

Einführung in die Computerlinguistik

Reguläre Ausdrücke und reguläre Grammatiken

Laura Kallmeyer

Heinrich-Heine-Universität Düsseldorf

Summer 2018



Regular expressions (1)

Let Σ be an alphabet. The set of **regular expressions over Σ** is recursively defined:

- \emptyset is a regular expression denoting the set \emptyset .
- ϵ is a regular expression denoting the set $\{\epsilon\}$.
- For each $a \in \Sigma$: a is a regular expression denoting $\{a\}$.
- If r and s are regular expressions denoting R and S , then $(r|s)$, (rs) and (r^*) are also regular expressions denoting $R \cup S$, $R \circ S$ and R^* respectively.

Assume that $*$ has a higher priority than concatenation which in turn has a higher priority than $|$.

a^+ is an abbreviation for aa^* .

Regular expressions (2)

Bsp.:

- $\varepsilon|a$ denotiert $\{\varepsilon\} \cup \{a\} = \{a, \varepsilon\}$.
- εa denotiert $\{\varepsilon\} \circ \{a\} = \{a\}$.
- $\emptyset|a$ denotiert $\emptyset \cup \{a\} = \{a\}$.
- $\emptyset a$ denotiert $\emptyset \circ \{a\} = \emptyset$.
- cc^* denotiert die Menge aller Wörter über $\{c\}$, deren Länge ≥ 1 ist.
- $(cc)^*$ denotiert die Menge aller Wörter über $\{c\}$, deren Länge eine gerade Zahl ist.

Regular expressions (3)

- $(a|\varepsilon)bcc^*$ denotiert $\{bc, abc, bcc, abcc, bccc, abccc, \dots\} = \{a^n bc^m \mid 0 \leq n \leq 1, m \geq 1\}$
- $((a|b)^*|de)^*$ denotiert $\{w_1 \dots w_n \mid n \geq 0, \text{jedes } w_i \text{ für } 1 \leq i \leq n \text{ ist entweder aus } \{a, b\}^* \text{ oder hat die Form } (de)^k \text{ für irgendein } k \geq 0\}$
⇒ die Sprache ist die Menge aller Wörter über den Alphabet $\{a, b, d, e\}$, in denen jedes d notwendig von einem e gefolgt ist.
Äquivalent: $(a|b|de)^*$
- $a(bd^+b)^*a$ denotiert die Menge aller Wörter der Form awa , wobei $w = \varepsilon$ oder $w = bw'b$ und es gilt, dass $w' \in \{b, d\}^*$ mit d anfängt und endet und dass in w' jede Gruppe von bs genau die Länge 2 hat.

Regular expressions (4)

The following holds:

For each language L : there is a regular expression x with $L = L(x)$ iff there is a FSA M with $L = L(M)$.

In order to show this, we

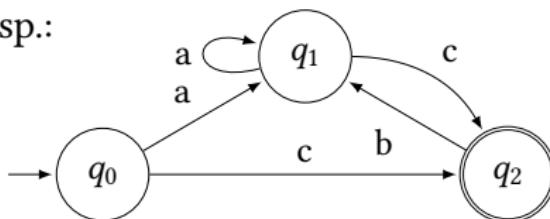
- ① define NFAs with empty transitions and show their equivalence to NFAs;
- ② show how to construct an equivalent NFA with empty transitions for a given regular expression;
- ③ show how to construct an equivalent regular expression for a given DFA.

Zu 1. und 2. siehe Vorlesung “Mathematische Grundlagen der Computerlinguistik”.

DFA and regular expressions (1)

For each DFA, there is an equivalent regular expression.

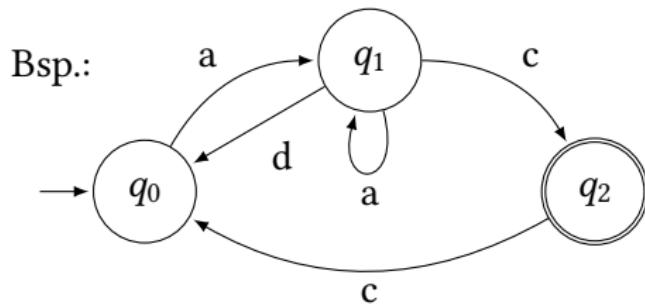
Bsp.:



Um von q_0 zu q_2 zu gelangen, kann man entweder

- (1) einen Weg **ohne Unterwegszustand q_1** wählen. Dies kann wiederum entweder **ohne Durchlauf von q_1** sein (c) oder ein **erstes Mal von q_0 zu q_1** (a), dann **beliebig oft von q_1 zu q_1 ohne Durchlauf von q_1** (a^*), dann **von q_1 nach q_2** (c) $\Rightarrow (c|a^+c)$, oder
- (2) man geht **ein erstes Mal von q_0 zu q_2** ($c|a^+c$) und dann **beliebig oft von q_2 zu q_2 ohne Durchlauf von q_2** ($(ba^*c)^*$).
 $\Rightarrow (c|a^+c)(ba^*c)^*$

DFAs and regular expressions (2)



| | |
|--------------------------------------|-------------------------------------|
| von q_0 nach q_2 ohne q_1, q_2 | \emptyset |
| von q_0 nach q_1 ohne q_1, q_2 | a |
| von q_1 nach q_1 ohne q_1, q_2 | $a da$ |
| von q_1 nach q_2 ohne q_1, q_2 | c |
| von q_0 nach q_2 ohne q_2 | $\emptyset a(a da)^*c = a(a da)^*c$ |
| von q_2 nach q_2 ohne q_2 | $ca(a da)^*c$ |
| von q_0 nach q_2 | $a(a da)^*c(ca(a da)^*c)^*$ |

DFA and regular expressions (3)

Algorithm for construction the regular expression for a given DFA:
Assume that $\{q_1, \dots, q_n\}$ is the set of states.

Define $R_{i,j}^k$ as the set of sequences of input symbols that can be obtained from following all paths from q_i to q_j that do not pass through states q_l with $l > k$.

Question: What do the $R_{i,j}^k$ look like and what are the corresponding regular expressions $r_{i,j}^k$?

- $k = 0$: Only paths of length 0 or 1 can be considered, since, between q_i and q_j , no other states q_l are possible.
Each $r_{i,j}^0$ has the form $a_1|a_2|\cdots|a_m$ or (if $i = j$) $a_1|a_2|\cdots|a_m|\epsilon$ or (if $i \neq j$ and there is no edge from q_i to q_j) \emptyset .

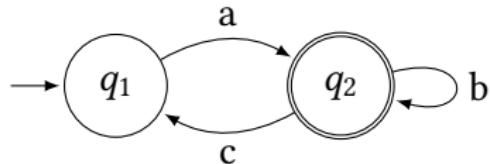
DFA and regular expressions (4)

- In general, R_{ij}^k contains
 - all elements from R_{ij}^{k-1} ,
 - all concatenations of
 - a) an element from R_{ik}^{k-1} ,
 - b) any number (including 0) of elements from R_{kk}^{k-1} and
 - c) an element from R_{kj}^{k-1} .

$$\text{Consequently, } r_{i,j}^k = r_{ij}^{k-1} | r_{ik}^{k-1} (r_{kk}^{k-1})^* r_{kj}^{k-1}.$$

Finally, the regular expression for the language accepted by the automaton is $r_{1f_1}^n | r_{1f_2}^n | \cdots | r_{1f_m}^n$ if $F = \{q_{f_1}, \dots, q_{f_m}\}$.

DFA and regular expressions (5)



$$r_{12}^2 = r_{12}^1 | r_{12}^1 (r_{22}^1)^* r_{22}^1$$

$$\begin{aligned} r_{12}^1 &= r_{12}^0 | r_{11}^0 (r_{11}^0)^* r_{12}^0 \\ &= a | \epsilon (\epsilon^*) a = a \end{aligned}$$

$$\begin{aligned} r_{22}^1 &= r_{22}^0 | r_{21}^0 (r_{11}^0)^* r_{12}^0 \\ &= (b | \epsilon) | c (\epsilon)^* a = \epsilon | b | ca \end{aligned}$$

$$r_{12}^2 = a | a (\epsilon | b | ca)^+ = a (\epsilon | b | ca)^* = a (b | ca)^*$$

Abschlusseigenschaften regulärer Sprachen (1)

Die von regulären Ausdrücken denotierten Sprachen heißen reguläre Sprachen.

- ① Wenn L_1 und L_2 reguläre Sprachen sind, dann
 - ist die Vereinigung von L_1 und L_2 ($L_1 \cup L_2$) ebenfalls eine reguläre Sprache.
 - ist die Schnittmenge von L_1 und L_2 ($L_1 \cap L_2$) ebenfalls eine reguläre Sprache.
 - ist die Konkatenation von L_1 und L_2 ($L_1 \circ L_2$) ebenfalls eine reguläre Sprache.
- ② Das Komplement einer regulären Sprache ist eine reguläre Sprache.
- ③ Wenn L eine reguläre Sprache, dann ist L^* eine reguläre Sprache.

Abschlusseigenschaften regulärer Sprachen (2)

Für Vereinigung, Konkatenation und L^* kann man ganz einfach die entsprechenden regulären Ausdrücke angeben:

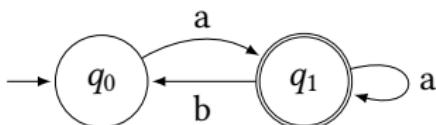
Seien r_1 und r_2 reguläre Ausdrücke mit $L_1 = L(r_1)$ und $L_2 = L(r_2)$. Dann gilt

- $L(r_1|r_2) = L_1 \cup L_2$
- $L(r_1r_2) = L_1 \circ L_2$
- $L(r_1^*) = L_1^*$

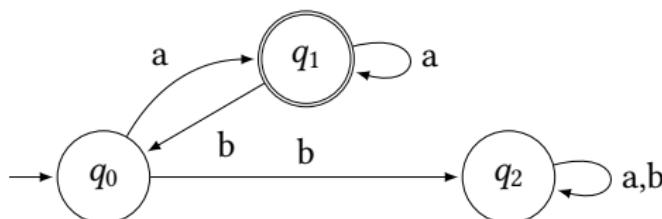
Abschlusseigenschaften regulärer Sprachen (3)

Für die Komplementbildung nimmt man den DFA, der die Sprache erkennt, macht die Übergangsfunktion vollständig, indem man einen weiteren Zustand (*trap state*) hinzufügt, und wählt als neue Endzustände alle Zustände, die im Ursprungsautomaten kein Endzustand sind.

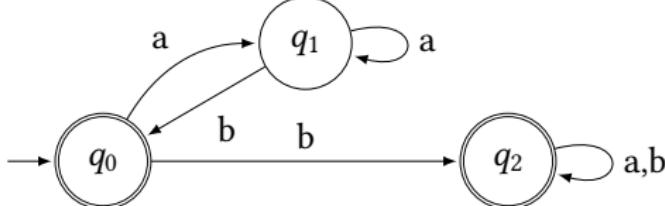
Bsp.:



Trap state:



Komplementbildung:



Abschlusseigenschaften regulärer Sprachen (4)

Schnittbildung kann (de Morgan) durch Vereinigung und Komplementbildung ausgedrückt werden:

$$L_1 \cap L_2 = \overline{\overline{L_1} \cap \overline{L_2}} = \overline{\overline{L_1} \cup \overline{L_2}}$$

Damit ist $L_1 \cap L_2$ eine reguläre Sprache, falls L_1 und L_2 regulär sind.

Regular Grammars (1)

Another way to define a language is via a grammar. A **grammar formalism** defines the form of rules and combination operations allowed in a grammar.

A **context-free grammar (CFG)** G is a tuple $\langle N, T, P, S \rangle$ with

- N and T disjoint alphabets, the nonterminals and terminals,
- $S \in N$ the start symbol, and
- P a set of productions of the form $A \rightarrow \alpha$ with $A \in N, \alpha \in (N \cup T)^*$.

Regular Grammars (2)

Let $G = \langle N, T, P, S \rangle$ be a CFG. The (*string*) *language* $L(G)$ of G is the set $\{w \in T^* \mid S \xrightarrow{*} w\}$ where

- for $w, w' \in (N \cup T)^*$: $w \Rightarrow w'$ iff there is a $A \rightarrow \alpha \in P$ and there are $v, u \in (N \cup T)^*$ such that $w = vAu$ and $w' = v\alpha u$.
- $\xrightarrow{*}$ is the reflexive transitive closure of \Rightarrow :
 - $w \xrightarrow{0} w$ for all $w \in (N \cup T)^*$, and
 - for all $w, w' \in (N \cup T)^*$: $w \xrightarrow{n} w'$ iff there is a v such that $w \Rightarrow v$ and $v \xrightarrow{n-1} w'$.
 - for all $w, w' \in (N \cup T)^*$: $w \xrightarrow{*} w'$ iff there is a $i \in \mathbb{N}$ such that $w \xrightarrow{i} w'$.

A language is called a **context-free language (CFL)** iff it is generated by a CFG.

Regular Grammars (3)

A CFG is called

- **right-linear** iff for all productions $A \rightarrow \beta$: $\beta \in T^*$ or $\beta = \beta'X$ with $\beta' \in T^*, X \in N$.
- **left-linear** iff for all productions $A \rightarrow \beta$: $\beta \in T^*$ or $\beta = X\beta'$ with $\beta' \in T^*, X \in N$.
- **regular** if it is left-linear or right-linear.

For each left-linear grammar there is an equivalent right-linear grammar and vice versa.

Regular Grammars (4)

Some examples: A CFG $G = \langle \{S, A, B\}, \{a, b, c\}, P, S \rangle$

- ① with $P = \{S \rightarrow abS \mid cA, A \rightarrow bB, B \rightarrow cbB \mid \varepsilon\}$ is right-linear.
It generates the language $L((ab)^*cb(cb)^*)$.
- ② with $P = \{S \rightarrow Sa \mid Sb \mid Abc, A \rightarrow B, B \rightarrow Bcb \mid \varepsilon\}$ is left-linear.
It generates the language $L((cb)^*bc(a|b)^*)$.
- ③ with $P = \{S \rightarrow abSA \mid c, A \rightarrow b\}$ is not regular.
It generates the language $\{(ab)^n cb^n \mid n \geq 0\}$.

Regular Grammars (5)

The following holds:

$L = L(G)$ for a regular grammar G iff L is a regular set (i.e., can be described by a regular expression).

To show this, we show that

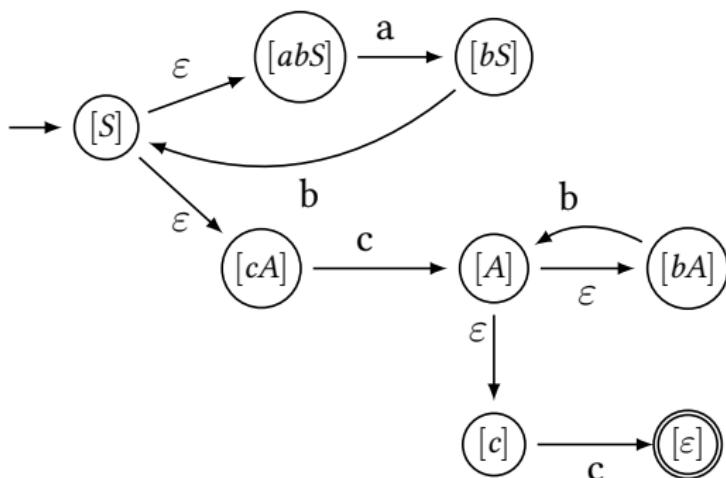
- for each right-linear grammar, there exists an equivalent NFA;
and
- for each DFA, there is an equivalent right-linear grammar.

Regular Grammars (6)

Example: NFA with empty transitions for a given right-linear grammar.

$G = \langle \{S, A\}, \{a, b, c\}, P, S \rangle$ with $P = \{S \rightarrow abS \mid cA, A \rightarrow bA \mid c\}$

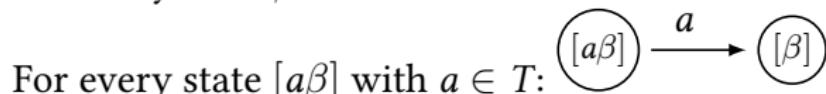
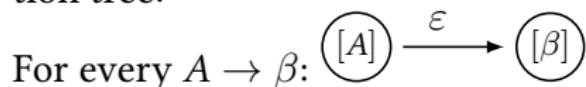
Corresponding NFA:



Regular Grammars (7)

Construction of equivalent NFA (with empty transitions) for given right-linear G :

- Start state $[S]$.
- For all productions $A \rightarrow \beta_1\beta_2$ there is a state $[\beta_2]$.
- Transitions simulate top-down left-to-right traversal of derivation tree:



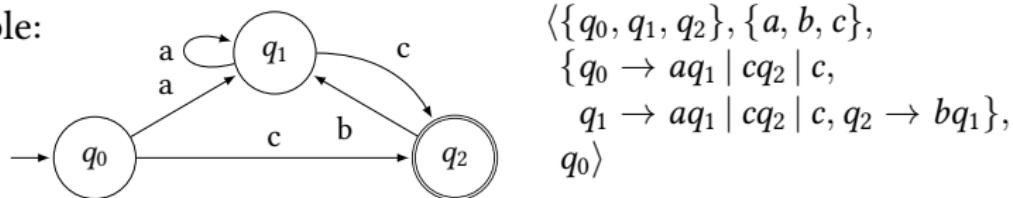
- Final state is $[\epsilon]$.

Regular Grammars (8)

Construction of a right-linear grammar for given DFA:

- The states are the nonterminals.
- The start state is the start symbol.
- For each transition $\overset{a}{\rightarrow}$ add a production $Q \rightarrow aQ'$ and, if $Q' \in F$, a production $Q \rightarrow a$.
- If the start state Q_0 is a final state, then add $Q_0 \rightarrow \varepsilon$

Example:

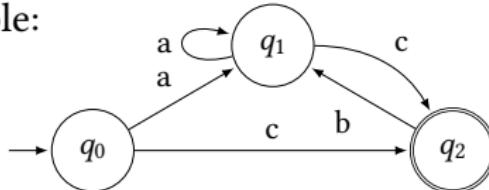


Regular Grammars (9)

For a left-linear grammar, we have to follow the transitions in the opposite direction.

- The nonterminals are $Q \cup \{S\}$ where S is a new start symbol.
- $q_0 \rightarrow \varepsilon$ where q_0 is the DFA's start state and $S \rightarrow q_f$ for all $q_f \in F$.
- For each transition $\overset{a}{\circlearrowleft} q \rightarrow q'$ we add $q' \rightarrow qa$.

Example:


$$\langle \{q_0, q_1, q_2, S\}, \{a, b, c\}, \{S \rightarrow q_2, q_0 \rightarrow \varepsilon, q_2 \rightarrow q_1 c \mid q_0 b, q_1 \rightarrow q_1 a \mid q_0 a \mid q_2 b\}, S \rangle$$