

# Automaten und Formale Sprachen

SoSe 2007 in Trier

Henning Fernau

Universität Trier

fernau@uni-trier.de

# Automaten und Formale Sprachen

Gesamtübersicht

- Organisatorisches
- Einführung
- Endliche Automaten und reguläre Sprachen
- **Kontextfreie Grammatiken und kontextfreie Sprachen**
- Chomsky-Hierarchie

# Kontextfreie Grammatiken und kontextfreie Sprachen

1. Automaten mit unendlichem Speicher
2. Kontextfreie Grammatiken
3. Normalformen
4. **Nichtkontextfreie Sprachen**
5. Algorithmen für kontextfreie Grammatiken

## Ein Beispiel zur Schulung der Intuition

Betrachte

$$L = \{a^n b^n c^n \mid n \in \mathbb{N}\}$$

Ein Kellerautomat für  $L$  müsste irgendwie die Länge des  $a$ -Blocks mit der des folgenden  $b$ -Blocks abgleichen.

Dazu muss er den Keller verwenden.

Danach ist der Keller aber leer, d.h., die Länge des  $c$ -Blocks kann nicht mehr mit der eines vorhergehenden  $a$ - oder  $b$ -Blocks abgeglichen werden.

**Vermutung:**  $L$  ist nicht kontextfrei.

Ein **binärer Wurzelbaum** ist gegeben durch ein Tripel  $B = (V, \phi, r)$  mit auszeichneter *Wurzel*  $r \in V$  und einer *Vater-Abbildung*  $\phi : V \setminus \{r\} \rightarrow V$  mit der Eigenschaft

$$\forall v \in V : \underbrace{\#\{u \in V \mid \phi(u) = v\}}_{\kappa(v) :=} \leq 2$$

$\kappa(v)$  liefert also die *Kinder* von  $v$ .

Knoten  $v$  mit  $\kappa(v) = \emptyset$  heißen *Blätter*.

**Lemma:** Der Ableitungsbaum eines jeden von einer kontextfreien Grammatik in Chomsky-Normalform akzeptierten Wortes ist als binärer Wurzelbaum auffassbar.

Die **Höhe** eines binären Wurzelbaumes  $B = (V, \phi, r)$  ist gegeben durch

$$h(B) = \max_{v \in V \setminus \{r\}} \{k \in \mathbb{N} \mid \phi^k(v) = r\}.$$

**Lemma:** Hat ein binärer Wurzelbaum  $B$  mehr als  $2^h$  Blätter, so gilt  $h(B) > h$ .

Beweis: Wir zeigen die **Kontraposition** per Induktion:

Gilt  $h(B) \leq h$ , so hat  $B = (V, \phi, r)$  höchstens  $2^h$  viele Blätter.

$h = 0$  ist trivial.

Es gelte  $h > 0$ . Daher gilt  $\kappa(r) \neq \emptyset$ .

Betrachte  $r' \in \kappa(r)$ .  $V' := \{v \in V \mid \exists k \in \mathbb{N} : \phi^k(v) = r'\}$ .

$\phi'$  sei die Einschränkung von  $\phi$  auf  $V' \setminus \{r'\}$ .

$B' = (V', \phi', r')$  ist ein binärer Wurzelbaum der Höhe höchstens  $h - 1$ .

Auf  $B'$  ist die Induktionshypothese anwendbar:  $B'$  hat höchstens  $2^{h-1}$  viele Blätter.

$\leadsto$   $B$  hat höchstens  $\#\kappa(r) \cdot 2^{h-1} \leq 2^h$  viele Blätter.

**Lemma:** Ist  $G = (\Sigma, N, R, S)$  eine kfG in Chomsky-Normalform und ist  $w \in L(G)$  mit  $\ell(w) > 2^{\#N}$ , so gilt für jeden Ableitungsbaum von  $w$  bzgl.  $G$ , dass es einen Weg von  $S$  zu einem Blatt gibt, auf dem mehr als  $\#N$  viele Nichtterminalzeichen ersetzt werden.

Beweis: Nach dem vorigen Lemma hat der unterliegende binäre Wurzelbaum die Höhe größer als  $\#N$ . Es gibt also einen Weg in besagtem Ableitungsbaum von der mit  $S$  beschrifteten Wurzel zu einem Blatt, dem mehr als  $\#N$  Regelanwendungen entspricht  $\rightsquigarrow$  Behauptung.

**Folgerung:** Auf besagtem Weg von der Wurzel zum Blatt im Ableitungsbaum von  $w$  finden wir also nach dem Schubfachprinzip zwei Regelanwendungen  $A \rightarrow v$  und  $A \rightarrow u$  mit gleicher linker Seite.

## Erweiterte Chomsky-Normalform

**Satz:** Jede  $L \in \mathbf{KF}$  lässt sich beschreiben durch eine kfG  $G = (\Sigma, N, R, S)$  mit Regeln der Form  $N \times ((NN) \cup (\Sigma))$ ; zusätzlich darf eine Regel  $S \rightarrow \lambda$  existieren, wobei dann gefordert ist, dass  $S$  in keiner rechten Regelseite vorkommt.

Beweis: Wie vorher erklärt, gibt es kfG  $G' = (\Sigma, N', R', S')$  in Chomsky-Normalform für  $L(G) \setminus \{\lambda\}$ .

Definiere  $R'' = \{S \rightarrow w \mid S' \rightarrow w \in R'\}$  für ein neues  $S \notin N'$  und

$R = R' \cup R'' \cup \{S \rightarrow \lambda \mid \lambda \in L\}$ ,  $N = N' \cup \{S\}$ .

$\leadsto G = (\Sigma, N, R, S)$  beschreibt  $L$  und hat die geforderten Eigenschaften.

Hinweis: Die vorige Folie hat auch für die erweiterte Chomsky-Normalform Gültigkeit.

## Ein Pumping-Lemma für KF

**Satz:** Zu jeder kfS  $L$  gibt es eine Konstante  $n > 0$ , sodass jedes Wort  $w \in L$  mit  $\ell(w) \geq n$  als Konkatination  $w = uvxyz$  dargestellt werden kann mit geeigneten  $u, v, x, y, z$  mit folgenden Eigenschaften:

1.  $\ell(v) > 0$  oder  $\ell(y) > 0$ ;
2.  $\ell(vxy) \leq n$ ;
3.  $\forall i \geq 0 : uv^i xy^i z \in L$ .

Beweis: L werde durch kfG  $G = (\Sigma, N, R, S)$  in erweiterter Chomsky-Normalform beschrieben.  
Es sei  $n = 2^{\#N}$ .

Gibt es kein  $w \in L$  mit  $\ell(w) \geq n$ , so stimmt die Aussage leer.

Sonst wähle ein  $w \in L$  mit  $\ell(w) \geq n$ .

Nach obiger Folgerung gibt es zwei Regelanwendungen  $A \rightarrow u'$  und  $A \rightarrow v'$  auf einem Weg in einem Ableitungsbaum von  $w$ .

$\rightsquigarrow$  Es gibt Linksableitung

$$S \xRightarrow{*} uA\zeta \xRightarrow{*} uvA\eta\zeta \xRightarrow{*} uvx\eta\zeta \xRightarrow{*} uvxy\zeta \xRightarrow{*} uvxyz.$$

Wegen Chomsky-NF (keine Kettenregeln oder  $\lambda$ -Regeln) gilt  $\ell(v) > 0$  oder  $\ell(y) > 0$ .

$\ell(vxy) \leq n$  ergibt sich aus dem Beweis der Folgerung sowie wegen Chomsky-NF.

Daher gibt es auch Ableitungen

$$S \xRightarrow{*} uA\zeta \xRightarrow{*} ux\zeta \xRightarrow{*} uxz$$

und allgemeiner

$$S \rightarrow uA\zeta \xRightarrow{*} uvA\eta\zeta \xRightarrow{*} uvvA\eta\eta\zeta \xRightarrow{*} uv^iA\eta^i\zeta \xRightarrow{*} uv^ixy^iz.$$

**Ein Beispiel** zur Anwendung des Pumping-Lemmas:

$$L = \{a^k b^k c^k \mid k \in \mathbb{N}\} \notin \mathbf{KF}$$

Wäre  $L$  kontext-frei, so gäbe es Pumping-Konstante  $n$ .

**Wähle**  $w = a^n b^n c^n$  als genügend langes Wort.

Diskutiere Zerlegungen  $w = uvwyz$ .

Wegen  $\ell(vxy) \leq n$  enthält  $vxy$  höchstens  $a$ 's gefolgt von  $b$ 's oder  $b$ 's gefolgt von  $c$ 's.

Beide Fälle sind analog; diskutiere also den ersten.

“Nullpumpen” liefert ein Wort, in dem alle  $a$ - und  $b$ -Vorkommen zusammen weniger als die doppelte Anzahl von  $c$ 's ausmachen, im Widerspruch zur Wortstruktur.

## Das Pumping-Lemma kennzeichnet nicht Kontextfreiheit

Betrachte

$$L = \{a^k d^r a^k d^s a^k \mid k, r, s \in \mathbb{N}\}$$

Mit der gleichen Intuition wie vorher ist die Sprache nicht kontextfrei.

L erfüllt aber das Pumping-Lemma:

Ein Wort der Form  $w = a^k d^r a^k d^s a^k$  mit  $r > 0$  lässt sich zerlegen in:  $w = uvxyz$  mit (z.B.)  $u = a^k$ ,  $v = d$  und  $y = \lambda$ .

Dann gilt  $uv^i xy^i z \in L$  für alle  $i \in \mathbb{N}$ .

Der Fall  $s = 0$  geht analog.

Gilt  $r = s = 0$ , so gilt für  $w = a^{3k}$ , und die Wahl  $v = a^3$ ,  $y = \lambda$  führt wiederum auf  $uv^i xy^i z \in L$  für alle  $i \in \mathbb{N}$ .

Wie kann man die **Intuition retten** ?

Betrachte

$$L' = \{a^k d a^k d a^k \mid k \in \mathbb{N}\}$$

Jetzt ermöglicht Nullpumpen einen Widerspruch zur angenommenen Kontextfreiheit. (Übungsaufgabe !)

**Idee:** Verwende Abschlusseigenschaften,  
**hier** Durchschnitt mit regulären Sprachen:

Wäre  $L = \{a^k d^r a^k d^s a^k \mid k, r, s \in \mathbb{N}\} \in \mathbf{KF}$ , so auch  $L' = L \cap \{a\}^* \{d\} \{a\}^* \{d\} \{a\}^*$ .

## Noch eine Übungsaufgabe...

Sei  $\#_x w =$  Anzahl der Vorkommen von  $x$  in  $w$ .

Zeigen Sie, dass

$$L = \{w \in \{a, b, c\}^* \mid \#_a w = \#_b w = \#_c w\}$$

nicht kontextfrei ist.

## Zur rechten Wahl des Pumpwortes

Betrachte  $L = \{tt \mid t \in \{a, b\}^*\}$ .

Wäre  $L \in \mathbf{KF}$ , so gäbe es Pump-Konstante  $n$  für  $L$ .

Diskutiere  $w = a^n b^n a^n b^n \in L$ .

Für  $vxy$  mit  $\ell(vxy) \leq n$  gibt es drei Unterfälle:

- (1)  $vxy \in \{a\}^*\{b\}^*$ ,  $z \in \{b\}^*\{a^n b^n\}$ .
- (2)  $vxy \in \{b\}^*\{a\}^*$ .
- (3)  $vxy \in \{a\}^*\{b\}^*$ ,  $u \in \{a^n b^n\}\{a\}^*$ .

Wir betrachten (3) eingehend (die anderen Fälle sind ähnlich):

$uxz = a^n b^n a^m b^k \in L$  mit  $m < n$  oder  $k < n$  (Nullpumpen).

$uxz = ss$  mit  $\ell(s) < 2n$ .

Das "erste  $s$ " muss mit  $a$  anfangen, aber das zweite muss mit  $b$  beginnen (wegen  $\ell(s) < 2n$  und da  $uxz$  nicht nur aus  $a$ 's besteht).

## Nachtrag zu Abschlusseigenschaften I

**Satz:** **KF** ist nicht unter Durchschnitt abgeschlossen.

Beweis:  $L_1 = \{a^n b^n c^k \mid k, n \in \mathbb{N}\}$

$L_2 = \{a^n b^k c^k \mid k, n \in \mathbb{N}\}$

$L_1$  und  $L_2$  sind kontextfrei.

$L_1 \cap L_2$  ist jedoch nicht kontextfrei (s.o.).

## Nachtrag zu Abschlusseigenschaften II

**Satz:** **KF** ist nicht unter Komplementbildung abgeschlossen.

Beweis: Betrachte das Komplement  $L'$  von  $L = \{a^k b^k c^k \mid k \in \mathbb{N}\}$ .

$$L' = \{w \in \{a, b, c\}^* \mid w \notin \{a\}^* \{b\}^* \{c\}^* \vee (\forall k \in \mathbb{N} : w \neq a^k b^k c^k)\}.$$

Mit  $L'' = \{w \in \{a\}^* \{b\}^* \{c\}^* \mid (\forall k \in \mathbb{N} : w \neq a^k b^k c^k)\}$  wäre auch  $L'$  kontextfrei, denn  $L' = L'' \cup \overline{\{a\}^* \{b\}^* \{c\}^*}$  (Vereinigungsabschluss von **KF** und Komplementabschluss von **REG**).

$L'' = \{a^k b^\ell c^m \mid k \neq \ell \vee k \neq m \vee \ell \neq m\} \in \mathbf{KF}$ , denn

$$\begin{aligned} L'' &= \{a^k b^\ell c^m \mid k < \ell\} \cup \{a^k b^\ell c^m \mid k > \ell\} \\ &\quad \cup \{a^k b^\ell c^m \mid k < m\} \cup \{a^k b^\ell c^m \mid k > m\} \\ &\quad \cup \{a^k b^\ell c^m \mid \ell < m\} \cup \{a^k b^\ell c^m \mid \ell > m\}. \end{aligned}$$

Jede dieser Teilsprachen ist "offensichtlich" kontextfrei, und wegen des Vereinigungsabschlusses von **KF** gilt dies auch für  $L''$  und somit für  $L'$ .

Wäre **KF** komplementabgeschlossen, so wäre mit  $L'$  auch  $L \in \mathbf{KF}$ , ein Widerspruch!

## Entscheidbarkeitsfragen I

**Frage:** Gibt es einen Algorithmus, sodass ...

**Satz:** Das Leerheitsproblem ist für kfG entscheidbar.

**1. Beweis:** Ersetze alle Terminalzeichenvorkommen in der Grammatik  $G$  durch das leere Wort; das liefert neue Grammatik  $G'$ . Dann gilt:  $L(G) \neq \emptyset$  gdw.  $L(G') = \{\lambda\}$ .  $\lambda \in L(G')$  kann man entscheiden (siehe letzter Foliensatz).

**2. Beweis:** o.E.  $G$  in erweiterter Chomsky-Normalform.

Die betreffende Pump-Konstante  $n_G$  garantiert: Ist  $L(G) \neq \emptyset$ , so gibt es  $w \in L(G)$  mit  $\ell(w) < n_G$  (Nullpumpen). Daher kann man  $L(G) = \emptyset$  durch Testen aller Wörter bis zur Länge  $n_G$  entscheiden.

## Entscheidbarkeitsfragen II

*Endlichkeitsproblem*: Gegeben Sprachbeschreibung  $G$  für  $L$ , ist  $L$  endlich ?

**Satz**: Das Endlichkeitsproblem ist für  $kg$  entscheidbar.

Beweis: Dies folgt wie in obigem 2. Beweis zum Leerheitsproblem aus:

**Lemma**: Zu jeder Sprache  $L \in \mathbf{KF}$  gibt es eine Konstante  $n > 0$ , sodass gilt:  $L$  ist unendlich gdw. es gibt ein Wort  $t \in L$  mit  $n \leq \ell(t) < 2n$ .

**Lemma:** Zu jeder Sprache  $L \in \mathbf{KF}$  gibt es eine Konstante  $n > 0$ , sodass gilt:  $L$  ist unendlich gdw. es gibt ein Wort  $t \in L$  mit  $n \leq \ell(t) < 2n$ .

Beweis: Es sei  $n$  die Pump-Konstante aus dem Pumping-Lemma.

Ist  $L$  unendlich, so gibt es insbesondere Wörter mit Mindestlänge  $2n$  in  $L$ .

Wähle unter diesen ein Wort  $t'$  minimaler Länge.

Nach dem Pumping-Lemma können wir  $t' = uvxyz$  schreiben mit  $\ell(vxy) \leq n$ .

$\rightsquigarrow$  Nullpumpen liefert  $t = uxz$  mit  $n \leq \ell(t) < 2n$ , da  $t'$  minimal.

Ein Wort  $t \in L$  mit  $n \leq \ell(t) < 2n$  können wir “aufpumpen”,

d.h., mit der Existenz solch eines  $t$  ist  $L$  unendlich.