

# AbschluÙeigenschaften

## Erinnerung

Die Klasse der regulären Sprachen ist abgeschlossen unter:

- Vereinigung ( $L_1, L_2$  regulär  $\Rightarrow L_1 \cup L_2$  regulär)
- Schnitt ( $L_1, L_2$  regulär  $\Rightarrow L_1 \cap L_2$  regulär)
- Komplement ( $L$  regulär  $\Rightarrow \Sigma^* \setminus L$  regulär)
- Produkt/Konkatenation ( $L_1, L_2$  regulär  $\Rightarrow L_1 L_2$  regulär)
- Stern-Operation ( $L$  regulär  $\Rightarrow L^*$  regulär)

## Frage

Welche dieser Eigenschaften gelten für die Klasse der kontextfreien Sprachen?

## Satz

Die Klasse der kontextfreien Sprachen ist abgeschlossen unter:

- ① Vereinigung ( $L_1, L_2$  kontextfrei  $\Rightarrow L_1 \cup L_2$  kontextfrei)
- ② Produkt/Konkatenation ( $L_1, L_2$  kontextfrei  $\Rightarrow L_1L_2$  kontextfrei)
- ③ Stern-Operation ( $L$  kontextfrei  $\Rightarrow L^*$  kontextfrei)

Die Klasse der kontextfreien Sprachen ist nicht abgeschlossen unter:

- ④ Schnitt (es gibt  $L_1, L_2$  deterministisch kontextfrei, so daß  $L_1 \cap L_2$  nicht kontextfrei ist)
- ⑤ Komplement (es gibt  $L$  kontextfrei, so daß  $\Sigma^* \setminus L$  nicht kontextfrei ist)

Es folgt:

- ⑥ Es gibt kontextfreie Sprachen, die nicht deterministisch kontextfrei sind.

**Beweis:**

(1)-(3): siehe Übungsaufgabe 6(3)

Bisher haben wir keine Methode, um zu zeigen, daß eine Sprache nicht kontextfrei ist. - Der Beweis wird auf Folie 15.24 vervollständigt werden.

# Das Pumping-Lemma für kontextfreie Sprachen

**Idee:** Man versucht auszunutzen, daß eine kontextfreie Sprache von einer Grammatik mit **endlich** vielen Nichtterminalen erzeugt werden muß. Das bedeutet auch: wenn ein Ableitungsbaum ausreichend tief ist, so gibt es einen Ast, der ein Nichtterminal mehrfach enthält. Die durch diese zwei Vorkommen bestimmten Teilbäume werden wir „pumpen“.

## Pumping Lemma (Bar-Hillel, Perles, Shamir '61)

Wenn  $L$  eine kontextfreie Sprache ist,  
dann gibt es  $n \geq 1$  derart,

daß für alle  $z \in L$  mit  $|z| \geq n$  gilt:

es gibt Wörter  $u, v, w, x, y \in \Sigma^*$  mit

- (i)  $z = uvwxy$ ,
- (ii)  $|vwx| \leq n$ ,
- (iii)  $|vx| \geq 1$  und
- (iv)  $uv^iwx^iy \in L$  für alle  $i \geq 0$ .

Dieses Lemma spricht nicht über kontextfreie Grammatiken, sondern nur über die Eigenschaften der Sprache. Daher ist es dazu geeignet, Aussagen über Nicht-Kontextfreiheit zu machen. Wir zeigen zunächst an einem Beispiel, wie dies funktioniert:

## Beispiel (Fortsetzung von Folie 2.7 bzw. 2.10)

Betrachte die kontextsensitive Grammatik  $G$  mit den Produktionen

$$\begin{array}{llll}
 S & \rightarrow & aSBC \mid aBC & CB \rightarrow HB \quad HB \rightarrow HC \\
 HC & \rightarrow & BC & aB \rightarrow ab \quad bB \rightarrow bb \\
 bC & \rightarrow & bc & cC \rightarrow cc.
 \end{array}$$

Sie erzeugt z.B. das Wort  $aabbcc$ :

$$\begin{aligned}
 \underline{S} &\Rightarrow a\underline{S}BC \Rightarrow aa\underline{B}C\underline{B}C \Rightarrow aaB\underline{H}BC \\
 &\Rightarrow aaB\underline{H}CC \Rightarrow aa\underline{B}BCC \Rightarrow aab\underline{B}CC \\
 &\Rightarrow aabb\underline{C}C \Rightarrow aabb\underline{c}C \Rightarrow aabbcc
 \end{aligned}$$

Die erzeugte Sprache ist  $L_1 = \{a^m b^m c^m \mid m \geq 1\}$ .

Diese kontextsensitive Sprache ist nicht kontextfrei. Also gilt  $\mathcal{L}_2 \subsetneq \mathcal{L}_1$ .

**Beweis:** indirekt

Angenommen,  $L_1$  wäre kontextfrei.

Nach dem Pumping-Lemma gibt es ein  $n \geq 1$ , so daß die folgende Aussage gilt:

Für jedes  $z \in L_1$ ,  $|z| \geq n$ , gibt es  $u, v, w, x, y \in \Sigma^*$  mit  
 (i), (ii), (iii) und (iv). (\*)

Wir wählen nun  $z = a^n b^n c^n$ .

Dann ist  $z \in L_1$  und  $|z| = 3n > n$ .

Nach der Aussage (\*) gibt es also  $u, v, w, x, y \in \Sigma^*$  mit

- |                         |  |
|-------------------------|--|
| (i) $z = uvwxy$ ,       | (ii) $ vwx  \leq n$ ,                            |
| (iii) $ vx  \geq 1$ und | (iv) $uv^i wx^i y \in L_1$ für alle $i \geq 0$ . |

$$uvwxy \stackrel{(i)}{=} z = \underbrace{aaaaa \cdots aaaa}_{n\text{-mal}} \underbrace{bbbbbb \cdots bbbb}_{n\text{-mal}} \underbrace{cccccc \cdots cccc}_{n\text{-mal}}$$

Wegen  $|vwx| \leq n$  nach (ii) gilt  $vwx \in L(a^*b^*) \cup L(b^*c^*)$  und damit  $vx \in L(a^*b^*) \cup L(b^*c^*)$ .

Mit anderen Worten: es ist nicht möglich, daß sowohl ein  $a$  als auch ein  $c$  in  $vx$  vorkommen.

Wir unterscheiden zwei Fälle:

- $c$  kommt in  $vx$  nicht vor: dann gilt  $|uv^2wx^2y|_c = |uvwxy|_c = n$ , aber

$$|uv^2wx^2y|_a + |uv^2wx^2y|_b = 2n + |vx|_a + |vx|_b = 2n + |vx| > 2n$$

wegen (iii), also  $|uv^2wx^2y|_a > n$  oder  $|uv^2wx^2y|_b > n$  und damit  $uv^2wx^2y \notin L_1$ , im Widerspruch zu (iv).

- $a$  kommt in  $vx$  nicht vor: man erhält analog einen Widerspruch zu (iv).

Also ist  $L_1$  tatsächlich nicht kontextfrei. □

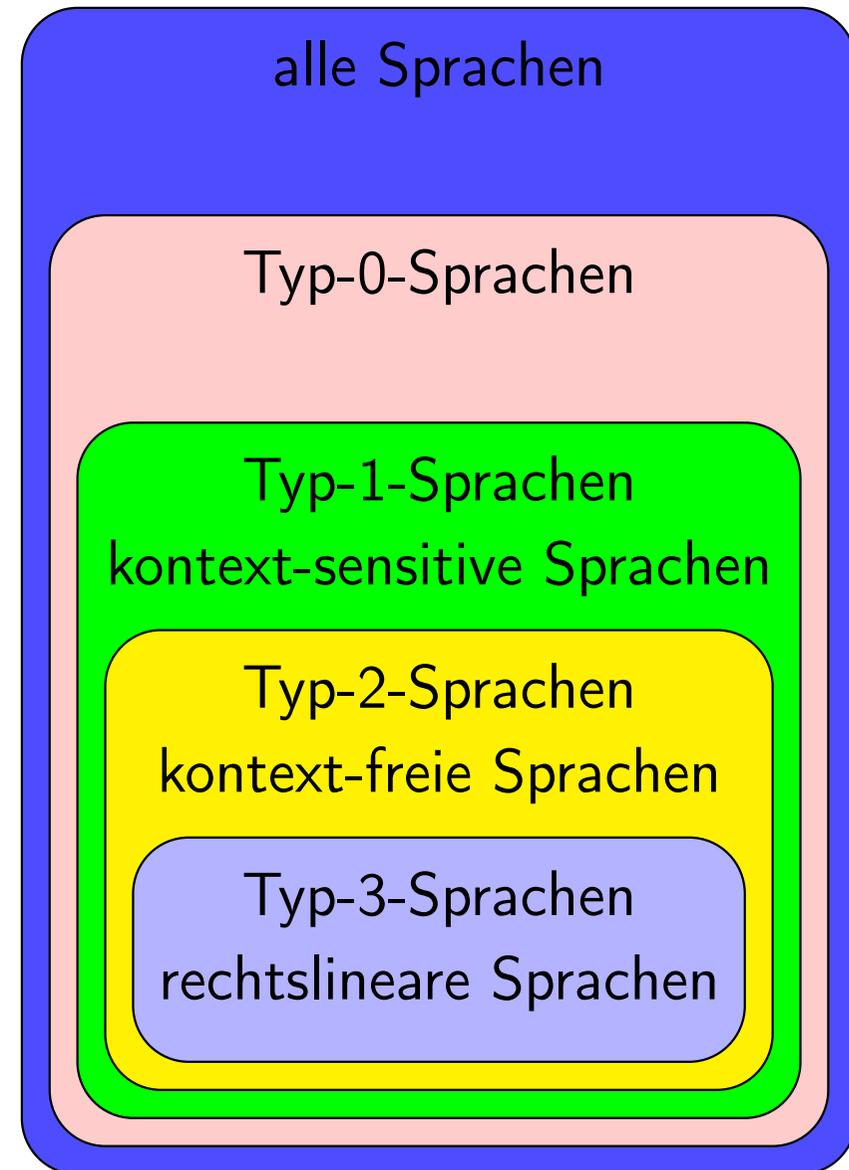
Auf Folien 2.22 und 10.28 wurde  $\mathcal{L}_3 \subseteq \mathcal{L}_2 \subseteq \mathcal{L}_1 \subseteq \mathcal{L}_0$  gezeigt.

Auf Folie 6.7 wurde  $\mathcal{L}_0 \subsetneq$  Klasse aller Sprachen und auf Folie 6.12 auch  $\mathcal{L}_3 \subsetneq \mathcal{L}_2$  gezeigt.

Jetzt wissen wir, daß auch  $\mathcal{L}_2 \subsetneq \mathcal{L}_1$  gilt.

Wir wissen noch nicht, ob  $\mathcal{L}_1 = \mathcal{L}_0$  oder  $\mathcal{L}_1 \subsetneq \mathcal{L}_0$  gilt.

Wir haben also  $\mathcal{L}_3 \subsetneq \mathcal{L}_2 \subsetneq \mathcal{L}_1 \subseteq \mathcal{L}_0 \subsetneq$  Klasse aller Sprachen.



Im Beweis des Pumping-Lemmas verwenden wir die folgende Aussage.

### Lemma

Sei  $B$  ein Binärbaum (d.h., jeder Knoten in  $B$  hat entweder null oder zwei Kinder) mit mindestens  $2^k$  Blättern.

Dann hat  $B$  einen von der Wurzel ausgehenden Ast, der aus mindestens  $k$  Kanten und  $k + 1$  Knoten besteht.

**Beweis:** Induktion über  $k$ .

**IA:**  $k = 0$ .

Sei  $B$  ein Binärbaum mit mindestens  $2^0$  Blättern, d.h. mit mindestens einem Blatt.

Dann hat  $B$  einen Ast, der aus mindestens einem Knoten besteht.

**IS:**  $k \geq 0$ .

Sei  $B$  ein Binärbaum mit mindestens  $2^{k+1} = 2^k + 2^k > 1$  Blättern.

Seien  $v_1$  und  $v_2$  die beiden Kinder der Wurzel und seien  $B_1$  und  $B_2$  die Binärbäume mit Wurzel  $v_1$  bzw.  $v_2$ .

Dann existiert  $i \in \{1, 2\}$ , so daß  $B_i$  mindestens  $2^k$  Blätter hat.

IV  $\Rightarrow$  in  $B_i$  gibt es einen Ast mit mindestens  $k$  Kanten und  $k + 1$  Knoten.

$\Rightarrow$  in  $B$  gibt es einen Ast mit mindestens  $k + 1$  Kanten und  $k + 2$  Knoten.



**Beweis des Pumping-Lemmas:**

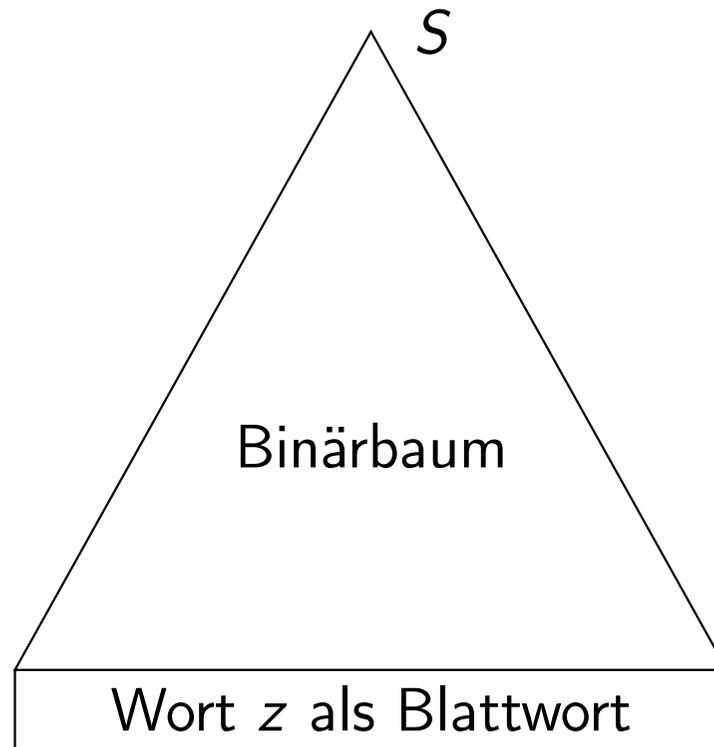
Sei  $L \subseteq \Sigma^*$  kontextfrei. Dann existiert eine kontextfreie Grammatik  $G = (V, \Sigma, P, S)$  in Chomsky-Normalform mit  $L = L(G)$ .

Setze  $k := |V|$  und  $n := 2^k$ .

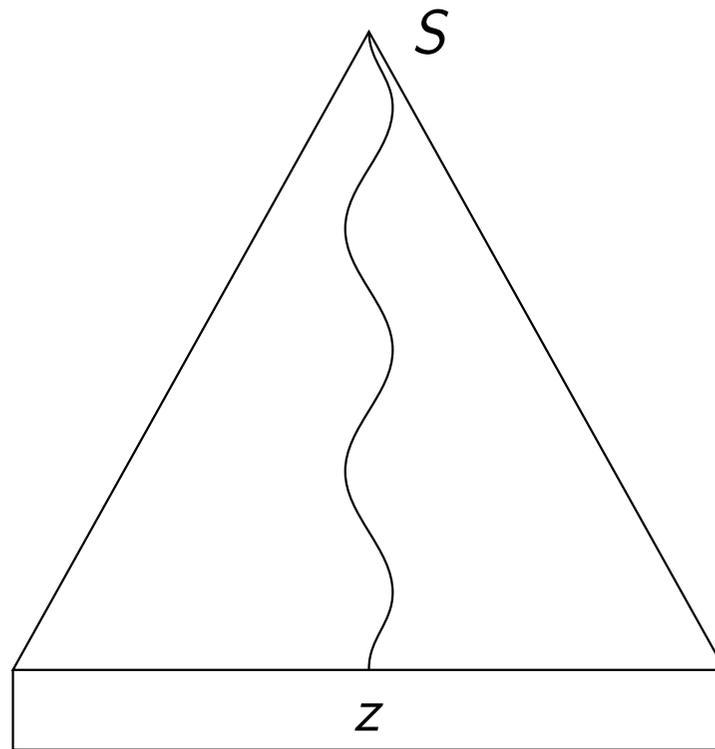
Sei weiter  $z \in L(G)$  mit  $|z| \geq n = 2^k$ .

Wegen  $z \in L(G)$  existiert ein Ableitungsbaum  $T$  mit  $\alpha(T) = z$ .

Der Ableitungsbaum  $T$   
mit  $\alpha(T) = z$  und  $|z| \geq$   
 $n = 2^k$ .

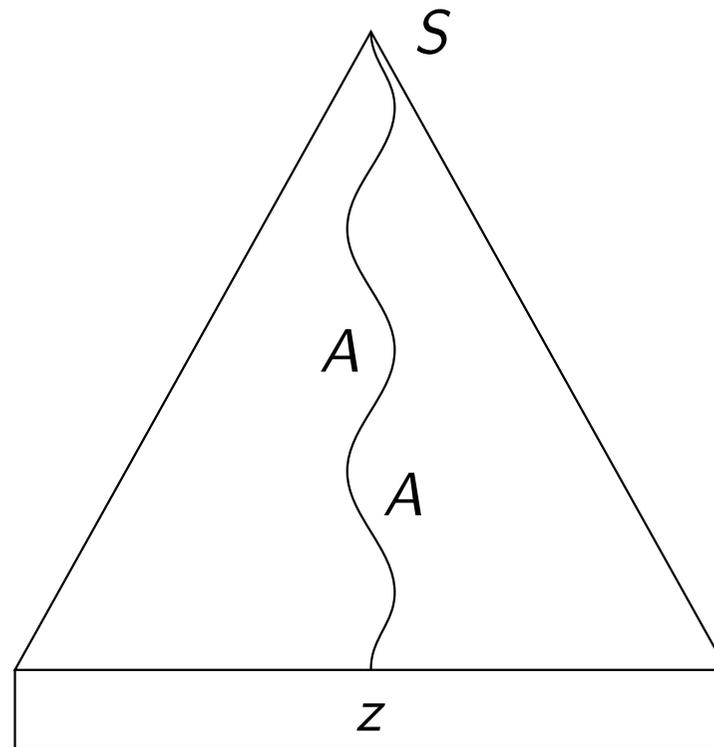


Nach dem vorherigen Lemma existiert ein Ast in  $T$  mit mindestens  $k + 1$  Knoten.



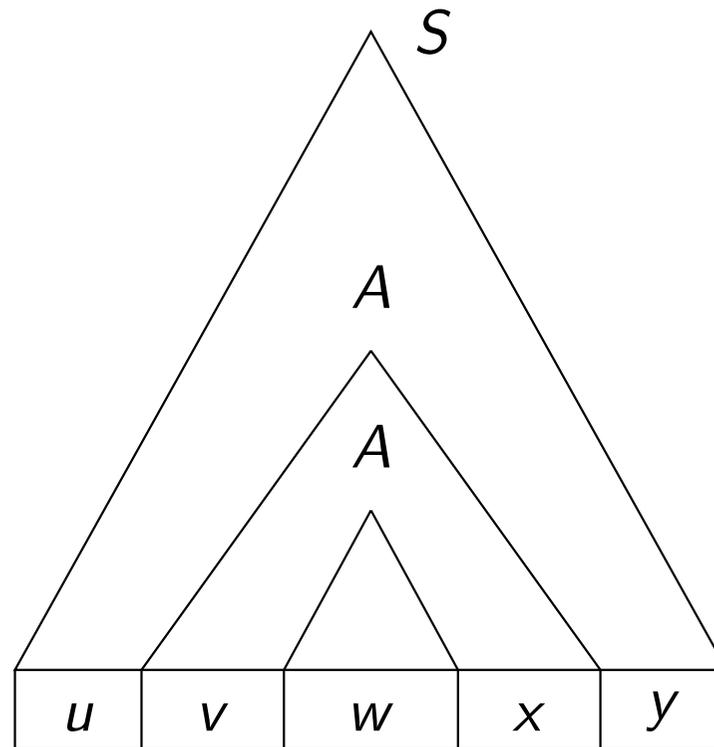
Also gibt es ein Nicht-terminal (etwa  $A$ ), das auf dem Ast zweimal auftaucht.

Wir können annehmen, daß auf jedem Ast, der vom oberen  $A$  ausgeht, höchstens das  $A$  mehrfach und dieses nicht dreimal vorkommt.

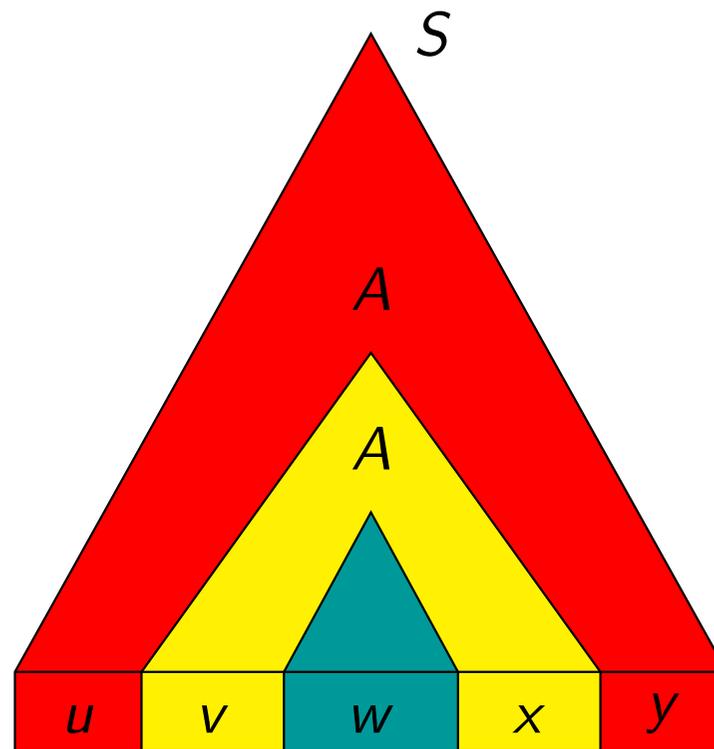


Das Wort  $z$  wird nun in fünf Teilwörter  $u, v, w, x, y$  aufgespalten (womit (i) gesichert ist):

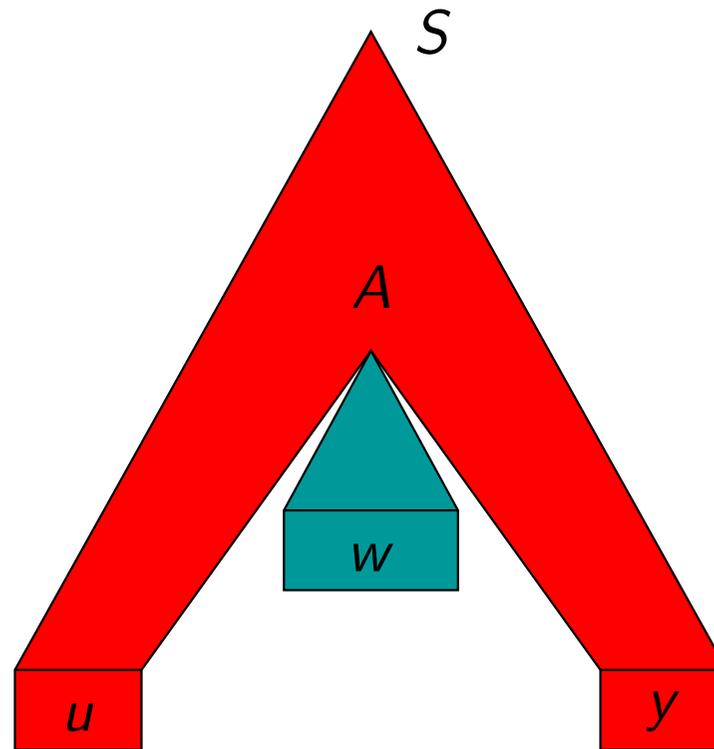
- $w$  wird aus dem unteren  $A$  abgeleitet:  
 $A \Rightarrow^* w$
- $vwx$  wird aus dem oberen  $A$  abgeleitet:  
 $A \Rightarrow^* vAx \Rightarrow^* vwx$



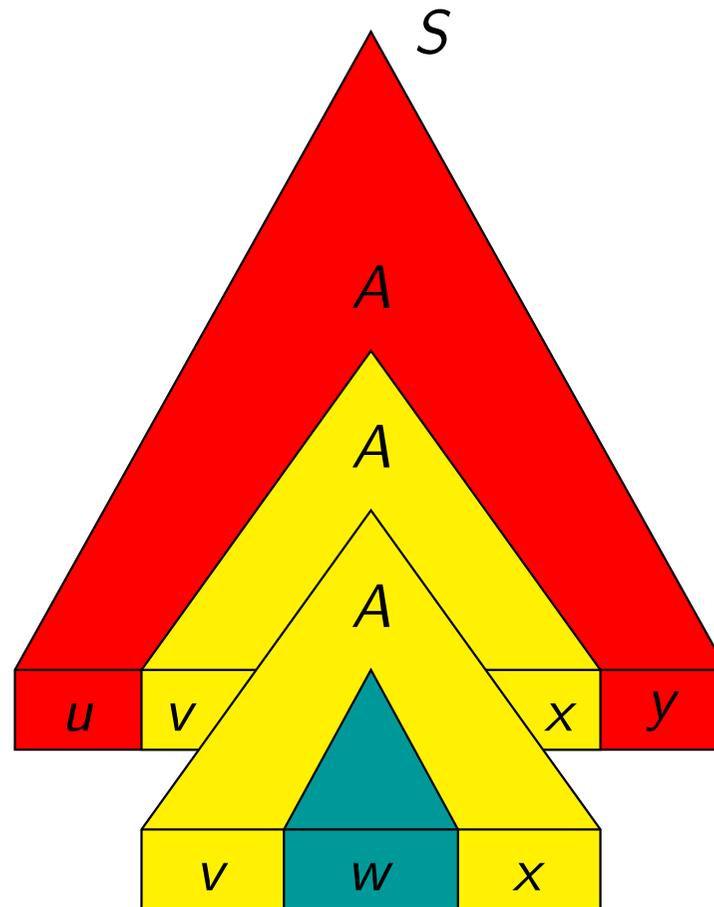
Damit erhält man drei  
ineinander enthaltene Teil-  
Ableitungsbäume, die man  
neu zusammenstecken  
kann.



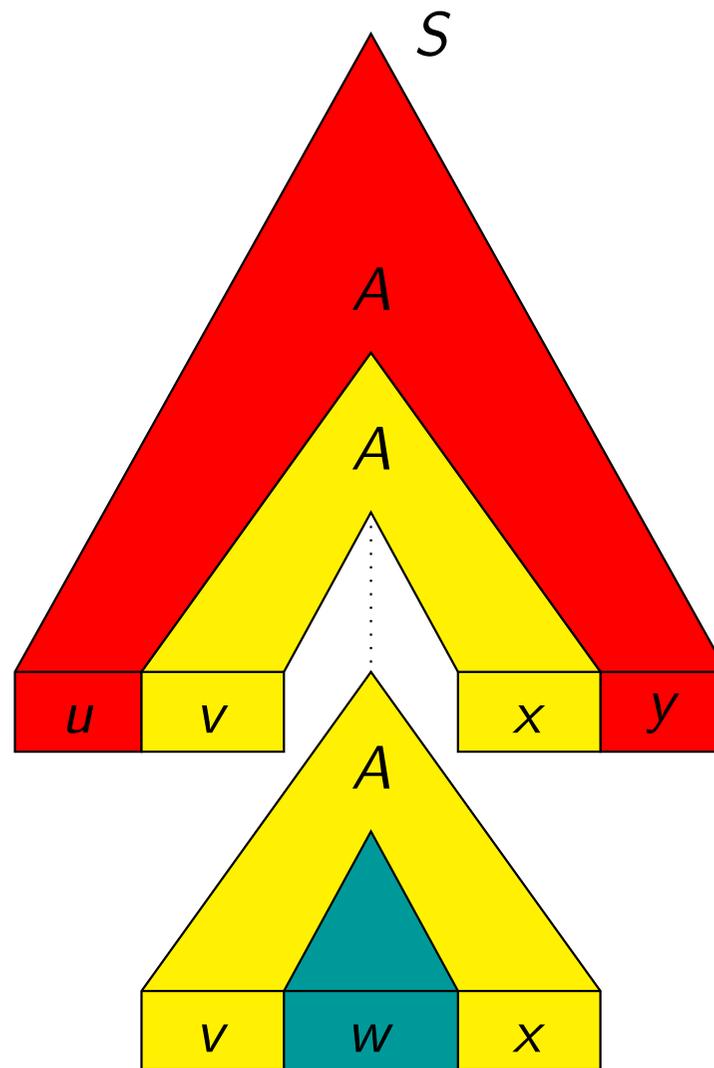
Durch Weglassen des mittleren Teilbaums erhält man einen Ableitungsbaum für  $uwy$ . Damit gilt:  $uwy \in L(G)$ .



Durch Verdoppeln des mittleren Teilbaums erhält man einen Ableitungsbaum für  $uv^2wx^2y$ . Damit gilt:  $uv^2wx^2y \in L(G)$ .



Durch Ver- $i$ -fachen des mittleren Teilbaums erhält man einen Ableitungsbaum für  $uv^iwx^iy$ . Damit gilt:  $uv^iwx^iy \in L(G)$ , d.h. wir haben (iv) gezeigt.



Wir zeigen als nächstes (ii), d.h.  $|vwx| \leq n$ :

Sei  $T_1$  der Teilbaum von  $T$ , der am oberen  $A$  beginnt (d.h. es gilt  $\alpha(T_1) = vwx$ ).

Da wir das obere  $A$  so gewählt haben, daß davon ausgehende Äste höchstens das  $A$  mehrfach (und dieses nicht dreimal) enthalten, kann kein Ast in  $T_1 > |V| + 1$  Knoten enthalten.

Das vorhergehende Lemma sichert  $|vwx| = \text{Blattanzahl in } T_1 \leq 2^{|V|} = n$ .

Es bleibt noch (iii) zu zeigen, also  $|vx| \geq 1$ :

Sei  $T_2$  der Teilbaum von  $T$ , der am unteren  $A$  beginnt (d.h. es gilt  $\alpha(T_2) = w$ ).

Da  $T$  nur binäre Verzweigungen enthält und  $T_2$  echter Teilbaum von  $T_1$  ist, hat  $T_1$  wenigstens ein Blatt, das nicht zu  $T_2$  gehört. Da es keine  $\varepsilon$ -Produktionen gibt, ist dieses Blatt mit  $a \in \Sigma$  beschriftet. Also gilt  $vx \neq \varepsilon$ . □

Unser Beweis, daß  $L_1$  nicht kontextfrei ist, folgt dem folgenden Schema:

**Behauptung:** Die Sprache  $L$  ist nicht kontextfrei.

[0] (wörtlich) **Beweis:** indirekt. Angenommen,  $L$  wäre kontextfrei. Nach dem Pumping-Lemma gibt es ein  $n \geq 1$ , so daß die folgende Aussage gilt:

Für jedes  $z \in L$ ,  $|z| \geq n$ , gibt es  $u, v, w, x, y \in \Sigma^*$  (\*)  
mit (i), (ii), (iii) und (iv).

[1] (problemspezifisch) Wir wählen ein **geeignetes**  $z \in L$  mit  $|z| \geq n$ , so daß Schritt [3] ausführbar ist.

[2] (wörtlich) Nach der Aussage (\*) gibt es  $u, v, w, x, y \in \Sigma^*$  mit (i)-(iv).

[3] (problemspezifisch) Wir wählen zu  $u, v, w, x, y$  ein **passendes**  $i \geq 0$  und zeigen, daß  $uv^iwx^iy$  nicht in  $L$  sein kann.

[4] (wörtlich) Widerspruch zu (iv). □

Dieses Beweisschema ist die Umsetzung der folgenden Formulierung des Pumping-Lemmas mit logischen Operatoren:

$L$  kontextfrei

$$\rightarrow \exists n \forall z \in L \text{ mit } |z| \geq n \exists u, v, w, x, y \text{ mit (i-iii)} \forall i : uv^iwx^iy \in L$$

Diese Aussage ist logisch äquivalent zu:

$$\forall n \exists z \in L \text{ mit } |z| \geq n \forall u, v, w, x, y \text{ mit (i-iii)} \exists i : uv^iwx^iy \notin L$$

$\rightarrow L$  ist nicht kontextfrei

Um zu zeigen, daß eine Sprache  $L$  nicht kontextfrei ist, reicht es also zu zeigen, daß es für alle  $n$  ein  $z \in L$  gibt ...

Dies können wir auch in dem folgenden **Spielschema** fassen:

Wir (die **B**eweiser oder **B**raven) wollen zeigen, daß die Sprache  $L$  nicht kontextfrei ist. Dazu müssen wir das folgende Spiel (gegen den **G**egner oder den **G**emeinen) gewinnen:

Runde 1 **G** wählt eine Zahl  $n \geq 1$ .

Runde 2 **B** wählt ein  $z \in L$  mit  $|z| \geq n$

Runde 3 **G** wählt  $u, v, w, x$  und  $y$  mit

(i)  $z = uvwxy$ , (ii)  $|vwx| \leq n$  und (iii)  $|vx| \geq 1$ .

Runde 4 **B** wählt ein  $i$  und zeigt, daß  $uv^iwx^iy \notin L$ .

Die Sprache  $L$  ist **nicht** kontextfrei, falls **B** unabhängig von den Wahlen von **G** in Runden 1 und 3 immer so wählen kann (in Runden 2 und 4), daß schließlich  $uv^iwx^iy \notin L$  gilt.

## Beispiel

$L_2 = \{w^2w \mid w \in \{0, 1\}^*\}$  ist nicht kontextfrei.

**Beweis:** wir zeigen, daß **B** im Spielschema immer so wählen kann, daß  $uv^iwx^iy \notin L_2$  gilt:

Runde 1 **G** wählt eine Zahl  $n \geq 1$ .

Runde 2 **B** wählt  $z = 0^n1^n20^n1^n$  (natürlich gelten  $z \in L_2$  und  $|z| \geq n$ )

Runde 3 **G** wählt  $u, v, w, x$  und  $y$  mit

(i)  $z = uvwxy$ , (ii)  $|vwx| \leq n$  und (iii)  $|vx| \geq 1$ .

Runde 4 **B** wählt  $i = 0$  und zeigt, daß  $uv^iwx^iy \notin L_2$ :

1. Fall:  $v$  oder  $x$  enthält die 2.  
Dann enthält  $uv^0wx^0y$  keine 2, gehört also nicht zu  $L_2$ .
2. Fall:  $u$  enthält 2.  
Dann stehen in  $uv^0wx^0y$  links von der 2 mehr Buchstaben als rechts, also  $uv^0wx^0y \notin L_2$ .
3. Fall:  $y$  enthält 2.  
analog
4. Fall:  $w$  enthält 2.  
Wegen (ii) ist  $vwx$  Faktor von  $1^n20^n$ , der 2 enthält. Also gilt  $v \in L(1^*)$  und  $x \in L(0^*)$  und damit  $uv^0wx^0y = 0^n1^{n-|v|}20^{n-|x|}1^n \notin L_2$ , da  $|v| > 0$  oder  $|x| > 0$  nach (iii).

Also kann  $B$  so wählen, daß  $uv^iwx^iy \notin L_2$ , d.h.,  $L_2$  ist tatsächlich nicht kontextfrei. □

## Beispiel

$$L_3 = \{u_13 \dots u_{r-1}3u_r2v_13 \dots v_{s-1}3v_s \mid u_1, \dots, u_r, v_1, \dots, v_s \in \{0, 1\}^* \\ \forall j \leq s \exists i \leq r : v_j = u_i\}$$

ist nicht kontextfrei.

**Beweisidee:** Wäre  $L_3$  kontextfrei, so auch  $L_3 \cap \{0, 1\}^* \{2\} \{0, 1\}^* = L_2$  (denn der Schnitt von kontextfreien und regulären Sprachen ist kontextfrei, siehe Satz auf Folie 14.9). Das ist aber nicht der Fall.  $\square$

**Hintergrund:** Viele Programmiersprachen haben die „Kontextbedingung“, daß eine Variable vor der Benutzung deklariert werden muß.

Diese Eigenschaft kann nicht in einer kontextfreien Grammatik ausgedrückt werden.

# Das Lemma von Ogden

## Lemma (William Ogden '68)

Wenn  $L$  eine kontextfreie Sprache ist,

dann gibt es  $n \geq 1$  derart,

daß für alle  $z \in L$  mit  $|z| \geq n$ , in denen  $n$  Positionen markiert sind, gilt:

es gibt Wörter  $u, v, w, x, y \in \Sigma^*$  mit

- (i)  $z = uvwxy$ ,
- (ii)  $|vwx| \leq n$ ,
- (iii)  $|vx| \geq 1$   $v$  oder  $x$  enthält wenigstens eine der Markierungen und
- (iv)  $uv^iwx^iy \in L$  für alle  $i \geq 0$ .

Beweis: ähnlich zum Beweis des Pumping-Lemmas. □

## Beispiele

weitere Sprachen, die nicht kontextfrei sind:

$$\begin{array}{ll}
 \{a^k b^m a^k b^m \mid k, m \geq 0\} & \{a^k b^m a^{k \cdot m} \mid k, m \geq 0\} \\
 \{w w \mid w \in \{0, 1\}^*\} & \{0^m 1 0^m 1 0^m \mid m \geq 0\} \\
 \{0^m 1^{2m} 0^{4m} \mid m \geq 0\} & \{0^p \mid p \text{ Primzahl} \}
 \end{array}$$

**Beweis** jeweils mit dem Pumping-Lemma oder dem Lemma von Ogden.

## Beweis der Aussagen (4)-(6) des Satzes auf Folie 15.2

4

$$L_4 = \{a^k b^\ell c^m \mid 0 \leq k = \ell, 0 \leq m\}$$

$$L_5 = \{a^k b^\ell c^m \mid 0 \leq k, 0 \leq \ell = m\}$$

sind deterministisch kontextfreie Sprachen (einfach).

Ihr Schnitt

$$L_4 \cap L_5 = \{a^k b^\ell c^m \mid 0 \leq k = \ell = m\} = L_1$$

ist jedoch nicht kontextfrei (siehe Folie 15.6).

- 5  $L_6 = \{a^k b^\ell c^m \mid k \neq \ell \text{ oder } \ell \neq m\} \cup \{a, b, c\}^+ \setminus L(a^* b^* c^*)$   
ist eine kontextfreie Sprache (einfach).

Ihr Komplement

$$\{a, b, c\}^* \setminus L_6 = \{a^k b^\ell c^m \mid 0 \leq k = \ell = m\} = L_1$$

ist jedoch nicht kontextfrei (siehe Folie 15.6).

- 6  $L_6$  ist kontextfrei. Wäre  $L_6$  deterministisch kontextfrei, so nach dem Satz auf Folie 14.21 auch ihr Komplement

$$\{a, b, c\}^* \setminus L_6 = \{a^k b^\ell c^m \mid k = \ell = m\} = L_1.$$

Diese Sprache ist aber nicht einmal kontextfrei (siehe Folie 15.6). Also kann  $L_6$  nicht deterministisch kontextfrei sein.  $\square$

## Zusammenfassung 15. Vorlesung

### in dieser Vorlesung neu

- Abschlußeigenschaften der Klasse der kontext-freien Sprachen
- Sprachen, die nicht kontext-frei sind (Pumping-Lemma)

### kommende Vorlesung

- Algorithmen für kontext-freie Sprachen