

Definition von Programmiersprachen

- Übliches Vorgehen beim Programmieren (im Kleinen)



- **ProgrammiererIn:** Welche Form muss ein Text haben, um ein Programm zu sein?
- **Computer:** Wie unterscheidet der Compiler zwischen Texten, die Programme sind und die keine Programme sind?

Grenzen endlicher Automaten

- Programme aller bekannten Programmiersprachen lassen sich nicht durch endliche Automaten erkennen (z.B. wegen der Klammerstrukturen)
- Endliche Automaten erkennen aber einzelne Konstrukte (Schlüsselwörter, Namen, ...) und erlauben lexikalische Analyse.
- Erkennung der Gesamtprogramme im Rahmen der Syntaxanalyse auf der Basis kontextfreier Grammatiken.

Kontextfreie Grammatiken

- sind eine Teilklasse der Chomsky-Grammatiken, die N. Chomsky in den 1950er Jahren ursprünglich zur Beschreibung natürlicher Sprachen eingeführt hat,
- formalisieren die Syntax von Programmier- und Markup-Sprachen (wie z.B. Java, C, HTML, LaTeX, ...),
- dienen als Eingabe für Parsergeneratoren (wie z.B. yacc oder JavaCC),
- beschreiben den strukturellen Aufbau von Dokumenten

Definition

Kontextfreie Grammatik: $G = (N, T, P, S)$ mit

- N : Menge nichtterminaler Zeichen,
- T : Menge terminaler Zeichen mit $N \cap T = \emptyset$,
- $P \subseteq N \times (N \cup T)^*$: endliche Menge kontextfreier Produktionen
- $S \in N$: Startsymbol

- Schreibweise für Produktionen $(A, u) \in P$: $A ::= u$
- Abkürzung für $A ::= u_1, A ::= u_2, \dots, A ::= u_k$:

$$A ::= u_1 | u_2 | \dots | u_k$$

Beispiel

$$G_{\text{bracket}_0} = (\{S\}, \{a, b\}, \{S ::= aSb \mid \lambda\}, S)$$

Ableitungen

Direkte Ableitung:

$$w = xAy \xrightarrow{p} xuy = w'$$

mit $w, w', x, y, u, v \in (N \cup T)^*$, $p = (A ::= u)$.

- **Schreibweise:** $w \xrightarrow{P} w'$,
falls P eine Menge von Produktionen ist mit $p \in P$.
- **Beispiel:** $aSb \xrightarrow{S ::= aSb} a^2Sb^2$

Ableitung (Iteration direkter Ableitungen)

$$w_0 \xrightarrow{p_1} w_1 \xrightarrow{p_2} \cdots \xrightarrow{p_n} w_n$$

für $w_0, \dots, w_n \in (N \cup T)^*$ und Produktionen p_1, \dots, p_n

Schreibweisen:

- $w_0 \xrightarrow{P} \cdots \xrightarrow{P} w_n$ oder $w_0 \xrightarrow[n]{P} w_n$ oder $w_0 \xrightarrow{P}^* w_n$,
falls $p_1, \dots, p_n \in P$.
- $w \xrightarrow{*} w'$, falls P aus dem Kontext klar ist.

Beispiel

$$G_{\text{bracket}_0} = (\{S\}, \{a, b\}, \{S ::= aSb \mid \lambda\}, S)$$

$$S \xrightarrow[S ::= aSb]{} aSb \xrightarrow[S ::= aSb]{} a^2Sb^2 \xrightarrow[S ::= aSb]{} a^3Sb^3 \xrightarrow[S ::= \lambda]{} a^3b^3$$

Nullableitung

$$w \xrightarrow[P]{0} w$$

für alle $w \in (N \cup T)^*$.

Erzeugte Sprache

- $G = (N, T, P, S)$: kontextfreie Grammatik

Erzeugte Sprache

$$L(G) = \{w \in T^* \mid S \xrightarrow[P]{*} w\}$$

Die von kontextfreien Grammatiken erzeugten Sprachen heißen **kontextfreie Sprachen**.

Beispiel: Wörter der Form $a^n b^n$

- $G_{\text{bracket}_0} = (\{S\}, \{a, b\}, \{S ::= aSb \mid \lambda\}, S)$

$$S \xrightarrow[S ::= \lambda]{} \lambda, \quad S \xrightarrow[S ::= aSb]{} aSb \xrightarrow[S ::= \lambda]{} ab$$

$$S \xrightarrow[S ::= aSb]{} aSb \xrightarrow[S ::= aSb]{} a^2 S b^2 \xrightarrow[S ::= \lambda]{} a^2 b^2$$

$$S \xrightarrow[S ::= aSb]{} aSb \xrightarrow[S ::= aSb]{} a^2 S b^2 \xrightarrow[S ::= aSb]{} a^3 S b^3 \xrightarrow[S ::= \lambda]{} a^3 b^3$$

...

$$S \xrightarrow[S ::= aSb]{} aSb \xrightarrow[S ::= aSb]{} a^2 S b^2 \xrightarrow[S ::= aSb]{} a^3 S b^3 \xrightarrow[S ::= aSb]{} \dots \xrightarrow[S ::= \lambda]{} a^n b^n$$

- $L(G_{\text{bracket}_0}) = \{a^n b^n \mid n \in \mathbb{N}\}$.

Wörter über A

$(\{\langle \text{word} \rangle\}, A, P, \langle \text{word} \rangle)$ mit den Produktionen

$$\langle \text{word} \rangle ::= \lambda \mid x \langle \text{word} \rangle$$

für alle $x \in A$.

Erzeugung von abc :

$$\begin{aligned} \langle \text{word} \rangle &\longrightarrow a \langle \text{word} \rangle \longrightarrow ab \langle \text{word} \rangle \\ &\longrightarrow abc \langle \text{word} \rangle \longrightarrow abc \end{aligned}$$

Klammerstrukturen

- $G_{\text{bracket}_1} = (\{S\}, \{[,], <, >\}, P_{\text{bracket}_1}, S)$ mit

$$P_{\text{bracket}_1} = \{S ::= [S] \mid <S> \mid SS \mid \lambda\}$$

$S \rightarrow SS \rightarrow S[S] \rightarrow <S> [S] \rightarrow <SS> [S] \rightarrow$
 $<[S]S> [S] \rightarrow <[]S> [S] \rightarrow <[]S> [<S>] \rightarrow$
 $<[]S> [<>] \rightarrow <[][S]> [<>] \rightarrow <[][]> [<>]$

Wörter der Form $a^{2k}b^{3l}$

- $G_{2a3b} = (\{S, A, B\}, \{a, b\}, P_{2a3b}, S)$ mit

$$P_{2a3b} = \{S ::= AB, A ::= a^2A \mid \lambda, B ::= b^3B \mid \lambda\}$$

- Erzeugung von a^4b^3 :

$$S \rightarrow AB \rightarrow a^2AB \rightarrow a^4AB \rightarrow a^4B \rightarrow a^4b^3B \rightarrow a^4b^3$$

oder

$$S \rightarrow AB \rightarrow Ab^3B \rightarrow a^2Ab^3B \rightarrow a^2Ab^3 \rightarrow a^4Ab^3 \rightarrow a^4b^3$$

- $L(G_{2a3b}) = \{a^{2k}b^{3l} \mid k, l \in \mathbb{N}\}$

Reguläre Ausdrücke über I

$$\langle \text{reg} \rangle ::= \text{empty} \mid \text{lambda} \mid x \mid (\langle \text{reg} \rangle + \langle \text{reg} \rangle) \mid (\langle \text{reg} \rangle \circ \langle \text{reg} \rangle) \mid (\langle \text{reg} \rangle^*)$$

für alle $x \in I$.

$$\begin{aligned} \langle \text{reg} \rangle &\longrightarrow (\langle \text{reg} \rangle + \langle \text{reg} \rangle) \longrightarrow (\text{lambda} + \langle \text{reg} \rangle) \\ &\longrightarrow (\text{lambda} + (\langle \text{reg} \rangle)^*) \longrightarrow (\text{lambda} + (a)^*) \end{aligned}$$

Boolesche Ausdrücke

$\langle \text{boolexp} \rangle ::= \text{true} \mid \text{false} \mid$
 $\langle \text{var} \rangle \mid (\neg \langle \text{boolexp} \rangle) \mid$
 $(\langle \text{boolexp} \rangle \langle \text{boolop} \rangle \langle \text{boolexp} \rangle)$
 $\langle \text{boolop} \rangle ::= \wedge \mid \vee \mid \Rightarrow \mid \Leftrightarrow$
 $\langle \text{var} \rangle ::= b \langle \text{cipherseq} \rangle$
 $\langle \text{cipherseq} \rangle ::= \langle \text{cipher} \rangle \mid$
 $\langle \text{cipher} \rangle \langle \text{cipherseq} \rangle$
 $\langle \text{cipher} \rangle ::= 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$

Kontextfreiheitslemma

Sei

- ▶ $G = (N, T, P, S)$ eine kontextfreie Grammatik,
- ▶ $u \xrightarrow[P]{n} v$ eine Ableitung und
- ▶ $u = u_1 u_2 \cdots u_k$ eine Zerlegung von u .

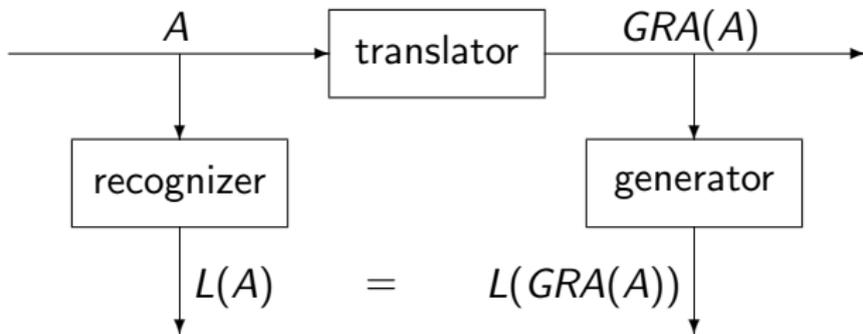
Dann gibt es Ableitungen $u_i \xrightarrow[P]{n_i} v_i$ ($i = 1, \dots, k$), so dass

$$v = v_1 \cdots v_k \text{ und } n = \sum_{i=1}^k n_i.$$

Fragestellungen

- Sind kfG's kompositional?
- Wie hängen endliche Automaten und kfG's zusammen?
- Ist für kfG's das Wortproblem schnell lösbar?
- Was können kfG's nicht?

Übersetzung endlicher Automaten in (rechtslineare) Grammatiken



Konstruktion von $GRA(A)$

Sei $A = (Z, I, d, s_0, F)$ ein NEA.

$GRA(A) = (Z, I, P_A, s_0)$ mit

$$P_A = \{s ::= xs' \mid s' \in d(s, x)\} \cup \{s'' ::= \lambda \mid s'' \in F\}$$

Satz

$$L(A) = L(GRA(A)).$$