

Der Satz von Kleene

Prof. Dr. David Sabel

LFE Theoretische Informatik



Letzte Änderung der Folien: 17. Mai 2022

Zum Auffrischen: Beispiele

Geben Sie reguläre Ausdrücke an, welche die folgenden Sprachen erzeugen:

- $L_1 = \{\text{alle Wörter über } \{a, b\}, \text{ die das Teilwort } abba \text{ enthalten}\}$

$$(a|b)^*abba(a|b)^*$$

- $L_2 = \{\text{alle Wörter über } \{a, b\}, \text{ die das Teilwort } aba \text{ mindestens 2 Mal enthalten}\}$

$$((a|b)^*aba(a|b)^*aba(a|b)^* \mid (a|b)^*ababa(a|b)^*)$$

- $L_3 = \{\text{alle Wörter über } \{a, b\}, \text{ die das Teilwort } aaa \text{ nicht enthalten}\}$

$$(b|ab|aab)^*(\varepsilon|a|aa)$$

Wiederholung: Reguläre Ausdrücke

Definition (Regulärer Ausdruck)

Sei Σ ein Alphabet. Ein **regulärer Ausdruck** über Σ ist induktiv definiert:

- \emptyset ist ein regulärer Ausdruck
- ε ist ein regulärer Ausdruck
- a mit $a \in \Sigma$ ist ein regulärer Ausdruck
- Wenn α_1 und α_2 reguläre Ausdrücke sind, dann auch $\alpha_1\alpha_2$
- Wenn α_1 und α_2 reguläre Ausdrücke sind, dann auch $(\alpha_1|\alpha_2)$
- Wenn α regulärer Ausdruck ist, dann auch $(\alpha)^*$

Erzeugte Sprache

Die von einem regulären Ausdruck α **erzeugte Sprache** $L(\alpha)$ ist induktiv über dessen Struktur definiert:

$$\begin{aligned} L(\emptyset) &:= \emptyset \\ L(\varepsilon) &:= \{\varepsilon\} \\ L(a) &:= \{a\} \quad \text{für } a \in \Sigma \\ L(\alpha_1\alpha_2) &:= L(\alpha_1)L(\alpha_2) \\ &= \{uv \mid u \in L(\alpha_1), v \in L(\alpha_2)\} \\ L(\alpha_1|\alpha_2) &:= L(\alpha_1) \cup L(\alpha_2) \\ L((\alpha)^*) &:= L(\alpha)^* \end{aligned}$$

Satz von Kleene

Theorem 4.7.4 (Satz von Kleene)

Reguläre Ausdrücke erzeugen genau die regulären Sprachen.

Beweis in zwei Teilen:

- 1 Jede von einem regulären Ausdruck erzeugte Sprache ist regulär.
- 2 Für jede reguläre Sprache gibt es einen regulären Ausdruck, der sie erzeugt.

Beweis: Satz von Kleene (1)

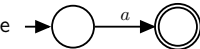


1. Jede von einem regulären Ausdruck erzeugte Sprache ist regulär.

Beweis:

- Wir konstruieren für regulären Ausdruck α einen NFA M_α mit ε -Übergängen und eindeutigen Start- und Endzuständen, sodass $L(M_\alpha) = L(\alpha)$.

- Induktion über die Struktur von α

- Basisfälle:

- Für $\alpha = a \in \Sigma$ konstruiere 
- Für $\alpha = \varepsilon$ konstruiere 
- Für $\alpha = \emptyset$ konstruiere 

In allen Fällen ist $L(\alpha) = L(M_\alpha)$ offensichtlich

Beweis: Satz von Kleene (2)

- Induktionsschritt: Betrachte den Aufbau von α (3 Fälle)

- Für $\alpha = \alpha_1\alpha_2$, liefert die I.H. $M_{\alpha_1}, M_{\alpha_2}$.




Konstruiere daraus M_α :




Beweis: Satz von Kleene (3)

- Für $\alpha = (\alpha_1|\alpha_2)$ liefert die I.H. $M_{\alpha_1}, M_{\alpha_2}$:



Konstruiere daraus M_α :




Beweis: Satz von Kleene (4)

- Für $\alpha = (\alpha_1)^*$ liefert die I.H. M_{α_1}



Konstruiere daraus M_α :




Einschub, Beispiel: Regulärer Ausdruck \rightarrow NFA mit ϵ -Übergängen

NFA zum regulären Ausdruck

$$(\epsilon|(a|b)^*b(a|b))$$

konstruieren:



Beweis: Satz von Kleene (5)

2. Für jede reg. Sprache L gibt es einen regulären Ausdruck α mit $L(\alpha) = L$

Beweis:

- Sei DFA $M = (\{z_1, \dots, z_n\}, \Sigma, \delta, z_1, E)$ mit $L(M) = L$ gegeben.
- Für $w \in \Sigma^*$ und z_i, z_j mit $\widehat{\delta}(z_i, w) = z_j$ sei $visit_i(w) = q_1, \dots, q_m$ die Folge der besuchten Zustände (wobei $q_1 = z_i$ und $q_m = z_j$).
- Wir definieren:

$$L_{i,j}^k = \left\{ w \in \Sigma^* \mid \begin{array}{l} \widehat{\delta}(z_i, w) = z_j \text{ und } visit_i(w) = q_1, \dots, q_m, \\ \text{so dass für } 1 < l < m: \text{ wenn } q_l = z_p \text{ dann } p \leq k \end{array} \right\}$$

$L_{i,j}^k$ enthält die Wörter, die M von Zustand z_i zu Zustand z_j führen ohne dabei Zwischenzustände mit Index größer als k zu benutzen.

- Mit Induktion über k zeigen wir:

Es gibt reguläre Ausdrücke $\alpha_{i,j}^k$ mit $L(\alpha_{i,j}^k) = L_{i,j}^k$.

Beweis: Satz von Kleene (6)

Zur Erinnerung: $L_{i,j}^k$ enthält die Wörter, die M von Zustand z_i zu Zustand z_j führen ohne dabei Zwischenzustände mit Index größer als k zu benutzen.

Basis: $k = 0$

- Wenn $i \neq j$, dann ist $L_{i,j}^0 = \{a \in \Sigma \mid \delta(z_i, a) = z_j\}$.
Falls $L_{i,j}^0 = \{a_1, \dots, a_q\}$, dann gilt $L(\alpha_{i,j}^0) = L_{i,j}^0$ für $\alpha_{i,j}^0 = (a_1 | \dots | a_q)$.
Falls $L_{i,j}^0 = \emptyset$, dann gilt $L(\alpha_{i,j}^0) = L_{i,j}^0$ mit $\alpha_{i,j}^0 = \emptyset$.
- Wenn $i = j$, dann ist $L_{i,i}^0 = \{\epsilon\} \cup \{a \in \Sigma \mid \delta(z_i, a) = z_i\}$.
Sei $L_{i,i}^0 = \{\epsilon, a_1, \dots, a_q\}$.
Dann gilt $L(\alpha_{i,i}^0) = L_{i,i}^0$ für $\alpha_{i,i}^0 = (\epsilon | a_1 | \dots | a_q)$.

Beweis: Satz von Kleene (7)

Zur Erinnerung: $L_{i,j}^k$ enthält die Wörter, die M von Zustand z_i zu Zustand z_j führen ohne dabei Zwischenzustände mit Index größer als k zu benutzen.

Induktionsschritt: $k \rightarrow k + 1$

$$L_{i,j}^{k+1} = L_{i,j}^k \cup L_{i,k+1}^k (L_{k+1,k+1}^k)^* L_{k+1,j}^k,$$

denn entweder läuft M ohne Zustand z_{k+1} zu besuchen, oder der Lauf kann in 3 Teile gespalten werden:

- 1 Lauf von z_i bis zum ersten Besuch des Zustands z_{k+1} (abgedeckt durch $L_{i,k+1}^k$)
- 2 Mehrmaliges, zyklisches Besuchen von $k + 1$ (beliebig oft) (abgedeckt durch $(L_{k+1,k+1}^k)^*$)
- 3 Letztmaliges Verlassen von z_{k+1} und Lauf bis zu z_j (abgedeckt durch $L_{k+1,j}^k$)

Daher gilt $\alpha_{i,j}^{k+1} = (\alpha_{i,j}^k | \alpha_{i,k+1}^k (\alpha_{k+1,k+1}^k)^* \alpha_{k+1,j}^k)$ und $L(\alpha_{i,j}^{k+1}) = L_{i,j}^{k+1}$.

Beweis: Satz von Kleene (8)

Zur Erinnerung: $L_{i,j}^k$ enthält die Wörter, die M von Zustand z_i zu Zustand z_j führen ohne dabei Zwischenzustände mit Index größer als k zu benutzen.

Damit haben wir bewiesen:


Es gibt reguläre Ausdrücke $\alpha_{i,j}^k$ mit $L(\alpha_{i,j}^k) = L_{i,j}^k$

Jetzt müssen wir noch zeigen, dass es einen regulären Ausdruck gibt, der $L(M)$ erzeugt.

Sei die Menge der Endzustände $E = \{z_{i_1}, \dots, z_{i_r}\}$.

Dann gilt $L(\alpha_{1,i_1}^n | \alpha_{1,i_2}^n | \dots | \alpha_{1,i_r}^n) = \bigcup_{z_i \in E} L_{1,i}^n = L(M)$ \square

Beispiel: DFA \rightarrow regulärer Ausdruck



Regulärer Ausdruck dazu:

$$\begin{aligned} \alpha_{1,2}^2 &= (\alpha_{1,2}^1 | \alpha_{1,2}^1 (\alpha_{2,2}^1)^* \alpha_{2,2}^1) \\ &= ((a | \varepsilon (\varepsilon)^* a) | (a | \varepsilon (\varepsilon)^* a) (\varepsilon | a (\varepsilon)^* a)^* (\varepsilon | a (\varepsilon)^* a)) \\ &= (a | a(aa)^*) \text{ (durch Vereinfachung)} \end{aligned}$$

denn

$$\begin{aligned} \alpha_{1,1}^0 &= \varepsilon & \alpha_{2,2}^0 &= \varepsilon & \alpha_{1,2}^0 &= a & \alpha_{2,1}^0 &= a \\ \alpha_{1,2}^1 &= (\alpha_{1,2}^0 | \alpha_{1,1}^0 (\alpha_{1,1}^0)^* \alpha_{1,2}^0) = (a | \varepsilon (\varepsilon)^* a) \\ \alpha_{2,2}^1 &= (\alpha_{2,2}^0 | \alpha_{2,1}^0 (\alpha_{1,1}^0)^* \alpha_{2,2}^0) = (\varepsilon | a (\varepsilon)^* a) \end{aligned}$$

Zusammenfassung: Formalismen für reguläre Sprachen

