

# Theorie der Informatik

## 7. Formale Sprachen und Grammatiken

Malte Helmert   Gabriele Röger

Universität Basel

16. März 2015

# 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

$$F \rightarrow A$$

$$A \rightarrow a$$

$$N \rightarrow \neg F$$

$$F \rightarrow N$$

$$A \rightarrow b$$

$$K \rightarrow (F \wedge F)$$

$$F \rightarrow K$$

$$A \rightarrow c$$

$$D \rightarrow (F \vee F)$$

$$F \rightarrow D$$

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

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

# 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**).

## Beispiel

$$\Sigma = \{a, b\}$$

# 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.

## Beispiel

$$\Sigma = \{a, b\}$$

$$\Sigma^* = \{\varepsilon, a, b, aa, ab, ba, bb, \dots\}$$

# 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.

## Beispiel

$$\Sigma = \{a, b\}$$

$$\Sigma^* = \{\varepsilon, a, b, aa, ab, ba, bb, \dots\}$$

$$|aba| = 3, |b| = 1, |\varepsilon| = 0$$

# 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

$$\Sigma = \{a, b\}$$

$$\Sigma^* = \{\varepsilon, a, b, aa, ab, ba, bb, \dots\}$$

$$|aba| = 3, |b| = 1, |\varepsilon| = 0$$

# Sprachen: Beispiele

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

- $S_1 = \{a, aa, aaa, aaaa, \dots\}$

# Sprachen: Beispiele

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

- $S_1 = \{a, aa, aaa, aaaa, \dots\}$
- $S_2 = \Sigma^*$

# Sprachen: Beispiele

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

- $S_1 = \{a, aa, aaa, aaaa, \dots\}$
- $S_2 = \Sigma^*$
- $S_3 = \{a^n b^n \mid n \geq 0\} = \{\varepsilon, ab, aabb, aaabbb, \dots\}$

# Sprachen: Beispiele

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

- $S_1 = \{a, aa, aaa, aaaa, \dots\}$
- $S_2 = \Sigma^*$
- $S_3 = \{a^n b^n \mid n \geq 0\} = \{\varepsilon, ab, aabb, aaabbb, \dots\}$
- $S_4 = \{\varepsilon\}$

# Sprachen: Beispiele

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

- $S_1 = \{a, aa, aaa, aaaa, \dots\}$
- $S_2 = \Sigma^*$
- $S_3 = \{a^n b^n \mid n \geq 0\} = \{\varepsilon, ab, aabb, aaabbb, \dots\}$
- $S_4 = \{\varepsilon\}$
- $S_5 = \emptyset$

# Sprachen: Beispiele

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

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

# Sprachen: Beispiele

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

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

# Fragen



Fragen?

# 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  $X$ :  $X^+ = X^* \setminus \{\epsilon\}$
- $\times$ : 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  $(V \cup \Sigma)^+ \times (V \cup \Sigma)^*$ :

$$X \rightarrow XaY$$

$$Yb \rightarrow a$$

$$XY \rightarrow \varepsilon$$

$$XYZ \rightarrow abc$$

$$abc \rightarrow XYZ$$

# 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  $n \in \mathbb{N}_0$ ) von  $u$  abgeleitet werden kann.

# Ableitung: Mehrdeutigkeit

## Beispiel

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

$$S \rightarrow aB$$

$$A \rightarrow ab$$

$$S \rightarrow Ac$$

$$B \rightarrow bc$$

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

# Ableitung: Mehrdeutigkeit

## Beispiel

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

$$S \rightarrow aB$$

$$A \rightarrow ab$$

$$S \rightarrow Ac$$

$$B \rightarrow bc$$

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

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

# Ableitung: Mehrdeutigkeit

## Beispiel

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

$$S \rightarrow aB$$

$$A \rightarrow ab$$

$$S \rightarrow Ac$$

$$B \rightarrow bc$$

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

# Fragen



Fragen?

# 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

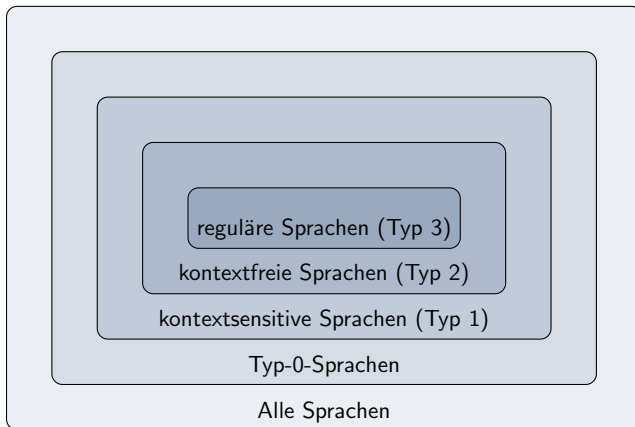
Beispiele: Tafel

# Chomsky-Hierarchie

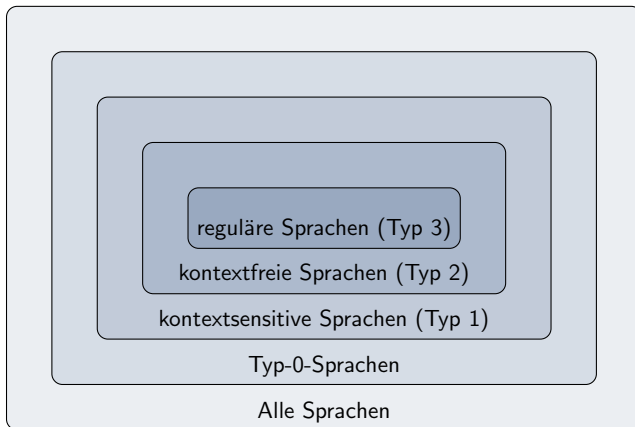
## Definition (Typ-0–3 Sprachen)

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



# Chomsky-Hierarchie



Nicht alle Sprachen sind durch Grammatiken beschreibbar.

# Fragen



Fragen?

# 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.

# 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