

## Musterlösung zur Klausur vom 19. Oktober 2002

### Aufgabe 1

Geben Sie für  $n \geq 5$  die Wahrscheinlichkeit  $p_n(n, 5)$  an, daß bei gleichverteiltem Hashing von  $n$  Schlüsseln in  $n$  Zellen in der ersten Zelle genau 5 Schlüssel zu liegen kommen.

$$\begin{aligned} p_n(n, 5) &= \binom{n}{5} p^5 (1-p)^{n-5} \quad \text{nach Bernoulli, mit } p = \frac{1}{n} \\ &= \binom{n}{5} \frac{1}{n^5} \cdot \frac{(n-1)^{n-5}}{n^{n-5}} = \binom{n}{5} \frac{(n-1)^{n-5}}{n^n} \end{aligned}$$

(Anmerkung: Statt "in der ersten Zelle" hätte es auch heißen können "in einer bestimmten Zelle", da wir es mit gleichverteiltem Hashing zu tun haben; die Nummer der Zelle geht nicht in die Rechnung ein.)

5 Punkte

## Aufgabe 2

- a) Zeigen Sie, daß der Einheitswürfel  $W = [0, 1]^3$  eine rationale Menge im  $\mathbb{R}^3$  ist, indem Sie ihn in die Standardform für rationale Mengen überführen.

Sei ein Vektor im  $\mathbb{R}^3$  bestehend aus den Komponenten  
$$X = \begin{pmatrix} x \\ y \\ z \end{pmatrix}. \text{ Dann ist}$$

$$W = \{ X \in \mathbb{R}^3 \mid B_1(X) \geq 0 \wedge B_2(X) \geq 0 \wedge B_3(X) \geq 0 \wedge \\ B_4(X) \geq 0 \wedge B_5(X) \geq 0 \wedge B_6(X) \geq 0 \}$$

mit

$$B_1(X) = x \quad \text{und} \quad B_2(X) = 1-x \quad \text{wegen} \quad 0 \leq x \leq 1$$

$$B_3(X) = y \quad \text{und} \quad B_4(X) = 1-y \quad \text{wegen} \quad 0 \leq y \leq 1$$

$$B_5(X) = z \quad \text{und} \quad B_6(X) = 1-z \quad \text{wegen} \quad 0 \leq z \leq 1$$

(4 Punkte)

- b) Definieren Sie im  $\mathbb{R}^3$  eine rationale Menge mit unendlich vielen Elementen, die dünn ist. Begründen Sie alle drei Eigenschaften kurz.

$$M = \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathbb{R}^3 \mid z = 0 \right\}$$

- $|M| = \infty$ , denn  $M$  ist eine (Hyper-)Ebene.
- $M$  ist rational, denn  $B_1(X) = z \geq 0$  und  $B_2(X) = -z \geq 0$ .
- Keine  $\varepsilon$ -Kugel paßt in  $M$ , denn die Kugel hat (für  $\varepsilon > 0$ ) auch eine  $z$ -Ausdehnung; also ist  $M$  dünn.

(Anmerkung: Jedes ein- oder zweidimensionale Artefakt im  $\mathbb{R}^3$  ist hier geeignet, beispielsweise die Gerade  $M = \{ (x \ y \ z)^\top \in \mathbb{R}^3 \mid x = y = 0 \}$ .)

(3 Punkte)

7 Punkte

### Aufgabe 3

Skizzieren Sie ein neuronales Netz, bestehend aus nur einem Neuron, das die logische Funktion

$$f(A, B, C) = (A \vee B) \wedge (B \vee C) \wedge (C \vee A)$$


realisiert. Geben Sie die Gewichte  $w_A, w_B, w_C$  der Eingaben sowie den Schwellwert  $\Theta$  des Neurons an, wenn sowohl für die Eingaben als auch für die Ausgabe gilt

$$\text{TRUE} \equiv 1 \quad \text{und} \quad \text{FALSE} \equiv 0$$

(Das Neuron sei dabei folgendermaßen beschaffen: ist die gewichtete Summe der Eingaben  $w_A A + w_B B + w_C C$  größer als der Schwellwert  $\Theta$ , so sei die Ausgabe Eins; ist  $w_A A + w_B B + w_C C < \Theta$ , so sei die Ausgabe Null; andernfalls ist die Ausgabe als undefiniert anzusehen!)

$A$	$B$	$C$	$f$	$A + B + C$
0	0	0	0	0
0	0	1	0	1
0	1	0	0	1
0	1	1	1	2
1	0	0	0	1
1	0	1	1	2
1	1	0	1	2
1	1	1	1	3

Wie aus der Tabelle zu ersehen ist, ist  $f$  genau dann TRUE (also Eins), wenn  $A + B + C \geq 2$ . Setze also alle Gewichte  $w_A = w_B = w_C := 1$  und die Schwelle auf  $\Theta := 1\frac{1}{2}$ .




(Anmerkungen: Natürlich funktioniert das ganze auch mit jeder anderen Zahl  $w_A = w_B = w_C := w > 0$ ; für den Schwellwert muß dann gelten  $w < \Theta < 2w$ . Anstatt der Wertetabelle hätte man auch mit De Morgan die Formel umformen können in  $f = (A \wedge B) \vee (B \wedge C) \vee (C \wedge A)$ ; hier kann quasi direkt die Schwelle abgelesen werden.)

8 Punkte

### Aufgabe 4

Betrachten Sie den Editierabstand von Zeichenketten, wenn als einzige Elementaroperation das Zeichen-Löschen (*delete*) erlaubt ist. Um also den Abstand der beiden Zeichenketten zu bestimmen, sollen möglichst wenige Zeichen in den Zeichenketten gelöscht werden, um Gleichheit der beiden übrigbleibenden Zeichenketten zu erreichen.

- a) Mit Hilfe einer  $m \times n$ -Matrix soll der Editierabstand zweier Zeichenketten  $v$  und  $w$  mit  $m$  bzw.  $n$  Buchstaben bestimmt werden. Geben Sie ein Schema an, nach dem ein Matrixelement  $(i, j)$  aus benachbarten Matrixelementen ermittelt werden kann.



Mit  $a = M(i, j - 1)$ ,  $b = M(i - 1, j - 1)$ ,  $c = M(i - 1, j)$  und

$$b' = \begin{cases} b & \Leftarrow \text{gleiches Zeichen übernehmen} \Leftarrow v[i] = w[j] \\ b + 2 & \Leftarrow \text{in } v \text{ und } w \text{ löschen} \Leftarrow v[i] \neq w[j] \end{cases}$$

ist

$$d = M(i, j) = \min \left\{ \underbrace{a + 1}_{\text{1 Zeichen in } w \text{ löschen}}, b', \underbrace{c + 1}_{\text{1 Zeichen in } v \text{ löschen}} \right\}$$

(4 Punkte)

b) Bestimmen Sie den Editierabstand zwischen ABAABB und ABBAB:

		A	A	B	B	A	B
	0	1	2	3	4	5	6
A	1	<b>0</b>	<b>1</b>	2	3	<b>4</b>	5
B	2	1	2	<b>1</b>	<b>2</b>	3	<b>4</b>
A	3	<b>2</b>	<b>1</b>	2	3	<b>2</b>	3
A	4	<b>3</b>	<b>2</b>	3	4	<b>3</b>	4
B	5	4	3	<b>2</b>	<b>3</b>	4	<b>3</b>
B	6	5	4	<b>3</b>	<b>2</b>	3	<b>4</b>

Das Endergebnis lautet also: 4 Editieroperationen.

(4 Punkte)

8 Punkte

### Aufgabe 5


Die Zeichenkette **BANANARAMA** soll mithilfe eines (speziell für die darin vorkommenden Zeichen **A,B,M,N,R** zu bestimmenden) binären Huffman-Kodes platzsparend kodiert werden.

- a) Bestimmen Sie für jedes dieser Zeichen eine solche Kodierung.

Häufigkeitstabelle:

A	B	M	N	R	$\Sigma$
5	1	1	2	1	10

Daraus läßt sich z. B. der folgende Huffman-Kodierungsbaum – bottom-up – erhalten, indem sukzessiv die am seltensten vorkommenden Zeichen bzw. Unterbäume (gegeneinander mit “0” und “1”) kodiert werden:



Demnach wäre ein Huffman-Kode also

A	B	M	N	R
0	101	110	100	111

(6 Punkte)

- b) Wie viele Bits enthält die Kodierung der Zeichenkette **BANANARAMA** demnach?

Die Kodierung von **BANANARAMA** wäre gemäß (a) die Bitfolge **10101000100011101100**, welche genau 20 Bits enthält.

(Anmerkung: Dieses Ergebnis ist eindeutig bestimmt, insbesondere unabhängig vom verwendeten Huffmankode. So gibt es auch Codes, die den Buchstaben **N** mit nur 2 Bits kodieren, dafür aber zwei der Buchstaben **B,M,R** mit 4 Bits.)

(2 Punkte)

- c) Bestimmen Sie die absolute Redundanz der Kodierung, indem Sie (nach Shannon) die Realinformation  $H$  der ursprünglichen Zeichenkette mit der Nominalinformation/Kodelänge  $\tilde{H}$  ihrer binären Kodierung verrechnen.  
Eine Tabelle für die numerischen Werte von  $-p \cdot \log p$  finden Sie im Anhang.

$$\tilde{H} = 20 \text{ bit} \quad (\text{siehe (b)})$$

$$H = 10 \cdot H\left(\frac{5}{10}, \frac{1}{10}, \frac{1}{10}, \frac{2}{10}, \frac{1}{10}\right) \quad \leftarrow \text{ in den Klammern die } p_i$$

$$= 10 \cdot \sum_i -p_i \log p_i$$

$$= 10 \cdot (0,500 + 3 \cdot 0,332 + 0,464) \quad - \text{ siehe Tabelle -}$$

$$= 10 \cdot 1,960 \quad \text{leicht schriftlich zu berechnen ...}$$

$$= 19,6 \text{ bit}$$

Die (absolute) Redundanz berechnet sich als Differenz aus Nominal- und Realinformation zu

$$\begin{aligned} R &= \tilde{H} - H \\ &= 20 \text{ bit} - 19,6 \text{ bit} \end{aligned}$$

$$\approx \frac{1}{2} \text{ bit}$$

(7 Punkte)

15 Punkte

### Aufgabe 6

Kodieren Sie die Zeichenkette ABACDBEACDFGDBEACDFG nach dem Lempel-Ziv-Welch-Verfahren (LZW).

- a) Lassen Sie dabei die neuen Wörterbuch-Einträge bei Kodenummer 256 anfangen.

Eingabe	Ausgabe	Wörterbuch
A	A	AB 256
B	B	BA 257
A	A	AC 258
C	C	CD 259
D	D	DB 260
B	B	BE 261
E	E	EA 262
A	258	ACD 263
C		
D	D	DF 264
⋮	⋮	⋮

⋮	⋮	⋮
F	F	FG 265
G	G	GD 266
D	260	DBE 267
B		
E	262	EAC 268
A		
C	259	CDF 269
D		
F	265	
G		
Eingabe	Ausgabe	Wörterbuch

(5 Punkte)

- b) Wieviel Byte werden eingespart, wenn die nichtkomprimierte Zeichenkette mit 8 bit/Zeichen und die komprimierte mit 9 bit/Ausgabezeichen dargestellt wird?

$$\text{unkodiert: } 8 \cdot 20 = 160 \text{ bit}$$

$$\text{kodiert: } 9 \cdot 15 = 135 \text{ bit}$$

25 bit gespart

$$\text{Also } \left\lfloor \frac{25}{8} \right\rfloor = 3 \text{ Byte gespart}$$

(2 Punkte)

7 Punkte

## Aufgabe 7

Kreuzen Sie für folgende Aussagen an, ob diese wahr oder falsch sind.

**Hinweis:** Für jede richtige Antwort gibt es einen Punkt, für jede falsche Antwort wird ein Punkt abgezogen. Die gesamte Aufgabe wird mit einer nichtnegativen Punktezahl gewertet.

<i>Aussage</i>	<i>Antwort</i>
Die Vereinigung zweier rationaler Dünn-Mengen ist stets in einer rationalen Dünn-Menge enthalten.	<b>wahr</b>
Zweidimensionale Zellraster sind ungeeignet, um sämtliche Berührungs- und Schnittpunkte von $n$ Strecken in der Ebene zu bestimmen.	<b>falsch</b>
Linear verkettete AVL-Bäume sind sehr gut geeignet, um Dateien index-sequentiell zu organisieren und auf Platten zu speichern (ISAM-Dateiorganisation).	<b>falsch</b>
Invertierte Dateien erlauben eine schnelle Suche nach beliebig vorgegebenen Suchbegriffen.	<b>wahr</b>
Udi Manbers Technik <i>Glimpse</i> ist eine der besten Methoden, um eine Suchmaschine für das Internet zu implementieren.	<b>falsch</b>
Ein störungsfreier Kanal ist deterministisch, aber eventuell verlustbehaftet.	<b>falsch</b>
Die im Beweis zum Shannonschen Fundamentalsatz der Informationstheorie vorkommenden Mengen $A$ der typischen Input-Output-Paare sind stets von endlicher Mächtigkeit.	<b>wahr</b>
Es gibt optimale Codes (variabler Länge), die eindeutig entzifferbar, aber nicht sofort entzifferbar sind.	<b>wahr</b>
Eine nicht komprimierte Computeranimation von 1 Minute Laufzeit kann 2 Gigabyte Speicher benötigen, wenn sie im Standardformat von 768·576 Pixel pro Bild aufgezeichnet wird.	<b>wahr</b>
Polynome in Stützstellendarstellung können nicht schneller als mit FFT ( <i>Fast Fourier Transform</i> ) multipliziert werden.	<b>falsch</b>

10 Punkte

## Konzeptpapier

### Logarithmentabelle (zu Aufgabe 5)

$p$	$-p \cdot \log_2 p$
0	0,000
1/10	0,332
2/10	0,464
3/10	0,521
4/10	0,529
5/10	0,500
6/10	0,442
7/10	0,360
8/10	0,258
9/10	0,137
1	0,000