

# Grundlagen der Informatik


- Lexikalische und Syntaktische Analyse -

Prof. Dr. Klaus Volbert



Hochschule für angewandte Wissenschaften  
Fakultät Informatik und Mathematik

Wintersemester 2010/11  
Regensburg, 16. November 2010



- Mittels **formaler Sprachen** soll entschieden werden, ob ein Element zu einer vorgegebenen Klasse gehört oder nicht
- Wie kann die Menge aller lexikalisch und syntaktisch korrekten C/C++- Programme beschrieben werden?
- Sei L die Menge aller syntaktisch korrekten C/C++- Programme, wie kann dann für ein Programm p entschieden werden, ob  $p \in L$  (**Wortproblem**)?
- Sprachen können durch **Grammatiken** beschrieben werden
- Grammatiken geben Regeln (**Produktionen**) an, nach denen syntaktisch korrekte Sätze aufgebaut werden dürfen
- Anmerkung: Ein großer Teil der Arbeit eines Informatikers besteht in der Definition neuer Sprachen (z. B. Protokolle)

- Ein **Alphabet**  $\Sigma$  ist eine endliche Menge von **Zeichen** ( $\Sigma = \{0,1\}$ )
- Ein **Wort** über einem Alphabet  $\Sigma$  ist eine endliche Folge von Zeichen aus  $\Sigma$ , alle Wörter der Länge  $n$ :  $\Sigma^n$
- Die **Menge aller Wörter** über  $\Sigma$  ist  $\Sigma^*$
- Das **leere Wort** ist  $\varepsilon$ , es gilt:  $\varepsilon \in \Sigma^*$
- Wörter können zusammengesetzt werden (**Konkatenation**), es gilt:  $\varepsilon u = u\varepsilon = u$ ,  $\Sigma^+ = \Sigma \Sigma^* = \Sigma^* \setminus \{\varepsilon\}$  („mindestens einmal“)
- Die **Länge eines Wortes** ist die Anzahl der Zeichen, aus der sich ein Wort zusammensetzt, Notation:  $|u|$ , es gilt:  $|\varepsilon| = 0$
- Eine **Sprache**  $L$  über einem Alphabet  $\Sigma$  ist eine Menge von Wörtern über  $\Sigma$ , d.h.  $L \subseteq \Sigma^*$
- Anmerkung:
  - Ein Programm ist ein Wort, d.h. hier weicht der Begriff von dem Wortbegriff in natürlichen Sprachen (z.B. deutsch) ab

- Eine Grammatik  $G$  ist beschrieben durch ein 4-Tupel  $G = (V, \Sigma, P, S)$  mit:
  - $V$  ist ein endliches Alphabet von **Variablen** (Nicht-Terminale)
  - $\Sigma$  ist ein endliches Alphabet von **Terminalen**
  - $S \in V$  ist das **Startsymbol**
  - $P \subseteq ((V \cup \Sigma)^+ \times (V \cup \Sigma)^*)$  ist eine endliche Menge von **Produktionen** (Produktionen werden auch **Regeln** genannt)
- **Ableitbarkeit**
  - $b \in (V \cup \Sigma)^*$  ist **(direkt) ableitbar** aus  $a \in (V \cup \Sigma)^+$ ,  $a \rightarrow b$ , wenn es eine Regel  $(u, v) \in P$  und  $\alpha, \beta \in (V \cup \Sigma)^*$  gibt:  $a = \alpha u \beta$ ,  $b = \alpha v \beta$
  - $b$  ist aus  $a$  **(indirekt) ableitbar**,  $a \xrightarrow{*} b$ , wenn  $b$  durch endlich viele direkte Ableitungsschritte aus  $a$  erzeugbar ist
- Die von  $G$  erzeugte Sprache ist

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

# Beispiele

- $G_1 = (V, \Sigma, P, S)$  mit
  - $V = \{S, A, B\}$
  - $\Sigma = \{0, 1\}$
  - $P = \{S \rightarrow ASB, A \rightarrow 0, B \rightarrow 1, S \rightarrow \varepsilon\}$
- Welche Sprache definiert  $G_1$ , also was ist  $L = L(G_1)$ ?
- $G_2 = (V, \Sigma, P, S)$  mit
  - $V = \{S, R, L\}$
  - $\Sigma = \{0, 1\}$
  - $P = \{S \rightarrow 01L0, 1L \rightarrow L11, 0L \rightarrow 0R, R1 \rightarrow 1R, R0 \rightarrow L0, L0 \rightarrow 0\}$
- Was ist  $L = L(G_2)$ ?