

## Beispiel 62

Wir wollen sehen, dass die Sprache

$$\{a^i b^i c^i; i \in \mathbb{N}_0\}$$

nicht kontextfrei ist.

Wäre sie kontextfrei, so könnten wir das Wort  $a^n b^n c^n$  ( $n$  die Konstante aus dem Pumping-Lemma) aufpumpen, ohne aus der Sprache herauszufallen. Wir sehen aber leicht, dass das Teilwort  $v$  nur aus  $a$ 's bestehen kann und bei jeder möglichen Verteilung des Teilworts  $x$  Pumpen entweder die Anzahl der  $a$ 's,  $b$ 's und  $c$ 's unterschiedlich ändert oder, wenn

$$(\#_a(vx) =) \#_b(vx) = \#_c(vx) > 0 ,$$

dass  $b$ 's und  $c$ 's in der falschen Reihenfolge auftreten.

Zur Vereinfachung von Beweisen wie in dem gerade gesehenen Beispiel führen wir die folgende Verschärfung des Pumping-Lemmas ein:

### Satz 63 (Ogdens Lemma)

*Für jede kontextfreie Sprache  $L$  gibt es eine Konstante  $n \in \mathbb{N}$ , so dass für jedes Wort  $z \in L$  mit  $|z| \geq n$  die folgende Aussage gilt: Werden in  $z$  mindestens  $n$  (beliebige) Buchstaben markiert, so lässt sich  $z$  zerlegen in*

$$z = uvwxy,$$

so dass

- 1 in  $vx$  mindestens ein Buchstabe und
- 2 in  $vwx$  höchstens  $n$  Buchstaben markiert sind und
- 3  $(\forall i \in \mathbb{N}_0)[uv^iwx^i y \in L]$ .

**Bemerkung:** Das Pumping-Lemma ist eine triviale Folgerung aus Ogdens Lemma (markiere alle Buchstaben in  $z$ ).

## Beweis:

Sei  $G = (V, \Sigma, P, S)$  eine Grammatik in Chomsky-Normalform mit  $L(G) = L$ . Wähle  $n = 2^{|V|+1}$ . Sei  $z \in L$  und seien in  $z$  mindestens  $n$  Buchstaben markiert. In einem Ableitungsbaum für  $z$  markieren wir alle (inneren) Knoten, deren linker *und* rechter Teilbaum *jeweils* mindestens ein markiertes Blatt enthalten. Es ist nun offensichtlich, dass es einen Pfad von der Wurzel zu einem Blatt gibt, auf dem mindestens  $|V| + 1$  markierte innere Knoten liegen.

## Beweis:

...

Wir betrachten die letzten  $|V| + 1$  markierten inneren Knoten eines Pfades mit maximaler Anzahl markierter Knoten; nach dem Schubfachprinzip sind zwei mit demselben Nichtterminal, z.B.  $A$ , markiert. Wir nennen diese Knoten  $v_1$  und  $v_2$ . Seien die Blätter des Teilbaumes mit der Wurzel  $v_2$  insgesamt mit  $w$  und die Blätter des Teilbaumes mit der Wurzel  $v_1$  insgesamt mit  $vwx$  beschriftet. Es ist dann klar, dass die folgende Ableitung möglich ist:

$$S \rightarrow^* uAy \rightarrow^* uvAxy \rightarrow^* uvwxy.$$

Es ist auch klar, dass der Mittelteil dieser Ableitung weggelassen oder beliebig oft wiederholt werden kann.

## Beweis:

...

Es bleibt noch zu sehen, dass  $vx$  mindestens einen und  $vw$  höchstens  $n$  markierte Buchstaben enthält. Ersteres ist klar, da auch der Unterbaum von  $v_1$ , der  $v_2$  nicht enthält, ein markiertes Blatt haben muss.

Letzteres ist klar, da der gewählte Pfad eine maximale Anzahl von markierten inneren Knoten hatte und unterhalb von  $v_1$  nur noch höchstens  $|V|$  markierte Knoten auf diesem Pfad sein können. Der Teilbaum mit Wurzel  $v_1$  kann also maximal  $2^{|V|+1} = n$  markierte Blätter haben. Formal kann man z.B. zeigen, dass ein Unterbaum, der auf jedem Ast maximal  $k$  markierte (innere) Knoten enthält, höchstens  $2^k$  markierte Blätter enthält. □

## Beispiel 64

$$L = \{a^i b^j c^k d^l; i = 0 \text{ oder } j = k = l\}.$$

Sei  $n$  die Konstante aus Ogden's Lemma. Betrachte das Wort  $ab^n c^n d^n$  und markiere darin  $bc^n d$ . Nun gibt es eine Zerlegung  $ab^n c^n d^n = uvwxy$ , so dass  $vx$  mindestens ein markiertes Symbol enthält und  $uv^2wx^2y \in L$ .

Es ist jedoch leicht zu sehen, dass dies einen Widerspruch liefert, da  $vx$  höchstens zwei verschiedene der Symbole  $b, c, d$  enthalten kann, damit beim Pumpen nicht die Reihenfolge durcheinander kommt.

## 4.5 Algorithmen für kontextfreie Sprachen/Grammatiken

### Satz 65

Sie  $G = (V, \Sigma, P, S)$  kontextfrei. Dann kann die Menge  $V'$  der Variablen  $A \in V$ , für die gilt:

$$(\exists w \in \Sigma^*)[A \rightarrow^* w]$$

in Zeit  $O(|V| \cdot s(G))$  berechnet werden.

Beweis:

Betrachte folgenden Algorithmus:

```
 $\Delta := \{A \in V; (\exists(A \rightarrow w) \in P \text{ mit } w \in \Sigma^*)\}; V' := \emptyset;$   
while  $\Delta \neq \emptyset$  do  
     $V' := V' \cup \Delta$   
     $\Delta := \{A \in V \setminus V'; (\exists A \rightarrow \alpha) \in P \text{ mit } \alpha \in (V' \cup \Sigma)^*\}$   
od
```

Induktion über die Länge der Ableitung. □

## Definition 66

$A \in V$  heißt **nutzlos**, falls es keine Ableitung

$$S \rightarrow^* w, \quad w \in \Sigma^*$$

gibt, in der  $A$  vorkommt.

## Satz 67

*Die Menge der nutzlosen Variablen kann in Zeit  $O(|V| \cdot s(G))$  bestimmt werden.*



## Beweis:

Sei  $V''$  die Menge der nicht nutzlosen Variablen.

Offensichtlich gilt:  $V'' \subseteq V'$  ( $V'$  aus dem vorigen Satz).

Falls  $S \notin V'$ , dann sind alle Variablen nutzlos.

Ansonsten:

$\Delta := \{S\}; V'' := \emptyset;$

**while**  $\Delta \neq \emptyset$  **do**

$V'' := V'' \cup \Delta$

$\Delta := \{B \in V' \setminus V''; (\exists A \rightarrow \alpha B \beta) \in P \text{ mit } A \in V'',$   
 $\alpha, \beta \in (V' \cup \Sigma)^*\}$

**od**

Induktion über Länge der Ableitung: Am Ende des Algorithmus ist  $V''$  gleich der Menge der nicht nutzlosen Variablen.  $\square$

**Bemerkung:** Alle nutzlosen Variablen und alle Produktionen, die nutzlose Variablen enthalten, können aus der Grammatik entfernt werden, ohne die erzeugte Sprache zu ändern.

## Korollar 68

Für eine kontextfreie Grammatik  $G$  kann in Zeit  $O(|V| \cdot s(G))$  entschieden werden, ob  $L(G) = \emptyset$ .

Beweis:

$$L(G) = \emptyset \iff S \notin V'' \text{ (bzw. } S \notin V')$$



## Satz 69

Für eine kontextfreie Grammatik  $G = (V, \Sigma, P, S)$  ohne nutzlose Variablen und in Chomsky-Normalform kann in linearer Zeit entschieden werden, ob

$$|L(G)| < \infty.$$

### Beweis:

Definiere gerichteten Hilfsgraphen mit Knotenmenge  $V$  und

$$\text{Kante } A \rightarrow B \iff (A \rightarrow BC) \text{ oder } (A \rightarrow CB) \in P.$$

$L(G)$  ist endlich  $\iff$  dieser Graph enthält keinen Zyklus.

Verwende DFS, um in linearer Zeit festzustellen, ob der Graph Zyklen enthält. □

## Satz 70

Seien kontextfreie Grammatiken  $G_1 = (V_1, \Sigma_1, P_1, S_1)$  und  $G_2 = (V_2, \Sigma_2, P_2, S_2)$  gegeben. Dann können in linearer Zeit kontextfreie Grammatiken für

- 1  $L(G_1) \cup L(G_2)$ ,
- 2  $L(G_1)L(G_2)$ ,
- 3  $(L(G_1))^*$

konstruiert werden. Die Klasse der kontextfreien Sprachen ist also unter *Vereinigung*, *Konkatenation* und *Kleene'scher Hülle* abgeschlossen.

## Beweis:

Ohne Beschränkung der Allgemeinheit nehmen wir an, dass  $V_1 \cap V_2 = \emptyset$ .

- 1  $V = V_1 \cup V_2 \cup \{S\}$ ;  $S$  neu  
 $P = P_1 \cup P_2 \cup \{S \rightarrow S_1|S_2\}$
- 2  $V = V_1 \cup V_2 \cup \{S\}$ ;  $S$  neu  
 $P = P_1 \cup P_2 \cup \{S \rightarrow S_1S_2\}$
- 3  $V = V_1 \cup \{S, S'\}$ ;  $S, S'$  neu  
 $P = P_1 \cup \{S \rightarrow S'|\epsilon, S' \rightarrow S_1S'|S_1\}$

Falls  $\epsilon \in L(G_1)$  oder  $\epsilon \in L(G_2)$ , sind noch Korrekturen vorzunehmen, die hier als Übungsaufgabe überlassen bleiben. □

## Satz 71

Die Klasse der kontextfreien Sprachen ist *nicht* abgeschlossen unter Durchschnitt oder Komplement.

### Beweis:

Es genügt zu zeigen (wegen **de Morgan** (1806–1871)): nicht abgeschlossen unter Durchschnitt.

$L_1 := \{a^i b^i c^j; i, j \geq 0\}$  ist kontextfrei

$L_2 := \{a^i b^j c^j; i, j \geq 0\}$  ist kontextfrei

$L_1 \cap L_2 = \{a^i b^i c^i; i \geq 0\}$  ist nicht kontextfrei



## Satz 72

*Die Klasse der kontextfreien Sprachen ist abgeschlossen gegenüber Substitution (mit kontextfreien Mengen).*

### Beweis:

Ersetze jedes Terminal  $a$  durch ein neues Nichtterminal  $S_a$  und füge zu den Produktionen  $P$  für jedes Terminal  $a$  die Produktionen einer kontextfreien Grammatik  $G_a = (V_a, \Sigma, P_a, S_a)$  hinzu. Forme die so erhaltene Grammatik in eine äquivalente Chomsky-2-Grammatik um. □

## 4.6 Greibach-Normalform

### Definition 73

Sei  $G = (V, \Sigma, P, S)$  eine kontextfreie Grammatik.  $G$  ist in **Greibach-Normalform** (benannt nach **Sheila Greibach** (UCLA)), falls jede Produktion  $\neq S \rightarrow \epsilon$  von der Form

$$A \rightarrow a\alpha \text{ mit } a \in \Sigma, \alpha \in V^*$$

ist.

### Lemma 74

Sei  $G = (V, \Sigma, P, S)$  kontextfrei,  $(A \rightarrow \alpha_1 B \alpha_2) \in P$ , und sei  $B \rightarrow \beta_1 | \beta_2 | \dots | \beta_r$  die Menge der  $B$ -Produktionen (also die Menge der Produktionen mit  $B$  auf der linken Seite). **Ersetzt** man  $A \rightarrow \alpha_1 B \alpha_2$  durch  $A \rightarrow \alpha_1 \beta_1 \alpha_2 | \alpha_1 \beta_2 \alpha_2 | \dots | \alpha_1 \beta_r \alpha_2$ , so ändert sich die von der Grammatik erzeugte Sprache nicht.



## Lemma 75

Sei  $G = (V, \Sigma, P, S)$  kontextfrei, sei  $A \rightarrow A\alpha_1 | A\alpha_2 | \dots | A\alpha_r$  die Menge der *linksrekursiven*  $A$ -Produktionen (alle  $\alpha_i \neq \epsilon$ , die Produktion  $A \rightarrow A$  kommt o.B.d.A. nicht vor), und seien  $A \rightarrow \beta_1 | \beta_2 | \dots | \beta_s$  die restlichen  $A$ -Produktionen (ebenfalls alle  $\beta_i \neq \epsilon$ ).

*Ersetzen* wir *alle*  $A$ -Produktionen durch

$$\begin{aligned} A &\rightarrow \beta_1 | \dots | \beta_s | \beta_1 A' | \dots | \beta_s A' \\ A' &\rightarrow \alpha_1 | \dots | \alpha_r | \alpha_1 A' | \dots | \alpha_r A', \end{aligned}$$

wobei  $A'$  ein neues Nichtterminal ist, so ändert sich die Sprache nicht, und die neue Grammatik enthält keine linksrekursive  $A$ -Produktion mehr.

## Beweis:

Von  $A$  lassen sich vor der Transformation alle Zeichenreihen der Form

$$(\beta_1|\beta_2|\dots|\beta_s)(\alpha_1|\alpha_2|\dots|\alpha_r)^+$$

ableiten.

Dies ist auch nach der Transformation der Fall. Während vor der Transformation alle Zeichenreihen der obigen Form von **rechts** her aufgebaut werden, werden sie danach von **links** nach rechts erzeugt.

Die Umkehrung gilt ebenso. □

## Satz 76

*Zu jeder kontextfreien Grammatik  $G$  gibt es eine äquivalente Grammatik in Greibach-Normalform.*

## Beweis:

Sei o.B.d.A.  $G = (V, \Sigma, P, S)$  mit  $V = \{A_1, \dots, A_m\}$  in Chomsky-Normalform und enthalte keine nutzlosen Variablen.

Bemerkung: Im folgenden Algorithmus werden ggf neue Variablen hinzugefügt, die Programmvariable  $m$  ändert sich dadurch entsprechend!

## Beweis:

**for**  $k = 1, \dots, m$  **do**

**for**  $j = 1, \dots, k - 1$  **do**

**for all**  $(A_k \rightarrow A_j \alpha) \in P$  **do**

      ersetze die Produktion gemäß der Konstruktion  
      in Lemma 74

**od**

**od**

**co** die rechte Seite keiner  $A_{k'}$ -Produktion,  $k' < k$ , beginnt  
  nun noch mit einer Variablen  $A_j$ ,  $j < k$  **oc**

ersetze alle linksrekursiven  $A_k$ -Produktionen gemäß der  
Konstruktion in Lemma 75

**co** die rechte Seite keiner  $A_{k'}$ -Produktion,  $k' \leq k$ , beginnt  
  nun noch mit einer Variablen  $A_j$ ,  $j \leq k$  **oc**

**od**



## Korollar 77

*Sei  $G$  eine kontextfreie Grammatik. Es gibt einen Algorithmus, der eine zu  $G$  äquivalente Grammatik in Greibach-Normalform konstruiert, deren rechte Seiten jeweils höchstens zwei Variablen enthalten.*

Beweis:

Klar!

