

# Theorie der Informatik

## 6. Formale Sprachen und Grammatiken

Malte Helmert Gabriele Röger

Universität Basel

17. März 2014

# Theorie der Informatik

17. März 2014 — 6. Formale Sprachen und Grammatiken

## 6.1 Einführung

## 6.2 Alphabete und formale Sprachen

## 6.3 Grammatiken

## 6.4 Chomsky-Hierarchie

## 6.5 Zusammenfassung

## 6.1 Einführung

## Beispiel: Aussagenlogische Formeln

Aus dem Logikteil:

### Definition (Syntax der Aussagenlogik)

Sei  $A$  eine Menge von atomaren Aussagen. Die Menge der aussagenlogischen Formeln (über  $A$ ) ist induktiv wie folgt definiert:

- ▶ Jedes **Atom**  $a \in A$  ist eine aussagenlogische Formel über  $A$ .
- ▶ Ist  $\phi$  eine aussagenlogische Formel über  $A$ , dann auch die **Negation**  $\neg\phi$ .
- ▶ Sind  $\phi$  und  $\psi$  aussagenlogische Formeln über  $A$ , dann ist es auch die **Konjunktion**  $(\phi \wedge \psi)$ .
- ▶ Sind  $\phi$  und  $\psi$  aussagenlogische Formeln über  $A$ , dann ist es auch die **Disjunktion**  $(\phi \vee \psi)$ .

## Beispiel: Aussagenlogische Formeln

Sei  $S_A$  die Menge aller aussagenlogischen Formeln über  $A$ .

Solche Mengen von Zeichenketten (oder **Wörtern**) nennt man **Sprachen**.

**Gesucht:** Allgemeine Konzepte, um solche (oftmals unendliche) Sprachen mit endlichen Beschreibungen zu definieren

- ▶ heute: **Grammatiken**
- ▶ nächste Kapitel zusätzlich: Automaten

## Beispiel: Aussagenlogische Formeln

**Beispiel (Grammatik für  $S_{\{a,b,c\}}$ )**

Grammatikvariablen  $\{F, A, N, K, D\}$  mit Startvariable  $F$ ,  
Terminalsymbole  $\{a, b, c, \neg, \wedge, \vee, (, )\}$  und Regeln

$$\begin{array}{lll} F \rightarrow A & A \rightarrow a & N \rightarrow \neg F \\ F \rightarrow N & A \rightarrow b & K \rightarrow (F \wedge F) \\ F \rightarrow K & A \rightarrow c & D \rightarrow (F \vee F) \\ F \rightarrow D & & \end{array}$$

Beginne mit  $F$  und ersetze schrittweise eine linke Regelseite durch eine rechte Regelseite bis keine Variablen mehr enthalten sind:

$$\begin{aligned} F &\Rightarrow N \Rightarrow \neg F \Rightarrow \neg D \Rightarrow \neg(F \vee F) \Rightarrow \neg(A \vee F) \Rightarrow \neg(b \vee F) \\ &\Rightarrow \neg(b \vee A) \Rightarrow \neg(b \vee c) \end{aligned}$$

## 6.2 Alphabete und formale Sprachen

## Alphabete und formale Sprachen

**Definition (Alphabete, Wörter und formale Sprache)**

Ein **Alphabet**  $\Sigma$  ist eine endliche, nicht-leere Menge von **Zeichen** (oder **Symbolen**).

Die Menge  $\Sigma^*$  aller **Wörter über  $\Sigma$**  enthält alle endlichen Folgen von Elementen aus  $\Sigma$ . Das **leere Wort** (die leere Elementfolge) wird dabei mit  $\varepsilon$  bezeichnet.

Für ein Wort  $w$  bezeichnet  $|w|$  seine Länge.

Eine **formale Sprache** ist eine Teilmenge von  $\Sigma^*$ .

**Beispiel**

$$\begin{aligned} \Sigma &= \{a, b\} \\ \Sigma^* &= \{\varepsilon, a, b, aa, ab, ba, bb, \dots\} \\ |aba| &= 3, |b| = 1, |\varepsilon| = 0 \end{aligned}$$

## Sprachen: Beispiele

### Beispiel (Sprachen über $\Sigma = \{a, b\}$ )

- ▶  $S_1 = \{a, aa, aaa, aaaa, \dots\}$
- ▶  $S_2 = \Sigma^*$
- ▶  $S_3 = \{a^n b^n \mid n \geq 0\} = \{\varepsilon, ab, aabb, aaabbb, \dots\}$
- ▶  $S_4 = \{\varepsilon\}$
- ▶  $S_5 = \emptyset$
- ▶  $S_6 = \{w \in \Sigma^* \mid w \text{ enthält doppelt so viele } a \text{ wie } b\}$   
 $= \{\varepsilon, aab, aba, baa, \dots\}$
- ▶  $S_7 = \{w \in \Sigma^* \mid |w| = 3\}$   
 $= \{aaa, aab, aba, baa, bba, bab, abb, bbb\}$

## 6.3 Grammatiken

## Grammatiken

### Definition (Grammatik)

Eine **Grammatik** ist ein 4-Tupel  $(\Sigma, V, P, S)$  mit

- ①  $\Sigma$  endliches Terminalalphabet,
- ②  $V$  endliche Menge von Variablen (mit  $V \cap \Sigma = \emptyset$ ),
- ③  $P \subseteq (V \cup \Sigma)^+ \times (V \cup \Sigma)^*$  endliche Menge von Regeln, und
- ④  $S \in V$  Startvariable.

## Regelmengen

Was genau bedeutet  $P \subseteq (V \cup \Sigma)^+ \times (V \cup \Sigma)^*$ ?

- ▶  $(V \cup \Sigma)^*$ : Alle Wörter über  $(V \cup \Sigma)$
- ▶  $(V \cup \Sigma)^+$ : Alle nicht-leeren Wörter über  $(V \cup \Sigma)$   
 Allgemein für Menge  $X$ :  $X^+ = X^* \setminus \{\varepsilon\}$
- ▶  $\times$ : kartesisches Produkt
- ▶  $(V \cup \Sigma)^+ \times (V \cup \Sigma)^*$ : Menge aller Paare  $(x, y)$ , wobei  $x$  nicht-leeres Wort über  $(V \cup \Sigma)$  und  $y$  Wort über  $(V \cup \Sigma)$
- ▶ Statt  $(x, y)$  schreiben wir Regeln meist in der Form  $x \rightarrow y$ .

## Regeln: Beispiele

### Beispiel

Sei  $\Sigma = \{a, b, c\}$  und  $V = \{X, Y, Z\}$ .

Folgende Regeln sind in  $(V \cup \Sigma)^+ \times (V \cup \Sigma)^*$ :

$$\begin{aligned} X &\rightarrow XaY \\ Yb &\rightarrow a \\ XY &\rightarrow \varepsilon \\ XYZ &\rightarrow abc \\ abc &\rightarrow XYZ \end{aligned}$$

## Ableitung

### Definition (Ableitung)

Sei  $(\Sigma, V, P, S)$  eine Grammatik. Ein Wort  $v \in (V \cup \Sigma)^*$  kann von Wort  $u \in (V \cup \Sigma)^+$  **abgeleitet** werden ( $u \Rightarrow v$ ), falls

- ①  $u = xyz$ ,  $v = xy'z$  mit  $x, z \in (V \cup \Sigma)^*$  und
- ② es existiert eine Regel  $y \rightarrow y' \in P$ .

Wir schreiben:  $u \Rightarrow^* v$  falls  $v$  in endlich vielen Schritten (d.h. durch die Anwendung von  $n$  Regeln für  $n \in \mathbb{N}$ ) von  $u$  abgeleitet werden kann.

## Ableitung: Mehrdeutigkeit

### Beispiel

$G = (\{a, b, c\}, \{S, A, B\}, P, S)$ , wobei  $P$  folgende Regeln enthält:

$$\begin{array}{ll} S \rightarrow aB & A \rightarrow ab \\ S \rightarrow Ac & B \rightarrow bc \end{array}$$

Wort  $abc$  kann von  $S$  abgeleitet werden:  $S \Rightarrow aB \Rightarrow abc$

Alternative Ableitung:  $S \Rightarrow Ac \Rightarrow abc$

- ▶ Es kann verschiedene Ableitungen für ein Wort geben.
- ▶ Dies gilt selbst, wenn man immer nur die erste vorkommende Variable ersetzt (sogenannte **Linksableitung**).

## Erzeugte Sprache einer Grammatik

### Definition (Sprache)

Die von einer Grammatik  $G = (\Sigma, V, P, S)$  erzeugte **Sprache**

$$\mathcal{L}(G) = \{w \in \Sigma^* \mid S \Rightarrow^* w\}$$

ist die Menge aller Wörter aus  $\Sigma^*$ , die von  $S$  mit endlich vielen Regelanwendungen abgeleitet werden können.

# Grammatiken

Beispiele: Tafel

# 6.4 Chomsky-Hierarchie

# Chomsky-Hierarchie

Grammatiken werden in die **Chomsky-Hierarchie** eingegliedert.

## Definition (Chomsky-Hierarchie)

- ▶ Jede Grammatik ist vom Typ 0 (beliebige Regeln erlaubt).
- ▶ Grammatik ist vom Typ 1 (kontextsensitiv), falls für alle Regeln  $w_1 \rightarrow w_2$  gilt:  $|w_1| \leq |w_2|$ .
- ▶ Grammatik ist vom Typ 2 (kontextfrei), falls für alle Regeln  $w_1 \rightarrow w_2$  gilt:  $w_1 \in V$  (einzelne Variable).
- ▶ Grammatik ist vom Typ 3 (regulär), falls zusätzlich  $w_2 \in \Sigma \cup \Sigma V$ .

**Spezialfall:** Regel  $S \rightarrow \varepsilon$  ist immer erlaubt, wenn  $S$  Startsymbol ist und auf keiner rechten Seite irgendeiner Regel auftritt.

# Chomsky-Hierarchie

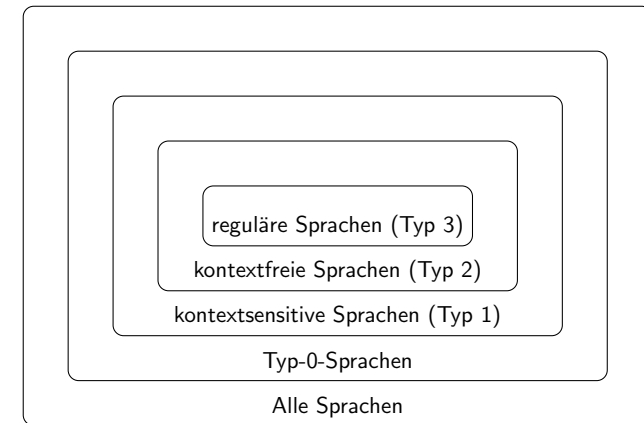
Beispiele: Tafel

## Chomsky-Hierarchie

### Definition (Typ-0–3 Sprachen)

Eine Sprache  $L \subseteq \Sigma^*$  heisst vom Typ 0 (Typ 1, Typ 2, Typ 3), falls es eine Typ-0- (Typ-1-, Typ-2-, Typ-3-) Grammatik  $G$  gibt mit  $\mathcal{L}(G) = L$ .

## Chomsky-Hierarchie



Nicht alle Sprachen sind durch Grammatiken beschreibbar.

## 6.5 Zusammenfassung

## Zusammenfassung

- ▶ **Sprachen** sind Mengen von Zeichenketten.
- ▶ **Grammatiken** sind eine Möglichkeit Sprachen zu beschreiben.
- ▶ Erzeugte **Sprache einer Grammatik** ist die Menge der **ableitbaren** variablenfreien Wörter.
- ▶ **Chomsky-Hierarchie** teilt Grammatiken in Stufen unterschiedlicher Erzeugungsmächtigkeit ein.

### Nächstes Kapitel

- ▶ Mehr zu regulären Sprachen
- ▶ Automaten als alternative Darstellungsform von Sprachen