


# Einführung in die Computerlinguistik Zwischenklausur

Laura Kallmeyer

Heinrich-Heine-Universität Düsseldorf

Erlaubte Hilfsmittel: Eine Din-A4 Seite mit Notizen.

**Aufgabe 1** Betrachten Sie den folgenden DFA:



1. Woran erkennt man, dass der Automat deterministisch ist?
2. Geben Sie den Automaten in Tupelschreibweise an. D.h., als Tupel  $\langle Q, \Sigma, \delta, q_0, F \rangle$ .
3. In welchem Zustand befindet sich der Automat nach den folgenden Übergängen?  
(a)  $\delta(q_1, a)$     (b)  $\hat{\delta}(q_2, ac)$     (c)  $\hat{\delta}(\delta(q_0, a), ba)$
4. Geben Sie einen regulären Ausdruck für die Sprache an, die von dem Automaten akzeptiert wird.

Lösung:


1. Kein Zustand hat mehr als eine ausgehende Kante mit gleichem Eingabesymbol. 1
2.  $\langle \{q_0, q_1, q_2, q_3\}, \{a, b, c\}, \delta, q_0, \{q_3\} \rangle$  mit  
 $\delta(q_0, a) = q_0, \delta(q_0, b) = q_1, \delta(q_0, c) = q_2, \delta(q_1, a) = q_3, \delta(q_2, a) = q_3, \delta(q_3, b) = q_1, \delta(q_3, c) = q_2$ .  
Für alle anderen Paare ist  $\delta$  nicht definiert. 4
3. (a)  $\delta(q_1, a) = q_3$     (b)  $\hat{\delta}(q_2, ac) = q_2$     (c)  $\hat{\delta}(\delta(q_0, a), ba) = q_3$  4
4.  $a^*(b|c)(a(b|c))^*a$  4

**Aufgabe 2** Betrachten Sie nochmals den DFA aus der vorhergehenden Aufgabe.

Minimieren Sie den Automaten. Geben Sie dabei die Ergebnisse der einzelnen Schritte (Automat mit trap state, Matrix, minimierter Automat) an.

Lösung:

Automat mit Trap State:




$|Q| \times |x|Q|$ -Matrix:

	0	1	2	3
4	X	X	X	X
3	X	X	X	
2	X			
1	X			

2  
3

Entferne anschließend wieder den überflüssige Trap State. Minimierter Automat ( $q_1$  und  $q_2$  sind äquivalent):



3

**Aufgabe 3** Welche Sprachen werden von den folgenden regulären Ausdrücken denotiert?

- (a)  $ab|c\emptyset$     (b)  $a(b|c)\emptyset$     (c)  $ab|c\varepsilon$     (d)  $a(b|c)\varepsilon$     (e)  $a(b^+|c^+)^*$

Lösung:

- (a)  $L(ab|c\emptyset) = \{ab\}$     (b)  $L(a(b|c)\emptyset) = \emptyset$     (c)  $L(ab|c\varepsilon) = \{ab, c\}$     (d)  $L(a(b|c)\varepsilon) = \{ab, ac\}$   
 (e)  $L(a(b^+|c^+)^*) = \{aw \mid w \text{ ist eine beliebige (eventuell leere) Folge von } bs \text{ und } cs\}$

6

**Aufgabe 4** Betrachten Sie folgende Grammatik:  $G = \langle \{S, A\}, \{a, b, c\}, P, S \rangle$  mit folgenden Produktionen in  $P$ :  $S \rightarrow bS, S \rightarrow cS, S \rightarrow aA, A \rightarrow a$

1. Handelt es sich um eine reguläre Grammatik? Begründen Sie Ihre Antwort.
2. Welche Sprache wird von dieser Grammatik erzeugt?
3. Geben Sie eine rechtslineare Grammatik für die Sprache  $L(a^*(b|c)dd)$  an.

Lösung:


1. Ja, da alle rechten Seiten von Produktionen höchstens ein Nichtterminales enthalten, das immer am Ende steht. Die Grammatik ist also rechtslinear und damit regulär.
2.  $L((b|c)^*aa)$

2  
3

3. Grammatik:  $\langle \{S, A\}, \{a, b\}, P, S \rangle$  mit folgenden Produktionen in  $P$ :  
 $S \rightarrow aS, S \rightarrow bA, S \rightarrow cA, A \rightarrow dd$

3

**Aufgabe 5** Betrachten Sie den folgenden DFA:



Geben Sie eine rechtslineare Grammatik an, die genau die Sprache generiert, die von diesem Automaten akzeptiert wird.

Lösung:  $G = \langle \{Q_0, Q_1, Q_2\}, \{a, b, c\}, P, Q_0 \rangle$  mit folgenden Produktionen in  $P$ :

$$\begin{aligned} Q_0 &\rightarrow aQ_0 & Q_0 &\rightarrow bQ_1 & Q_0 &\rightarrow b & Q_1 &\rightarrow aQ_0 & Q_1 &\rightarrow bQ_2 \\ Q_1 &\rightarrow b & Q_2 &\rightarrow cQ_2 & Q_2 &\rightarrow c & Q_2 &\rightarrow aQ_1 & Q_2 &\rightarrow a \end{aligned}$$

6

**Aufgabe 6** Nehmen Sie an, Sie haben einen HMM-POS Tagger, unter anderem mit folgenden Wahrscheinlichkeiten:

Emissionswahrscheinlichkeiten:

$$\begin{aligned} P(a|Det) &= 6 \cdot 10^{-3} & P(try|N) &= 2 \cdot 10^{-3} & P(drink|N) &= 3 \cdot 10^{-3} \\ P(try|V) &= 5 \cdot 10^{-3} & P(drink|V) &= 2 \cdot 10^{-3} \end{aligned}$$

Alle anderen Emissionswahrscheinlichkeiten für try, a und drink seien 0.

Übergangswahrscheinlichkeiten sind (unter anderem):

$$P(Det|V) = 2 \cdot 10^{-1} \quad P(Det|N) = 1 \cdot 10^{-1} \quad P(N|Det) = 3 \cdot 10^{-1} \quad P(V|Det) = 1 \cdot 10^{-1}$$

Die Wahrscheinlichkeiten, dass der Satz mit einem V eingeleitet wird, ist  $8 \cdot 10^{-1}$ , und mit einem N  $2 \cdot 10^{-1}$ . Die Wahrscheinlichkeit, dass auf ein N oder V ein Satzende folgt, ist jeweils  $0.1 = 1 \cdot 10^{-1}$ .

- Geben Sie die Viterbi Matrix an, die sich bei diesen Wahrscheinlichkeiten für die Eingabe try a drink ergibt. Es reicht, die Einträge anzugeben, die  $\neq 0$  sind. Geben Sie für jedes Feld Ihren Rechenweg an.
- Was ist die beste POS-TAG Sequenz, die sich als Ergebnis für try a drink ergibt?

Lösung:

$q_F$				$432 \cdot 10^{-12}, N$
Det		$48 \cdot 10^{-7}, V$		
V	$4 \cdot 10^{-3}, q_0$		$96 \cdot 10^{-11}, Det$	
N	$4 \cdot 10^{-4}, q_0$		$432 \cdot 10^{-11}, Det$	
	1	2	3	
	try	a	drink	

$$\text{try, V: } 8 \cdot 10^{-1} \cdot 5 \cdot 10^{-3} = 40 \cdot 10^{-4} = 4 \cdot 10^{-3}$$

$$\text{try, N: } 2 \cdot 10^{-1} \cdot 2 \cdot 10^{-3} = 4 \cdot 10^{-4}$$

$$\text{a, Det: } \max\{4 \cdot 10^{-3} \cdot 2 \cdot 10^{-1} \cdot 6 \cdot 10^{-3} \text{ (Vorgänger V)}, 4 \cdot 10^{-4} \cdot 1 \cdot 10^{-1} \cdot 6 \cdot 10^{-3} \text{ (Vorgänger N)}\} = 48 \cdot 10^{-7} \text{ (Vorgänger V)}$$

$$\text{drink, V: } 48 \cdot 10^{-7} \cdot 1 \cdot 10^{-1} \cdot 2 \cdot 10^{-3} = 96 \cdot 10^{-11}$$

$$\text{drink, N: } 48 \cdot 10^{-7} \cdot 3 \cdot 10^{-1} \cdot 3 \cdot 10^{-3} = 432 \cdot 10^{-11}$$

$$q_F: \max\{96 \cdot 10^{-10} \cdot 1 \cdot 10^{-1} \text{ (Vorgänger V)}, 432 \cdot 10^{-10} \cdot 1 \cdot 10^{-1} \text{ (Vorgänger N)}\}$$

8

- Die beste POS-TAG Folge ist V Det N.

1