

Datenkompression

Sommersemester 2019

Übungsblatt 1

Prof. Dr. Enno Ohlebusch

Institut für Theoretische Informatik

Uwe Baier

Ausgegeben am 30.04.2019

Besprechung am 07.05.2019

Aufgabe 1.1

Wir betrachten die folgenden Mengen von Codewörtern:

$$\begin{aligned} M_1 &:= \{01, 10, 000, 011, 100, 111\}, & M_2 &:= \{0, 10, 11, 101\}, \\ M_3 &:= \{00, 01, 11, 100, 101\}, & M_4 &:= \{00, 11, 010, 0100\}. \end{aligned}$$

- Welche Mengen erfüllen die Kraft-McMillan-Ungleichung?
- Welche Mengen sind Bildbereich eines eindeutig dekodierbaren Codes, und warum?
- Geben Sie für jede Menge M_i einen Präfixcode an, welcher dieselben Codewortlängen wie M_i hat. Für welche Mengen ist dies nicht möglich?

Aufgabe 1.2

Auf dem Alphabet $\{d, i, l, m, n, r, u\}$ sei eine Wahrscheinlichkeitsfunktion P definiert:

x	d	i	l	m	n	r	u
$P(x)$	1/24	1/24	1/6	7/24	1/12	1/24	1/3

- Bestimmen Sie einen Präfixcode nach dem Shannon-Verfahren.
- Bestimmen Sie einen Präfixcode nach dem Shannon-Fano-Verfahren (Variante mit Teilmengenbetrachtung, siehe Vorlesungsfolien H. Fernau, Vorlesung 2, Folie 15).
- Bestimmen Sie einen Präfixcode nach dem Huffman-Verfahren.
- Berechnen Sie die erwarteten Codewortlängen der Codes aus den Teilaufgaben (a) bis (c).

Aufgabe 1.3

Gegeben sei ein Text S der Länge n über einem Alphabet Σ der Größe $|\Sigma| = \sigma$. Weiter sei die Häufigkeit des Buchstabens mit Rang i gegeben durch c_i , es gilt $\sum_{i=1}^{\sigma} c_i = n$. In der Vorlesung haben Sie den Begriff der Shannon-Entropie kennen gelernt:

$$H(S) = \sum_{i=1}^{\sigma} \frac{c_i}{n} \log_2 \left(\frac{n}{c_i} \right) \stackrel{P(i) := \frac{c_i}{n}}{=} \sum_{i=1}^{\sigma} P(i) \log_2 \left(\frac{1}{P(i)} \right)$$

- Gegeben sei die Häufigkeitsverteilung c_1, \dots, c_{σ} wie am Anfang der Aufgabe beschrieben. Wie viele verschiedene Texte können mithilfe dieser Buchstabenhäufigkeiten erzeugt werden? Geben Sie eine allgemeine Formel in Abhängigkeit von n und c_1, \dots, c_{σ} an. Zeigen Sie, dass diese zu $\frac{n!}{c_1! \cdot c_2! \cdot \dots \cdot c_{\sigma}!}$ äquivalent ist.
- Leiten Sie mithilfe der Teilaufgabe (a), der Stirlingschen Abschätzung $\log_2(n!) \approx n \log_2(n)$ und folgendem Theorem die Shannon-Entropie her:

Theorem

Sei A eine Menge von Texten. Treten die Elemente in A mit gleicher Wahrscheinlichkeit auf, so benötigt ein beliebiger, eindeutig dekodierbarer Code für A (jedem Element wird eine Binärsequenz zugeordnet) im Mittel mindestens $\log_2(|A|)$ Bits um ein einzelnes Element aus A zu kodieren.