

# Einführung in die Theoretische Informatik

Johannes Köbler



Institut für Informatik  
Humboldt-Universität zu Berlin

WS 2020/21

Man unterscheidet vier Typen von Grammatiken  $G = (V, \Sigma, P, S)$

## Definition

- ①  $G$  heißt vom Typ 3 oder regulär, falls für alle Regeln  $u \rightarrow v$  gilt:

$$u \in V \text{ und } v \in \Sigma V \cup \Sigma \cup \{\varepsilon\}$$

(d.h. alle Regeln haben die Form  $A \rightarrow aB$ ,  $A \rightarrow a$  oder  $A \rightarrow \varepsilon$ )

- ②  $G$  heißt vom Typ 2 oder kontextfrei, falls für alle Regeln  $u \rightarrow v$  gilt:

$$u \in V \quad (\text{d.h. alle Regeln haben die Form } A \rightarrow v)$$

- ③  $G$  heißt vom Typ 1 oder kontextsensitiv, falls für alle Regeln  $u \rightarrow v$  gilt:

$$|v| \geq |u| \quad (\text{mit Ausnahme der } \varepsilon\text{-Sonderregel, s. unten})$$

- ④ Jede Grammatik ist automatisch vom Typ 0

## Die $\varepsilon$ -Sonderregel

In einer kontextsensitiven Grammatik ist auch die Regel  $S \rightarrow \varepsilon$  zulässig, falls das Startsymbol  $S$  nicht auf der rechten Seite einer Regel vorkommt

## Bemerkung

- Es ist klar, dass jede reguläre Grammatik auch kontextfrei ist
- Zudem ist die Sprache  $L = \{a^n b^n \mid n \geq 0\}$  nicht regulär
- Es ist aber leicht, eine kontextfreie Grammatik für  $L$  anzugeben:

$$G = (\{S\}, \{a, b\}, P, S) \text{ mit } P = \{S \rightarrow aSb, \varepsilon\}$$

- Also gilt  $\text{REG} \subsetneq \text{CFL}$
- Allerdings sind nicht alle kontextfreien Grammatiken kontextsensitiv
- Z.B. ist obige Grammatik  $G$  nicht kontextsensitiv, da sie die Regel  $S \rightarrow \varepsilon$  enthält und  $S$  auf der rechten Seite der Regel  $S \rightarrow aSb$  vorkommt
- Wir können  $G$  jedoch wie folgt in eine Grammatik  $G'$  umwandeln:
  - ersetze die Regel  $S \rightarrow \varepsilon$  durch die Regel  $S \rightarrow ab$  und
  - füge ein neues Startsymbol  $S'$  sowie die Regeln  $S' \rightarrow S, \varepsilon$  hinzu
- Tatsächlich lässt sich jede kontextfreie Grammatik  $G$  in eine äquivalente kontextfreie Grammatik  $G'$  umwandeln, die auch kontextsensitiv ist

**Definition**

Eine Grammatik  $G = (V, \Sigma, P, S)$  ist in **Chomsky-Normalform (CNF)**, falls  $P \subseteq V \times (V^2 \cup \Sigma)$  ist, d.h. alle Regeln haben die Form  $A \rightarrow BC$  oder  $A \rightarrow a$

**Satz**

Zu jeder kontextfreien Grammatik  $G$  lässt sich eine CNF-Grammatik  $G'$  mit  $L(G') = L(G) \setminus \{\varepsilon\}$  konstruieren

## Korollar

CFL  $\subseteq$  CSL

## Beweis

- Sei  $L \in \text{CFL}$  und sei  $G = (V, \Sigma, P, S)$  eine CNF-Grammatik mit  $L(G) = L \setminus \{\varepsilon\}$
- Im Fall  $\varepsilon \notin L$  folgt sofort  $L = L(G) \in \text{CSL}$ , da  $G$  kontextsensitiv ist
- Ist  $\varepsilon \in L$ , so erzeugt folgende kontextsensitive (und kontextfreie) Grammatik  $G'$  die Sprache  $L = L(G) \cup \{\varepsilon\}$ :

$$G' = (V \cup \{S_{\text{neu}}\}, \Sigma, P \cup \{S_{\text{neu}} \rightarrow S, \varepsilon\}, S_{\text{neu}})$$

□

- Der Beweis des Pumping-Lemmas für kontextfreie Sprachen basiert auf CNF-Grammatiken
- Zudem ermöglichen sie einen effizienten Algorithmus zur Lösung des Wortproblems für kontextfreie Sprachen

## Das Pumping-Lemma für kontextfreie Sprachen

Zu jeder kontextfreien Sprache  $L \in \text{CFL}$  gibt es eine Zahl  $l$ , so dass sich alle Wörter  $z \in L$  mit  $|z| \geq l$  in  $z = uvwxy$  zerlegen lassen mit

- ❶  $vx \neq \varepsilon$ ,
- ❷  $|vwx| \leq l$  und
- ❸  $uv^iwx^iy \in L$  für alle  $i \geq 0$

## Das Wortproblem für kontextfreie Grammatiken

Gegeben: Eine kontextfreie Grammatik  $G$  und ein Wort  $x$

Gefragt: Ist  $x \in L(G)$ ?

## Beispiel

- Betrachte die Sprache  $L = \{a^n b^n \mid n \geq 0\}$
- Dann lässt sich jedes Wort  $z = a^n b^n = a^{n-1} a b b^{n-1}$  in  $L$  mit  $|z| \geq l = 2$  pumpen
- Zerlegen wir nämlich  $z$  in

$$z = uvwxy \text{ mit } u = a^{n-1}, v = a, w = \varepsilon, x = b \text{ und } y = b^{n-1},$$

dann gilt

- ❶  $vx = ab \neq \varepsilon$
- ❷  $|vwx| = |ab| \leq 2$  und
- ❸  $uv^iwx^iy = a^{n-1}a^ib^ib^{n-1} \in L$  für alle  $i \geq 0$



## Beispiel

- Die Sprache  $L = \{a^n b^n c^n \mid n \geq 0\}$  ist nicht kontextfrei
- Für eine vorgegebene Zahl  $l \geq 0$  hat nämlich das Wort  $z = a^l b^l c^l \in L$  die Länge  $|z| = 3l \geq l$
- Dieses Wort lässt sich aber nicht pumpen:

Für jede Zerlegung  $z = uvwx$  mit  $vx \neq \varepsilon$  und  $|vwx| \leq l$  gehört  $z' = uv^0wx^0y$  nicht zu  $L$ :

- Wegen  $vx \neq \varepsilon$  ist  $|z'| < |z|$
- Wegen  $|vwx| \leq l$  kommen in  $vx$  nicht alle drei Zeichen  $a, b, c$  vor
- Kommt aber in  $vx$  beispielsweise kein  $a$  vor, so ist  $\#_a(z) = \#_a(z')$  und somit gilt

$$|z'| < |z| = 3 \#_a(z) = 3 \#_a(z')$$

- Also gehört  $z'$  nicht zu  $L$



# Abschlusseigenschaften von CFL

## Satz

CFL ist abgeschlossen unter Vereinigung, Produkt und Sternhülle

## Beweis

- Seien  $G_1 = (V_1, \Sigma, P_1, S_1)$  und  $G_2 = (V_2, \Sigma, P_2, S_2)$  kontextfreie Grammatiken mit  $V_1 \cap V_2 = \emptyset$  und sei  $S$  eine neue Variable
- Dann gilt
  - $L(G_1) \cup L(G_2) = L(G_3)$  für die kontextfreie Grammatik  
 $G_3 = (V_1 \cup V_2 \cup \{S\}, \Sigma, P_1 \cup P_2 \cup \{S \rightarrow S_1, S_2\}, S)$
  - $L(G_1)L(G_2) = L(G_4)$  für die kontextfreie Grammatik  
 $G_4 = (V_1 \cup V_2 \cup \{S\}, \Sigma, P_1 \cup P_2 \cup \{S \rightarrow S_1 S_2\}, S)$  und
  - $L(G_1)^* = L(G_5)$  für die kontextfreie Grammatik  
 $G_5 = (V_1 \cup \{S\}, \Sigma, P_1 \cup \{S \rightarrow S_1 S, \varepsilon\}, S)$

□

Für  $G_6 = (V_1, \Sigma, P_1 \cup \{S_1 \rightarrow S_1 S_1, \varepsilon\}, S_1)$  muss nicht  $L(G_6) = L(G_1)^*$  gelten, da  $L(G_6)$  z.B. für  $P_1 = \{S_1 \rightarrow aS_1 b, \varepsilon\}$  das Wort  $aababb \notin L(G_1)^*$  enthält

## Satz

CFL ist nicht abgeschlossen unter Schnitt und Komplement

Beweis von  $L_1, L_2 \in \text{CFL} \not\Rightarrow L_1 \cap L_2 \in \text{CFL}$

- Folgende Sprachen sind kontextfrei (siehe Übungen):

$$L_1 = \{a^n b^m c^m \mid n, m \geq 0\} \quad \text{und} \quad L_2 = \{a^n b^n c^m \mid n, m \geq 0\}$$

- Nicht jedoch ihr Schnitt  $L_1 \cap L_2 = \{a^n b^n c^n \mid n \geq 0\}$

□

Beweis von  $L \in \text{CFL} \not\Rightarrow \bar{L} \in \text{CFL}$

- Wäre CFL unter Komplement abgeschlossen, so wäre CFL wegen de Morgan auch unter Schnitt abgeschlossen
- Mit  $A, B \in \text{CFL}$  wären dann nämlich auch  $\bar{A}, \bar{B} \in \text{CFL}$ , woraus wegen

$$\bar{A}, \bar{B} \in \text{CFL} \Rightarrow \overline{\bar{A} \cap \bar{B}} = \overline{\bar{A} \cap \bar{B}} \in \text{CFL}$$

wiederum  $A \cap B \in \text{CFL}$  folgen würde

□

## Satz

Zu jeder kontextfreien Grammatik  $G$  lässt sich eine CNF-Grammatik  $G'$  mit  $L(G') = L(G) \setminus \{\varepsilon\}$  konstruieren

## Beweis

Wir wandeln  $G = (V, \Sigma, P, S)$  wie folgt in eine CNF-Grammatik  $G'$  um:

- Wir beseitigen zunächst alle Regeln der Form  $A \rightarrow \varepsilon$  und danach alle Regeln der Form  $A \rightarrow B$  (siehe folgende Folien)
- Dann fügen wir für jedes Terminal  $a \in \Sigma$  eine neue Variable  $X_a$  und eine neue Regel  $X_a \rightarrow a$  hinzu und ersetzen jedes Vorkommen von  $a$ , bei dem  $a$  nicht alleine auf der rechten Seite einer Regel steht, durch  $X_a$
- Anschließend führen wir für jede Regel  $A \rightarrow B_1 \dots B_k$ ,  $k \geq 3$ , neue Variablen  $A_1, \dots, A_{k-2}$  ein und ersetzen sie durch die  $k-1$  Regeln

$$A \rightarrow B_1 A_1, A_1 \rightarrow B_2 A_2, \dots, A_{k-3} \rightarrow B_{k-2} A_{k-2}, A_{k-2} \rightarrow B_{k-1} B_k$$

□

Falls  $G$  Regeln mit vielen Variablen auf der rechten Seite hat, empfiehlt es sich, Regeln der Form  $A \rightarrow \varepsilon$  und  $A \rightarrow B$  zuletzt zu beseitigen (s. Übungen)

## Satz

Zu jeder kontextfreien Grammatik  $G = (V, \Sigma, P, S)$  gibt es eine kontextfreie Grammatik  $G' = (V, \Sigma, P', S)$  ohne  $\varepsilon$ -Regeln mit  $L(G') = L(G) \setminus \{\varepsilon\}$

## Beweis

- Zuerst berechnen wir die Menge  $E = \{A \in V \mid A \Rightarrow^* \varepsilon\}$  aller Variablen, die nach  $\varepsilon$  ableitbar sind:

```

1    $E' := \{A \in V \mid A \rightarrow \varepsilon\}$ 
2   repeat
3      $E := E'$ 
4      $E' := E \cup \{A \in V \mid \exists B_1, \dots, B_k \in E : A \rightarrow B_1 \dots B_k\}$ 
5   until  $E = E'$ 
    
```

- Nun bilden wir  $P'$  wie folgt:

$$\left\{ A \rightarrow v' \mid \begin{array}{l} \text{es ex. eine Regel } A \rightarrow_G v, \text{ so dass } v' \neq \varepsilon \text{ aus } v \text{ durch} \\ \text{Entfernen von beliebig vielen Variablen } A \in E \text{ entsteht} \end{array} \right\} \quad \square$$

## Beispiel

Betrachte die Grammatik  $G = (\{S, T, U, X, Y, Z\}, \{a, b, c\}, P, S)$  mit

$$\begin{array}{lll}
 P: & S \rightarrow aY, bX, Z & Y \rightarrow bS, aYY & T \rightarrow U \\
 & X \rightarrow aS, bXX & Z \rightarrow \varepsilon, S, T, cZ & U \rightarrow abc
 \end{array}$$

- Berechnung von  $E$ :

$E'$	$\{Z\}$	$\{Z, S\}$
$E$	$\{Z, S\}$	$\{Z, S\}$

- Entferne  $Z \rightarrow \varepsilon$  und füge die Regeln  $Y \rightarrow b$  (wegen  $Y \rightarrow bS$ ),  $X \rightarrow a$  (wegen  $X \rightarrow aS$ ) und  $Z \rightarrow c$  (wegen  $Z \rightarrow cZ$ ) hinzu:

$$\begin{array}{lll}
 P': & S \rightarrow aY, bX, Z & Y \rightarrow b, bS, aYY & T \rightarrow U \\
 & X \rightarrow a, aS, bXX & Z \rightarrow c, S, T, cZ & U \rightarrow abc
 \end{array}$$

## Satz

Zu jeder kontextfreien Grammatik  $G = (V, \Sigma, P, S)$  gibt es eine kontextfreie Grammatik  $G' = (V, \Sigma, P', S)$  ohne Regeln der Form  $A \rightarrow B$  mit  $L(G') = L(G)$

## Beweis

- Zuerst entfernen wir sukzessive alle Zyklen  $A_1 \rightarrow A_2 \rightarrow \dots \rightarrow A_k \rightarrow A_1$
- Hierzu entfernen wir diese Regeln aus  $P$  und ersetzen alle Vorkommen der Variablen  $A_2, \dots, A_k$  in den übrigen Regeln durch  $A_1$
- Befindet sich die Startvariable unter  $A_1, \dots, A_k$ , so sei dies o.B.d.A.  $A_1$
- Nun eliminieren wir sukzessive die restlichen Variablenumbenennungen, indem wir
  - eine Regel  $A \rightarrow B$  wählen, so dass in  $P$  keine Variablenumbenennung  $B \rightarrow C$  mit  $B$  auf der linken Seite existiert,
  - diese Regel  $A \rightarrow B$  aus  $P$  entfernen und
  - für jede Regel  $B \rightarrow v$  in  $P$  die Regel  $A \rightarrow v$  zu  $P$  hinzunehmen

# Beseitigung von Variablenumbenennungen

## Beispiel (Fortsetzung)

$P: S \rightarrow aY, bX, Z \quad Y \rightarrow b, bS, aYY \quad T \rightarrow U$   
 $X \rightarrow a, aS, bXX \quad Z \rightarrow c, S, T, cZ \quad U \rightarrow abc$

- Entferne den Zyklus  $S \rightarrow Z \rightarrow S$  und ersetze  $Z$  durch  $S$ :

$S \rightarrow aY, bX, c, T, cS \quad Y \rightarrow b, bS, aYY \quad T \rightarrow U$   
 $X \rightarrow a, aS, bXX \quad U \rightarrow abc$

- Ersetze die Regel  $T \rightarrow U$  durch  $T \rightarrow abc$  (wegen  $U \rightarrow abc$ ):

$S \rightarrow aY, bX, c, T, cS \quad Y \rightarrow b, bS, aYY \quad T \rightarrow abc$   
 $X \rightarrow a, aS, bXX \quad U \rightarrow abc$

- Ersetze dann auch die Regel  $S \rightarrow T$  durch  $S \rightarrow abc$  (wegen  $T \rightarrow abc$ ):

$S \rightarrow abc, aY, bX, c, cS \quad Y \rightarrow b, bS, aYY \quad T \rightarrow abc$   
 $X \rightarrow a, aS, bXX \quad U \rightarrow abc$

- Da  $T$  und  $U$  nirgends mehr auf der rechten Seite vorkommen, können wir die Regeln  $T \rightarrow abc$  und  $U \rightarrow abc$  weglassen:

$S \rightarrow abc, aY, bX, c, cS \quad Y \rightarrow b, bS, aYY \quad X \rightarrow a, aS, bXX$

## Beispiel (Schluss)

Betrachte die Grammatik  $G = (\{S, X, Y, Z\}, \{a, b, c\}, P, S)$  mit

$$P: S \rightarrow abc, aY, bX, c, cS \quad Y \rightarrow b, bS, aYY \quad X \rightarrow a, aS, bXX$$

- Ersetze  $a$ ,  $b$  und  $c$  durch  $A$ ,  $B$  und  $C$  (außer wenn sie alleine auf der rechten Seite einer Regel stehen) und füge die Regeln  $A \rightarrow a$ ,  $B \rightarrow b$ ,  $C \rightarrow c$  hinzu:

$$S \rightarrow ABC, AY, BX, c, CS \quad Y \rightarrow b, BS, AYY \quad X \rightarrow a, AS, BXX \\ A \rightarrow a \quad B \rightarrow b \quad C \rightarrow c$$

- Ersetze die Regeln  $S \rightarrow ABC$ ,  $Y \rightarrow AYY$  und  $X \rightarrow BXX$  durch die Regeln  $S \rightarrow AS'$ ,  $S' \rightarrow BC$ ,  $Y \rightarrow AY'$ ,  $Y' \rightarrow YY$  und  $X \rightarrow BX'$ ,  $X' \rightarrow XX$ :

$$S \rightarrow AS', AY, BX, c, CS \quad S' \rightarrow BC \quad Y \rightarrow b, BS, AY' \quad Y' \rightarrow YY \\ X \rightarrow a, AS, BX' \quad X' \rightarrow XX \quad A \rightarrow a \quad B \rightarrow b \quad C \rightarrow c$$





# Links- und Rechtsableitungen

## Definition

Sei  $G = (V, \Sigma, P, S)$  eine kontextfreie Grammatik

- Eine Ableitung

$$\underline{S} \Rightarrow l_1 \underline{A_1} r_1 \Rightarrow \dots \Rightarrow l_{m-1} \underline{A_{m-1}} r_{m-1} \Rightarrow \alpha_m$$

heißt **Linksableitung** von  $\alpha_m$  (kurz  $S \Rightarrow_L^* \alpha_m$ ), falls in jedem Ableitungsschritt die am weitesten links stehende Variable ersetzt wird, d.h. es gilt  $l_i \in \Sigma^*$  für  $i = 1, \dots, m-1$

- **Rechtsableitungen**  $S_0 \Rightarrow_R^* \alpha_m$  sind analog definiert
- $G$  heißt **mehrdeutig**, wenn es ein Wort  $x \in L(G)$  gibt, das mindestens zwei verschiedene Linksableitungen hat
- Andernfalls heißt  $G$  **eindeutig**

Für alle  $x \in \Sigma^*$  gilt:  $x \in L(G) \Leftrightarrow S \Rightarrow^* x \Leftrightarrow S \Rightarrow_L^* x \Leftrightarrow S \Rightarrow_R^* x$

## Beispiel

- In  $G = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, \varepsilon\}, S)$  gibt es **8** Ableitungen für  $aabb$ :

$$\underline{S} \Rightarrow_L a\underline{S}bS \Rightarrow_L aa\underline{S}bSbS \Rightarrow_L aab\underline{S}bS \Rightarrow_L aabb\underline{S} \Rightarrow_L aabb$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow aa\underline{S}bSbS \Rightarrow aabSb\underline{S} \Rightarrow aab\underline{S}b \Rightarrow aabb$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow aa\underline{S}bSbS \Rightarrow aa\underline{S}bbS \Rightarrow aabb\underline{S} \Rightarrow aabb$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow aa\underline{S}bSbS \Rightarrow aaSbb\underline{S} \Rightarrow aa\underline{S}bb \Rightarrow aabb$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow aa\underline{S}bSbS \Rightarrow aa\underline{S}bSb \Rightarrow aab\underline{S}b \Rightarrow aabb$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow aa\underline{S}bSbS \Rightarrow aaSb\underline{S}b \Rightarrow aa\underline{S}bb \Rightarrow aabb$$

$$\underline{S} \Rightarrow a\underline{S}b\underline{S} \Rightarrow a\underline{S}b \Rightarrow aa\underline{S}bSb \Rightarrow aab\underline{S}b \Rightarrow aabb$$

$$\underline{S} \Rightarrow_R a\underline{S}bS \Rightarrow_R a\underline{S}b \Rightarrow_R aa\underline{S}bSb \Rightarrow_R aa\underline{S}bb \Rightarrow_R aabb$$

- Darunter sind genau eine **Links-** und genau eine **Rechtsableitung**
- In  $G' = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, ab, \varepsilon\}, S)$  gibt es **3** Ableitungen für  $ab$ :

$$\underline{S} \Rightarrow ab$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow ab\underline{S} \Rightarrow ab$$

$$\underline{S} \Rightarrow a\underline{S}bS \Rightarrow a\underline{S}b \Rightarrow ab$$

- Darunter sind **zwei Links-** und **zwei Rechtsableitungen**

## Beispiel

- Die Grammatik  $G = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, \varepsilon\}, S)$  ist eindeutig
- Dies liegt daran, dass keine Satzform von  $G$  das Teilwort  $Sa$  enthält
- Daher kann in einer Linksableitung

$$S \Rightarrow_L^* y \underline{S} \beta \Rightarrow_L^* yz = x$$

auf die aktuelle Satzform  $y \underline{S} \beta$  nicht die Regel  $S \rightarrow \varepsilon$  angewandt werden, wenn in  $x$  auf das Präfix  $y$  ein  $a$  folgt

- Daher muss auf die aktuelle Satzform  $y \underline{S} \beta$  genau dann die Regel  $S \rightarrow aSbS$  angewandt werden, wenn in  $x$  auf das Präfix  $y$  ein  $a$  folgt
- Dagegen ist die Grammatik  $G' = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, ab, \varepsilon\}, S)$  mehrdeutig, da das Wort  $x = ab$  zwei Linksableitungen hat:

$$\underline{S} \Rightarrow ab \text{ und } \underline{S} \Rightarrow a \underline{S} b S \Rightarrow ab \underline{S} \Rightarrow ab$$

Sei  $G = (V, E)$  ein Digraph.

- Ein (gerichteter)  $v_0$ - $v_k$ -Weg in  $G$  ist eine Folge von Knoten  $v_0, \dots, v_k$  mit  $(v_i, v_{i+1}) \in E$  für  $i = 0, \dots, k-1$ . Seine Länge ist  $k$
- Ein Weg heißt Pfad, falls alle Knoten paarweise verschieden sind
- Ein  $u$ - $v$ -Weg der Länge  $\geq 1$  mit  $u = v$  heißt Zyklus
- $G$  heißt azyklisch, wenn es in  $G$  keinen Zyklus gibt
- Ein Zyklus heißt Kreis, falls alle Knoten paarweise verschieden sind
- $G$  heißt gerichteter Wald, wenn  $G$  azyklisch ist und jeder Knoten  $v \in V$  Eingangsgrad  $\deg^-(v) \leq 1$  hat
- Ein Knoten  $u \in V$  vom Ausgangsgrad  $\deg^+(u) = 0$  heißt Blatt
- Ein Knoten  $w \in V$  heißt Wurzel, wenn  $\deg^-(w) = 0$  ist
- Ein gerichteter Wald mit genau einer Wurzel heißt gerichteter Baum
- Da in einem gerichteten Baum alle Kanten von der Wurzel  $w$  wegführen, ist die Angabe der Kantenrichtungen bei Kenntnis von  $w$  überflüssig. Man spricht dann auch von einem Wurzelbaum

Wir ordnen einer Ableitung

$$\underline{A_0} \Rightarrow l_1 \underline{A_1} r_1 \Rightarrow \dots \Rightarrow l_{m-1} \underline{A_{m-1}} r_{m-1} \Rightarrow \alpha_m$$

den **Syntaxbaum** (oder **Ableitungsbaum**, engl. *parse tree*)  $T_m$  zu, wobei die Bäume  $T_0, \dots, T_m$  induktiv wie folgt definiert sind:

- $T_0$  besteht aus einem einzigen Knoten, der mit  $A_0$  markiert ist
- Wird im  $(i+1)$ -ten Ableitungsschritt die Regel  $A_i \rightarrow v_1 \dots v_k$  mit  $v_1, \dots, v_k \in \Sigma \cup V$  angewandt, so entsteht  $T_{i+1}$  aus  $T_i$ , indem wir das Blatt  $A_i$  durch folgenden Unterbaum ersetzen:

$$\begin{array}{cc} k > 0: & \begin{array}{c} A_i \\ / \quad \backslash \\ v_1 \quad \dots \quad v_k \end{array} & k = 0: & \begin{array}{c} A_i \\ | \\ \varepsilon \end{array} \end{array}$$


- Hierbei stellen wir uns die Kanten von oben nach unten gerichtet und die Kinder  $v_1 \dots v_k$  von links nach rechts geordnet vor
- Syntaxbäume sind also **geordnete** Wurzelbäume

## Beispiel

- Betrachte die Grammatik  $G = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, \epsilon\}, S)$  und die Ableitung


$$S \Rightarrow aSbS \Rightarrow aaSbbS \Rightarrow aaSbbbS \Rightarrow aabbbS \Rightarrow aabbb$$

- Die zugehörigen Syntaxbäume sind dann




## Beispiel

- In  $G = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, \epsilon\}, S)$  führen alle acht Ableitungen des Wortes  $aabb$  auf denselben Syntaxbaum:



- Dagegen führen in  $G' = (\{S\}, \{a, b\}, \{S \rightarrow aSbS, ab, \epsilon\}, S)$  die drei Ableitungen des Wortes  $ab$  auf zwei unterschiedliche Syntaxbäume:



# Syntaxbäume und Linksableitungen

- Seien  $T_0, \dots, T_m$  die zu einer Ableitung  $S = \alpha_0 \Rightarrow \dots \Rightarrow \alpha_m$  gehörigen Syntaxbäume
- Dann haben alle Syntaxbäume  $T_0, \dots, T_m$  die Wurzel  $S$
- Die Satzform  $\alpha_i$  ergibt sich aus  $T_i$ , indem wir die Blätter von  $T_i$  von links nach rechts zu einem Wort zusammensetzen
- Auf den Syntaxbaum  $T_m$  führen neben  $\alpha_0 \Rightarrow \dots \Rightarrow \alpha_m$  alle Ableitungen, die sich von dieser nur in der Reihenfolge der Regelanwendungen unterscheiden
- Dazu gehört genau eine Linksableitung
- Linksableitungen und Syntaxbäume entsprechen sich also eineindeutig
- Dasselbe gilt für Rechtsableitungen
- Ist  $T$  Syntaxbaum einer CNF-Grammatik, so hat jeder Knoten in  $T$  höchstens zwei Kinder (d.h.  $T$  ist ein **Binärbaum**)



## Definition

Die **Tiefe** eines Baumes mit Wurzel  $w$  ist die maximale Länge eines Weges von  $w$  zu einem Blatt

## Lemma

Ein Binärbaum  $B$  der Tiefe  $\leq k$  hat  $\leq 2^k$  Blätter

## Beweis durch Induktion über $k$ :

$k = 0$ : Ein Baum der Tiefe 0 kann nur einen Knoten haben

$k \rightsquigarrow k + 1$ : Sei  $B$  ein Binärbaum der Tiefe  $\leq k + 1$

Dann hängen an  $B$ 's Wurzel maximal zwei Unterbäume

Da deren Tiefe  $\leq k$  ist, haben sie nach IV  $\leq 2^k$  Blätter

Also hat  $B \leq 2^{k+1}$  Blätter



## Lemma

Ein Binärbaum  $B$  der Tiefe  $\leq k$  hat  $\leq 2^k$  Blätter

## Korollar

Ein Binärbaum  $B$  mit  $> 2^{k-1}$  Blättern hat eine Tiefe  $\geq k$

## Beweis

Wäre die Tiefe von  $B$  kleiner als  $k$  (also  $\leq k - 1$ ), so hätte  $B$  nach obigem Lemma  $\leq 2^{k-1}$  Blätter (Widerspruch) □

## Satz (Pumping-Lemma für kontextfreie Sprachen)


Zu jeder kontextfreien Sprache  $L \in \text{CFL}$  gibt es eine Zahl  $l$ , so dass sich alle Wörter  $z \in L$  mit  $|z| \geq l$  in  $z = uvwxy$  zerlegen lassen mit

- ①  $vx \neq \varepsilon$ ,
- ②  $|vwx| \leq l$  und
- ③  $uv^iwx^iy \in L$  für alle  $i \geq 0$

## Beweis



- Sei  $G = (V, \Sigma, P, S)$  eine CNF-Grammatik für  $L \setminus \{\varepsilon\}$
- Ist nun  $z = z_1 \dots z_n \in L$  mit  $n \geq 1$ , so ex. in  $G$  eine Ableitung  

$$S = \alpha_0 \Rightarrow \dots \Rightarrow \alpha_m = z \text{ mit zugehörigen Syntaxbäumen } T_0, \dots, T_m$$
- Da  $G$  in CNF ist, werden hierbei genau  $n - 1$  Regeln der Form  $A \rightarrow BC$  und genau  $n$  Regeln der Form  $A \rightarrow a$  angewandt
- Folglich ist  $m = 2n - 1$  und wir können annehmen, dass die Regeln der Form  $A \rightarrow BC$  vor den Regeln der Form  $A \rightarrow a$  zur Anwendung kommen
- Dann besteht  $\alpha_{n-1}$  aus  $n$  Variablen und die Syntaxbäume  $T_{2n-1}$  und  $T_{n-1}$  haben genau  $n$  Blätter
- Setzen wir  $l = 2^k$ , wobei  $k = \|V\|$  ist, so hat  $T_{n-1}$  im Fall  $n \geq l$  mindestens die Tiefe  $k$ , da  $T_{n-1}$  mindestens  $l = 2^k > 2^{k-1}$  Blätter hat



## Beweis (Fortsetzung)






- Setzen wir  $l = 2^k$ , wobei  $k = \|V\|$  ist, so hat  $T_{n-1}$  im Fall  $n \geq l$  mindestens die Tiefe  $k$ , da  $T_{n-1}$  mindestens  $l = 2^k > 2^{k-1}$  Blätter hat
- Sei  $\pi$  ein von der Wurzel ausgehender Pfad maximaler Länge in  $T_{n-1}$
- Dann hat  $\pi$  mindestens die Länge  $k$  und unter den letzten  $k + 1 > \|V\|$  Knoten von  $\pi$  müssen zwei mit derselben Variablen  $A$  markiert sein
- Seien  $U$  und  $U'$  die Unterbäume von  $T_{2n-1}$  mit diesen Knoten als Wurzel
- Dann hat  $U$  höchstens  $l = 2^k$  Blätter und  $U'$  hat weniger Blätter als  $U$
- Nun zerlegen wir  $z$  wie folgt:
  - $w'$  ist das Teilwort von  $z = uw'y$ , das von  $U$  erzeugt wird und
  - $w$  ist das Teilwort von  $w' = vwx$ , das von  $U'$  erzeugt wird



# Beweis des Pumping-Lemmas für CFL

## Beweis (Schluss)

- Dann ist  $vx \neq \varepsilon$  (Bed. 1), da  $U$  mehr Blätter als  $U'$  hat
- Zudem gilt  $|vwx| \leq l$  (Bed. 2), da  $U$  höchstens  $2^k = l$  Blätter hat (sonst hätte der Baum  $U^* = U \cap T_{n-1}$  eine Tiefe größer  $k$  und  $\pi$  wäre nicht maximal)
- Schließlich lassen sich Syntaxbäume  $B_i$  für die Wörter  $uv^iwx^iy$ ,  $i \geq 0$ , wie folgt konstruieren (Bed. 3):
  - $B_0$  entsteht aus  $B_1 = T_{2n-1}$ , indem wir  $U$  durch  $U'$  ersetzen
  - $B_{i+1}$  entsteht aus  $B_i$ , indem wir  $U'$  durch  $U$  ersetzen:



## Das Wortproblem für kontextfreie Grammatiken

Gegeben: Eine kontextfreie Grammatik  $G$  und ein Wort  $x$

Gefragt: Ist  $x \in L(G)$ ?

## Frage

Wie lässt sich das Wortproblem für kontextfreie Grammatiken entscheiden?


- Sei eine Grammatik  $G = (V, \Sigma, P, S)$  und ein Wort  $x = x_1 \dots x_n$  gegeben
- Falls  $x = \varepsilon$  ist, können wir effizient prüfen, ob  $S \Rightarrow^* \varepsilon$  gilt
- Hierzu genügt es, die Menge  $E = \{A \in V \mid A \Rightarrow^* \varepsilon\}$  aller  $\varepsilon$ -ableitbaren Variablen zu berechnen und zu prüfen, ob  $S \in E$  ist
- Andernfalls bringen wir  $G$  in CNF und starten den nach seinen Autoren Cocke, Younger und Kasami benannten CYK-Algorithmus
- Dieser bestimmt mittels dynamischer Programmierung für  $l = 1, \dots, n$  und  $k = 1, \dots, n - l + 1$  die Menge  $V_{l,k}$  aller Variablen, aus denen das Teilwort  $x_k \dots x_{k+l-1}$  ableitbar ist
- Dann gilt  $x \in L(G) \Leftrightarrow S \in V_{n,1}$



- Sei  $G = (V, \Sigma, P, S)$  eine CNF-Grammatik und sei  $x \in \Sigma^+$
- Dann lassen sich die Mengen  $V_{l,k} = \{A \in V \mid A \Rightarrow^* x_k \dots x_{k+l-1}\}$  wie folgt bestimmen
- Für  $l = 1$  gehört  $A$  zu  $V_{1,k}$ , falls die Regel  $A \rightarrow x_k$  existiert:

$$V_{1,k} = \{A \in V \mid A \rightarrow x_k\}$$

- Für  $l > 1$  gehört  $A$  zu  $V_{l,k}$ , falls eine Regel  $A \rightarrow BC$  und eine Zahl  $l' \in \{1, \dots, l-1\}$  ex. mit  $B \in V_{l',k}$  und  $C \in V_{l-l',k+l'}$ :



$$V_{l,k} = \{A \in V \mid \exists l' < l, B \in V_{l',k}, C \in V_{l-l',k+l'}: A \rightarrow BC \in P\}$$

## Algorithmus CYK( $G, x$ )

```
1  Input: CNF-Grammatik  $G = (V, \Sigma, P, S)$  und Wort  $x = x_1 \dots x_n$ 
2  for  $k := 1$  to  $n$  do
3       $V_{1,k} := \{A \in V \mid A \rightarrow x_k \in P\}$ 
4  for  $l := 2$  to  $n$  do
5      for  $k := 1$  to  $n - l + 1$  do
6           $V_{l,k} := \emptyset$ 
7          for  $l' := 1$  to  $l - 1$  do
8              for all  $A \rightarrow BC \in P$  do
9                  if  $B \in V_{l',k}$  and  $C \in V_{l-l',k+l'}$  then
10                      $V_{l,k} := V_{l,k} \cup \{A\}$ 
11  if  $S \in V_{n,1}$  then accept else reject
```

Der CYK-Algorithmus lässt sich dahingehend erweitern, dass er im Fall  $x \in L(G)$  auch einen Syntaxbaum  $T$  von  $x$  bestimmt

## Beispiel

- Betrachte die CNF-Grammatik mit den Regeln

$P: S \rightarrow AS', AY, BX, CS, c, \quad S' \rightarrow BC, \quad X \rightarrow AS, BX', a, \quad X' \rightarrow XX, \\ Y \rightarrow BS, AY', b, \quad Y' \rightarrow YY, \quad A \rightarrow a, \quad B \rightarrow b, \quad C \rightarrow c$

- Dann erhalten wir für das Wort  $x = abb$  folgende Mengen  $V_{l,k}$ :

$k:$	1	2	3
	$a$	$b$	$b$
$l: 1$	$\{X, A\}$	$\{Y, B\}$	$\{Y, B\}$
2	$\{S\}$	$\{Y'\}$	
3	$\{Y\}$		

- Wegen  $S \notin V_{3,1}$  ist  $x \notin L(G)$

## Beispiel (Fortsetzung)

- Betrachte die CNF-Grammatik mit den Regeln

$P: S \rightarrow AS', AY, BX, CS, c, \quad S' \rightarrow BC, \quad X \rightarrow AS, BX', a, \quad X' \rightarrow XX, \\ Y \rightarrow BS, AY', b, \quad Y' \rightarrow YY, \quad A \rightarrow a, \quad B \rightarrow b, \quad C \rightarrow c$

- Dagegen gehört das Wort  $y = aababb$  zu  $L(G)$ :

$a$	$a$	$b$	$a$	$b$	$b$
$\{X, A\}$	$\{X, A\}$	$\{Y, B\}$	$\{X, A\}$	$\{Y, B\}$	$\{Y, B\}$
$\{X'\}$	$\{S\}$	$\{S\}$	$\{S\}$	$\{Y'\}$	
$\{X\}$	$\{X\}$	$\{Y\}$	$\{Y\}$		
$\{X'\}$	$\{S\}$	$\{Y'\}$			
$\{X\}$	$\{Y\}$				
$\{S\}$					

## Frage


Wie lässt sich das Maschinenmodell des DFA erweitern, um die Sprache

$$L = \{a^n b^n \mid n \geq 0\}$$

und alle anderen kontextfreien Sprachen erkennen zu können?

## Antwort

- Ein DFA kann Sprachen wie  $L$  nicht erkennen, da er nur seinen Zustand als Speicher benutzen kann und die Anzahl der Zustände zwar von  $L$  aber nicht von der Eingabe abhängen darf
- Um kontextfreie Sprachen erkennen zu können, genügt bereits ein **Kellerspeicher** (auch **Stapel**, engl. *stack* oder *pushdown memory*)
- Dieser erlaubt nur den Zugriff auf die höchste belegte Speicheradresse



- verfügt zusätzlich über einen Kellerspeicher
- kann auch  $\varepsilon$ -Übergänge machen
- hat Lesezugriff auf das aktuelle Eingabezeichen und auf das oberste Kellersymbol
- kann in jedem Rechenschritt das oberste Kellersymbol löschen und durch beliebig viele Symbole ersetzen

## Notation

Für eine Menge  $M$  bezeichne  $\mathcal{P}_e(M)$  die Menge aller endlichen Teilmengen von  $M$ , d.h.  $\mathcal{P}_e(M) = \{A \subseteq M \mid A \text{ ist endlich}\}$

## Definition

Ein **Kellerautomat mit Endzuständen** (auch **FS-PDA** für engl. *Final State PushDown Automaton*) ist ein 7-Tupel  $M = (Z, \Sigma, \Gamma, \delta, q_0, \#, E)$ . Dabei ist

- $Z \neq \emptyset$  eine endliche Menge von **Zuständen**
- $\Sigma$  das **Eingabealphabet**
- $\Gamma$  das **Kelleralphabet**
- $\delta : Z \times (\Sigma \cup \{\varepsilon\}) \times \Gamma \rightarrow \mathcal{P}_e(Z \times \Gamma^*)$  die **Überföhrungsfunktion**
- $q_0 \in Z$  der **Startzustand**
- $\# \in \Gamma$  das **Kelleranfangszeichen**
- $E \subseteq Z$  die Menge der **Endzustände**

- Wenn  $p$  der momentane Zustand,  $A$  das oberste Kellerzeichen und  $u \in \Sigma$  das nächste Eingabezeichen (bzw.  $u = \varepsilon$ ) ist, so kann  $M$  im Fall  $(q, B_1 \dots B_k) \in \delta(p, u, A)$ 
  - in den Zustand  $q$  wechseln,
  - den Lesekopf auf dem Eingabeband um  $|u| \in \{0, 1\}$  Positionen vorrücken und
  - das Zeichen  $A$  aus- sowie die Zeichenfolge  $B_1 \dots B_k$  einkellern (danach ist  $B_1$  das oberste Kellerzeichen)
- Hierfür sagen wir auch,  $M$  führt die Anweisung  $puA \rightarrow qB_1 \dots B_k$  aus, und sprechen im Fall
  - $k = 0$  von einer **pop-Operation**,
  - $k = 2$  und  $B_2 = A$  von einer **push-Operation**, sowie
  - im Fall  $u = \varepsilon$  von einem  **$\varepsilon$ -Übergang**
- Man beachte, dass bei leerem Keller kein Übergang mehr möglich ist



## Beispiel

- Sei  $M = (Z, \Sigma, \Gamma, \delta, p, \#, E)$  mit  $Z = \{p, q, r\}$ ,  $\Sigma = \{a, b\}$ ,  $\Gamma = \{A, \#\}$ ,  $E = \{r\}$  und der Überföhrungsfunktion

$$\delta : pa\# \rightarrow pA\# \quad (1)$$


$$paA \rightarrow pAA \quad (2)$$

$$p\epsilon\# \rightarrow q\# \quad (3)$$

$$pbA \rightarrow q \quad (4)$$

$$qbA \rightarrow q \quad (5)$$

$$q\epsilon\# \rightarrow r \quad (6)$$



# Konfiguration eines Kellerautomaten

- Eine **Konfiguration** von  $M$  wird durch ein Tripel

$$K = (p, x_i \dots x_n, A_1 \dots A_l) \in Z \times \Sigma^* \times \Gamma^*$$

beschrieben und besagt, dass

- $p$  der momentane Zustand,
- $x_i \dots x_n$  der ungelesene Rest der Eingabe und
- $A_1 \dots A_l$  der aktuelle Kellerinhalt ist ( $A_1$  ist oberstes Symbol)
- In einer solchen Konfiguration  $K$  kann  $M$  eine beliebige Anweisung  $puA_1 \rightarrow qB_1 \dots B_k$  mit  $u \in \{\varepsilon, x_i\}$  ausführen
- Diese überführt  $M$  in die **Folgekonfiguration**

$$K' = (q, x_j \dots x_n, B_1 \dots B_k A_2 \dots A_l) \text{ mit } j = i + |u|$$

- Hierfür schreiben wir auch kurz  $K \vdash K'$
- Eine **Rechnung** von  $M$  bei Eingabe  $x$  ist eine Folge von Konfigurationen

$$K_0, K_1, K_2 \dots \text{ mit } K_0 \vdash K_1 \vdash K_2 \dots,$$

wobei  $K_0 = (q_0, x, \#)$  die **Startkonfiguration** von  $M$  bei Eingabe  $x$  ist

## Notation

Die reflexive, transitive Hülle von  $\vdash$  bezeichnen wir wie üblich mit  $\vdash^*$

## Definition

Die von einem Kellerautomaten  $M = (Z, \Sigma, \Gamma, \delta, q_0, \#, E)$  **akzeptierte (oder erkannte) Sprache** ist

$$L(M) = \{x \in \Sigma^* \mid \exists q \in E, \alpha \in \Gamma^* : (q_0, x, \#) \vdash^* (q, \varepsilon, \alpha)\}$$

- Ein Kellerautomat  $M$  mit Endzuständen akzeptiert also genau dann ein Wort  $x$ , wenn es bei dieser Eingabe eine Rechnung gibt, bei der  $M$ 
  - alle Eingabezeichen liest und
  - einen Endzustand  $q \in E$  erreicht

## Beispiel (Fortsetzung)

- Sei  $M = (Z, \Sigma, \Gamma, \delta, p, \#, E)$  mit  $Z = \{p, q, r\}$ ,  $\Sigma = \{a, b\}$ ,  $\Gamma = \{A, \#\}$ ,  $E = \{r\}$  und der Überföhrungsfunktion

$$\delta : pa\# \rightarrow pA\# \quad (1)$$


$$paA \rightarrow pAA \quad (2)$$

$$p\varepsilon\# \rightarrow q\# \quad (3)$$

$$pbA \rightarrow q \quad (4)$$

$$qbA \rightarrow q \quad (5)$$

$$q\varepsilon\# \rightarrow r \quad (6)$$



- Dann akzeptiert  $M$  die Eingabe  $x = aabb$ :

$$\begin{array}{ccccccc} (p, aabb, \#) & \vdash_{(1)} & (p, abb, A\#) & \vdash_{(2)} & (p, bb, AA\#) & \vdash_{(4)} & (q, b, A\#) \vdash_{(5)} (q, \varepsilon, \#) \\ & & \vdash_{(6)} & & & & \\ & & (r, \varepsilon, \varepsilon) & & & & \end{array}$$



Es gibt auch ein Akzeptanzkriterium, das keine Endzustände erfordert.

## Definition

- Sei  $M = (Z, \Sigma, \Gamma, \delta, q_0, \#)$  ein Kellerautomat ohne Endzustandsmenge
- Die von  $M$  durch Leeren des Kellers akzeptierte (oder erkannte) Sprache ist

$$L(M) = \{x \in \Sigma^* \mid \exists p \in Z: (q_0, x, \#) \vdash^* (p, \varepsilon, \varepsilon)\}$$

- Wir nennen  $M$  auch einen **ES-PDA** (für engl. *Empty Stack PushDown Automaton*) oder einfach **PDA**
- Ein PDA  $M$  akzeptiert also genau dann eine Eingabe, wenn es eine Rechnung gibt, bei der  $M$  alle Eingabezeichen liest und den Keller leert
- Es gilt (siehe Übungen)

$$\{L(M) \mid M \text{ ist ein FS-PDA}\} = \{L(M) \mid M \text{ ist ein ES-PDA}\}$$

# Ein PDA für die Sprache $\{a^n b^n \mid n \geq 0\}$

## Beispiel

- Sei  $M = (Z, \Sigma, \Gamma, \delta, p, \#)$  mit  $Z = \{p, q\}$ ,  
 $\Sigma = \{a, b\}$ ,  $\Gamma = \{A, \#\}$  und

$$\begin{aligned} \delta : p\epsilon\# &\rightarrow p \quad (1) & pa\# &\rightarrow pA \quad (2) & paA &\rightarrow pAA \quad (3) \\ pbA &\rightarrow q \quad (4) & qbA &\rightarrow q \quad (5) \end{aligned}$$

- Dann akzeptiert  $M$  die Eingabe  $x = aabb$ :


$$(p, aabb, \#) \xrightarrow{(2)} (p, abb, A) \xrightarrow{(3)} (p, bb, AA) \xrightarrow{(4)} (q, b, A) \xrightarrow{(5)} (q, \epsilon, \epsilon)$$

- Allgemeiner akzeptiert  $M$  das Wort  $x = a^n b^n$  mit folgender Rechnung:

$$n = 0: (p, \epsilon, \#) \xrightarrow{(1)} (p, \epsilon, \epsilon)$$

$$\begin{aligned} n \geq 1: (p, a^n b^n, \#) &\xrightarrow{(2)} (p, a^{n-1} b^n, A) \xrightarrow{(3)^{n-1}} (p, b^n, A^n) \\ &\xrightarrow{(4)} (q, b^{n-1}, A^{n-1}) \xrightarrow{(5)^{n-1}} (q, \epsilon, \epsilon) \end{aligned}$$


- Dies zeigt, dass  $M$  alle Wörter der Form  $a^n b^n$ ,  $n \geq 0$ , akzeptiert



# Ein PDA für die Sprache $\{a^n b^n \mid n \geq 0\}$

## Beispiel (Fortsetzung)

- Sei  $M = (Z, \Sigma, \Gamma, \delta, p, \#)$  mit  $Z = \{p, q\}$ ,  
 $\Sigma = \{a, b\}$ ,  $\Gamma = \{A, \#\}$  und  
 $\delta : p\epsilon\# \rightarrow p$  (1)  $pa\# \rightarrow pA$  (2)  $paA \rightarrow pAA$  (3)  
 $pbA \rightarrow q$  (4)  $qbA \rightarrow q$  (5)



- Es gilt auch die umgekehrte Inklusion:


alle Wörter  $x = x_1 \dots x_m \in L(M)$  haben die Form  $x = a^n b^n$

- Ausgehend von der Startkonfiguration  $(p, x, \#)$  sind nämlich nur die Anweisungen (1) oder (2) ausführbar
- Führt  $M$  zuerst Anweisung (1) aus, so wird der Keller geleert
- Daher kann  $M$  in diesem Fall nur das leere Wort  $x = \epsilon = a^0 b^0$  akzeptieren
- Falls  $M$  mit Anweisung (2) beginnt, muss  $M$  später mittels Anweisung (4) in den Zustand  $q$  gelangen, da sonst der Keller nicht geleert wird

# Ein PDA für die Sprache $\{a^n b^n \mid n \geq 0\}$

## Beispiel (Schluss)

- Sei  $M = (Z, \Sigma, \Gamma, \delta, p, \#)$  mit  $Z = \{p, q\}$ ,  
 $\Sigma = \{a, b\}$ ,  $\Gamma = \{A, \#\}$  und  
 $\delta : p\epsilon\# \rightarrow p$  (1)  $pa\# \rightarrow pA$  (2)  $paA \rightarrow pAA$  (3)  
 $pbA \rightarrow q$  (4)  $qbA \rightarrow q$  (5)



- Falls  $M$  mit Anweisung (2) beginnt, muss  $M$  später mittels Anweisung (4) in den Zustand  $q$  gelangen, da sonst der Keller nicht geleert wird
- Dies geschieht, sobald  $M$  nach Lesen von  $n \geq 1$   $a$ 's das erste  $b$  liest:

$$\begin{array}{ccc}
 (p, x_1 x_2 \dots x_m, \#) & \xrightarrow{(2)} & (p, x_2 \dots x_n x_{n+1} \dots x_m, A) \\
 & & \xrightarrow{(3)}^{n-1} (p, x_{n+1} x_{n+2} \dots x_m, A^n) \xrightarrow{(4)} (q, x_{n+2} \dots x_m, A^{n-1})
 \end{array}$$

mit  $x_1 = x_2 = \dots = x_n = a$  und  $x_{n+1} = b$ .

- Damit der Keller nach dem Lesen von  $x_m$  leer ist, muss  $M$  nun noch genau  $n - 1$   $b$ 's lesen, weshalb  $m = 2n$  und  $x = a^n b^n$  folgt.



## Ziel

Als nächstes wollen wir zeigen, dass PDAs genau die kontextfreien Sprachen erkennen

## Satz

$$\text{CFL} = \{L(M) \mid M \text{ ist ein PDA}\}$$

**Idee:**

Konstruiere zu einer kontextfreien Grammatik  $G = (V, \Sigma, P, S)$  einen PDA  $M = (\{z\}, \Sigma, \Gamma, \delta, z, S)$  mit  $\Gamma = V \cup \Sigma$  und folgenden Anweisungen:

- für jede Regel  $A \rightarrow_G \alpha$  die Anweisung  $z \varepsilon A \rightarrow z \alpha$
- für jedes Zeichen  $a \in \Sigma$  die Anweisung  $z a a \rightarrow z \varepsilon$

# Beweis von $\text{CFL} \subseteq \{L(M) \mid M \text{ ist ein PDA}\}$

## Beispiel

- Betrachte die Grammatik  $G = (\{S\}, \{a, b\}, P, S)$  mit den Regeln

$$P: S \rightarrow aSb \quad (1) \quad S \rightarrow \varepsilon \quad (2)$$

- Der zugehörige PDA besitzt dann die Anweisungen


$$\delta: zaa \rightarrow z \quad (0) \quad zbb \rightarrow z \quad (0') \quad z\varepsilon S \rightarrow zaSb \quad (1') \quad z\varepsilon S \rightarrow z \quad (2')$$

- Der Linksableitung  $\underline{S} \xRightarrow{(1)} a\underline{S}b \xRightarrow{(1)} aa\underline{S}bb \xRightarrow{(2)} aabb$  in  $G$  entspricht dann die Rechnung

$$(z, aabb, S) \xrightarrow{(1')} (z, aabb, aSb) \xrightarrow{(0)} (z, abb, Sb)$$

$$\xrightarrow{(1')} (z, abb, aSbb) \xrightarrow{(0)} (z, bb, Sbb)$$

$$\xrightarrow{(2')} (z, bb, bb) \xrightarrow{(0')} (z, b, b) \xrightarrow{(0')} (z, \varepsilon, \varepsilon)$$



von  $M$  und umgekehrt

**Idee:**

Konstruiere zu einer kontextfreien Grammatik  $G = (V, \Sigma, P, S)$  einen PDA  $M = (\{z\}, \Sigma, \Gamma, \delta, z, S)$  mit  $\Gamma = V \cup \Sigma$  und folgenden Anweisungen:

- für jede Regel  $A \rightarrow_G \alpha$  die Anweisung  $z\epsilon A \rightarrow z\alpha$
- für jedes Zeichen  $a \in \Sigma$  die Anweisung  $zaa \rightarrow z\epsilon$

- $M$  versucht also, eine Linksableitung für die Eingabe  $x$  zu finden. Da  $M$  hierbei den Syntaxbaum von oben nach unten aufbaut, wird  $M$  als *Top-Down Parser* bezeichnet
- Zudem gilt  $S \Rightarrow_L^m x_1 \dots x_n$  gdw.  $(z, x_1 \dots x_n, S) \vdash^{m+n} (z, \epsilon, \epsilon)$
- Daher folgt

$$x \in L(G) \Leftrightarrow S \Rightarrow_L^* x \Leftrightarrow (z, x, S) \vdash^* (z, \epsilon, \epsilon) \Leftrightarrow x \in L(M)$$



**Vorbetrachtung:**

- Obige Konstruktion eines PDA  $M$  aus einer kontextfreien Grammatik lässt sich leicht umdrehen, falls  $M$  nur einen Zustand hat
- Zu einem solchen PDA  $M = (\{z\}, \Sigma, \Gamma, \delta, z, \#)$  lässt sich wie folgt eine kontextfreie Grammatik  $G = (V, \Sigma, P, X_{\#})$  mit  $L(G) = L(M)$  konstruieren:

- Die Variablenmenge von  $G$  ist  $V = \{X_A \mid A \in \Gamma\}$   
(wir können auch o.B.d.A.  $\Sigma \cap \Gamma = \emptyset$  annehmen und  $V = \Gamma$  setzen)
- die Startvariable von  $G$  ist  $X_{\#}$  und
- $P$  enthält für jede Anweisung  $z u A \rightarrow z A_1 \dots A_k$  von  $M$  die Regel

$$X_A \rightarrow u X_{A_1} \dots X_{A_k}$$

- Dann lässt sich jede akzeptierende Rechnung  $(z, x, \#) \vdash^m (z, \varepsilon, \varepsilon)$  von  $M(x)$  der Länge  $m$  direkt in eine Linksableitung  $X_{\#} \Rightarrow_L^m x$  in  $G$  der Länge  $m$  transformieren und umgekehrt

# Beweis von $\{L(M) \mid M \text{ ist ein PDA}\} \subseteq \text{CFL}$

## Beispiel

- Betrachte den PDA  $M = (\{z\}, \{a, b\}, \{S, a, b\}, \delta, z, S)$  mit

$$\delta: zaa \rightarrow z \quad (1) \quad zbb \rightarrow z \quad (2) \quad z\epsilon S \rightarrow zaSb \quad (3) \quad z\epsilon S \rightarrow z \quad (4)$$

den wir aus der Grammatik  $G = (\{S\}, \{a, b\}, P, S)$  mit den beiden Regeln  $S \rightarrow aSb, \epsilon$  konstruiert haben

- Dann führt  $M$  auf die Grammatik  $G' = (\{X_S, X_a, X_b\}, \{a, b\}, P', X_S)$  mit

$$P': X_a \rightarrow a \quad (1') \quad X_b \rightarrow b \quad (2') \quad X_S \rightarrow X_a X_S X_b \quad (3') \quad X_S \rightarrow \epsilon \quad (4')$$

- Der Rechnung

$$(z, ab, S) \underset{(3)}{\vdash} (z, ab, aSb) \underset{(1)}{\vdash} (z, b, Sb) \underset{(4)}{\vdash} (z, b, b) \underset{(2)}{\vdash} (z, \epsilon, \epsilon)$$

von  $M$  entspricht dann folgende Linksableitung in  $G'$  (und umgekehrt):

$$\underline{X_S} \underset{(3')}{\Rightarrow} \underline{X_a X_S X_b} \underset{(1')}{\Rightarrow} \underline{a X_S X_b} \underset{(4')}{\Rightarrow} \underline{a X_b} \underset{(2')}{\Rightarrow} \underline{ab}$$

- Man beachte, dass  $G'$  eine aufgeblähte Variante von  $G$  ist.

**Idee:**

Transformiere einen PDA  $M = (Z, \Sigma, \Gamma, \delta, q_0, \#)$  wie folgt in einen äquivalenten PDA  $M' = (\{z\}, \Sigma, \Gamma', \delta', z, S)$  mit nur einem Zustand:

- $M'$  simuliert  $M$  schrittweise und speichert dabei im obersten Kellersymbol  $X_{pAq} \in \Gamma' = \{S\} \cup \{X_{pAq} \mid A \in \Gamma, p, q \in Z\}$ 
  - den aktuellen Zustand  $p$  von  $M$
  - das oberste Kellersymbol  $A$  von  $M$ , sowie
  - den Zustand  $q$ , den  $M$  nach Freigabe der aktuell mit  $A$  belegten obersten Speicherzelle annimmt
- Die Überföhrungsfunktion  $\delta'$  von  $M$  enthält folgende Anweisungen:
  - für jeden Zustand  $q \in Z$  die Anweisung  $z \in S \rightarrow zX_{q_0\#q}$  und
  - für jede Anweisung  $p_0 u A_0 \rightarrow p_1 A_1 \dots A_k$ ,  $k \geq 0$ , von  $M$  und für jede Folge von  $k$  Zuständen  $p_2, \dots, p_{k+1} \in Z$  die Anweisung

$$zuX_{p_0 A_0 p_{k+1}} \rightarrow zX_{p_1 A_1 p_2} \dots X_{p_k A_k p_{k+1}}$$

**Idee (Fortsetzung):**

- Dabei rät  $M'$  durch die Wahl der Anweisung
  - $z \in S \rightarrow zX_{q_0\#q}$  den Zustand  $q$ , den  $M$  im letzten Rechenschritt (also nach Entfernen von  $\#$  aus dem Keller) annimmt
- Zudem rät  $M'$  im Fall  $k \geq 2$  durch die Wahl der Anweisung
  - $zuX_{p_0A_0p_{k+1}} \rightarrow zX_{p_1A_1p_2} \dots X_{p_kA_kp_{k+1}}$  für  $i = 1, \dots, k-1$  die Zustände  $p_{i+1}$ , die  $M$  bei Freigabe der mit  $A_i$  belegten Speicherzelle annimmt
- Im Fall  $k = 1$  gibt  $M'$  beim Ausführen der Anweisung
  - $zuX_{p_0A_0p_2} \rightarrow zX_{p_1A_1p_2}$  lediglich den (zuvor geratenen) Zustand  $p_2$ , der nach Entfernen von  $A_0$  aus dem Keller angenommen werden soll, vom Kellersymbol  $X_{p_0A_0p_2}$  an das Kellersymbol  $X_{p_1A_1p_2}$  weiter
- Dagegen verifiziert  $M'$  im Fall  $k = 0$  beim Ausführen der Anweisung
  - $zuX_{p_0A_0p_1} \rightarrow z$ , dass  $M$  ausgehend von  $p_0$  den (zuvor geratenen) Zustand  $p_1$  nach Entfernen von  $A_0$  aus dem Keller auch annehmen kann (sonst würde diese Anweisung in  $\delta'$  nicht existieren)



## Beispiel

- Betrachte den PDA  $M = (\{p, q\}, \{a, b\}, \{A, \#\}, \delta, p, \#)$  mit den Anweisungen

$$\begin{array}{lll} \delta : p\varepsilon\# \rightarrow q & (1) & pa\# \rightarrow pA \quad (2) \quad paA \rightarrow pAA \quad (3) \\ pbA \rightarrow q & (4) & qbA \rightarrow q \quad (5) \end{array}$$

- Der zugehörige PDA  $M' = (\{z\}, \{a, b\}, \Gamma', \delta', z, S)$  mit nur einem Zustand hat dann das Kelleralphabet

$$\Gamma' = \{S, X_{p\#p}, X_{p\#q}, X_{q\#p}, X_{q\#q}, X_{pAp}, X_{pAq}, X_{qAp}, X_{qAq}\}$$

## Beispiel (Fortsetzung)


- Zudem enthält  $M'$  neben den beiden Anweisungen  ~~$z\epsilon S \rightarrow zX_{p\#p}$  (0)~~ und  $z\epsilon S \rightarrow zX_{p\#q}$  (0')

Anweisung von $M$	$k$	$p_2, \dots, p_{k+1}$	Anweisungen von $M'$
$p\epsilon\# \rightarrow q$ (1)	0	-	$z\epsilon X_{p\#q} \rightarrow z$ (1')
$pa\# \rightarrow pA$ (2)	1	$p$	<del><math>z\epsilon X_{p\#p} \rightarrow zX_{pAp}</math> (2')</del>
		$q$	$z\epsilon X_{p\#q} \rightarrow zX_{pAq}$ (2'')
$paA \rightarrow pAA$ (3)	2	$p, p$	$z\epsilon X_{pAp} \rightarrow zX_{pAp}X_{pAp}$ (3')
		$p, q$	$z\epsilon X_{pAq} \rightarrow zX_{pAp}X_{pAq}$ (3'')
		$q, p$	<del><math>z\epsilon X_{pAp} \rightarrow zX_{pAq}X_{qAp}</math> (3''')</del>
		$q, q$	$z\epsilon X_{pAq} \rightarrow zX_{pAq}X_{qAq}$ (3''')
$pbA \rightarrow q$ (4)	0	-	$z\epsilon X_{pAq} \rightarrow z$ (4')
$qbA \rightarrow q$ (5)	0	-	$z\epsilon X_{qAq} \rightarrow z$ (5')

## Beispiel (Schluss)

- Der (akzeptierenden) Rechnung

$$(\textcolor{violet}{p}, aabb, \textcolor{violet}{\#}) \stackrel{(2)}{\vdash} (\textcolor{blue}{p}, abb, \textcolor{blue}{A}) \stackrel{(3)}{\vdash} (\textcolor{red}{p}, bb, \textcolor{red}{AA}) \stackrel{(4)}{\vdash} (\textcolor{orange}{q}, b, \textcolor{orange}{A}) \stackrel{(5)}{\vdash} (\textcolor{green}{q}, \varepsilon, \varepsilon)$$



von  $M$  entspricht dann folgende Rechnung von  $M'$ :

$$\begin{aligned}
 (z, aabb, S) &\stackrel{(0')}{\vdash} (z, aabb, X_{\textcolor{violet}{p}\textcolor{green}{\#}\textcolor{orange}{q}}) \stackrel{(2'')}{\vdash} (z, abb, X_{\textcolor{blue}{p}\textcolor{orange}{A}\textcolor{green}{q}}) \\
 &\stackrel{(3''')}{\vdash} (z, bb, X_{\textcolor{red}{p}\textcolor{orange}{A}\textcolor{green}{q}} X_{\textcolor{orange}{q}\textcolor{orange}{A}\textcolor{green}{q}}) \stackrel{(4')}{\vdash} (z, b, X_{\textcolor{orange}{q}\textcolor{orange}{A}\textcolor{green}{q}}) \stackrel{(5')}{\vdash} (z, \varepsilon, \varepsilon)
 \end{aligned}$$

