

Theoretische Informatik 1

WiSe 23/24

Prof. Dr. Sebastian Siebertz
AG Theoretische Informatik
MZH, Raum 3160
siebertz@uni-bremen.de



Universität
Bremen

Definition Grammatik

Eine *Grammatik* ist von der Form $G = (N, \Sigma, P, S)$, wobei

- N und Σ endliche, disjunkte Alphabete von *Nichtterminalsymbolen* bzw. *Terminalsymbolen* sind,
 - $S \in N$ das *Startsymbol* ist,
 - $P \subseteq (N \cup \Sigma)^+ \times (N \cup \Sigma)^*$ eine endliche Menge von Ersetzungsregeln (*Produktionen*) ist.
-
- Wir schreiben Produktionen $(u, v) \in P$ gewöhnlich als $u \rightarrow v$.
 - Wir schreiben Elemente von N mit Großbuchstaben und Elemente von Σ mit Kleinbuchstaben.

Weitere Konvention

- Wenn es mehrere Regeln $A \rightarrow w_1, \dots, A \rightarrow w_n$ gibt, so schreiben wir dies in eine Zeile als

$$A \rightarrow w_1 \mid w_2 \mid \dots \mid w_n.$$

- Beispiel:

$$\begin{aligned} - \quad P = \{ & S \rightarrow aSBc, \\ & S \rightarrow abc, \\ & cB \rightarrow Bc, \\ & bB \rightarrow bb \} \end{aligned}$$

\Rightarrow

$$\begin{aligned} P = \{ & S \rightarrow aSBc \mid abc \\ & cB \rightarrow Bc, \\ & bB \rightarrow bb \}. \end{aligned}$$

Ableitbarkeit, erzeugte Sprache

Definition Ableitbarkeit, erzeugte Sprache

Sei $G = (N, \Sigma, P, S)$ eine Grammatik und x, y Wörter aus $(N \cup \Sigma)^*$.

1) y aus x direkt ableitbar:

$$x \vdash_G y \Leftrightarrow x = x_1 u x_2 \text{ und } y = x_1 v x_2 \text{ mit } u \longrightarrow v \in P \text{ und } x_1, x_2 \in (N \cup \Sigma)^*$$

2) y aus x in n Schritten ableitbar:

$$x \vdash_G^n y \Leftrightarrow x \vdash_G x_1 \vdash_G \cdots \vdash_G x_{n-1} \vdash_G y \text{ für } x_1, \dots, x_{n-1} \in (N \cup \Sigma)^*$$

3) y aus x ableitbar:

$$x \vdash_G^* y \Leftrightarrow x \vdash_G^n y \text{ für ein } n \geq 0$$

4) Die durch G erzeugte Sprache ist

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

Die Chomsky-Hierarchy

Definition Chomsky-Hierarchy

Es sei $G = (N, \Sigma, P, S)$ eine Grammatik.

Typ 0		Jede Grammatik G
Typ 1	monoton	Falls alle Regeln in G <i>nicht verkürzend</i> sind, also die Form $w \rightarrow u$ haben wobei $w, u \in (\Sigma \cup N)^+$ und $ u \geq w $
Typ 2	kontextfrei	Falls alle Regeln in G die Form $A \rightarrow w$ haben mit $A \in N, w \in (\Sigma \cup N)^*$
Typ 3	rechtslinear	Falls alle Regeln in G die Form $A \rightarrow uB$ oder $A \rightarrow u$ haben mit $A, B \in N, u \in \Sigma^*$.

Definition Sprachklassen

Für $i = 0, 1, 2, 3$ ist die *Klasse der Typ- i -Sprachen* definiert als

$$\mathcal{L}_i := \{L(G) \mid G \text{ ist Grammatik vom Typ } i\}.$$

Sprachklassen der Chomsky-Hierarchie

Die Sprachtypen bilden eine *strikte Hierarchie*.

Satz: Chomsky-Hierarchie

Es gilt $\mathcal{L}_3 \subsetneq \mathcal{L}_2 \subsetneq \mathcal{L}_1 \subsetneq \mathcal{L}_0$.

Satz: Typ 3 = regulär

Die Typ-3-Sprachen sind genau die regulären Sprachen, d. h.:

$$\mathcal{L}_3 = \{L \mid L \text{ ist regulär}\}$$

Wir haben bereits gezeigt:

Satz

Es gilt $\mathcal{L}_3 \subsetneq \mathcal{L}_2$.

Vereinfachung kontextfreier Grammatiken

Terminierende und erreichbare Symbole; reduzierte Grammatik

Es sei $G = (N, \Sigma, P, S)$ eine kontextfreie Grammatik.

- 1) $A \in N$ heißt *terminierend*, falls es ein $w \in \Sigma^*$ gibt mit $A \vdash_G^* w$.
- 2) $A \in N$ heißt *erreichbar*, falls es $u, v \in (\Sigma \cup N)^*$ gibt mit $S \vdash_G^* uAv$.
- 3) G heißt *reduziert*, falls alle Elemente von N *erreichbar* und *terminierend* sind.

Lemma

Für jede kontextfreie Grammatik $G = (N, \Sigma, P, S)$ ist die Menge der terminierenden Symbole (in polynomieller Zeit) berechenbar.

Lemma

Für jede kontextfreie Grammatik $G = (N, \Sigma, P, S)$ ist die Menge der erreichbaren Nichtterminalsymbole (polynomieller Zeit) berechenbar.

Leerheitsproblem für kontextfreie Grammatiken

Korollar

Zu jeder kontextfreien Grammatik G mit $L(G) \neq \emptyset$ kann in (polynomieller Zeit) eine äquivalente reduzierte kontextfreie Grammatik konstruiert werden.

Definition: Leerheitsproblem für kontextfreie Grammatiken

- Gegeben: kontextfreie Grammatik G .
- Frage: gilt $L(G) = \emptyset$?

Satz

Das Leerheitsproblem ist für kontextfreie Grammatiken in polynomieller Zeit entscheidbar.

Chomsky-Normalform

Definition

Eine kontextfreie Grammatik (N, Σ, P, S) ist in *Chomsky-Normalform*, wenn alle Ableitungsregeln die folgende Form haben:

- $A \longrightarrow a$ oder $A \longrightarrow BC$ mit $A, B, C \in N$, $a \in \Sigma$
- $S \longrightarrow \varepsilon$ ist erlaubt, wenn es keine Regeln $A \rightarrow BC$ mit $S \in \{B, C\}$ gibt.

Vorgehen zum erstellen der CNF:

- 1 Aufheben der Mischung von Terminalen und Nichtterminalen auf den rechten Seiten von Produktionen. [\rightarrow separierte Grammatiken]
- 2 Aufbrechen langer Wörter auf den rechten Seiten von Produktionen.
- 3 Eliminieren von Regeln der Form $A \longrightarrow \varepsilon$ (ε -Regeln).
- 4 Eliminieren von Regeln der Form $A \longrightarrow B$ (*Kettenregeln*).

Das Wortproblem für kontextfreie Grammatiken

Definition: Wortproblem für (feste) kontextfreie Grammatik G

- Gegeben: $w \in \Sigma^*$
- Frage: gilt $w \in L(G)$?
- Für Grammatiken in *Chomsky-Normalform* gilt:
Ableitung eines Wortes $w \in L(G)$ hat *höchstens die Länge* $2|w| + 1$:
 - Produktionen der Form $A \rightarrow BC$ verlängern um 1, sie werden genau $(|w| - 1)$ mal angewendet.
 - Produktionen der Form $A \rightarrow a$ erzeugen genau ein Terminalsymbol von w , sie werden genau $|w|$ mal angewendet.
 - Das leere Wort wird durch $S \rightarrow \varepsilon$ abgeleitet:
Ableitung der Länge $2|w| + 1$.

Das Wortproblem für kontextfreie Grammatiken

- Es gibt nur endlich viele Ableitungen der Länge höchstens $2|w| + 1$.
- Um das Wortproblem zu entscheiden können wir
 - alle diese Ableitungen aufzählen und
 - prüfen, ob sie das Eingabewort w erzeugen.
- Aber: *exponentielle Laufzeit*, denn es kann exponentiell viele Ableitungen der Länge $2|w| + 1$ geben.
- Unser Ziel: polynomielle Laufzeit.

Der CYK-Algorithmus (Cocke, Younger, Kasami)

Definition

Sei $G = (N, \Sigma, P, S)$ kf. Grammatik in Ch. NF und $w = a_1 \cdots a_n \in \Sigma^*$. Sei

- $w_{ij} := a_i \cdots a_j$ (für $i \leq j$)
- $N_{ij} := \{A \in N \mid A \vdash_G^* w_{ij}\}$.

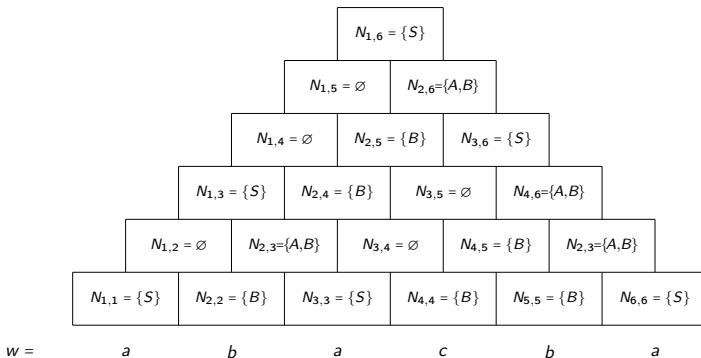
- 1) $S \in N_{1n} \iff w \in L(G)$
- 2) $A \in N_{ii} \iff A \vdash_G^* a_i \iff A \longrightarrow a_i \in P$
- 3) $A \in N_{ij}$ für $i < j$
 $\iff A \vdash_G^* a_i \cdots a_j$
 $\iff \exists A \longrightarrow BC \in P$ und ein k mit $i \leq k < j$ mit
 $B \vdash_G^* a_i \cdots a_k$ und $C \vdash_G^* a_{k+1} \cdots a_j$
 $\iff \exists A \longrightarrow BC \in P$ und k mit $i \leq k < j$ mit
 $B \in N_{ik}$ und $C \in N_{(k+1)j}$

Beispiel

- Grammatik $G = (N, \Sigma, P, S)$ mit

$$P = \begin{aligned} &\{ S \longrightarrow SA \mid a, \\ &\quad A \longrightarrow BS, \\ &\quad B \longrightarrow BB \mid BS \mid b \mid c \} \end{aligned}$$

- $w = abacba$.



Der CYK-Algorithmus (Cocke, Younger, Kasami)

```
for  $i := 1$  to  $n$  do
   $N_{ii} := \{A \mid A \rightarrow a_i \in P\}$ 

for  $\ell := 1$  to  $n - 1$  do  // wachsende Teilwortlänge  $\ell = j - i$ 
  for  $i := 1$  to  $n - \ell$  do  // Startposition  $i$  von Teilwort
     $j := i + \ell$   // Endposition  $j$  von Teilwort
     $N_{ij} := \emptyset$ 
    for  $k := i$  to  $j - 1$  do  // Mögliche Trennpositionen  $k$ 
       $N_{ij} := N_{ij} \cup \{A \mid \exists A \rightarrow BC \in P \text{ mit } B \in N_{ik} \text{ und } C \in N_{(k+1)j}\}$ 

if  $S \in N_{1n}$  then output  $w \in L(G)$ 
```

Der CYK-Algorithmus (Cocke, Younger, Kasami)

Satz

Für jede Grammatik G in Chomsky-Normalform entscheidet der CYK-Algorithmus das Wortproblem für $w \in \Sigma^*$ in Zeit $\mathcal{O}(|w|^3)$.

Beweis.

- Erste for-Schleife: $|w|$ Schritte
- Dann drei geschachtelte Schleifen, jeweils $\leq |w|$ Schritte,
 - also $\leq |w|^3$ Schritte in der innersten Schleife.
 - Suche nach den Produktionen $A \rightarrow a_i$ und $A \rightarrow BC$ nur konstante Zeit, denn G wird als konstant angenommen.

Das Äquivalenzproblem

Definition Äquivalenzproblem

- Gegeben: kontextfreie Grammatiken G_1, G_2 .
- Frage: Gilt $L(G_1) = L(G_2)$?
- Wir werden in *Theoretische Informatik 2* beweisen:

Satz

Das Äquivalenzproblem für kontextfreie Sprachen ist *unentscheidbar*.

Zusammenfassung Entscheidungsprobleme

	Wortproblem	Leerheitsprob.	Äquivalenzprob.
Typ 0			Unentscheidbar
Typ 1			Unentscheidbar
Typ 2	Polyzeit	Polyzeit	Unentscheidbar
Typ 3 NEA/reg. Ausdr.	Linearzeit	Linearzeit	Exponentialzeit
Typ 3 DEA	Linearzeit	Linearzeit	Polynomialzeit