

## Übungsblatt 4

**Aufgabe 1** Gegeben seien folgende Scannerregeln über dem Alphabet  $\{a,b\}$ :

$$\begin{aligned} a & \{action_1\} \\ a^*b & \{action_2\} \end{aligned}$$

Bestimmen Sie den Scanner (Folien 51 und 52).

**Lösung:**

Sei  $\Sigma = \{a, b\}$ ,  $e_1 = a$  und  $e_2 = a^*b$ . Zunächst müssen wir den Berry-Sethi-Automat zu  $e := e_1 \mid e_2$  konstruieren. Wir erhalten

$$e' := \text{num}(e) = [1, a] \mid [2, a]^*[3, b].$$

Für  $\text{empty}$ ,  $\text{first}$ ,  $\text{last}$  und  $\text{next}$  ergibt sich:

$$\begin{aligned} \text{empty}(e') &= \text{empty}([1, a]) \vee \text{empty}([2, a]^*[3, b]) = f \\ &\quad \left\{ \begin{array}{l} \text{empty}([1, a]) = f \\ \text{empty}([2, a]^*[3, b]) = \text{empty}([2, a]^*) \wedge \text{empty}([3, b]) = f \\ \quad \left\{ \begin{array}{l} \text{empty}([2, a]^*) = t \\ \quad \text{empty}([2, a]) = f \\ \text{empty}([3, b]) = f \end{array} \right. \end{array} \right. \\ \text{first}(e') &= \text{first}([1, a]) \cup \text{first}([2, a]^*[3, b]) = \{[1, a], [2, a], [3, b]\} \\ &\quad \left\{ \begin{array}{l} \text{first}([1, a]) = \{[1, a]\} \\ \text{first}([2, a]^*[3, b]) = \text{first}([2, a]^*) \cup \text{first}([3, b]) = \{[2, a], [3, b]\}^1 \\ \quad \left\{ \begin{array}{l} \text{first}([2, a]^*) = \text{first}([2, a]) = \{[2, a]\} \\ \quad \text{first}([2, a]) = \{[2, a]\} \\ \text{first}([3, b]) = \{[3, b]\} \end{array} \right. \end{array} \right. \end{aligned}$$

---

<sup>1</sup>weil  $\text{empty}([2, a]^*) = t$

$$\text{last}(e') = \text{last}([1, a]) \cup \text{last}([2, a]^*[3, b]) = \{[1, a], [3, b]\}$$

$$\begin{array}{l} \left\{ \begin{array}{l} \text{last}([1, a]) = \{[1, a]\} \\ \text{last}([2, a]^*[3, b]) = \text{last}([3, b]) = \{[3, b]\}, \text{ weil } \text{empty}([3, b]) = f \\ \quad \left\{ \begin{array}{l} \text{last}([2, a]^*) = \text{last}([2, a]) = \{[2, a]\} \\ \quad \left\{ \begin{array}{l} \text{last}([2, a]) = \{[2, a]\} \end{array} \right. \\ \text{last}([3, b]) = \{[3, b]\} \end{array} \right. \end{array} \right. \end{array}$$

$$\text{next}(e') = \emptyset$$

$$\begin{array}{l} \left\{ \begin{array}{l} \text{next}([1, a]) = \text{next}(e') = \emptyset \\ \text{next}([2, a]^*[3, b]) = \text{next}(e') = \emptyset \\ \quad \left\{ \begin{array}{l} \text{next}([2, a]^*) = \text{first}([3, b]) = \{[3, b]\}, \text{ weil } \text{empty}([3, b]) = f \\ \quad \left\{ \begin{array}{l} \text{next}([2, a]) = \text{first}([2, a]) \cup \text{next}([2, a]^*) = \{[2, a], [3, b]\} \end{array} \right. \\ \text{next}([3, b]) = \text{next}([2, a]^*[3, b]) = \emptyset \end{array} \right. \end{array} \right. \end{array}$$

Der Berry-Sethi-Automat ist dann  $A = (Q, \Sigma, \Delta, I, F)$  mit

$$Q = \{q_0\} \cup \{1, \dots, \ell(e')\} = \{q_0, 1, 2, 3\},$$

$$\Sigma = \{a, b\},$$

$$\Delta = \{(q_0, x, i) \mid [i, x] \in \text{first}(e')\}$$

$$\cup \{(i, x, j) \mid \exists y. [j, x] \in \text{next}([i, y])\}$$

$$= \{(q_0, a, 1), (q_0, a, 2), (q_0, b, 3), (2, a, 2), (2, b, 3)\}$$


$$I = \{q_0\},$$

$$F = \{i \mid \exists x. [i, x] \in \text{last}(e')\}$$


$$\cup \{q_0 \mid \text{empty}(e') = t\}$$

$$= \{1, 3\}.$$

Grafisch:



Der erreichbare Teil des Potenzmengenautomat  $\mathcal{P}(A)$  ist dann



Wir bezeichnen obigen Automaten (also den erreichbaren Teil von  $\mathcal{P}(A)$ ) mit  $(Q', \Sigma, \delta, I', F')$ . D.h. der erreichbare Teil der Endzustände von  $\mathcal{P}(A)$  ist  $F' = \{\{1, 2\}, \{3\}\}$ . Da wir in der Übung zunächst die Alphabetsymbole in last stehen lassen, ergibt sich eine leicht andere Definition der Endzustandsmengen  $F_i$  als in der Vorlesung. Zum Löschen der Alphabetsymbole sei  $f: \Sigma_n \rightarrow \mathbb{N}$  definiert als  $f([j, a]) = j$  und für eine Menge  $M \subseteq \Sigma_n$  schreiben wir  $f(M) = \{f(z) \mid z \in M\}$ . Dann ist  $F_i$  (für  $1 \leq i \leq n$  bei  $n$  regulären Ausdrücken  $e_1, \dots, e_n$ ) definiert als

$$F_i = \{q \in (F' \setminus (F_1 \cup \dots \cup F_{i-1})) \mid q \cap f(\text{last}(e_i)) \neq \emptyset\}.$$

Für  $e_1$  und  $e_2$  ergibt sich

$$F_1 = \{q \in \{\{1, 2\}, \{3\}\} \mid q \cap \{1\} \neq \emptyset\} = \{\{1, 2\}\},$$

$$F_2 = \{q \in \{\{3\}\} \mid q \cap \{3\} \neq \emptyset\} = \{\{3\}\}.$$

**Aufgabe 2** Verwenden Sie den Scanner aus Aufgabe 1. Führen Sie jeweils den Tokenizing-Algorithmus (Folie 54), gefolgt von Reps' Maximal-Munch-Algorithmus (Folie 57) für die folgenden Wörter durch:

**Lösung:**

Zu einem Wort  $w \in \Sigma^*$  sei  $P_w = \{1, \dots, |w| + 1\}$  die Menge seiner Positionen. Ein Zustand des Tokenizing-Algorithmus in  $w$  besteht aus einem Paar  $(q, k) \in Q' \times P_w$  und einem Element  $\ell \in (Q' \times P_w) \cup \{\perp\}$ . Hier ist  $q$  der aktuelle Zustand und  $k$  die Position in  $w$ . Die Position  $k$  bedeutet, dass man vor dem  $k$ -ten Symbol steht, wobei  $k = |w| + 1$  bedeutet, dass man am Ende des Worts angekommen ist. Der Wert  $\ell$  ist die Position und der Wert des zuletzt gesehenen Endzustands. Wenn  $\ell = \perp$ , so wurde noch kein Endzustand gesehen. Wenn  $\ell = (p, j)$ , dann wurde zuletzt der Endzustand  $p$  vor dem  $j$ -ten Symbol gesehen. Außerdem merken wir uns mit  $s \in P_w$ , von wo wir das nächste Mal ein Token abschneiden müssen, was zu Anfang  $s = 1$  ist. Wenn wir zu Reps' Algorithmus übergehen, muss der Algorithmus noch zusätzlich die Menge  $\text{fv} \subseteq Q' \times P_w$  (Fehlversuch) verwalten, die sagt, welche Konfigurationen nicht mehr zu einem Endzustand führen.

(a)  $w_1 = aababa$

**Lösung:**

Wir notieren Zustände wie folgt: Der Startzustand ist  $|\{q_0\}aababa$ . Dies bedeutet, dass  $k = 1$ ,  $q = \{q_0\}$  und  $\ell = \perp$  (was wir nicht explizit repräsentieren). Das Symbol  $|$  wird benutzt, um  $s$  zu markieren, d.h.  $s = 1$ . Der erste Übergang des Scanners ist  $\delta(\{q_0\}, a) = \{1, 2\}$ , also wäre der nächste Zustand  $|a\{1, 2\}ababa$ . Dass  $\{1, 2\}$  der zuletzt gesehene Endzustand ist, müssen wir allerdings auch noch markieren, was wir tun, indem wir  $|a\{1, 2\}\{1, 2\}ababa$  schreiben, d.h.  $\ell = (\{1, 2\}, 2)$ . Es geht weiter mit

$$|a\{1, 2\}a\{2\}baba, |aab\{3\}\{3\}aba \text{ und} \\ |aab\{3\}a\emptyset ba.$$

Da wir  $\emptyset$  erreicht haben, muss nun das Token zwischen  $|$  und  $\{3\}$  abgeschnitten werden. Wir rufen also  $\text{write}(aab)$  und  $\text{action}_2$  auf, weil  $\{3\} \in F_2$  ist. Der nächste Zustand ist  $aab|\{q_0\}aba$ . Es geht weiter mit

$$aab|a\{1, 2\}\{1, 2\}ba, aab|ab\{3\}\{3\}a \text{ und } aab|ab\{3\}a\emptyset.$$

Wir rufen  $\text{write}(ab)$  und  $\text{action}_2$  auf und machen weiter mit  $aabab|\{q_0\}a$ , gefolgt von  $aabab|a\{1, 2\}\{1, 2\}$ . Weil hier das Wortende erreicht wurde und wir einen Endzustand gesehen haben, rufen wir  $\text{write}(a)$  und  $\text{action}_1$  auf, da  $\{1, 2\} \in F_1$  gilt. Da  $s$  nun am Ende ist, stoppt der Algorithmus.

Reps' Algorithmus muss zusätzlich die Menge  $fv$  verwalten. Wenn wir  $\emptyset$  oder das Wortende erreichen, müssen alle Konfigurationen in  $fv$  aufgenommen werden, die wir seit dem letzten Endzustand gesehen haben. Wir starten zunächst wieder in  $|\{q_0\}aababa$  und erreichen nach ein paar Schritten  $|aab\{3\}a\emptyset ba$  (wie oben). Die zuletzt gesehene Konfiguration,  $|aab\{3\}\{3\}aba$ , ist in einem Endzustand, also wird nichts in  $fv$  eingetragen. Ebenso wird in  $aab|ab\{3\}a\emptyset$  und in  $aabab|a\{1, 2\}\{1, 2\}$  nichts in  $fv$  eingetragen.

(b)  $w_2 = aaaaa$

**Lösung:**

Wir beginnen in  $|\{q_0\}aaaaa$ . Danach folgen die Zustände

$$|a\{1, 2\}\{1, 2\}aaaa, |a\{1, 2\}a\{2\}aaa, |a\{1, 2\}aa\{2\}aa, \\ |a\{1, 2\}aaa\{2\}a \text{ und } |a\{1, 2\}aaaa\{2\}.$$

Wir erreichen das Wortende. Es wird also  $\text{write}(a)$  mit  $\text{action}_1$  aufgerufen. Danach geht es weiter in  $a|\{q_0\}aaaa$ , gefolgt von

$$a|a\{1,2\}\{1,2\}aaa, a|a\{1,2\}a\{2\}aa, a|a\{1,2\}aa\{2\}a, a|a\{1,2\}aaa\{2\}.$$

Es wird wieder  $\text{write}(a)$  mit  $\text{action}_1$  aufgerufen. Danach geht es weiter mit  $aa|\{q_0\}aaa$ ,  $aa|a\{1,2\}\{1,2\}aa$ ,  $aa|a\{1,2\}a\{2\}a$  und  $aa|a\{1,2\}aa\{2\}$ . Es wird wieder  $\text{write}(a)$  mit  $\text{action}_1$  aufgerufen. Die nächste Iteration ist  $aaa|\{q_0\}aa$ ,  $aaa|a\{1,2\}\{1,2\}a$  und  $aaa|a\{1,2\}a\{2\}$ . Da das Wortende erreicht wurde, rufen wir  $\text{write}(a)$  und  $\text{action}_1$  auf. Zuletzt werden noch  $aaaa|\{q_0\}a$  und  $aaaa|a\{1,2\}\{1,2\}$  durchlaufen, wonach wir wieder  $\text{write}(a)$  und  $\text{action}_1$  aufrufen.

Mit Reps' Algorithmus kürzen wir einige Schritte ab. Beim ersten Erreichen von  $\{2\}$  (kein Endzustand) sind wir in  $|a\{1,2\}aaaa\{2\}$ . Alle seit dem letzten Endzustand gesehenen Konfigurationen werden nun in  $\text{fv}$  eingetragen, also

$$|a\{1,2\}a\{2\}aaa, |a\{1,2\}aa\{2\}aa, |a\{1,2\}aaa\{2\}a \text{ und } |a\{1,2\}aaaa\{2\}.$$

Dabei spielen der Wert von  $s$ , also der Marker  $|$ , und die zuletzt gesehenen Endzustände keine Rolle und werden weggelassen. Wir haben also

$$\text{fv} = \{(\{2\}, 3), (\{2\}, 4), (\{2\}, 5), (\{2\}, 6)\}.$$

Im nächsten Durchlauf starten wir wieder in  $a|\{q_0\}aaaa$ . Nach zwei Schritten erreichen wir  $a|a\{1,2\}a\{2\}aa$ . Da  $(\{2\}, 4)$  in  $\text{fv}$  eingetragen wurde, brechen wir hier ab und es geht mit  $aa|\{q_0\}aaa$  weiter. Nach zwei Schritten erreichen wir  $aa|a\{1,2\}a\{2\}a$ . Da  $(\{2\}, 5)$  in  $\text{fv}$  eingetragen wurde, brechen wir auch hier ab. Wir starten nun in  $aaa|\{q_0\}aa$ . Nach zwei Schritten erreichen wir  $aaa|a\{1,2\}a\{2\}$ . An dieser Stelle brechen wir ohnehin ab, da wir das Wortende erreicht haben. Zuletzt starten wir in  $aaaa|\{q_0\}a$  und erreichen  $aaaa|a\{1,2\}\{1,2\}$ .