

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 empty , first , last und next ergibt sich:

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

¹weil $\text{empty}([2, a]^*) = t$

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

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

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

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

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 zunächst die Alphabetsymbole in last stehen lassen, ergibt sich eine leicht andere Definition der Endzustandsmengen F_i . 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

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

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 ℓ 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 $\text{fv} \subseteq Q' \times P_w$ 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 ist $\delta(\{q_0\}, a) = \{1, 2\}$, also wäre der nächste Zustand $|a\{1, 2\}aababa$. Dass $\{1, 2\}$ der zuletzt gesehene Endzustand ist, müssen wir allerdings auch noch markieren, was wir tun, indem wir $|a\{1, 2\}\{1, 2\}aababa$ schreiben, d.h. $\ell = (\{1, 2\}, 2)$. Es geht weiter mit

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

Da wir \emptyset erreicht haben, muss nun das Token zwischen $|$ und $\{3\}$ abgeschnitten werden. Wir rufen also $\text{write}(aaab)$ und action_2 auf, weil $\{3\} \in F_2$. Der nächste Zustand ist $aaab|\{q_0\}aba$. Es geht weiter mit

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

Wir rufen $\text{write}(ab)$ und action_2 auf und machen weiter mit $aaabab|\{q_0\}a$, gefolgt von $aaabab|a\{1, 2\}\{1, 2\}$. Weil hier das Wortende erreicht wurde und wir einen Endzustand gesehen haben, rufen wir $\text{write}(a)$ und action_1 auf, da $\{1, 2\} \in F_1$. 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 $|aaab\{3\}a\emptyset ba$. Die zuletzt gesehene Konfiguration, $|aaab\{3\}\{3\}aba$, ist in einem Endzustand, also wird nichts in fv eingetragen. Ebenso wird in $aaab|ab\{3\}a\emptyset$ und in $aaabab|a\{1, 2\}\{1, 2\}$ nichts in fv eingetragen.

(b) $w_2 = aaaaa$

Lösung:

Wir beginnen in $|\{q_0\}aaaaa$. Die folgenden Zustände sind

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

Es wird also $\text{write}(a)$ mit action_1 aufgerufen. Danach geht es weiter in $a|\{q_0\}aaaa$, gefolgt von

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

Es wird wieder $\text{write}(a)$ mit 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 $aa|a\{1,2\}aa\emptyset$. Es wird wieder $\text{write}(a)$ mit 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 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 action_1 aufrufen.

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

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

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

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

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 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 fv eingetragen wurde, brechen wir auch hier ab. Wir starten nun in $aaa|\{q_0\}aa$. Nach zwei Schritten erreichen wir $aaa|a\{1,2\}a\emptyset$. Zuletzt starten wir in $aaaa|\{q_0\}a$ und erreichen $aaaa|a\{1,2\}\{1,2\}$.