



Kontextfreie Grammatiken

Struktur von Sprache

Wie werden korrekte Sätze einer Sprache gebildet?

Gemüß den Regeln einer Grammatik.

Beispiel für eine kontextfreie Grammatik G

Satz \rightarrow S P O \Rightarrow Satz \Rightarrow S P O \Rightarrow A N P O

S \rightarrow A N

P \rightarrow sieht | frisst

A \rightarrow der | die | das | den

N \rightarrow Haus | Hund | Katze

O \rightarrow A N

Ableitungsschritt

\Rightarrow der N P O

\Rightarrow der N sieht O

\Rightarrow der N sieht A N

\Rightarrow der Hund sieht A N *Satzform*

\Rightarrow der Hund sieht A Haus

\Rightarrow der Hund sieht das Haus *Satz*

Variablen (Nichtterminalsymbole)

Regeln (Produktionen)

Ableitung

Satz $\overset{*}{\Rightarrow}$ die Katze frisst das Haus

Ableitung in 0 oder mehr Schritten

Satz $\overset{*}{\Rightarrow}$ den Katze sieht das Katze

Satz $\overset{*}{\Rightarrow}$ den Hund frisst die Katze

sollte eigentlich O sein

sollte eigentlich S sein

Variante von G:

Satz \rightarrow S P O | O P S

Satz \Rightarrow O P S $\overset{*}{\Rightarrow}$...

Definition Eine kontextfreie Grammatik $G = (\Sigma, V, P, S)$

besteht aus

- einer Menge Σ von Terminalsymbolen
- einer Menge V von Variablen (Nichtterminalsymbolen, syntaktischen Kategorien) ($V \cap \Sigma = \emptyset$)
- einer Menge P von Regeln (Produktionen)

der Form $\alpha \rightarrow \beta$

wobei die linke Seite $\alpha \in V$

und die rechte Seite $\beta \in (V \cup \Sigma)^*$ ist.

- ein Startsymbol $S \in V$

Konventionen: Mehrere Regeln $\alpha \rightarrow \beta_1, \alpha \rightarrow \beta_2, \dots$ mit derselben linken Seite werden zusammengefasst: $\alpha \rightarrow \beta_1 \mid \beta_2 \mid \dots$

- Variablen: Großbuchstaben, Terminalsymbole: der Rest
- Startsymbol: linke Seite der ersten Regel.

Es reicht aus, die Regeln der Grammatik anzugeben.

Eine Zeichenkette $\alpha \in (\Sigma \cup V)^*$ heißt Satzform

Eine Zeichenkette $\alpha \in \Sigma^*$ heißt Satz

Bei Grammatiken spricht man eher von „Sätzen“ $\alpha \in \Sigma^*$ als von „Wörtern“ $\alpha \in \Sigma^*$.

Die Elemente von $\Sigma = \{ \text{der, die, Hund, Hans, if, else, ...} \}$ sind die „Wörter“, aus denen die Sprache aufgebaut ist.

(Bei theoretischen „Spielzeugsprachen“ $L \in \{0,1\}^*$ spricht man auch im Zusammenhang von Grammatiken von Wörtern $x \in \{0,1\}^*$)

Definition Ableitung:

Wir schreiben $\alpha \beta \gamma \Rightarrow \alpha \delta \gamma$, (Ableitungsschritt)

wenn es eine Regel $\beta \rightarrow \delta \in P$ gibt. $\alpha, \beta, \gamma, \delta \in (\Sigma \cup V)^*$

Wir schreiben $\alpha \xRightarrow{*} w$, (Ableitung)

Wenn es eine Folge $\alpha = \alpha_0 \Rightarrow \alpha_1 \Rightarrow \alpha_2 \Rightarrow \dots \Rightarrow \alpha_k = w$ gibt
 $k \geq 0$, $\alpha_0, \alpha_1, \dots, \alpha_k \in (\Sigma \cup V)^*$

Ableitung ist nicht deterministisch: Man darf eine beliebige Variable auswählen und eine passende Regel anwenden.

Bei einer Linksableitung wird immer die erste (linkste) in α_i vorkommende Variable ersetzt.

Die von $G = (\Sigma, V, P, S)$ erzeugte Sprache $L(G)$ ist

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

Ableitungsbaum (Syntaxbaum, parse tree)

Satz \Rightarrow S P O \Rightarrow A N P O

\Rightarrow der N P O


\Rightarrow der N sieht O

\Rightarrow der N sieht A N

\Rightarrow der Hund sieht A N

\Rightarrow der Hund sieht A Haus

\Rightarrow der Hund sieht das Haus



Kontextfreie Sprachen

Eine Sprache L heißt kontextfrei, wenn sie von einer kontextfreien Grammatik erzeugt wird:

$$\exists G: L = L(G)$$

Bsp 2. $S \rightarrow 0S1 \mid \varepsilon$

$$S \Rightarrow 0S1 \Rightarrow 00S11 \Rightarrow 000S111 \Rightarrow 0001111 \in L(G_2)$$

$$L(G_2) = \{0^n 1^n \mid n \geq 0\} \quad \text{nicht regulär}$$

Bsp 3. $S \rightarrow 0S0 \mid 1S1 \mid \varepsilon$

$$S \Rightarrow 0S0 \Rightarrow 00S00 \Rightarrow 001S100 \Rightarrow \overleftarrow{001100} \in L(G_3)$$

$$L(G_3) = \{w w^R \mid w \in \{0,1\}^*\} = \text{Palindrome}$$

gerader Länge

$$00100 \notin L(G_3)$$

Bsp 4. $S \rightarrow 0T \mid 1T \mid \varepsilon$
 $T \rightarrow 0S \mid 1S$

$$S \Rightarrow 1T \Rightarrow 10S \Rightarrow 100T \Rightarrow 1000S \Rightarrow 1000 \in L(G_4)$$

$$L(G_4) = \{00, 01, 10, 11\}^* \quad (\text{alle Wörter gerader Länge})$$

Bsp 5: $S \rightarrow 0S1S \mid 1S0S \mid \varepsilon$

$$S \Rightarrow 0S1S \Rightarrow 00S1S1S \Rightarrow 001S1S \Rightarrow 0011S0S1S$$

$$\stackrel{*}{\Rightarrow} 001101 \in L(G_5)$$

Behauptung: Jede Satzform in der Ableitung hat gleich viele Nullen und Einsen. ✓

$L(G_5) = L_5 := \{w \in \{0,1\}^* \mid w \text{ enthält gleich viele Nullen und Einsen.}\}$

Beweis: $L(G_5) \subseteq L_5 \checkmark$


$$S \rightarrow OS1S \mid 1S0S \mid \varepsilon$$

$L_5 \subseteq L(G_5) : w \in L_5$

vollständige Induktion nach $|w|$


Induktionsbasis: $w = \varepsilon \in L(G_5)$

Induktionsschritt: $w \neq \varepsilon$



Fall 1: w fängt mit 0 an.

Suche den kürzesten nichtleeren Präfix u von w , der ausgeglichen ist. ($\#0 = \#1$) ($u = w$ ist möglich)



u muss mit einer 1 aufhören.

$w = u.y = \overbrace{0x1}^u y$ Nach Induktionsvoraussetzung:
 $\uparrow \quad \uparrow$
 $\in L_5 \quad \in L_5$
 $S \stackrel{*}{\Rightarrow} x, S \stackrel{*}{\Rightarrow} y$

$S \Rightarrow OS1S \stackrel{*}{\Rightarrow} 0x1S \stackrel{*}{\Rightarrow} 0x1y = w \in L(G_5)$

Fall 2: analog

Variante: $S \rightarrow OS1 \mid 1S0 \mid SS \mid \varepsilon$