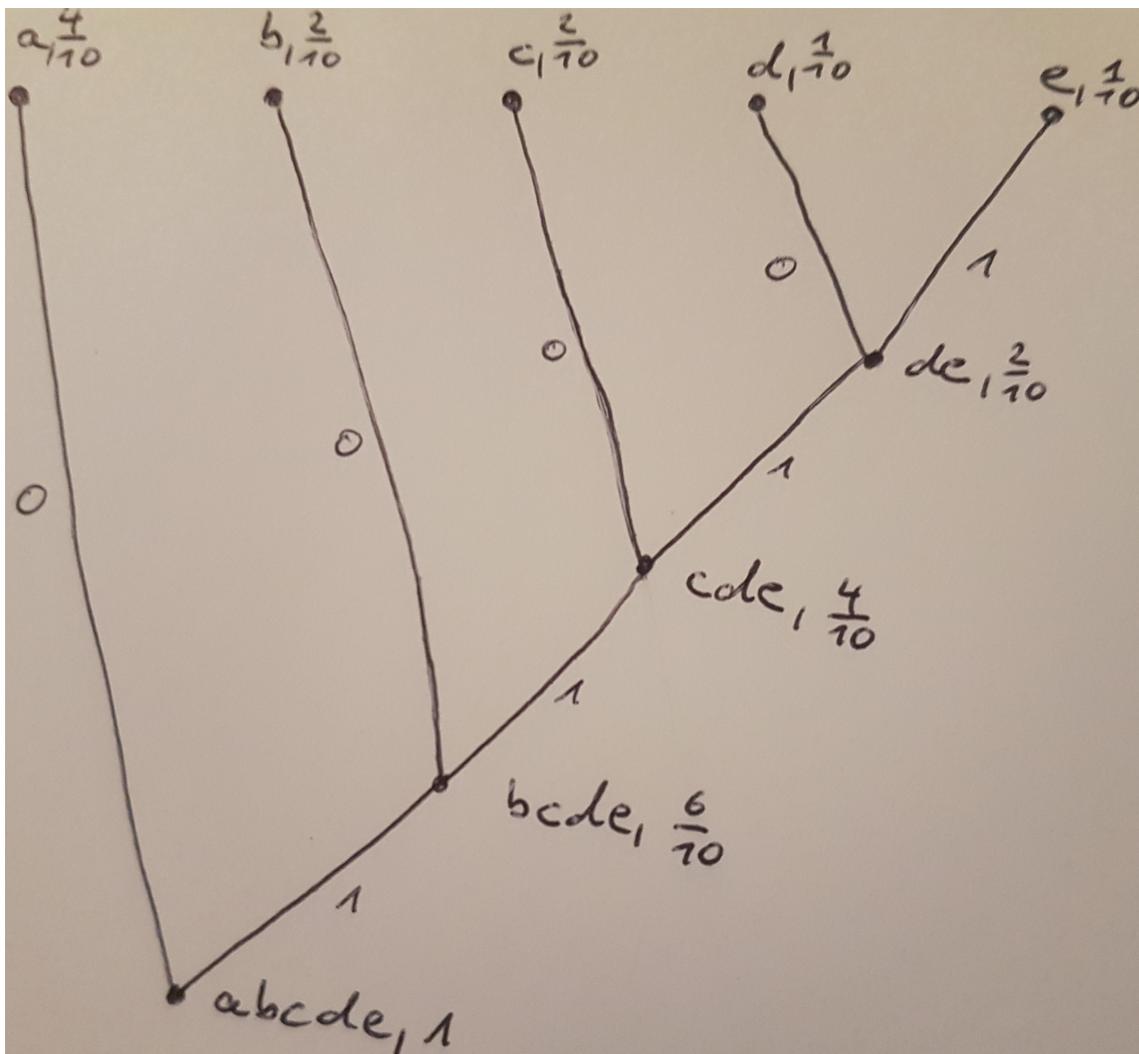


## Übungsblatt 2

Auf dem gesamten Übungszettel behandeln wir die Begriffe (binärer) Wurzelbaum und Präfixcode als Synonyme. Dies ist durch Blatt 1 Aufgabe 3 gerechtfertigt.

**Aufgabe 1.** Kodieren Sie mit Huffman eine Quelle mit Wahrscheinlichkeitsverteilung  $p = (0.4, 0.2, 0.2, 0.1, 0.1)$ .

Sei  $X = \{a, b, c, d, e\}$  eine Quelle mit  $p(a) = 0.4$ ,  $p(b) = p(c) = 0.2$  und  $p(d) = p(e) = 0.1$ . Eine Huffman Kodierung dieser lautet  $a \mapsto 0$ ,  $b \mapsto 10$ ,  $c \mapsto 110$ ,  $d \mapsto 1110$  und  $e \mapsto 1111$ , wobei der dazugehörige gewichtete Wurzelbaum wie folgt aussieht.



**Aufgabe 2.** Zeigen Sie  $\bar{L}(C_{i-1}) = \bar{L}(C_i) + h_{i-1}$ , wobei  $h_{i-1}$  die Summe zweier minimaler Wahrscheinlichkeiten der Quelle  $X_{i-1}$  ist.

*Beweis.* Seien, wie auf dem Aufgabenzettel beschrieben,  $T_i$  die Wurzelbäume assoziiert zu den Codes  $C_i$  für  $1 \leq i \leq n$ . Diese lassen sich auf natürliche Weise wie folgt ineinander einbetten. Es gilt

$$T_n \hookrightarrow T_{n-1} \hookrightarrow \dots \hookrightarrow T_1,$$

wobei  $T_n$  die Wurzel der  $T_i$  für  $1 \leq i \leq n$  und  $T_1$  der Wurzelbaum einer Huffman Kodierung ist. Bezeichne mit  $B_i$  die Menge der Blätter des Wurzelbaumes  $T_i$  für  $1 \leq i \leq n$ . Beachte, dass die obige Wahrscheinlichkeitsverteilung  $p$  von der Quelle  $X_i$  abhängt. Aus Gründen der Übersichtlichkeit ignoriert unsere Notation diesen Fakt.

Nach Konstruktion gibt es eindeutige  $c \in B_i$  und  $c_1, c_2 \in B_{i-1}$  mit  $p(c) = p(c_1) + p(c_2)$  und  $B_i \setminus \{c\} = B_{i-1} \setminus \{c_1, c_2\}$  für alle  $2 \leq i \leq n$ . Bemerke, dass die Summe zweier minimaler Wahrscheinlichkeiten  $h_{i-1} = p(c) = p(c_1) + p(c_2)$  ist. Wir erhalten somit

$$\begin{aligned} \bar{L}(C_{i-1}) &= \sum_{x \in B_{i-1}} p(x)\ell(x) \\ &= \sum_{x \in B_i \setminus \{c\}} p(x)\ell(x) + p(c_1)\ell(c_1) + p(c_2)\ell(c_2) \\ &= \sum_{x \in B_i \setminus \{c\}} p(x)\ell(x) + p(c_1)(\ell(c) + 1) + p(c_2)(\ell(c) + 1) \\ &= \sum_{x \in B_i} p(x)\ell(x) + p(c_1) + p(c_2) \\ &= \bar{L}(C_i) + h_{i-1}. \end{aligned}$$

□

**Bemerkung.** Wir bezeichnen den Schritt, beschrieben auf dem Aufgabenzettel, der aus dem Code  $C_i$  den Code  $C_{i-1}$  erzeugt, mit **Huffman-Schritt**.

**Lemma.** Seien  $n \geq 2$  und  $X_1 = \{x_1, \dots, x_n\}$  eine  $n$ -elementige Quelle mit Wahrscheinlichkeitsverteilung  $p$  und nehme o.E. an, dass  $p(x_1) \geq p(x_2) \geq \dots \geq p(x_n)$ . Sei nun  $C_2$  ein optimaler Code der Quelle  $X_2 = \{x_1, \dots, x_{n-2}, x_{n-1}x_n\}$  mit Wahrscheinlichkeitsverteilung  $p'(x_i) = p(x_i)$  für  $1 \leq i \leq n-2$  und  $p'(x_{n-1}x_n) = p(x_{n-1}) + p(x_n)$ . So ist der Code  $C_1$  der Quelle  $X_1$  mit Wahrscheinlichkeitsverteilung  $p$ , der durch einen Huffman-Schritt entsteht, optimal.

*Beweis.* Sei  $A_1$  ein optimaler Code der Quelle  $X_1$  mit Wahrscheinlichkeitsverteilung  $p$ . Wegen der Optimalität gilt folgende Aussage. Für je zwei Blätter  $x, y$  von  $A_1$  mit  $l(x) \geq l(y)$  gilt  $p(x) \leq p(y)$ . (Wenn dem nicht so ist, so tausche einfach im entsprechenden Baum  $x$  und  $y$ . Dies liefert einen kleineren Wert für  $\bar{L}$ ). Mit anderen Worten, Blätter kurzer Pfade haben hohe Wahrscheinlichkeiten, wobei Blätter langer Pfade niedrige Wahrscheinlichkeiten haben.

Sei  $c_1 \in X_1$  ein Blatt von  $A_1$  maximaler Länge. So existiert wegen der Optimalität von  $A_1$  ein weiteres Blatt  $c_2$  mit demselben Vorgänger. Da die Längen von  $c_1$  und  $c_2$  maximal sind, sind ihre Wahrscheinlichkeiten minimal, d.h.  $p(c_1) = p(x_n)$  und  $p(c_2) = p(x_{n-1})$ . Wir können ohne Einschränkung annehmen, dass  $c_1 = x_n$  und  $c_2 = x_{n-1}$ , denn Blätter derselben Wahrscheinlichkeit dürfen im Baum getauscht werden und dabei bleibt die Optimalität des Codes erhalten. Sei nun  $A_2$  der Code auf  $X_2$  bzgl.  $p'$ , der aus  $A_1$  mittels eines Huffman-Schritts, der  $x_{n-1}$  und  $x_n$  zusammenlegt, entstanden ist. So gilt nach Aufgabe 2

$$\bar{L}(A_1) - \bar{L}(A_2) = p(x_{n-1}) + p(x_n) = \bar{L}(C_1) - \bar{L}(C_2),$$

was zu

$$\bar{L}(A_1) - \bar{L}(C_1) = \bar{L}(A_2) - \bar{L}(C_2)$$

äquivalent ist.

Da  $A_2$  und  $C_2$  Codes auf der Quelle  $X_2$  bzgl.  $p'$  sind, folgt aus der Optimalität von  $C_2$ , dass  $\bar{L}(C_2) \leq \bar{L}(A_2)$ . Somit erhalten wir

$$\bar{L}(A_1) - \bar{L}(C_1) = \bar{L}(A_2) - \bar{L}(C_2) \geq 0.$$

Also gilt  $\bar{L}(A_1) \geq \bar{L}(C_1)$ , d.h.  $C_1$  ist optimal. □

**Aufgabe 3.** Zeigen Sie, dass im Huffman-Code, die im  $i$ -ten Schritt entstandene Quelle  $X_i$ , durch  $C_i$  optimal kodiert ist.

*Beweis.* Wir beweisen die Aussage per vollständiger Induktion nach  $i$ . Sei zunächst  $i = n = |X| = |X_1|$ , so besteht der Code  $C_i$  nur aus einem Wort und somit ist  $\bar{L}(C_i) = 0$  minimal. Sei nun  $1 < i < n$ , so ist nach Induktionsvoraussetzung  $C_i$  ein optimaler Code. Da  $C_{i-1}$  durch einen Huffman-Schritt aus  $C_i$  entstanden ist, ist  $C_{i-1}$  nach obigen Lemma optimal.  $\square$

**Aufgabe 4.** Es sei  $p$  die Wahrscheinlichkeitsverteilung auf den Quellen  $A$  und es sei  $|A| = r$ . Zeigen Sie

- (a)  $H(p) \leq \log_2(r)$  und
- (b)  $H(p)$  ist maximal, falls  $p$  die Gleichverteilung ist.

*Beweis.* (a)

**Lemma** (Vorlesung: Lemma (2.3)). *Seien  $s_1, \dots, s_r, y_1, \dots, y_r$  positive reelle Zahlen, so gilt für  $q \geq 2$*

$$0 \leq \sum_{i=1}^r y_i \log_q \left( \frac{y_i}{s_i} \right)$$

*und genau dann Gleichheit, wenn  $s_i = y_i$  für alle  $1 \leq i \leq r$ .*

Seien ohne Einschränkung  $p_i = 0$  für alle  $k+1 \leq i \leq r$  für ein  $1 \leq k \leq r$ . So gilt

$$\sum_{i=1}^k p_i = 1 \geq \sum_{i=1}^k \frac{1}{r}$$

und damit nach obigen Lemma

$$0 \leq \sum_{i=1}^k p_i \log_2(p_i r) = \sum_{i=1}^k p_i \log_2(p_i) + \sum_{i=1}^k p_i \log_2(r) = -H(p) + \sum_{i=1}^r p_i \log_2(r) = -H(p) + \log_2(r)$$

- (b) Ist nun  $p$  gleichverteilt, so ist in der Situation von Teilaufgabe (a)  $k = r$  und  $p_i = \frac{1}{r}$  für alle  $1 \leq i \leq r$ . Das obige Lemma liefert somit  $H(p) = \log_2(r)$ .  $\square$