

Anwendung:  
 man grep  
 man sed  
 vi / vim  
 emacs  
 flex / lex

## 1.4. Kontextfreie Sprachen (Kfs) und Kellerautomaten (KA)

Ch-3-Gs genügen i.a. nicht um komplexere formale Sprachen wie Programmiersprachen zu beschreiben (z.B. Klammerstrukturen wie in  $L_{ab} = \{a^n b^n : n \in \mathbb{N}\}$ ).

Es gilt  $\text{REG} \subsetneq \text{CFL}$ . D.h. die Klasse der Kfs ist mächtiger als die der regulären Sprachen (rs).

Ch-3-Gs, RA, und EA eignen sich nicht um Kfs zu beschreiben.

Analog zu RA, EA und Ch-3-Gs bei rs sind in der Klasse Kfs folgende Beschreibungsformen gleich mächtig:

- Ch-2-Gs
- BNF-Ausdrücke
- Kellerautomaten

Diese Mittel werden bei Spezifikation und der Syntaxanalyse von Programmiersprachen in Übersetzern und Interpretierern eingesetzt.

### 1.4.1. BNF-Notation

Erweiterung von RA:  
 1. Hilfszeichen (Nichtterminale),  
 2. (rekursive) Gleichungen für Hilfszeichen.

Sei  $T$  eine Menge von Terminalzeichen und  $N$  eine Menge von Nichtterminalzeichen. Eine BNF-Beschreibung einer Sprache  $L$  hat die Form:

$$\begin{aligned} X_1 &::= E_1 \\ &\vdots \end{aligned}$$

$X_n ::= E_n$  mit  $X_1, \dots, X_n \in N$  und  $E_1, \dots, E_n$  RA über  $T \cup N$ .

z.B.  $<z> ::= ab \mid a<z>b$  beschreibt die Kfs  $\{a^n b^n : n \in \mathbb{N} \setminus \{0\}\}$

für eine BNF-Beschreibung kann für jedes  $X_i$  ( $1 \leq i \leq n$ ) eine Ch-2-G (KfG) angegeben werden. Die RA  $E_i$  werden in Ch-3-G (mit neuem Nichtterminal  $z$  als Axiom) umgeformt und für die BNF-Regel

$$X_i ::= E_i$$

wird die Regel  $Z_i \rightarrow X_i$  in die Grammatik aufgenommen. □

Anmerkung: Es gibt zahlreiche Stile und Erweiterungen von BNF.

Die Klammern [...] dienen oft der Kennzeichnung

optionaler Anteile; z.B.  $X[Y]$  für  $X \mid XY$ .  $X[...]$  sprich  $X$  optional!

$\{X\}_n^m$  bezeichnet die  $n$ - bis  $m$ -malige Wiederholung von  $X$ .

### 1.4.2. Kellerautomaten (KA)

Ein Kellerautomat  $KA = (S, T, K, \delta, s_0, k_0, S_2)$

$S$  endl. Menge von Zuständen

$T$  " von Eingabezeichen

$K$  " von Kellereichen

$\delta$  endl. Übergangsfunktion  $\delta: S \times (T \cup \{\epsilon\}) \times K \rightarrow P(S \times K^*)$

$s_0 \in S$  Anfangszustand

$S_2 \subseteq S$  Endzustände

Prinzip: KA verarbeitet ein Wort  $w \in T^*$ , indem er  $w$  von links nach rechts liest und in jedem Schritt abhg. vom aktuellen Zustand  $s$  Eingabezeichen

Prinzip: KA verarbeitet ein Wort  $w \in T^*$ , indem er  $w$  von links nach rechts liest, und in jedem Schritt abhg vom aktuellen Zustand  $s$ , Eingabezeichen  $a$  und obersten Kellerzeichen  $k$ , entsprechend  $\delta$  folgendes tut:

- in einen neuen Zustand  $s' \in S$  übergeht
- das obere Zeichen  $k$  im Keller entfernt
- eine (ggf. leere) Sequenz  $u \in K^*$  auf den Keller legt.

KA akzeptiert  $w \in T^*$ , wenn die vollst. Verarbeitung von  $w$  von  $s_0$  zu einem Endzustand  $s \in S_2$  führt.

Darstellung Graph analog zu EA. Knoten:  $s \in S$ , Kanten  $(a, k, u)$

Kanten:  $(a, k, u) \in (\Gamma \cup \{\epsilon\}) \times K \times K^*$

eine Kante  $(a, k, u)$  von  $s$  nach  $s'$  existiert g.d.w.

$$(s', u) \in \delta(s, a, k)$$

zsp. (KA für  $\{C^n\}^n : n \in \mathbb{N} \setminus \{0\}\}$ )


$$KA = (S, T, K, \delta, s_0, 0, \{s_2\})$$

$$S = \{s_0, s_1, s_2\} \quad T = \{C\} \quad K = \{1, 0\}$$

Übergangsrelation  $\delta$ :

$$\begin{aligned} \delta(s_0, C, 0) &= \{(s_0, \langle 10 \rangle)\} && \text{erne öffnende Klammer lesen} \\ \delta(s_0, C, 1) &= \{(s_0, \langle 11 \rangle)\} && \text{auf dem Keller ablegen} \\ \delta(s_1, C, 1) &= \{(s_1, \epsilon)\} && s_1: Zustand \rightarrow Erkennung von \\ \delta(s_1, C, 0) &= \{(s_1, \epsilon)\} && \text{schließenden Klammern} \\ \delta(s_1, \epsilon, 0) &= \{(s_2, \epsilon)\} && \text{nichts auf dem Keller ablegen} \end{aligned}$$

Darstellung:



Arbeitsweise formal:

wir betrachten Kellerkonfiguration  $(s, w, v) \in S \times T^* \times K^*$  mit Kontrollzustand  $s$ , (Rest-)Eingabewort  $w$  und Kellerzustand  $v$ .

Ein KA induziert eine Übergangsrelation  $\rightarrow$  auf Konfigurationen,

Vermöge:  $(s_1, w, \langle k \rangle \circ v) \rightarrow (s_2, w, u \circ v)$  falls  $(s_2, u) \in \delta(s_1, \epsilon, k)$   
und  $(s_1, \langle a \rangle \circ w, \langle k \rangle \circ v) \rightarrow (s_2, w, u \circ v)$  falls  $(s_2, u) \in \delta(s_1, a, k)$

$w \in T^*$  von KA akzeptiert, wenn es ein  $s \in S_2$  und ein  $v \in K^*$  gibt, so dass:  $(s_0, w, \langle k \rangle) \xrightarrow{*} (s, \epsilon, v)$  (Akzeptanz durch Endzustände)

Die von KA akzeptierte Sprache bezeichnet wir mit  $L(KA)$ .

Anm.: Akzeptieren durch „leeren Keller“ ist gleich mächtig.

D.h.  $w \in T^*$  von KA akzeptiert, wenn  $(s_0, w, \epsilon) \xrightarrow{*} (s, \epsilon, \epsilon)$  mits.  $s$ .

Durch KA erhalten wir für beliebige Kfs unmittelbar einen (r-d. R-sehr effizienten) Erkennungsalgorithmus!

Im Gegensatz zu EA sind deterministische KA nicht äquivalent zu nichtdeterministischen KA!

### 1.4.3. Äquivalenz von KA und KfS

Satz: Ist  $L$  eine KfS, dann gibt es einen KA  $K$ , so dass  $L(K) = L$ .

Idee: Gege. sei eine KfG  $G = (\Gamma, N, \rightarrow, Z)$ .

Aus: ICA  $K$  mit  $L(K) = L(G)$

$$K = CS, \Gamma, T \cup NV \{ \#, \delta, \epsilon, \#, \{Se\} \}$$

Kellerr-Ende-Zeichen

Wähle  $S = \{\epsilon, Se, Sv\} \cup$  Menge aller (Teil-)sequenzen der linken Seiten der Grammatik-Regeln.

Sei  $\langle e_1, \dots, e_n \rangle, e_i \in NUT$ , linke Seite einer Grammatik-Regel  
 $\langle e_1, \dots, e_n \rangle \rightarrow A$  rechte Seite d. Regels

Übergangs relation  $\delta$ :

1. Kellern  $(\epsilon, < a_k >) \in \delta(\epsilon, a, k)$   $a \in T$

2. Regelerkennung:

a)  $(\langle e_{i-1} \dots e_j \rangle, \epsilon) \in \delta(\langle e_i \dots e_j \rangle, \epsilon, e_{i-1})$   
Teilsequenz einer linken Seite

b)  $(\langle e_i \dots e_j, \langle k \rangle) \in \delta(\langle e_i \dots e_j \rangle, e_{j+1}, k)$

3. Regelanwendung:

$(\epsilon, < Ak >) \in \delta(\langle e_1, \dots, e_n \rangle, \epsilon, k)$

4. Akzeptanz:

a)  $(Sv, \epsilon) \in \delta(\epsilon, \epsilon, \#)$   
Eingabe Einstieg Kellerr

b)  $(Se, \epsilon) \in \delta(Sv, \epsilon, \#)$

ein Zeichen vom  
Vorher gelten und  
vorne „raum tun“

Automat muss  
an d. richtigen Stelle  
mit Regelaufbau beginnen

$K$  ist nichtdeterministisch und ineffizient!

$K$  kellert Eingabe, bis er an bel. Stelle mit dem Aufbau der linken Seite einer Regel beginnt.

Beispiel: KfG  $G = (\{a, b\}, \{Z\}, \{aZb \rightarrow Z, ZZ \rightarrow b, ab \rightarrow Z\})$

Konstruiere Kellerautomaten:

$$\Sigma = \{\epsilon, Sv, Se, \langle a \rangle, \langle b \rangle, \langle Z \rangle, \langle aZ \rangle, \langle Zb \rangle, \langle ZZ \rangle, \langle aZb \rangle, \langle ZZb \rangle\}$$

$$\delta = (\text{Sei } x \in T, k \in K) \quad \delta(\epsilon, x, k) = \{(\langle x \rangle, \langle k \rangle), (\epsilon, \langle xk \rangle)\}$$


$$K \neq \# \Rightarrow \delta(\epsilon, \epsilon, k) = \{(\langle k \rangle, \epsilon)\}$$

$$2a \quad \delta(\langle Z \rangle, b, k) = \{(\langle Zb \rangle, \langle k \rangle), (\langle ZZ \rangle, \langle k \rangle)\}$$

$$\delta(\epsilon, \epsilon, Z) = \{(Sv, \epsilon)\}$$

⋮

Ausschnitt aus Ableitungsbäum für  $\langle aabb \rangle$ :



Beobachtung:  $K$  nichtdeterministisch und sackgassen

d.h. sehr ineffizient.

ICA akzeptiert selbe L.

$\langle c_1 \dots c_m \rangle \rightarrow A$  für  $w = x \circ c_1 \dots c_m \circ y$  durch Betrachtung eines endlichen Präfix von  $y$  gesteuert werden.

Kontextbedingung (KB): Menge von Wörtern, die die Präfixe von  $y$  festlegt, welche die Regelanwendung zulassen.

KfG  $G$  heißt LR-deterministisch, wenn es für alle Regeln endliche KB gibt, so dass der von links nach rechts arbeitende KA für alle  $w \in L(G)$  und alle akzeptierenden Reduktionen in jedem Schritt genau eine Regel zulässt, die Reduktion vollzieht und Sackgassen vermeidet.

Satz: Jede LR-deterministische KfG ist eindeutig.

Beweis: Gemäß Definition LR-deterministischer KfG gibt es eine eindeutige Einschränkung des KA, der die Ableitung erzeugt.

Def. (LR(k))

$w \in \Sigma^*$  bezeichnet Teilwort  $\langle w_1 \dots w_k \rangle$  von  $w = \langle w_1 \dots w_n \rangle$ ,  $i, k \in \mathbb{N}, 1 \leq i$ . Eine azyklische KfG  $(T, N, \rightarrow, Z)$  heißt LR(k)-Grammatik, wenn für jedes Paar von Ableitungen in Linksnormalform gilt:

$$u_1 \circ a_1 \circ x_1 \xrightarrow{*} u_1 \circ c_1 \circ B_1 \circ x_1 \xrightarrow{*} \dots \xrightarrow{*} Z \quad \rightarrow \text{Regelanwendung}$$

$$u_2 \circ a_2 \circ x_2 \xrightarrow{*} u_2 \circ c_2 \circ B_2 \circ x_2 \xrightarrow{*} \dots \xrightarrow{*} Z$$

wobei  $\{a_1 \rightarrow B_1, a_2 \rightarrow B_2\} \subseteq \rightarrow$  gilt:

$$u_1 \circ a_1 \circ (x_1[1:k]) = u_2 \circ a_2 \circ (x_2[1:k]) \Rightarrow a_1 = a_2 \wedge B_1 = B_2 \wedge u_1 = u_2 \circ$$

D.h., durch  $x_i[1:k]$  ist die anzuwendende Regel eindeutig festgelegt.

Bsp. (LR(0))

$$G = (\{a, b\}, \{Z, X\}, \{Z \xrightarrow{*} Z, X \xrightarrow{*} Z, aZb \xrightarrow{*} X, ab \xrightarrow{*} X\}, Z)$$

Ableitung von caabbab: (Sprache  $a^n b^n a b$ )

$$\text{caabbab} \xrightarrow{4} \text{caXbab} \xrightarrow{2} \text{cazbab} \xrightarrow{3} \text{cab} \xrightarrow{2} \text{Zab} \xrightarrow{4} \text{Z} \xrightarrow{1} Z$$

KA: kellen bis Regel anwendbar, Regeln anwenden so lange wie möglich.

Keller: Präfix des zu reduzierenden Wortes!

Bei LR(0) ist kein Kontext notwendig, um die richtigen Regeln zu wählen. o

Satz: Jede LR(k)-Grammatik ist eindeutig.

Beweis: LR(k)-Grammatiken sind LR-deterministisch

Bsp. (LR(1))  $G = (T, N, \rightarrow, Z)$   $N = \{Z, A, P, E\}$   $T = \{\{, \}, +, -, *, /, a\}$

Regel	Kontextbedingungen	Keller	Restwort
$A \rightarrow Z$	$\epsilon$	$\epsilon$	aabbab
$E \rightarrow A$	$+, -, *, /$	a	abbab
$A \leftarrow E \rightarrow A$	$+, -, *, /$	aa	bab
$A \leftarrow E \rightarrow A$	$+, -, *, /$	aab	bab
$P \rightarrow E$	$t \in T$	ax	bab
$E \leftarrow P \rightarrow E$	$t \in T$	az	bab
$(A) \rightarrow P$	$t \in T$	?	?
$a \rightarrow P$	$t \in T$	z	?

Regel	Kontextbedingungen
$A \rightarrow Z$	$\epsilon$
$E \rightarrow A$	$+, -, *, /$
$A \leftarrow E \rightarrow A$	$+, -, *, /$
$A \leftarrow E \rightarrow A$	$+, -, *, /$
$P \rightarrow E$	$t \in T$
$E \leftarrow P \rightarrow E$	$t \in T$
$(A) \rightarrow P$	$t \in T$
$a \rightarrow P$	$t \in T$

da auf der linken Seite  
nur  $+, -, *, /$  vorkommt  
folgt

$$\text{Bsp. } \langle a + a * a \rangle \rightarrow \dots \rightarrow \langle A + E * a \rangle \rightarrow \dots \rightarrow \langle A + E * P \rangle \rightarrow \dots Z$$

LR(k)-Grammatiken erlauben Reduktion von Wörtern durch KA mit akzeptablem Aufwand. Insbesondere LR(1)-G werden in der Praxis eingesetzt.

Anmerkung: Es gibt keinen Algorithmus, der für eine beliebige Grammatik  $G$  entscheidet, ob  $G$  LR(k) ist. d.h. es kann ja nur dann kein Alg. ex.

#### 4.4.6. LL(k)-Grammatiken (Left-Leftmost)

Gegensatz zu LR(k): top-down Produktion der Ableitung startend vom Axiom. Dadurch Linkstableitung (bzw. Rechtireduktion) statt Linkssubstitution.

Idee (KA):

1. Produktion von  $v \in T^*$  ausgehend von Nichtterminal auf Keller und abhängig vom Rechtskontext.
2. Vergleich des erzeugten  $v$  mit dem Präfix des Resteingabewortes.
3. Bei Übereinstimmung entfernen wir  $v$  sowohl aus dem Keller als auch aus dem Eingabewort.

Def (LL(k))

Eine azyklische KfG  $G = (T, N, \rightarrow, Z)$  heißt LL(k)-Gramm. ( $k \in \mathbb{N}$ ), falls für alle Paare von Ableitungen in Rechtsnormalform  $(a_1, a_2, v, u_1, u_2 \in (T \cup N)^*, w \in T^*, B \in N)$ :

$$v \circ u_1 \xrightarrow{*} v \circ a_1 \circ w \xrightarrow{*} v \circ c_1 \circ B \circ w \xrightarrow{*} Z \quad \text{wobei } \{a_1 \rightarrow B, a_2 \rightarrow B\} \subseteq \rightarrow \text{ gilt:}$$

$$v \circ u_2 \xrightarrow{*} v \circ a_2 \circ w \xrightarrow{*} v \circ c_2 \circ B \circ w \xrightarrow{*} Z \quad u_1[1:k] = u_2[1:k] \rightarrow a_1 = a_2.$$

D.h. die Zer teilung ist mit  $u_1[1:k]$  eindeutig festgelegt.

