

Reguläre Ausdrücke

Reguläre Ausdrücke

- ▶ Beschreibung regulärer Sprachen
- ▶ Anwendungsgebiete:
 - **Compilerbau**: Lexikalische Analyse, Eingabe für Scannergeneratoren
 - **Softwaretechnik**: Spezifikation zulässiger Eingaben für Dialogschnittstellen
 - **Suchbefehle**: Unix, Webbrowser
 - **Kontrollbedingungen, Ablaufspezifikationen**
 -

Definition

- I : endliches Alphabet mit $\lambda, \text{empty}, +, \circ, *, (,) \notin I$

Menge $REX(I)$ der regulären Ausdrücke über I

1. $\text{empty}, \lambda \in REX(I)$,
2. $I \subseteq REX(I)$,
3. für alle $r, r_1, r_2 \in REX(I)$ sind auch $(r_1 + r_2)$, $(r_1 \circ r_2)$ und (r^*) in $REX(I)$.

Sprache regulärer Ausdrücke

Jedem regulären Ausdruck r über I wird wie folgt eine Sprache $L(r)$ zugeordnet:

1. $L(\text{empty}) = \emptyset$, $L(\text{lambd}) = \{\lambda\}$ und $L(x) = \{x\}$ für alle $x \in I$,

2. für alle $r, r_1, r_2 \in REX(I)$

(a) $L((r_1 + r_2)) = L(r_1) \cup L(r_2)$,

(b) $L((r_1 \circ r_2)) = L(r_1)L(r_2)$,

(c) $L((r^*)) = L(r)^*$.

Klammerregeln/Vereinfachung

1. Der Operator $*$ bindet stärker als \circ ,
entsprechende Klammern dürfen entfallen
2. Der Operator \circ bindet stärker als $+$,
entsprechende Klammern dürfen entfallen
3. Der Operator \circ und $+$ sind assoziativ,
entsprechende Klammern dürfen entfallen
4. Der Operator \circ darf entfallen.

Rechenregeln

1. $empty \circ r = empty = r \circ empty$
2. $empty^* = lambda = lambda^*$
3. $lambda + r^* = r^*$, $lambda + r \circ r^* = r^*$
4. **Kommutativgesetz:** $r + t = t + r$
5. **Neutralität:** $r + empty = r = lambda \circ r = r \circ lambda$
6. **Assoziativgesetze:** $(r + s) + t = r + (s + t) = r + s + t$,
 $(r \circ s) \circ t = r \circ (s \circ t) = r \circ s \circ t = rst$
7. **Distributivgesetze:** $r(s + t) = rs + rt$, $(s + t)r = sr + tr$
8. **Idempotenz:** $(r^*)^* = r^*$, $r + r = r$

Vereinfachung eines regulären Ausdrucks

Beispiel

$$\begin{aligned} ((b^*) + ((b^*) \circ (a \circ (a^*)))) &= (b^*) + ((b^*) \circ (a \circ (a^*))) = \\ b^* + (b^* \circ (a \circ a^*)) &= b^* + (b^* \circ a \circ a^*) = b^* + b^* \circ a \circ a^* \\ = b^* + b^*aa^* &= b^* \circ \text{lambda} + b^*aa^* = b^* \circ (\text{lambda} + \\ aa^*) &= b^*(a^*) = b^*a^* \end{aligned}$$

Sprache eines regulären Ausdrucks

Beispiel

$$\begin{aligned}L(b^* + b^*aa^*) &= L(b^*) \cup L(b^*aa^*) \\ &= L(b)^* \cup L(b^*)L(aa^*) \\ &= \{b\}^* \cup L(b)^*L(a)L(a^*) \\ &= \{b\}^* \cup \{b\}^*\{a\}L(a)^* \\ &= \{b\}^* \cup \{b\}^*\{a\}\{a\}^* \\ &= \{b\}^*(\{\lambda\} \cup \{a\}\{a\}^*) \\ &= \{b\}^*\{a\}^* = \{b^m a^n \mid m, n \in \mathbb{N}\} \\ &= \{w \in \{a, b, \}^* \mid ab \text{ ist kein Teilwort} \\ &\quad \text{von } w\}\end{aligned}$$

Satz

1. Jeder reguläre Ausdruck r definiert eine reguläre Sprache, d.h. $L(r) \in \mathcal{L}_{REG(I)}$.
2. Jede reguläre Sprache $L \in \mathcal{L}_{REG(I)}$ lässt sich durch einen regulären Ausdruck beschreiben, d.h. es existiert ein regulärer Ausdruck r mit $L(r) = L$.

Schlussfolgerung

- ▶ Endliche Automaten erkennen genau die Klasse der regulären Sprachen.
- ▶ Reguläre Ausdrücke beschreiben genau die Klasse der regulären Sprachen.

$$\mathcal{L}_{REG(I)} = \mathcal{L}_{REX(I)} = \mathcal{L}_{AUT(I)}$$

mit $\mathcal{L}_{REX(I)} = \{L(r) \mid r \in REX(I)\}$

und $\mathcal{L}_{AUT(I)} = \{L(A) \mid A \text{ ist ein endlicher Automat}\}$