

Lösungen zu Übungsblatt 3

3.1

Geben Sie Beispiele für binäre Code an, die nicht präfixfrei aber dennoch eindeutig decodierbar sind.

Z.B. sind die Codes mit den Codewörtern $\{0, 01, 11\}$ bzw. $\{01, 10, 11, 100\}$ nicht präfixfrei aber eindeutig decodierbar.

3.2

Gegeben seien zwölf Bälle, von denen elf das gleiche Gewicht haben und einer schwerer oder leichter ist. Sie haben die Aufgabe, mit einer Balkenwaage in möglichst wenigen Wägungen den besonderen Ball zu finden und herauszufinden, ob er schwerer oder leichter ist. Beschreiben Sie eine Strategie dafür. Denken Sie darüber nach, wie sich verschiedene Varianten in Bezug auf den jeweiligen Informationsgewinn unterscheiden. Überlegen Sie sich, was die Aufgabe mit Codierung zu tun hat.

Wir modellieren das Problem als Wahrscheinlichkeitsraum $(\Omega = \{1^-, 1^+, \dots, 12^-, 12^+\}, P)$, wobei die Elementarereignisse n^-, n^+ bedeuten, dass Ball n leichter bzw. schwerer als alle anderen ist, und mit der Gleichverteilung P . Für $I, J \subset \{1, \dots, 12\}$ mit $I \cap J = \emptyset$ und $|I| = |J|$ können wir das Abwägen der Bälle $(B_i)_{i \in I}$ gegen die Bälle $(B_j)_{j \in J}$ als Zufallsvariable $X_{I,J} : \Omega \rightarrow \{-1, 0, 1\}$ betrachten, deren Werte den Ergebnissen “die $(B_i)_{i \in I}$ sind schwerer”, “die $(B_j)_{j \in J}$ sind schwerer” und “beide sind gleich schwer” entsprechen.

Wir untersuchen zunächst, durch welche Wahl von I, J sich beim ersten Wägen die Unsicherheit darüber, welches Elementarereignis eingetreten ist, maximal reduzieren lässt. Die durchschnittliche Reduktion dieser Unsicherheit ist die Entropie $H(X_{I,J})^1$, und deswegen sollte die Verteilung von $X_{I,J}$ möglichst nah an einer Gleichverteilung sein. Mit $n := |I| = |J|$ gilt $P_{X_{I,J}}(-1) = \frac{n}{12} = P_{X_{I,J}}(1)$ und $P_{X_{I,J}}(0) = 1 - \frac{n}{6}$ (z.B. tritt $X_{I,J} = -1$ genau dann ein, wenn entweder einer der B_i schwerer oder einer der B_j leichter ist als alle anderen, also in $2n$ von 24 Fällen), was für $n = 4$ tatsächlich eine Gleichverteilung ist. Eine optimale Strategie für den ersten Schritt ist also das Abwägen von zwei Sets von vier Bällen gegeneinander. Die weiteren Schritte kann man sich analog überlegen. (Siehe [MacKay, Kapitel 4] für die komplette Beschreibung einer optimalen Strategie.)

Wir können eine Strategie, an deren Ende feststeht, welcher Ball schwerer oder leichter ist als alle anderen, als ternären Code $\Omega \rightarrow \{-1, 0, 1\}^*$ auffassen, der jedes Elementarereignis auf die Folge der Ergebnisse der jeweiligen Wägungen abbildet. Eine optimale Strategie entspricht einem Code mit minimaler erwarteter Länge.

¹Die Unsicherheit zu Beginn ist nämlich $H(P) = H(\text{id}_\Omega)$, und damit ist die Reduktion der Unsicherheit gleich $H(\text{id}_\Omega) - H(\text{id}_\Omega|X_{I,J}) = H(\text{id}_\Omega, X_{I,J}) - H(\text{id}_\Omega|X_{I,J}) = H(X_{I,J})$.

3.3

Zeigen Sie die allgemeine Form der Kettenregel für Entropien: Für Zufallsvariablen X_1, \dots, X_n gilt

$$H(X_1, \dots, X_n) = H(X_1) + \sum_{i=2}^n H(X_i | X_1, \dots, X_{i-1}).$$

Was folgt daraus, wenn X_1, \dots, X_n unabhängig sind?

Wir verwenden vollständige Induktion, wobei der Fall $n = 2$ schon aus der Vorlesung bekannt ist. Angenommen, wir haben die allgemeine Kettenregel für gegebenes $n - 1 \in \mathbb{N}$ bewiesen; indem wir $Y = (X_1, \dots, X_{n-1})$ setzen, erhalten wir

$$\begin{aligned} H(X_1, \dots, X_n) &= H(Y, X_n) \\ &= H(Y) + H(X_n | Y) \\ &= H(X_1, \dots, X_{n-1}) + H(X_n | X_1, \dots, X_{n-1}) \\ &= H(X_1) + \sum_{i=2}^{n-1} H(X_i | X_1, \dots, X_{i-1}) + H(X_n | X_1, \dots, X_{n-1}) \\ &= H(X_1) + \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}), \end{aligned}$$

unter Verwendung der schon bewiesenen Kettenregel für 2 und $n - 1$ Zufallsvariablen. Falls die Zufallsvariablen X_1, \dots, X_n *unabhängig* sind, sind die bedingten Entropien $H(X_i | X_1, \dots, X_{i-1}) = H(X_i)$, und damit folgt $H(X_1, \dots, X_n) = \sum_{i=1}^n H(X_i)$.

3.4

Gegeben seien Zufallsvariablen X, Y, Z . Die *bedingte gegenseitige Information*, die X bei gegebenem Z über Y gibt, definieren wir als

$$I(X; Y | Z) = H(X | Z) - H(X | Y, Z).$$

Zeigen Sie, dass $I(X; Y | Z)$ symmetrisch in X und Y ist und dass $I(X; Y | Z) \geq 0$ ist.

Indem wir die Definition $I(X; Y | Z) = H(X | Z) - H(X | Y, Z)$ mit Hilfe der Kettenregel umformen, erhalten wir

$$I(X; Y | Z) = H(X, Z) - H(Z) - H(X, Y, Z) + H(Y, Z),$$

was symmetrisch in X und Y ist.

Für gegebenes z mit $P_Z(z) > 0$ bezeichnen wir mit X_z und Y_z die Zufallsvariablen, die wir durch Einschränkung von X und Y auf das Ereignis $\{Z = z\}$ erhalten (dieses ist mit der Verteilung $P(\cdot | Z = z)$ ein Wahrscheinlichkeitsraum). Damit gilt $H(X | Z) = E_z(H(X_z))$ und $H(X | Y, Z) = E_z(H(X_z | Y_z))$, und damit $I(X; Y | Z) = E_z(H(X_z) - H(X_z | Y_z)) = E_z(I(X_z; Y_z))$. Da für alle z die wechselseitige Information $I(X_z; Y_z) \geq 0$ ist (siehe Vorlesung), folgt $I(X; Y | Z) \geq 0$. (Alternativ kann man die Positivität auch durch Ausschreiben der bedingten Entropien und Anwendung der Jensen-Ungleichung zeigen.)

3.5

Zufallsvariablen X, Y, Z bilden eine *Markov-Kette* $X \rightarrow Y \rightarrow Z$, falls für alle x, y, z mit $P_Y(y) > 0$ die Gleichung $P(Z = z|X = x, Y = y) = P(Z = z|Y = y)$ gilt.

- a) Zeigen Sie, dass X, Y, Z genau dann eine Markov-Kette $X \rightarrow Y \rightarrow Z$ bilden, wenn $I(X; Z|Y) = 0$ ist.

Ähnlich wie in der vorigen Aufgabe bezeichnen wir für gegebenes y mit $P_Y(y) > 0$ mit X_y bzw. Z_y die Zufallsvariablen, die wir durch Einschränken von X bzw. Z auf $\{Y = y\}$ erhalten. Es gilt $H(Z|Y) = E_y(H(Z_y))$ und $H(Z|X, Y) = E_y(H(Z_y|X_y))$, und somit

$$I(X; Z|Y) = E_y(H(Z_y) - H(Z_y|X_y)) = E_y(I(X_y; Z_y)).$$

Daran sieht man, dass $I(X; Z|Y)$ genau dann verschwindet (also $= 0$ ist), wenn $I(X_y; Z_y)$ für alle y mit $P_Y(y) > 0$ verschwindet; das wiederum ist genau dann der Fall, wenn X_y und Z_y für alle y mit $P_Y(y) > 0$ unabhängig sind, und das ist äquivalent zu $P(Z = z|X = x, Y = y) = P(Z = z|Y = y)$ für alle x, y, z mit $P_Y(y) > 0$, d.h. dazu, dass X, Y, Z eine Markovkette $X \rightarrow Y \rightarrow Z$ bilden.

- b) Zeigen Sie die *data processing inequality*: Falls X, Y, Z eine Markov-Kette $X \rightarrow Y \rightarrow Z$ bilden, dann folgt

$$I(X; Z) \leq I(X; Y).$$

Es gilt allgemein folgende *Kettenregel für die wechselseitige Information*:

$$\begin{aligned} I(X; Y, Z) &= H(X) - H(X|Y, Z) \\ &= H(X) - H(X|Y) + H(X|Y) - H(X|Y, Z) \\ &= I(X; Y) + I(X; Z|Y); \end{aligned}$$

durch Vertauschung der Rollen von Y und Z ergibt sich auf die gleiche Weise

$$I(X; Y, Z) = I(X; Z) + I(X; Y|Z).$$

Im Fall einer Markovkette $X \rightarrow Y \rightarrow Z$ gilt $I(X; Z|Y) = 0$, und damit ergibt sich aus der ersten Anwendung der Kettenregel $I(X; Y, Z) = I(X; Y)$. Zusammen mit der zweiten Anwendung der Kettenregel folgt

$$I(X; Y) = I(X; Z) + I(X; Y|Z) \geq I(X; Z),$$

da $I(X; Y|Z) \geq 0$.

- c) Folgern Sie, dass für beliebige Zufallsvariablen X, Y und jede Funktion f

$$I(X; f(Y)) \leq I(X; Y)$$

gilt. Geben Sie eine intuitive Interpretation.

Die Zufallsvariablen X, Y und $f(Y)$ bilden eine Markovkette $X \rightarrow Y \rightarrow f(Y)$, denn $P(f(Y) = z|X = x, Y = y) = P(f(Y) = z|Y = y)$ für alle x, y, z (beide Ausdrücke sind 1 falls $f(y) = z$ und 0 sonst). Daher folgt $I(X; f(Y)) \leq I(X; Y)$. Intuitiv ist klar, dass bei Anwendung einer Funktion (dem ‘‘Verarbeiten von Daten’’, vgl. die Bezeichnung ‘‘data processing inequality’’) höchstens Information verloren geht.