

Grundlagen der Informatik

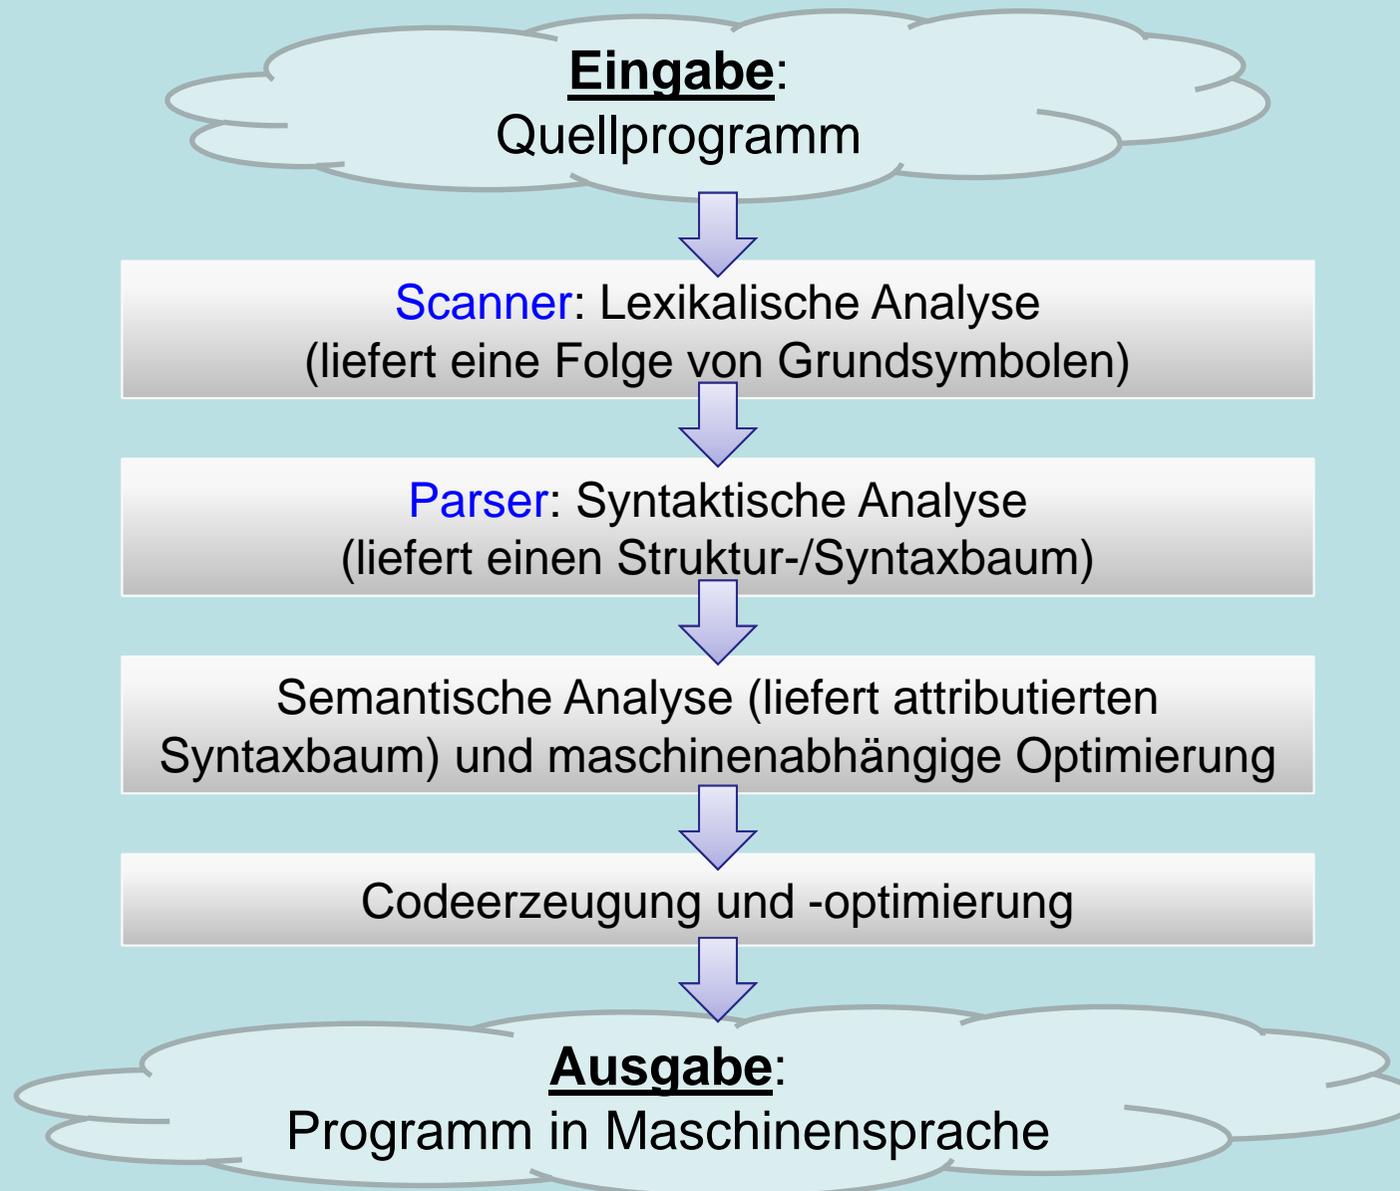
- Lexikalische und Syntaktische Analyse Forts. -

Prof. Dr. Klaus Volbert



Hochschule für angewandte Wissenschaften
Fakultät Informatik und Mathematik

Wintersemester 2010/11
Regensburg, 23. November 2010



Chomsky-Hierarchie

- Eine Grammatik $G = (V, \Sigma, P, S)$ heißt vom Typ Chomsky-0.
- G heißt **kontextsensitiv** (vom Typ Chomsky-1), wenn für jede Regel $a \rightarrow b$ gilt: $|a| \leq |b|$ (Ausnahme: $A \rightarrow \varepsilon$ wird zugelassen)
- G heißt **kontextfrei** (vom Typ Chomsky-2), wenn alle Regeln die Form $A \rightarrow b$ mit $A \in V$ haben
- G heißt **regulär** (vom Typ Chomsky-3), wenn alle Regeln die Form $A \rightarrow \varepsilon$ oder $A \rightarrow aB$ mit $a \in \Sigma$ und $A, B \in V$ haben
- Eine Sprache heißt kontextsensitiv, kontextfrei oder regulär, wenn sie durch eine entspr. Grammatik erzeugt werden kann
- Sei L_i die Menge der Typ Chomsky- i Sprachen, dann gilt:

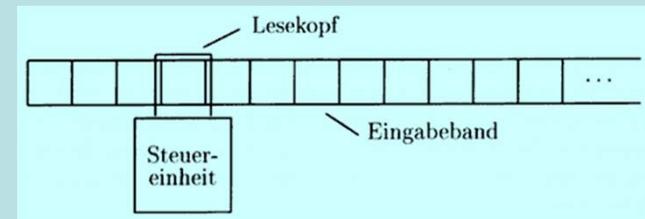
$$L_3 \subseteq L_2 \subseteq L_1 \subseteq L_0$$

(Anmerkung: Chomsky-Hierarchie ist sogar echt)

- Welche besondere Struktur haben **reguläre Sprachen**?

Deterministischer endlicher Automat

- Ein deterministischer endlicher Automat (DEA/DFA) ist beschrieben durch ein 5-Tupel $M = (Q, \Sigma, \delta, q_0, F)$ mit:
 - Q ist eine endliche, nichtleere Menge von **Zuständen**
 - Σ ist ein endliches, nicht leeres **Eingabealphabet**
 - $\delta: Q \times \Sigma \rightarrow Q$ ist die **Übergangsfunktion**
 - $q_0 \in Q$ ist der **Startzustand**
 - $F \subseteq Q$ ist die Menge der **akzeptierenden Endzustände**



- **Akzeptanz**

- Ein DFA **akzeptiert** eine Eingabe x_1, \dots, x_n , wenn gilt:

$$q_0 x_1, \dots, x_n \xrightarrow{*} x_1, \dots, x_n q \text{ mit } q \in F$$

- Alternativ durch induktive Fortsetzung von δ auf $Q \times \Sigma^* \rightarrow Q$:

$$\delta(q, \varepsilon) = q \text{ für } n > 0, \text{ sonst } \delta(q, x_1, \dots, x_n) = \delta(\delta(q, x_1, \dots, x_{n-1}), x_n)$$

- Damit: Ein DFA akzeptiert $x = x_1, \dots, x_n \Leftrightarrow \delta(q_0, x) \in F$

- Satz: Eine Sprache L ist genau dann regulär, wenn es einen DFA gibt, der L akzeptiert
- Scanner in Compilern implementieren DFAs zur lexikalischen Analyse
 - Je einen für Zahlen, Schlüsselwörter, Namen, Sonderzeichen, ...
 - Die vorgefundenen Symbole (**Token**) werden in Tabellen abgelegt
- Bei der lexikalischen Analyse reicht es aus, einmalig von „links nach rechts“ über die Eingabe zu gehen, d.h. Zeichen für Zeichen der Eingabe zu lesen und zu verarbeiten
- Kann ein DFA eine Syntaxanalyse durchführen?
 - Können **Klammerausdrücke** auf Korrektheit geprüft werden?

Pumping-Lemma

- Sei L eine reguläre Sprache, dann gibt es eine Konstante $n \in \mathbb{N}$, so dass sich jedes $z \in L$ mit $|z| \geq n$, so als $z = uvw$ schreiben lässt, dass $|uv| \leq n$, $|v| \geq 1$ und $uv^i w \in L$ für alle $i \geq 0$ gilt
- Beweisidee:
 - Ein Zustand muss mehrmals vorkommen
 - An dem Zustand können beliebige Schleifen durchlaufen werden
- Bemerkung:
 - Eine ähnliche Aussage gilt auch für kontextfreie Sprachen
- Anwendungsbeispiele:
 - $L_1 = \{0^k 1^k \mid k \geq 1\}$ ist nicht regulär
 - $L_2 = \{0^k \mid k \text{ ist Quadratzahl}, k \geq 1\}$ ist nicht regulär
- Was bedeutet das für die Auswertung von Programmen?