

Datenkompression

Sommersemester 2018

Übungsblatt 2

Prof. Ohlebusch

Institut für Theoretische Informatik

Uwe Baier

Ausgegeben am 17.05.2018

Besprechung am 24.05.2018

Aufgabe 2.1

Bestimmen Sie für $\Sigma = \{a, b, c, d\}$ mit $P(a) = 0,7$ und $P(b) = P(c) = P(d) = 0,1$ einen Huffmancode. Wie viele Huffmancodes gibt es insgesamt für P ?

Wie kann sichergestellt werden, dass der Decodierer den gleichen Huffmancode verwendet, wie der Codierer und welche Information(en) müssen hierfür zusätzlich übertragen werden?

Aufgabe 2.2

Die Zeichen des Alphabetes $\{\mathbf{a}, \mathbf{b}, \mathbf{c}\}$ mit der Anordnung $\mathbf{a} < \mathbf{b} < \mathbf{c}$ treten mit den Wahrscheinlichkeiten $P(\mathbf{a}) = \frac{1}{4}$, $P(\mathbf{b}) = \frac{1}{2}$ und $P(\mathbf{c}) = \frac{1}{4}$ auf.

- Berechnen Sie die arithmetische Kodierung des Wortes **baac**.
- Dekodieren Sie die arithmetische Kodierung 0100010 eines Wortes der Länge 4.

Aufgabe 2.3

Auf einem Alphabet Σ sei die Wahrscheinlichkeitsfunktion $P: \Sigma \rightarrow [0, 1]$ definiert. Für Zeichenketten aus Σ^m , deren Zeichen unabhängig voneinander gezogen werden, erhalten wir die Wahrscheinlichkeitsfunktion $P_m: \Sigma^m \rightarrow [0, 1]$, $(c_1, \dots, c_m) \mapsto P(c_1) \cdots P(c_m)$.

Beweisen Sie die Additivität der Entropie: $H(\Sigma^m, P_m) = mH(\Sigma, P)$.

Aufgabe 2.4

Gegeben sei ein Text S der Länge n über einem Alphabet Σ der Größe $|\Sigma| = \sigma$. Weiter sei die Häufigkeit des Buchstaben 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:

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

Wie Sie bereits aus der Vorlesung wissen, bildet die Shannon-Entropie eine untere Schranke für die mittlere Codewortlänge eines eindeutig dekodierbaren Codes. In dieser Aufgabe sollen Sie herleiten, warum die Shannon-Entropie eine solche untere Schranke bildet.

- 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.