

6. Übung aus Informations- und Codierungstheorie SS 2016

1. Sei $P = (p_1, \dots, p_m)$ mit $p_1 > p_2 \geq \dots \geq p_m$. Man zeige, dass aus $p_1 > \frac{2}{5}$ folgt, dass das kürzeste Wort im binären Huffman-Code die Länge 1 hat.

Lösung: Für $m = 2, 3$ ist die Aussage trivial.

$m = 4$: $p_1 > \frac{2}{5} \Rightarrow p_2 + p_3 + p_4 < \frac{3}{5}$, und damit gilt für $p_2 \geq \frac{1}{5}$
 $p_3 + p_4 \leq \frac{2}{5} < p_1$ Aber auch für $p_2 < \frac{1}{5}$ gilt wegen $p_2 \geq p_3 \geq p_4$

$p_3 + p_4 \leq \frac{2}{5} < p_1$. Somit werden nach 3, 4 die Ausgänge 2, {3, 4} zusammengefasst und die 1-te Frage entscheidet zwischen 1 und diesem Ausgang.

$m \geq 5$: Wir nehmen an, dass die Behauptung für $m - 1$ richtig ist. Klarerweise gilt $\sum_{i=2}^m p_i < \frac{3}{5}$. Daraus folgt

$$2(p_{m-1} + p_m) \leq \lfloor \frac{m-1}{2} \rfloor (p_{m-1} + p_m) \leq \sum_{i=2}^m p_i < \frac{3}{5}$$

$$\Rightarrow p_{m-1} + p_m < \frac{3}{10} < p_1.$$

Damit ist p_1 auch in der reduzierten Verteilung die größte Wahrscheinlichkeit und die Behauptung folgt aus der Induktionsannahme.

2. Sei $P = (p_1, \dots, p_m)$ mit $p_1 > p_2 \geq \dots \geq p_m$. Man zeige, dass für $p_1 < \frac{1}{3}$ das kürzeste Wort im binären Huffman-Code aus mindestens 2 Zeichen bestehen muss.

Lösung: Der Huffman-Algorithmus führt nach $m - 3$ Schritten zu einer Verteilung $\tilde{P} = (\tilde{p}_1, \tilde{p}_2, \tilde{p}_3)$ mit $\tilde{p}_1 \geq \tilde{p}_2 \geq \tilde{p}_3$. Gilt $p_1 \neq \tilde{p}_i$, $i = 1, 2, 3$, so wurde p_1 schon in einem der bisherigen Schritte zusammengefasst, sodass gilt $l_1 > 1$. Gilt $p_1 = \tilde{p}_2$ oder $p_1 = \tilde{p}_3$, so impliziert das $l_1 = 2$. Aber $p_1 = \tilde{p}_1$ kann nicht sein wegen $p_1 < \frac{1}{3}$ und $\tilde{p}_1 + \tilde{p}_2 + \tilde{p}_3 = 1$.

3. Man beweise, dass für jede Verteilung $P = (p_1, \dots, p_m)$, zu der es einen Präfix-Code C mit den Wortlängen l_1, \dots, l_m auf dem Codealphabet $\{0, \dots, r - 1\}$ gibt, dessen mittlere Wortlänge $l(C)$ mit $H_r(P)$ übereinstimmt, gilt $m \equiv 1 \pmod{r - 1}$ und $p_i = r^{-l_i} \quad \forall i = 1, \dots, m$.

Beweis: Da C ein Präfix-Code ist, gilt $\sum_{i=1}^m r^{-l_i} \leq 1$. Mit $Q := (r^{-l_1}, \dots, r^{-l_m})$

gilt $0 = D(P|Q) = \sum_{i=1}^m p_i \log_r r^{l_i} - H(P) = \sum_{i=1}^m p_i l_i - H(P) = l(C) - H(P)$

genau dann, wenn $P = Q$, d.h. $p_i = r^{-l_i} \quad \forall 1 \leq i \leq m$. Aber dann gilt auch $\sum_{i=1}^m r^{-l_i} = \sum_{i=1}^m p_i = 1$, d.h. C ist vollständig. Das impliziert $m \equiv 1 \pmod{r - 1}$.

4. Man zeige, dass es zu jedem Präfixcode zum Codealphabet $\{0, \dots, r-1\}$, für dessen Wortlängen l_1, \dots, l_m gilt $\sum_{i=1}^m r^{-l_i} < 1$ Codefolgen gibt, die nicht entziffert werden können.

Beweis: Gilt o.E.d.A. $l_1 \leq \dots \leq l_m$, so gibt es eine Folge aus $\{0, \dots, r-1\}^{l_m}$, die weder Codewort noch Präfix eines Codewortes ist (wegen $\sum_{i=1}^m r^{-l_i} < 1$ ist der Code nicht vollständig). Dieser Folge kann keine Nachricht zugeordnet werden.

5. Ist $\mathcal{P} := \{P := (p_1, \dots, p_m) : 0 \leq p_i \leq 1, \sum_{i=1}^m p_i = 1\}$ die Menge der

Verteilungen auf $\Omega := \{\omega_1, \dots, \omega_m\}$, so zeige man, dass $l(P)$ die mittlere Wortlänge des optimalen Codes zu P eine stetige Funktion auf \mathcal{P} ist.

Beweis: Ist C ein beliebiger Code mit den Wortlängen $l_1(C), \dots, l_m(C)$, so ist $l(C) := \sum_{i=1}^m l_i(C) p_i$ natürlich eine stetige Funktion von p_1, \dots, p_m .

Aber das Huffman-Verfahren liefert einen optimalen Code C_H zum Codealphabet $\{0, \dots, r-1\}$ mit $\max_{1 \leq i \leq m} l_i \leq \lceil \frac{m}{r-1} \rceil \leq m-1$. Daher gilt auch $l(P) = \min\{l(C) : 1 \leq l_i(C) \leq m-1 \ \forall 1 \leq i \leq m\}$, sodass $l(P)$ als Minimum von endlich vielen stetigen Funktionen stetig ist.