;

**solange** es einen Zyklus  $(A_1, A_2), \dots, (A_{n-1}, A_n), (A_n, A_1) \in E$  gibt **tue**

```
P := P \setminus \{A_1 \rightarrow A_2, \dots, A_{n-1} \rightarrow A_n, A_n \rightarrow A_1\};           /* entferne zyklische Regeln */
P := P[A_1/A_2, \dots, A_1/A_n];           /* ersetze alle Vorkommen von A_i durch A_1 für i = 2, \dots, n */
V := V \setminus \{A_2, A_3, \dots, A_n\};           /* lösche A_2, \dots, A_n */
S := S[A_1/A_2, \dots, A_1/A_n];           /* ersetze Startsymbol durch A_1, falls es A_i, 2 \le i \le n war */
E := E \setminus \{(A_1, A_2), \dots, (A_{n-1}, A_n), (A_n, A_1)\};           /* entferne Zyklus aus Graph */
E := E[A_1/A_2, \dots, A_1/A_n];           /* ersetze A_i durch A_1 für i = 2, \dots, n in anderen Kanten */
```

Sortiere  $D$  topologisch und nummeriere die Variablen in  $V$  durch (und benenne entsprechend in  $E, P, S$  um), so dass gilt:  $A_i \rightarrow A_j$  impliziert  $i < j$ ;

Sei  $V = \{A_1, \dots, A_k\}$ ;

**für**  $i = k$  bis 1 **tue**

**wenn**  $A_i \rightarrow A_j \in P$  **dann**

Seien  $A_j \rightarrow w_1, \dots, A_j \rightarrow w_m$  alle Produktionen mit  $A_j$  als linker Seite;

```
P := P \cup \{A_i \rightarrow w_1, \dots, A_i \rightarrow w_m\};           /* füge A_i \rightarrow w_k hinzu für A_i \rightarrow A_j und A_j \rightarrow w_k */
```

```
P := P \setminus \{A_i \rightarrow A_j\};           /* entferne A_i \rightarrow A_j */
```

Gib die so entstandene Grammatik als  $G'$  aus;

### Satz

Algorithmus 5 berechnet bei Eingabe einer CFG  $G$  mit  $\varepsilon \notin L(G)$  eine CFG  $G'$ , die keine Einheitsproduktionen hat, sodass gilt  $L(G') = L(G)$ . Wenn  $G$  keine  $\varepsilon$ -Produktionen hat, dann hat auch  $G'$  keine  $\varepsilon$ -Produktionen.

### Satz

Algorithmus 5 berechnet bei Eingabe einer CFG  $G$  mit  $\varepsilon \notin L(G)$  eine CFG  $G'$ , die keine Einheitsproduktionen hat, sodass gilt  $L(G') = L(G)$ . Wenn  $G$  keine  $\varepsilon$ -Produktionen hat, dann hat auch  $G'$  keine  $\varepsilon$ -Produktionen.

**Beweis** Das Entfernen eines Zyklus ändert die erzeugte Sprache nicht.

### Satz

Algorithmus 5 berechnet bei Eingabe einer CFG  $G$  mit  $\varepsilon \notin L(G)$  eine CFG  $G'$ , die keine Einheitsproduktionen hat, sodass gilt  $L(G') = L(G)$ . Wenn  $G$  keine  $\varepsilon$ -Produktionen hat, dann hat auch  $G'$  keine  $\varepsilon$ -Produktionen.

**Beweis** Das Entfernen eines Zyklus ändert die erzeugte Sprache nicht.

Das Entfernen einer Einheitsproduktion  $A_i \rightarrow A_j$  in der rückwärts-laufenden für-Schleife ändert die erzeugte Sprache nicht. Dies ist eine Instanz der Operation „Inlining von Produktionen“, die wir gleich korrekt beweisen werden.

## Korrektheit von Algorithmus 5

---

**Beweis** (Fortsetzung) Es werden keine Einheitsproduktionen eingeführt, da die Produktionen topologisch sortiert behandelt werden. Wenn  $A_i \rightarrow A_j$  entfernt wird, wurden **vorher** alle Einheitsproduktionen  $A_j \rightarrow A_k$  entfernt. D.h. zu diesem Zeitpunkt gilt: für alle Produktionen  $A_j \rightarrow w$  besteht  $w$  nicht nur aus einer Variablen.

## Korrektheit von Algorithmus 5

---

**Beweis** (Fortsetzung) Es werden keine Einheitsproduktionen eingeführt, da die Produktionen topologisch sortiert behandelt werden. Wenn  $A_i \rightarrow A_j$  entfernt wird, wurden **vorher** alle Einheitsproduktionen  $A_j \rightarrow A_k$  entfernt. D.h. zu diesem Zeitpunkt gilt: für alle Produktionen  $A_j \rightarrow w$  besteht  $w$  nicht nur aus einer Variablen. Es werden offensichtlich nie  $\varepsilon$ -Produktionen eingeführt.

## Korrektheit von Algorithmus 5

---

**Beweis** (Fortsetzung) Es werden keine Einheitsproduktionen eingeführt, da die Produktionen topologisch sortiert behandelt werden. Wenn  $A_i \rightarrow A_j$  entfernt wird, wurden **vorher** alle Einheitsproduktionen  $A_j \rightarrow A_k$  entfernt. D.h. zu diesem Zeitpunkt gilt: für alle Produktionen  $A_j \rightarrow w$  besteht  $w$  nicht nur aus einer Variablen.

Es werden offensichtlich nie  $\varepsilon$ -Produktionen eingeführt.

Der Algorithmus terminiert:

- ▶ Die solange-Schleife terminiert, da jede Iteration die Anzahl der Zyklen strikt verkleinert.
- ▶ Die für-Schleife terminiert offensichtlich. □

## Lemma (Inlining von Produktionen)

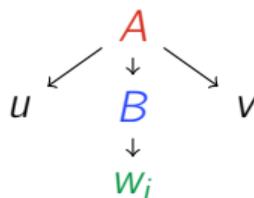
Sei  $G = (V, \Sigma, P, S)$  eine CFG mit

- ▶  $A \rightarrow uBv \in P$
- ▶  $B \rightarrow w_1 \mid \dots \mid w_n$  alle Regeln mit  $B$  als linker Seite

und sei  $G' = (V, \Sigma, (P \setminus \{A \rightarrow uBv\}) \cup \{A \rightarrow uw_1v \mid \dots \mid uw_nv\}, S)$ .  
Dann erzeugen  $G'$  und  $G$  dieselbe Sprache, d.h.  $L(G') = L(G)$ .

# Inlining von Produktionen

**Beweis** Das folgt durch Modifizieren der Syntaxbäume zur Ableitung mit  $G$  bzw.  $G'$ :  
Tausche alle Baumabschnitte



im Syntaxbaum mit  $G$  durch



im Syntaxbaum mit  $G'$ .



# Algorithmus 6: Herstellen der Chomsky-Normalform

**Eingabe:** CFG  $G$  mit  $\varepsilon \notin L(G)$

**Ausgabe:** CFG  $G'$  in Chomsky-Normalform mit  $L(G') = L(G)$

## Beginn

Entferne die  $\varepsilon$ -Produktionen in  $G$  mit Algorithmus 1 und entferne anschließend die Einheitsproduktionen mit Algorithmus 5;

Sei  $G' = (V', \Sigma, P', S')$  die entstandene Grammatik;

**für alle**  $a \in \Sigma$  **tue**

Sei  $B$  eine neue Variable;

*/\* Führe neue Variable  $B$  für  $a$  ein, und ersetze Vorkommen von  $a$  durch  $B$  \*/*

$G' := (V' \cup \{B\}, \Sigma, \{A \rightarrow w[B/a] \mid A \rightarrow w \in P' \text{ und } |w| > 1\}$   
 $\cup \{A \rightarrow w \mid A \rightarrow w \in P' \text{ und } |w| = 1\} \cup \{B \rightarrow a\}, S)$

*/\* Nun sind alle Regeln von der Form  $A \rightarrow a$  oder  $A \rightarrow B_1 \cdots B_m$  mit  $m \geq 2$  \*/*

**für alle**  $A \rightarrow B_1 \cdots B_m \in P'$  mit  $m > 2$  **tue**

Seien  $C_1, \dots, C_{m-2}$  neue Variablen;

$V' := V' \cup \{C_1, \dots, C_{m-2}\}$ ;

*/\* Ersetze in  $P'$  die Produktion  $A \rightarrow B_1 \cdots B_m$  durch neue Regeln \*/*

$P' := (P' \setminus \{A \rightarrow B_1 \cdots B_m\})$   
 $\cup \{A \rightarrow B_1 C_1\} \cup \{C_i \rightarrow B_{i+1} C_{i+1} \mid \text{für } i = 1, \dots, m-3\} \cup \{C_{m-2} \rightarrow B_{m-1} B_m\}$ ;

### Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

## Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

**Beweis** Algorithmus 6 berechnet eine solche äquivalente CFG.

## Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

**Beweis** Algorithmus 6 berechnet eine solche äquivalente CFG.

Die Schritte „Entfernen der  $\varepsilon$ -Produktionen“ und „Entfernen von Einheitsproduktionen“ haben wir als korrekt gezeigt.

# Korrektheit von Algorithmus 6

## Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

**Beweis** Algorithmus 6 berechnet eine solche äquivalente CFG.

Die Schritte „Entfernen der  $\varepsilon$ -Produktionen“ und „Entfernen von Einheitsproduktionen“ haben wir als korrekt gezeigt.

Die Schritte „Einführen von Produktionen  $B \rightarrow a$ “ und „Behandlung von  $A \rightarrow B_1 \cdots B_m$ “ sind Varianten der korrekten Operation „Boxing von Satzformen“, die wir gleich korrekt beweisen werden.

## Korrektheit von Algorithmus 6

### Theorem

Für jede CFG  $G$  mit  $\varepsilon \notin L(G)$  kann eine CFG  $G'$  in Chomsky-Normalform berechnet werden, sodass  $L(G') = L(G)$  gilt.

**Beweis** Algorithmus 6 berechnet eine solche äquivalente CFG.

Die Schritte „Entfernen der  $\varepsilon$ -Produktionen“ und „Entfernen von Einheitsproduktionen“ haben wir als korrekt gezeigt.

Die Schritte „Einführen von Produktionen  $B \rightarrow a$ “ und „Behandlung von  $A \rightarrow B_1 \cdots B_m$ “ sind Varianten der korrekten Operation „Boxing von Satzformen“, die wir gleich korrekt beweisen werden.

Am Ende der Berechnung haben alle Produktionen die gewünschte Form. □

## Lemma (Boxing von Satzformen)

Sei  $G$  eine CFG mit  $G = (V, \Sigma, P \cup \{A \rightarrow w_1 \cdots w_n\}, S)$ .

Seien  $B_1, \dots, B_n$  neue Variablen (d.h.  $V \cap \{B_1, \dots, B_n\} = \emptyset$ ) und sei

$G' = (V \cup \{B_1, \dots, B_n\}, \Sigma, P \cup \{A \rightarrow B_1 \cdots B_n, B_1 \rightarrow w_1, \dots, B_n \rightarrow w_n\}, S)$ .

Dann gilt  $L(G') = L(G)$ .

## Lemma (Boxing von Satzformen)

Sei  $G$  eine CFG mit  $G = (V, \Sigma, P \cup \{A \rightarrow w_1 \cdots w_n\}, S)$ .

Seien  $B_1, \dots, B_n$  neue Variablen (d.h.  $V \cap \{B_1, \dots, B_n\} = \emptyset$ ) und sei

$G' = (V \cup \{B_1, \dots, B_n\}, \Sigma, P \cup \{A \rightarrow B_1 \cdots B_n, B_1 \rightarrow w_1, \dots, B_n \rightarrow w_n\}, S)$ .

Dann gilt  $L(G') = L(G)$ .

## Beweis

$\supseteq$  Wir zeigen:  $w \in L(G)$  impliziert  $w \in L(G')$ .

Konstruiere aus  $S \Rightarrow_G^* w$  die Ableitung  $S \Rightarrow_{G'}^* w$ : Übersetze jeden Schritt

$uAv \Rightarrow_G uw_1 \cdots w_nv$  in  $uAv \Rightarrow_{G'} uB_1 \cdots B_nv \Rightarrow_{G'}^n uw_1 \cdots w_nv$ .

## Beweis

⊆ Wir zeigen:  $w \in L(G')$  impliziert  $w \in L(G)$ .

Betrachte den Syntaxbaum für  $S \Rightarrow_{G'}^* w$ .

Identifiziere die Anwendungen der Regeln  $A \rightarrow B_1 \cdots B_n$  und  $B_i \rightarrow w_i$ , und modifiziere den Syntaxbaum durch Anwendung der Regel  $A \rightarrow w_1 \cdots w_n$ .

Lies Ableitung  $S \Rightarrow_G^* w$  ab. □

## Weiteres Beispiel für die Herstellung der Chomsky-Normalform

---

Eingabe:  $G_0 = (\{A, B, C, D, S\}, \{0, 1\}, P_0, S)$  mit  
 $P_0 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, A \rightarrow \varepsilon,$   
 $B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$

## Schritt 1: Entfernen der $\varepsilon$ -Produktionen

---

$G_0 = (\{A, B, C, D, S\}, \{0, 1\}, P_0, S)$  mit  
 $P_0 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, A \rightarrow \varepsilon, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$

## Schritt 1: Entfernen der $\varepsilon$ -Produktionen

---

$G_0 = (\{A, B, C, D, S\}, \{0, 1\}, P_0, S)$  mit  
 $P_0 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, A \rightarrow \varepsilon, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$

- Menge  $W$  der Variablen, die  $\varepsilon$  herleiten:  
 $W = \{A, C\}$  da  $A \rightarrow \varepsilon$  und  $C \rightarrow AAA$ .

## Schritt 1: Entfernen der $\varepsilon$ -Produktionen

$G_0 = (\{A, B, C, D, S\}, \{0, 1\}, P_0, S)$  mit  
 $P_0 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, A \rightarrow \varepsilon, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$

- ▶ Menge  $W$  der Variablen, die  $\varepsilon$  herleiten:  
 $W = \{A, C\}$  da  $A \rightarrow \varepsilon$  und  $C \rightarrow AAA$ .

- ▶ Starte mit

$G_1 = (\{A, B, C, D, S\}, \{0, 1\}, P_1, S)$  mit  
 $P_1 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$ .

## Schritt 1: Entfernen der $\varepsilon$ -Produktionen

$G_0 = (\{A, B, C, D, S\}, \{0, 1\}, P_0, S)$  mit  
 $P_0 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, A \rightarrow \varepsilon, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$

- ▶ Menge  $W$  der Variablen, die  $\varepsilon$  herleiten:  
 $W = \{A, C\}$  da  $A \rightarrow \varepsilon$  und  $C \rightarrow AAA$ .

- ▶ Starte mit

$G_1 = (\{A, B, C, D, S\}, \{0, 1\}, P_1, S)$  mit  
 $P_1 = \{S \rightarrow 1A, A \rightarrow AB, A \rightarrow DA, B \rightarrow 0,$   
 $B \rightarrow 1, C \rightarrow AAA, D \rightarrow 1AC\}$ .

- ▶ Füge Produktionen für Vorkommen von  $A$  und  $C$  hinzu:

$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D,$   
 $B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A,$   
 $D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$ .

## Schritt 2: Entfernen der Einheitsproduktionen

---

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

## Schritt 2: Entfernen der Einheitsproduktionen

---

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

- ▶ Der gerichtete Graph ist  $D' = (\{S, A, B, C, D\}, \{(A, B), (A, D), (C, A)\})$ .

## Schritt 2: Entfernen der Einheitsproduktionen

---

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

- ▶ Der gerichtete Graph ist  $D' = (\{S, A, B, C, D\}, \{(A, B), (A, D), (C, A)\})$ .
- ▶ Es gibt keine Zyklen, wir erhalten  $P_2 = P_1$ .

## Schritt 2: Entfernen der Einheitsproduktionen

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

- ▶ Der gerichtete Graph ist  $D' = (\{S, A, B, C, D\}, \{(A, B), (A, D), (C, A)\})$ .
- ▶ Es gibt keine Zyklen, wir erhalten  $P_2 = P_1$ .
- ▶ Topologisches Sortieren und Umbenennen der Variablen, sodass „ $A_i \rightarrow A_j$  impliziert  $i < j$ “ gilt, erfordert eine Umbenennung  $\rho$ , welche die Beziehungen  $A < B, A < D, C < A$  erzeugt.

## Schritt 2: Entfernen der Einheitsproduktionen

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

- ▶ Der gerichtete Graph ist  $D' = (\{S, A, B, C, D\}, \{(A, B), (A, D), (C, A)\})$ .
- ▶ Es gibt keine Zyklen, wir erhalten  $P_2 = P_1$ .
- ▶ Topologisches Sortieren und Umbenennen der Variablen, sodass „ $A_i \rightarrow A_j$  impliziert  $i < j$ “ gilt, erfordert eine Umbenennung  $\rho$ , welche die Beziehungen  $A < B$ ,  $A < D$ ,  $C < A$  erzeugt.
- ▶ Wir wählen  $\rho$  mit  $\rho(C) = A_1$ ,  $\rho(A) = A_2$ ,  $\rho(B) = A_3$ ,  $\rho(D) = A_4$ ,  $\rho(S) = A_5$ .

## Schritt 2: Entfernen der Einheitsproduktionen

$$P_1 = \{S \rightarrow 1A, S \rightarrow 1, A \rightarrow AB, A \rightarrow B, A \rightarrow DA, A \rightarrow D, \\ B \rightarrow 0, B \rightarrow 1, C \rightarrow AAA, C \rightarrow AA, C \rightarrow A, \\ D \rightarrow 1AC, D \rightarrow 1A, D \rightarrow 1C, D \rightarrow 1\}$$

- ▶ Der gerichtete Graph ist  $D' = (\{S, A, B, C, D\}, \{(A, B), (A, D), (C, A)\})$ .
- ▶ Es gibt keine Zyklen, wir erhalten  $P_2 = P_1$ .
- ▶ Topologisches Sortieren und Umbenennen der Variablen, sodass „ $A_i \rightarrow A_j$  impliziert  $i < j$ “ gilt, erfordert eine Umbenennung  $\rho$ , welche die Beziehungen  $A < B, A < D, C < A$  erzeugt.
- ▶ Wir wählen  $\rho$  mit  $\rho(C) = A_1, \rho(A) = A_2, \rho(B) = A_3, \rho(D) = A_4, \rho(S) = A_5$ .
- ▶ Das liefert uns  $G_3 = (\{A_1, A_2, A_3, A_4, A_5\}, \Sigma, P_3, A_5)$  mit
$$P_3 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow A_3, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow A_4, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, \\ A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

## Schritt 2: Entfernen der Einheitsproduktionen

---

$$P_3 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow A_3, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow A_4, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, \\ A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

- Nun läuft die für-Schleife für  $i$  von 5 bis 1:

## Schritt 2: Entfernen der Einheitsproduktionen

---

$$P_3 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow A_3, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow A_4, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, \\ A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

- ▶ Nun läuft die für-Schleife für  $i$  von 5 bis 1:
  - ▶ Für  $i = 5, i = 4, i = 3$  gibt es jeweils keine Produktion der Form  $A_i \rightarrow A_j$ .

## Schritt 2: Entfernen der Einheitsproduktionen

$$P_3 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow A_3, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow A_4, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, \\ A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

► Nun läuft die für-Schleife für  $i$  von 5 bis 1:

► Für  $i = 5, i = 4, i = 3$  gibt es jeweils keine Produktion der Form  $A_i \rightarrow A_j$ .

► Für  $i = 2$  wird  $A_2 \rightarrow A_3$  ersetzt durch  $A_2 \rightarrow 0, A_2 \rightarrow 1$ , und es wird  $A_2 \rightarrow A_4$  ersetzt durch  $A_2 \rightarrow 1A_2A_1, A_2 \rightarrow 1A_2, A_2 \rightarrow 1A_1$  und  $A_2 \rightarrow 1$ .  
Danach ist

$$P_4 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow 0, A_2 \rightarrow 1, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow 1A_2A_1, A_2 \rightarrow 1A_2, A_2 \rightarrow 1A_1, A_3 \rightarrow 0, A_3 \rightarrow 1, \\ A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, \\ A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

## Schritt 2: Entfernen der Einheitsproduktionen

$$P_3 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow A_3, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow A_4, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, \\ A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

► Nun läuft die für-Schleife für  $i$  von 5 bis 1:

► Für  $i = 5, i = 4, i = 3$  gibt es jeweils keine Produktion der Form  $A_i \rightarrow A_j$ .

► Für  $i = 2$  wird  $A_2 \rightarrow A_3$  ersetzt durch  $A_2 \rightarrow 0, A_2 \rightarrow 1$ , und es wird  $A_2 \rightarrow A_4$  ersetzt durch  $A_2 \rightarrow 1A_2A_1, A_2 \rightarrow 1A_2, A_2 \rightarrow 1A_1$  und  $A_2 \rightarrow 1$ .  
Danach ist

$$P_4 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow 0, A_2 \rightarrow 1, A_2 \rightarrow A_4A_2, \\ A_2 \rightarrow 1A_2A_1, A_2 \rightarrow 1A_2, A_2 \rightarrow 1A_1, A_3 \rightarrow 0, A_3 \rightarrow 1, \\ A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, A_1 \rightarrow A_2, A_4 \rightarrow 1A_2A_1, \\ A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$$

► Für  $i = 1$  wird  $A_1 \rightarrow A_2$  ersetzt durch  $A_1 \rightarrow A_2A_3, A_1 \rightarrow 0, A_1 \rightarrow 1, A_1 \rightarrow A_4A_2, \\ A_1 \rightarrow 1A_2A_1, A_1 \rightarrow 1A_2$  und  $A_1 \rightarrow 1A_1$ .

## Schritt 2: Entfernen der Einheitsproduktionen

- Daher ist die Grammatik nach Entfernen der Einheitsproduktionen:

$G_5 = (V_5, \Sigma, P_5, A_5)$  mit  $V_5 = \{A_1, A_2, A_3, A_4, A_5\}$  und

$P_5 = \{A_5 \rightarrow 1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow 0, A_2 \rightarrow 1,$

$A_2 \rightarrow A_4A_2, A_2 \rightarrow 1A_2A_1, A_2 \rightarrow 1A_2, A_2 \rightarrow 1A_1, A_3 \rightarrow 0,$

$A_3 \rightarrow 1, A_1 \rightarrow A_2A_2A_2, A_1 \rightarrow A_2A_2, A_1 \rightarrow A_2A_3, A_1 \rightarrow 0,$

$A_1 \rightarrow 1, A_1 \rightarrow A_4A_2, A_1 \rightarrow 1A_2A_1, A_1 \rightarrow 1A_2, A_1 \rightarrow 1A_1,$

$A_4 \rightarrow 1A_2A_1, A_4 \rightarrow 1A_2, A_4 \rightarrow 1A_1, A_4 \rightarrow 1\}$

## Schritt 3: Terminale durch Variablen darstellen

- Füge  $B_0 \rightarrow 0$  und  $B_1 \rightarrow 1$  hinzu und ersetze in rechten Seiten mit Wortlänge  $> 1$ :

$$P_6 = \{B_0 \rightarrow 0, B_1 \rightarrow 1, A_5 \rightarrow B_1 A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2 A_3, A_2 \rightarrow 0, \\ A_2 \rightarrow 1, A_2 \rightarrow A_4 A_2, A_2 \rightarrow B_1 A_2 A_1, A_2 \rightarrow B_1 A_2, \\ A_2 \rightarrow B_1 A_1, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2 A_2 A_2, A_1 \rightarrow A_2 A_2, \\ A_1 \rightarrow A_2 A_3, A_1 \rightarrow 0, A_1 \rightarrow 1, A_1 \rightarrow A_4 A_2, A_1 \rightarrow B_1 A_2 A_1, \\ A_1 \rightarrow B_1 A_2, A_1 \rightarrow B_1 A_1, A_4 \rightarrow B_1 A_2 A_1, \\ A_4 \rightarrow B_1 A_2, A_4 \rightarrow B_1 A_1, A_4 \rightarrow 1\}$$

## Schritt 4: Rechte Seiten zerlegen

- Zerlege rechte Seiten mit Wortlänge  $> 2$ :

Ergibt  $G_7 = (V_7, \Sigma, P_7, A_5)$ , wobei

$$V_7 = \{A_1, A_2, A_3, A_4, A_5, B_0, B_1, C_1, C_2, C_3, C_4\}$$

$$P_7 = \{B_0 \rightarrow 0, B_1 \rightarrow 1, A_5 \rightarrow B_1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow 0, \\ A_2 \rightarrow 1, A_2 \rightarrow A_4A_2, A_2 \rightarrow B_1C_1, C_1 \rightarrow A_2A_1, \\ A_2 \rightarrow B_1A_2, A_2 \rightarrow B_1A_1, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2C_2, \\ C_2 \rightarrow A_2A_2, A_1 \rightarrow A_2A_2, A_1 \rightarrow A_2A_3, A_1 \rightarrow 0, A_1 \rightarrow 1, \\ A_1 \rightarrow A_4A_2, A_1 \rightarrow B_1C_3, C_3 \rightarrow A_2A_1, A_1 \rightarrow B_1A_2, \\ A_1 \rightarrow B_1A_1, A_4 \rightarrow B_1C_4, C_4 \rightarrow A_2A_1, A_4 \rightarrow B_1A_2, \\ A_4 \rightarrow B_1A_1, A_4 \rightarrow 1\}$$

## Schritt 4: Rechte Seiten zerlegen

- Zerlege rechte Seiten mit Wortlänge  $> 2$ :

Ergibt  $G_7 = (V_7, \Sigma, P_7, A_5)$ , wobei

$$V_7 = \{A_1, A_2, A_3, A_4, A_5, B_0, B_1, C_1, C_2, C_3, C_4\}$$

$$P_7 = \{B_0 \rightarrow 0, B_1 \rightarrow 1, A_5 \rightarrow B_1A_2, A_5 \rightarrow 1, A_2 \rightarrow A_2A_3, A_2 \rightarrow 0, \\ A_2 \rightarrow 1, A_2 \rightarrow A_4A_2, A_2 \rightarrow B_1C_1, C_1 \rightarrow A_2A_1, \\ A_2 \rightarrow B_1A_2, A_2 \rightarrow B_1A_1, A_3 \rightarrow 0, A_3 \rightarrow 1, A_1 \rightarrow A_2C_2, \\ C_2 \rightarrow A_2A_2, A_1 \rightarrow A_2A_2, A_1 \rightarrow A_2A_3, A_1 \rightarrow 0, A_1 \rightarrow 1, \\ A_1 \rightarrow A_4A_2, A_1 \rightarrow B_1C_3, C_3 \rightarrow A_2A_1, A_1 \rightarrow B_1A_2, \\ A_1 \rightarrow B_1A_1, A_4 \rightarrow B_1C_4, C_4 \rightarrow A_2A_1, A_4 \rightarrow B_1A_2, \\ A_4 \rightarrow B_1A_1, A_4 \rightarrow 1\}$$

$G_7$  ist in Chomsky-Normalform.