


Einführung in die Computerlinguistik Zwischenklausur

Laura Kallmeyer

Heinrich-Heine-Universität Düsseldorf

Erlaubte Hilfsmittel: Eine Din-A4 Seite mit Notizen.

Aufgabe 1 (4 Pkte) Betrachten Sie den folgenden NFA:




1. Ist dieser Automat ein DFA, also deterministisch? Begründen Sie Ihre Antwort.
2. δ sei die Übergangsfunktion dieses Automaten. Berechnen Sie:
 - (i) $\delta(q_0, c)$
 - (ii) $\delta(q_3, b)$
3. $\hat{\delta}$ sei die reflexive transitive Hülle von δ wie in der Vorlesung definiert. Berechnen Sie die folgenden Werte:
 - (i) $\hat{\delta}(q_0, \varepsilon)$
 - (ii) $\hat{\delta}(q_1, ac)$
 - (iii) $\hat{\delta}(q_1, aaca)$

Lösung:


1. Nein, da z.B. q_3 zwei ausgehende Kanten mit gleichem Label (nämlich a) hat. 1 Pkt
2. (i) $\delta(q_0, c) = \{q_2, q_3\}$ (ii) $\delta(q_3, b) = \emptyset$ 1 Pkt
3. (i) $\hat{\delta}(q_0, \varepsilon) = \{q_0\}$ (ii) $\hat{\delta}(q_1, ac) = \emptyset$ (iii) $\hat{\delta}(q_1, aaca) = \{q_2, q_4\}$ 2 Pkte

Aufgabe 2 (5 Pkte) Betrachten Sie nun den folgenden NFA:




Konstruieren Sie einen äquivalenten DFA.

Lösung:



Aufgabe 3 (6 Pkte) Betrachten Sie nun den folgenden DFA.




Minimieren Sie diesen DFA, indem Sie die entsprechende 3×3 Matrix angeben und anschließend äquivalente Zustände zusammenfassen. Geben Sie die Matrix und den resultierenden minimierten Automaten an.

Lösung

| | 0 | 1 | 2 |
|---|---|---|---|
| 3 | x | x | |
| 2 | x | x | |
| 1 | | | |

4 Pkte



2 Pkte

Aufgabe 4 (5+5 Pkte)

1. Welche Sprache wird jeweils von den folgenden regulären Ausdrücken denotiert?

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

2. Geben Sie für jede der folgenden Sprachen einen regulären Ausdruck an, der diese denotiert.


- (a) $\{a, \varepsilon\}$
 (b) $\{w \in \{a, b\}^* \mid w \text{ hat eine Länge } \geq 2\}$
 (c) $\{w \in \{a, b\}^* \mid \text{es dürfen keine zwei oder mehr } b \text{ hintereinander stehen ohne } a \text{ dazwischen}\}$

Lösung:

1. (a) $L(b|\varepsilon) = \{b, \varepsilon\}$ 1 Pkt
 (b) $L((c|ab|b)^+) = \{w \in \{a, b, c\}^+ \mid \text{jedes } a \text{ in } w \text{ ist notwendig von einem } b \text{ gefolgt}\}$ 2 Pkte
 (c) $L(((\varepsilon|a)b|(\varepsilon|\emptyset)c)^+) = L((c|ab|b)^+)$ 2 Pkte
2. (a) $(a|\varepsilon)$ 1 Pkt
 (b) $(a|b)(a|b)^+$ 1 Pkt
 (c) $(a|ba)^*(\varepsilon|b)$ 3 Pkte

Aufgabe 5 (8 Pkte)

Betrachten Sie nun den folgenden DFA:




1. Berechnen Sie den regulären Ausdruck, der die von diesem Automaten akzeptierte Sprache charakterisiert. Wenden Sie den Algorithmus aus der Vorlesung an, indem Sie rekursiv den Ausdruck $r_{1,2}^2$ berechnen. Die Formel hierzu ist $r_{1,2}^2 = r_{1,2}^1 | r_{1,2}^1 (r_{2,2}^1)^* r_{1,2}^1$.
2. Geben Sie eine rechtslineare Grammatik an, die genau die Sprache erzeugt, die von diesem Automaten akzeptiert wird.

Lösung:

1. $r_{1,2}^2 = r_{1,2}^1 | r_{1,2}^1 (r_{2,2}^1)^* r_{1,2}^1$
 $r_{1,2}^1 = r_{1,2}^0 | r_{1,1}^0 (r_{1,1}^0)^* r_{1,2}^0 = b | (a|\varepsilon)^+ b = a^+ b | b = a^* b$ 2 Pkte
 $r_{2,2}^1 = r_{2,2}^0 | r_{2,1}^0 (r_{1,1}^0)^* r_{2,2}^0 = (b|\varepsilon) | c (a|\varepsilon)^* b = \varepsilon | b | c a^* b$ 2 Pkte
 $r_{1,2}^2 = a^* b | a^* b (\varepsilon | b | c a^* b)^+ = a^* b (\varepsilon | b | c a^* b)^* = a^* b (b | c a^* b)^*$ 1 Pkt
2. $G = \langle \{S, A\}, \{a, b, c\}, P, S \rangle$ mit folgenden Produktionen in P :
 $S \rightarrow aS | bA, A \rightarrow cS | bA | \varepsilon$ 3 Pkte

Aufgabe 6 (3 Pkte) Betrachten Sie folgenden FST:



1. Worauf bilden der Automat die Eingaben bab und $aabbab$ ab?
2. Welche Eingabewörter akzeptiert der Automat und wie transformiert er sie?

Lösung:

1. Die Bilder sind bab und $bbab$. 1 Pkt
2. Der Automat akzeptiert beliebige Folgen von as und bs , die mindestens ein b enthalten.
 Er löscht am Wortanfang alle as , ab dem ersten Auftreten eines bs wird die Eingabe unverändert in die Ausgabe kopiert. 2 Pkte

Aufgabe 7 (6 Pkte)

Nehmen Sie an, wir wollen ein Bigram-Sprachmodell mit Laplace-Smoothing erstellen. Unsere Trainingsdaten sind die folgenden zwei Sätze:

$\langle s \rangle a a b a b \langle /s \rangle$
 $\langle s \rangle a a b b b b a a b \langle /s \rangle$

1. Wie sehen die folgenden Bigram-Wahrscheinlichkeiten in diesem Modell aus?
 (a) $P(a|\langle s \rangle)$ (b) $P(b|a)$ (b) $P(a|b)$ (b) $P(\langle /s \rangle|a)$
2. Wie ist die Wahrscheinlichkeit und die Perplexity des folgenden Eingabesatzes?

$\langle s \rangle a b a \langle /s \rangle$

(Die Berechnung muss angegeben werden, der Wert muss jedoch nicht ausgerechnet werden.)

Lösung:

1. (a) $P(a|\langle s \rangle) = \frac{3}{5}$ (b) $P(b|a) = \frac{5}{10} = \frac{1}{2}$ (b) $P(a|b) = \frac{3}{10}$ (b) $P(\langle /s \rangle|a) = \frac{1}{10}$
 4 Pkte

2. Wahrscheinlichkeit $\frac{3}{5} \cdot \frac{1}{2} \cdot \frac{3}{10} \cdot \frac{1}{10} = 9 \cdot 10^{-3} = 0.009$ 1 Pkt

Perplexity $\sqrt[4]{\frac{1000}{9}}$ 1 Pkt

Aufgabe 8 (8 Pkte)

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

Emissionswahrscheinlichkeiten:

$$P(\text{the}|\text{Det}) = 1 \quad P(\text{end}|N) = 2 \cdot 10^{-3} \quad P(\text{walks}|N) = 1 \cdot 10^{-3}$$

$$P(\text{end}|V) = 1 \cdot 10^{-3} \quad P(\text{walks}|V) = 3 \cdot 10^{-3}$$

Alle anderen Emissionswahrscheinlichkeiten für end, the und walks seien 0.

Übergangswahrscheinlichkeiten:

$$P(N|\text{Det}) = 5 \cdot 10^{-1} \quad P(N|N) = 1 \cdot 10^{-1} \quad P(N|V) = 2 \cdot 10^{-1}$$

$$P(V|\text{Det}) = 1 \cdot 10^{-1} \quad P(V|N) = 4 \cdot 10^{-1} \quad P(V|V) = 2 \cdot 10^{-1}$$

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

Angenommen, die Wahrscheinlichkeit, dass ein V am Satzanfang steht, ist $3 \cdot 10^{-1}$, die, dass ein N am Satzanfang steht, ist $2 \cdot 10^{-1}$ und die, dass ein Det am Satzanfang steht, ist $4 \cdot 10^{-1}$.

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 end the walks 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 end the walks ergibt?

Lösung:

| | | | | |
|--------|------------------------|----------------------|--------------------------------|----------------------|
| q_F | | | | $3 \cdot 10^{-9}, N$ |
| N | $4 \cdot 10^{-4}, q_0$ | | $3 \cdot 10^{-8}, \text{Det}$ | |
| V | $3 \cdot 10^{-4}, q_0$ | | $18 \cdot 10^{-9}, \text{Det}$ | |
| 1. Det | | $6 \cdot 10^{-5}, V$ | | |
| | 1 end | 2 the | 3 walks | |

end, N: $P(\text{end}|N) \cdot 2 \cdot 10^{-1} = 2 \cdot 10^{-3} \cdot 2 \cdot 10^{-1}$ 1 Pkt

end, V: $P(\text{end}|V) \cdot 3 \cdot 10^{-1} = 1 \cdot 10^{-3} \cdot 3 \cdot 10^{-1}$ 1 Pkt

the, Det: $\max\{4 \cdot 10^{-4} \cdot 1 \cdot 10^{-1} \cdot 1 \text{ Vorgänger N}, 3 \cdot 10^{-4} \cdot 2 \cdot 10^{-1} \cdot 1 \text{ Vorgänger V}\}$ 2 Pkte

walks, N: $6 \cdot 10^{-5} \cdot 5 \cdot 10^{-1} \cdot 1 \cdot 10^{-3}$ 1 Pkt

walks, V: $6 \cdot 10^{-5} \cdot 1 \cdot 10^{-1} \cdot 3 \cdot 10^{-3}$ 1 Pkt

q_F : $\max\{3 \cdot 10^{-8} \cdot 1 \cdot 10^{-1} \text{ Vorgänger N}, 18 \cdot 10^{-9} \cdot 1 \cdot 10^{-1} \text{ Vorgänger V}\}$ 1 Pkt

2. Die beste POS-Tag Folge ist demnach V Det N. 1 Pkt