

# Einführung in die Computerlinguistik

## Reguläre Ausdrücke und reguläre Grammatiken

Laura Kallmeyer  
 Heinrich-Heine-Universität Düsseldorf  
 Sommersemester 2013

### Regular expressions (1)

Let  $\Sigma$  be an alphabet. The set of regular expressions over  $\Sigma$  is recursively defined:

- $\emptyset$  is a regular expression denoting the set  $\emptyset$ .
- $\epsilon$  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  $aa^*$ .

### Overview

1. Regular expressions
2. Regular expressions and NFA
3. Closure properties of regular languages
4. Regular grammars

### Regular expressions (2)

Bsp.:

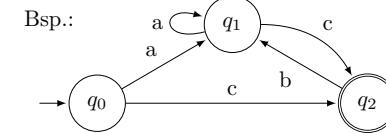
- $\epsilon|a$  denotiert  $\{\epsilon\} \cup \{a\} = \{a, \epsilon\}$ .
- $\epsilon a$  denotiert  $\{\epsilon\} \circ \{a\} = \{a\}$ .
- $\emptyset|a$  denotiert  $\emptyset \cup \{a\} = \{a\}$ .
- $\emptyset a$  denotiert  $\emptyset \circ \{a\} = \emptyset$ .
- $cc^*$  denotiert die Menge aller Wörter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

**Regular expressions (3)**

- $(a|\varepsilon)bcc^*$  denotiert  
 $\{bc, abc, bcc, abcc, bccc, \dots\} = \{a^nbc^m \mid 0 \leq n \leq 1, m \geq 1\}$
- $((a|b)^*|de)^*$  denotiert  $\{w_1 \dots w_n \mid n \geq \varepsilon, \text{jedes der } w_i \text{ für } 1 \leq i \leq n \text{ ist entweder aus } \{a,b\}^* \text{ oder hat die Form } (de)^k \text{ für irgendein } k \geq 0\}$   
 ⇒ 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.

**DFAs and regular expressions (1)**

For each DFA, there is an equivalent regular expression.



Um von  $q_0$  zu  $q_2$  zu gelangen, kann man entweder

- (1) einen Weg ohne Unterwegszustand  $q_2$  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  $q_2$  ( $c$ ) ⇒  $(c|a^+c)$ , 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  $q_2$  ( $(ba^*c)^*$ ).  
 ⇒  $(c|a^+c)(ba^*c)^*$

**Regular expressions (4)**

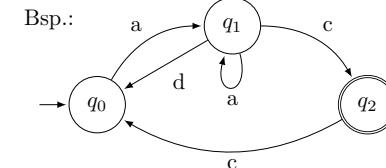
The following holds:

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".

**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 $q_2$	$a(a da)^*c(ca(a da)^*c)^*$

**DFAs and regular expressions (3)**

Algorithm for construction the regular expression for a given DFA:

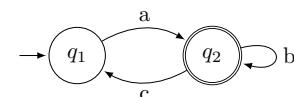
Assume that  $\{q_1, \dots, q_n\}$  it the set of states.

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  $a_1|a_2|\dots|a_m$  or (if  $i = j$ )  $a_1|a_2|\dots|a_m|\epsilon$  or (if  $i \neq j$  and there is no edge from  $q_i$  to  $q_j$ )  $\emptyset$ .

**DFAs and regular expressions (5)**

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

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

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

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

**DFAs 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  $R_{kj}^{k-1}$ .

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

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

**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.

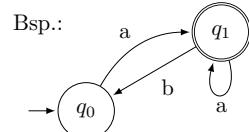
Für die Komplementbildung nimmt man den DFA, der die Sprache erkennt, macht die Übergangsfunktion vollständig, indem man einen weiteren Zustand (*trap state*) hinzufügt, und wählt als neue Endzustände alle Zustände, die im Ursprungsautomaten kein Endzustand sind.

**Abschlusseigenschaften regulärer Sprachen (4)**

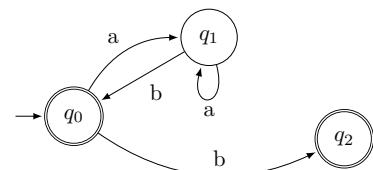
Schmittbildung kann (de Morgan) durch Vereinigung und Komplementbildung ausgedrückt werden:

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

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

**Abschlusseigenschaften regulärer Sprachen (3)**

Komplementbildung:

**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 (4)

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 (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 (5)

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:

For every  $A \rightarrow \beta$ :

For every state  $[a\beta]$  with  $a \in T$ :

- Final state is  $[\epsilon]$ .

**Regular Grammars (6)**

Construction of a right-linear grammar for given DFA:

- The states are the nonterminals.
- The start state is the start symbol.
- For each transition  $(Q \xrightarrow{a} Q')$   
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  $Q_0 \rightarrow \varepsilon$

If we construct the right-linear grammar for  $L^R$  ( $L$  reversed) and we mirror all right-hand sides of productions, we obtain a left-linear grammar for  $L$ .