

SS 2006

# Einführung in die Informatik IV

Ernst W. Mayr

Fakultät für Informatik  
TU München

<http://www14.in.tum.de/lehre/2006SS/info4/>

Sommersemester 2006

## 2.2 Die Chomsky-Hierarchie

Sei  $G = (V, \Sigma, P, S)$  eine Phrasenstrukturgrammatik.

- 1 Jede Phrasenstrukturgrammatik (Chomsky-Grammatik) ist (zunächst) automatisch vom **Typ 0**.
- 2 Eine Chomsky-Grammatik heißt (längen-)monoton, falls für alle Regeln

$$\alpha \rightarrow \beta \in P \text{ mit } \alpha \neq S$$

gilt:

$$|\alpha| \leq |\beta| ,$$

und, falls  $S \rightarrow \epsilon \in P$ , dann das Axiom  $S$  auf keiner rechten Seite vorkommt.

- ③ Eine Chomsky-Grammatik ist vom **Typ 1** (auch: **kontextsensitiv**), falls sie monoton ist und für alle Regeln  $\alpha \rightarrow \beta$  in  $P$  mit  $\alpha \neq S$  gilt:

$$\alpha = \alpha' A \alpha'' \text{ und } \beta = \alpha' \beta' \alpha''$$

für geeignete  $A \in V$ ,  $\alpha', \alpha'' \in (V \cup \Sigma)^*$  und  $\beta' \in (V \cup \Sigma)^+$ .

- ④ Eine Chomsky-Grammatik ist vom **Typ 2** (auch: **kontextfrei**), falls sie monoton ist und für alle Regeln  $\alpha \rightarrow \beta \in P$  gilt:

$$\alpha \in V .$$

Bemerkung: Manchmal wird “kontextfrei” auch ohne die Monotonie-Bedingung definiert; **streng monoton** schließt dann die Monotonie mit ein.

- 5 Eine Chomsky-Grammatik ist vom **Typ 3** (auch: **regulär**, **rechtslinear**), falls sie monoton ist und für alle Regeln  $\alpha \rightarrow \beta$  in  $P$  mit  $\beta \neq \epsilon$  gilt:

$$\alpha \in V \text{ und } \beta \in \Sigma^+ \cup \Sigma^*V .$$

Auch hier gilt die entsprechende Bemerkung zur Monotonie-Bedingung.

## Beispiel 6

- Die folgende Grammatik ist regulär:

$$\begin{aligned} S &\rightarrow \epsilon, S \rightarrow A, \\ A &\rightarrow aa, A \rightarrow aaA \end{aligned}$$

- Eine Produktion

$$A \rightarrow Bcde$$

heißt **linkslinear**.

- Eine Produktion

$$A \rightarrow abcDef$$

heißt **linear**.

## Definition 7

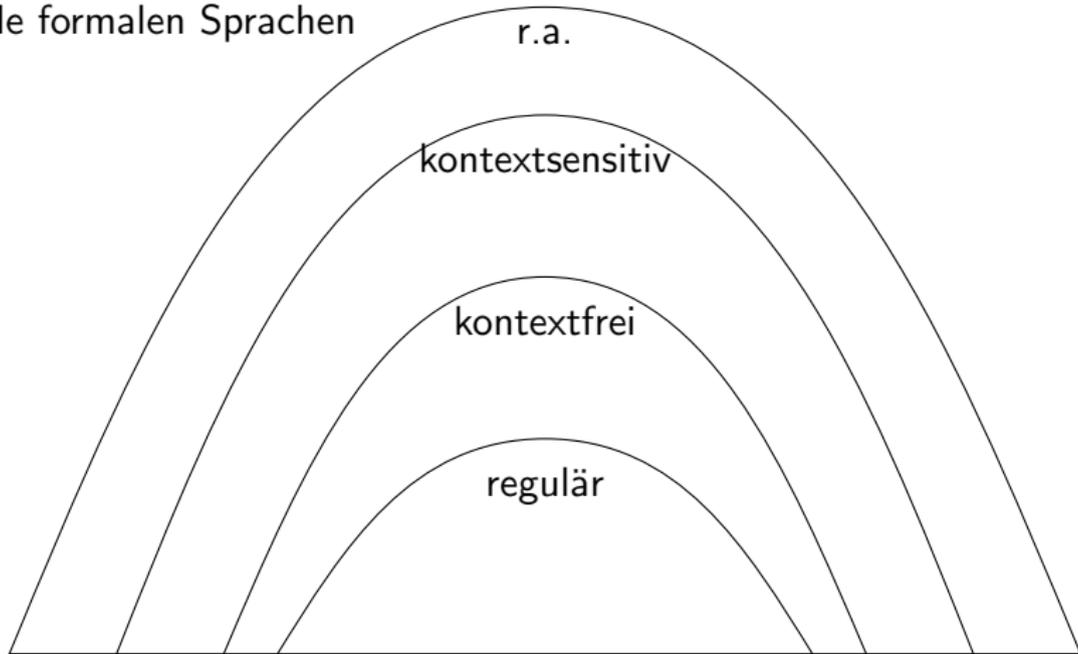
Eine Sprache  $L \subseteq \Sigma^*$  heißt **vom Typ  $k$** ,  $k \in \{0, 1, 2, 3\}$ , falls es eine Chomsky- $k$ -Grammatik  $G$  mit  $L(G) = L$  gibt.

In der Chomsky-Hierarchie bilden also die Typ-3- oder regulären Sprachen die kleinste, unterste Stufe, darüber kommen die kontextfreien, dann die kontextsensitiven Sprachen. Oberhalb der Typ-1-Sprachen kommen die Typ-0-Sprachen, die auch **rekursiv aufzählbar** oder **semientscheidbar** genannt werden. Darüber (und nicht mehr Teil der Chomsky-Hierarchie) findet sich die Klasse aller formalen Sprachen.

In Typ-3-Grammatiken müssen entweder alle Produktionen rechtslinear oder alle linkslinear sein.

Überlegen Sie sich eine **lineare** Grammatik, deren Sprache nicht regulär ist! (Beweismethode später!)

alle formalen Sprachen



## Lemma 8

Sei  $G = (V, \Sigma, P, S)$  eine Chomsky-Grammatik, so dass alle Produktionen  $\alpha \rightarrow \beta$  die Bedingung  $\alpha \in V$  erfüllen. Dann ist  $L(G)$  kontextfrei.

Beweis:

## Definition 9

Ein  $A \in V$  mit  $A \rightarrow^* \epsilon$   
heißt **nullierbar**.

Bestimme alle nullierbaren  $A \in V$ :

$N := \{A \in V; (A \rightarrow \epsilon) \in P\}$

$N' := \emptyset$

**while**  $N \neq N'$  **do**

$N' := N$

$N := N' \cup \{A \in V;$

$(\exists(A \rightarrow \beta) \in P)[\beta \in N'^*]\}$

**od**

Wie man leicht durch Induktion sieht, enthält  $N$  zum Schluss genau alle nullierbaren  $A \in V$ .

Sei nun  $G$  eine Grammatik, so dass alle linken Seiten  $\in V$ , aber die Monotoniebedingung nicht unbedingt erfüllt ist.

Modifiziere  $G$  zu  $G'$  mit Regelmenge  $P'$  wie folgt:

- 1 für jedes  $(A \rightarrow x_1x_2 \cdots x_n) \in P$ ,  $n \geq 1$ , füge zu  $P'$  alle Regeln  $A \rightarrow y_1y_2 \cdots y_n$  hinzu, die dadurch entstehen, dass für nicht-nullierbare  $x_i$   $y_i := x_i$  und für nullierbare  $x_i$  die beiden Möglichkeiten  $y_i := x_i$  und  $y_i := \epsilon$  eingesetzt werden, ohne dass die ganze rechte Seite  $= \epsilon$  wird.
- 2 falls  $S$  nullierbar ist, sei  $T$  ein neues Nichtterminal; füge zu  $P'$  die Regeln  $S \rightarrow \epsilon$  und  $S \rightarrow T$  hinzu, ersetze  $S$  in allen rechten Seiten durch  $T$  und füge für jede Regel  $(S \rightarrow x) \in P$ ,  $|x| > 0$ , die Regel  $T \rightarrow x$  zu  $P'$  hinzu.

## Lemma 10

$G' = (V \cup T, \Sigma, P', S)$  ist kontextfrei, und es gilt

$$L(G') = L(G) .$$

Beweis:

Klar!



Auch für reguläre Grammatiken gilt ein entsprechender Satz über die “Entfernbarkeit” nullierbarer Nichtterminale:

### Lemma 11

Sei  $G = (V, \Sigma, P, S)$  eine Chomsky-Grammatik, so dass für alle Regeln  $\alpha \rightarrow \beta \in P$  gilt:

$$\alpha \in V \text{ und } \beta \in \Sigma^* \cup \Sigma^*V .$$

Dann ist  $L(G)$  regulär.

Beweis:

Übungsaufgabe!



## Beispiel 12

Typ 3:  $L = \{a^n; n \in \mathbb{N}\}$ , Grammatik:  $S \rightarrow a,$   
 $S \rightarrow aS$

Typ 2:  $L = \{a^n b^n; n \in \mathbb{N}_0\}$ , Grammatik:  $S \rightarrow \epsilon,$   
 $S \rightarrow T,$   
 $T \rightarrow ab,$   
 $T \rightarrow aTb$

Wir benötigen beim Scannen *einen* Zähler.

## Beispiel 12 (Forts.)

Typ 1:  $L = \{a^n b^n c^n; n \in \mathbb{N}\}$ , Grammatik:

$$\begin{aligned} S &\rightarrow aSXY, \\ S &\rightarrow abY, \\ YX &\rightarrow XY, \\ bX &\rightarrow bb, \\ bY &\rightarrow bc, \\ cY &\rightarrow cc \end{aligned}$$

Wir benötigen beim Scannen *mindestens zwei* Zähler.

**Bemerkung:** Diese Grammatik entspricht *nicht* unserer Definition von Typ 1. Wir zeigen als Hausaufgabe eine geeignete erweiterte Definition!

Die **Backus-Naur-Form** (BNF) ist ein Formalismus zur kompakten Darstellung von Typ-2-Grammatiken.

- Statt

$$A \rightarrow \beta_1$$

$$A \rightarrow \beta_2$$

$$\vdots$$

$$A \rightarrow \beta_n$$

schreibt man

$$A \rightarrow \beta_1 | \beta_2 | \dots | \beta_n .$$

Die **Backus-Naur-Form** (BNF) ist ein Formalismus zur kompakten Darstellung von Typ-2-Grammatiken.

- Statt

$$A \rightarrow \alpha\gamma$$

$$A \rightarrow \alpha\beta\gamma$$

schreibt man

$$A \rightarrow \alpha[\beta]\gamma .$$

(D.h., das Wort  $\beta$  kann, muss aber nicht, zwischen  $\alpha$  und  $\gamma$  eingefügt werden.)

Die **Backus-Naur-Form** (BNF) ist ein Formalismus zur kompakten Darstellung von Typ-2-Grammatiken.

- Statt

$$A \rightarrow \alpha\gamma$$

$$A \rightarrow \alpha B\gamma$$

$$B \rightarrow \beta$$

$$B \rightarrow \beta B$$

schreibt man

$$A \rightarrow \alpha\{\beta\}\gamma.$$

(D.h., das Wort  $\beta$  kann beliebig oft (auch Null mal) zwischen  $\alpha$  und  $\gamma$  eingefügt werden.)

## Beispiel 13

⟨Satz⟩	→	⟨Subjekt⟩⟨Prädikat⟩⟨Objekt⟩
⟨Subjekt⟩	→	⟨Artikel⟩⟨Attribut⟩⟨Substantiv⟩
⟨Prädikat⟩	→	ist hat ...
⟨Artikel⟩	→	ε der die das ein ...
⟨Attribut⟩	→	{⟨Adjektiv⟩}
⟨Adjektiv⟩	→	gross klein schön ...

## 2.3 Das Wortproblem

### Beispiel 14 (Arithmetische Ausdrücke)

$$\begin{aligned}\langle \text{exp} \rangle &\rightarrow \langle \text{term} \rangle \\ \langle \text{exp} \rangle &\rightarrow \langle \text{exp} \rangle + \langle \text{term} \rangle \\ \langle \text{term} \rangle &\rightarrow (\langle \text{exp} \rangle) \\ \langle \text{term} \rangle &\rightarrow \langle \text{term} \rangle \times \langle \text{term} \rangle \\ \langle \text{term} \rangle &\rightarrow a \mid b \mid \dots \mid z\end{aligned}$$

Aufgabe eines **Parsers** ist nun, zu prüfen, ob eine gegebene Zeichenreihe einen gültigen arithmetischen Ausdruck darstellt und, falls ja, ihn in seine Bestandteile zu zerlegen.

Sei  $G = (V, \Sigma, P, S)$  eine Grammatik.

## Definition 15

- ❶ **Wortproblem:** Gegeben ein Wort  $w \in \Sigma^*$ , stelle fest, ob

$$w \in L(G) ?$$

- ❷ **Ableitungsproblem:** Gegeben ein Wort  $w \in L(G)$ , gib eine Ableitung  $S \rightarrow_G^* w$  an, d.h., eine Folge

$$S = w^{(0)} \rightarrow_G w^{(1)} \rightarrow_G \cdots \rightarrow_G w^{(n)} = w$$

mit  $w^{(i)} \in (\Sigma \cup V)^*$  für  $i = 1, \dots, n$ .

- ❸ **uniformes Wortproblem:** Wortproblem, bei dem jede Probleminstance sowohl die Grammatik  $G$  wie auch die zu testende Zeichenreihe  $w$  enthält. Ist  $G$  dagegen **global** festgelegt, spricht man von einem **nicht-uniformen** Wortproblem.