

1 Einführung

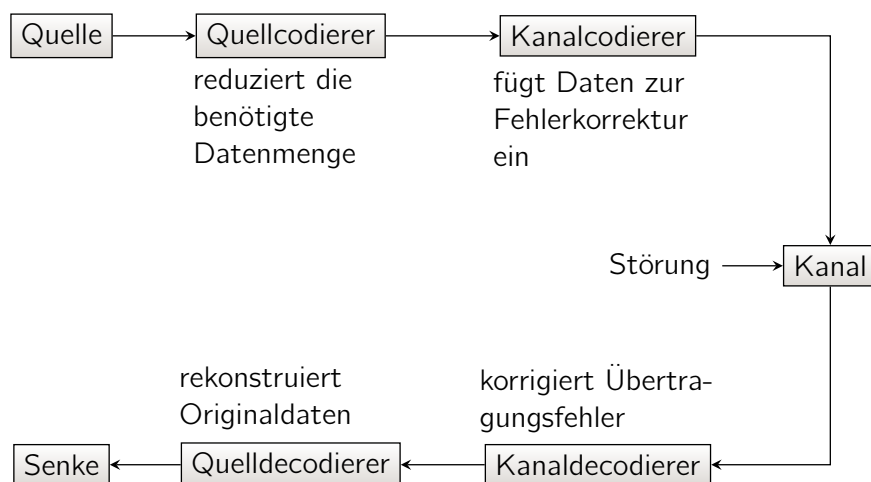
- 1.1 Modell der Nachrichtenübertragung
- 1.2 Informationsbegriff

2 Diskrete Quellen

- 2.1 Diskrete Quellen mit unabhängigen Ereignissen
- 2.2 Informationsgehalt eines Symbols
- 2.3 Entropie
- 2.4 Verbundquellen
- 2.5 Verbundentropie
- 2.6 Bedingte Entropie
- 2.7 Transinformation
- 2.8 Darstellung als Venn-Diagramm
- 2.9 Zusammenfassung

1.1 Modell der Nachrichtenübertragung

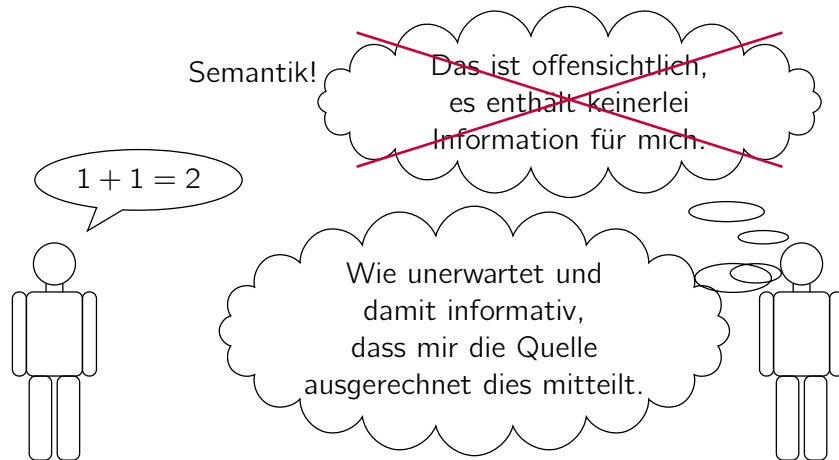
Aufgabe: Effiziente Übertragung von Daten über einen gestörten Kanal.



Die Aufteilung in Quell- und Kanalcodierung dient der Vereinfachung durch Betrachtung von Teilproblemen.

1.2 Informationsbegriff

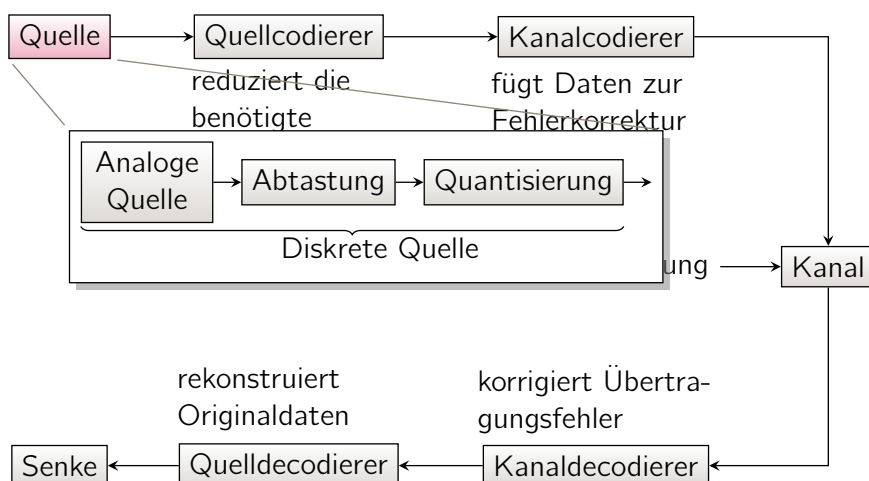
Der Shannonschen¹ Informationstheorie liegt ein *statistischer* Informationsbegriff zu Grunde.



Information ist beseitigte Unbestimmtheit.

¹Claude E. Shannon gilt mit seinen Arbeiten vom Ende der 40er als (einer) der Begründer der Informations- und Kodierungstheorie.

2 Diskrete Quellen



2.1 Diskrete Quellen mit unabhängigen Ereignissen

Definition 2.1

Eine *diskrete Quelle* \mathcal{X} liefert eine Sequenz x_k von zufälligen Symbolen aus einer Menge X , dem Alphabet. Wir nehmen eine stationäre Quelle an, sodass die Auftretswahrscheinlichkeiten $p_X(x) \in [0, 1]$, $\sum_{x \in X} p_X(x) = 1$, von k unabhängig sind. Ferner gehen wir von unabhängigen Ereignissen aus, also $p_X(x_k) = p_X(x_k | x_1, \dots, x_{k-1}, x_{k+1}, \dots)$.

Beispiel 2.1 (Werfen einer Münze)

$X = \{\text{Kopf}, \text{Zahl}\}$, $p_X(\text{Kopf}) = p_X(\text{Zahl}) = 0,5$.

Beispiel 2.2 (Würfeln)

$X = \{1, \dots, 6\}$, $p_X(1) = \dots = p_X(6) = \frac{1}{6}$.

2.2 Informationsgehalt eines Symbols

Jedem Symbol x soll ein Informationsgehalt H_x zugeordnet werden, sodass

- $p_X(x) = 1 \Leftrightarrow H_x = 0$, ein sicheres Ereignis also keine Information trägt, da keine Unbestimmtheit beseitigt wird,
- $p_X(x) < p_X(y) \Leftrightarrow H_x > H_y$, unwahrscheinliche Symbole also mehr Information tragen und
- sich der Informationsgehalt H_{x_1, x_2} zweier *unabhängiger* Symbole x_1, x_2 (d.h. $p_{X, X}(x_1, x_2) = p_X(x_1) \cdot p_X(x_2)$) durch Addition der Einzelinformationen ergibt.

Diese Bedingungen werden von

$$H_x = -\log_r p_X(x) \quad (2.1)$$

erfüllt, wobei üblicherweise $r = 2$ verwendet wird. Wir schreiben $\text{Id} = \log_2$.

2.3 Entropie

Definition 2.2 (Entropie)

Unter der Entropie $H(\mathcal{X})$ einer Quelle \mathcal{X} versteht man den durchschnittlichen Informationsgehalt der Symbole,

$$H(\mathcal{X}) = \sum_{x \in \mathcal{X}} p_{\mathcal{X}}(x) \cdot H_x = - \sum_{x \in \mathcal{X}} p_{\mathcal{X}}(x) \operatorname{ld}(p(x)), \quad (2.2)$$

wobei für $0 \operatorname{ld} 0$ die stetige Fortsetzung $0 \operatorname{ld} 0 = \lim_{x \rightarrow 0} x \operatorname{ld} x = 0$ verwendet wird.

Beispiel 2.3

Für das Münzwerfen aus Beispiel 2.1 ergibt sich

$$H(\mathcal{X}) = -\frac{1}{2} \operatorname{ld} \left(\frac{1}{2} \right) - \frac{1}{2} \operatorname{ld} \left(\frac{1}{2} \right) = -\frac{1}{2} \cdot (-1) - \frac{1}{2} \cdot (-1) = 1.$$

Beispiel 2.4

Für den Würfel aus Beispiel 2.2 ergibt sich

$$H(\mathcal{X}) = -6 \cdot \frac{1}{6} \operatorname{ld} \left(\frac{1}{6} \right) = -\operatorname{ld} \left(\frac{1}{6} \right) \approx 2,585.$$

Beispiel 2.5

Für einen gezinkten Würfel mit $p_{\mathcal{X}}(1) = \frac{1}{21}$, $p_{\mathcal{X}}(2) = \frac{2}{21}$, $p_{\mathcal{X}}(3) = \frac{3}{21}$, $p_{\mathcal{X}}(4) = \frac{4}{21}$, $p_{\mathcal{X}}(5) = \frac{5}{21}$, $p_{\mathcal{X}}(6) = \frac{6}{21}$ ergibt sich

$$H(\mathcal{X}) = -\frac{1}{21} \operatorname{ld} \left(\frac{1}{21} \right) - \dots - \frac{6}{21} \operatorname{ld} \left(\frac{6}{21} \right) \approx 2,398.$$

Die Symbole, die der gezinkte Würfel erzeugt, tragen weniger Information, da sie sich besser vorhersagen lassen.

Satz 2.1

Für die Entropie $H(\mathcal{X})$ einer Quelle \mathcal{X} mit einem Alphabet X aus N Symbolen gilt

$$0 \leq H(\mathcal{X}) \leq \text{ld } N. \quad (2.3)$$

Dabei ist $H(\mathcal{X}) = 0$ g.d.w. es ein sicheres Ereignis x' mit $p_X(x') = 1$ gibt ($p_X(x) = 0$ für $x \neq x'$), und $H(\mathcal{X}) = \text{ld } N$ g.d.w. alle Symbole gleich wahrscheinlich sind mit $p_X(x) = \frac{1}{N}$ für alle $x \in X$.

Beweis für die untere Schranke.

Offenbar gilt

$$-p_X(x) \text{ld}(p_X(x)) > 0 \text{ für } 0 < p_X(x) < 1 \quad (2.4)$$

$$\text{und} \quad -p_X(x) \text{ld}(p_X(x)) = 0 \text{ für } p_X(x) \in \{0, 1\}. \quad (2.5)$$

Daraus folgt unmittelbar

$$H(\mathcal{X}) = \sum_{x \in X} -p_X(x) \text{ld}(p_X(x)) \geq 0. \quad (2.6)$$

Gleichheit gilt dabei nur, wenn $-p_X(x) \text{ld}(p_X(x)) = 0$ für alle x , also alle $p_X(x) \in \{0, 1\}$. Da $\sum_{x \in X} p_X(x) = 1$, muss in diesem Fall genau ein x' das sichere Ereignis mit $p_X(x') = 1$ sein, für die übrigen $x \neq x'$ muss $p_X(x) = 0$ gelten. \square

Beweis für die obere Schranke.

Unter Verwendung eines Lagrange-Multiplikators λ für die Nebenbedingung $\sum_{x \in X} p_X(x) = 1$ und mit der abkürzenden Schreibweise $p_x = p_X(x)$ wird die Hilfsfunktion

$$f = - \sum_{x \in X} p_x \text{ld } p_x + \lambda \left(1 - \sum_{x \in X} p_x \right) \quad (2.7)$$

gebildet. Nullsetzen der partiellen Ableitungen

$$\frac{\partial f}{\partial p_x} = -1 \cdot \text{ld } p_x - p_x \cdot \frac{\text{ld } e}{p_x} - \lambda = -\text{ld } p_x - \text{ld } e - \lambda = 0 \quad (2.8)$$

führt auf

$$\text{ld } p_x = -\text{ld } e - \lambda, \quad (2.9)$$

es sind also p_x gleich, was mit der Nebenbedingung auf das eindeutige Maximum $p_x = \frac{1}{N}$ führt, für das der Wert

$$- \sum_{x \in X} \frac{1}{N} \text{ld} \left(\frac{1}{N} \right) = \text{ld } N \quad (2.10)$$

erreicht wird. \square

2.4 Verbundquellen

Definition 2.3

Die diskreten Quellen \mathcal{X} und \mathcal{Y} mit den Alphabeten X und Y und der Verbundwahrscheinlichkeit $p_{\mathcal{X},\mathcal{Y}}(x, y)$ bilden eine *Verbundquelle* $(\mathcal{X}, \mathcal{Y})$.

Beispiel 2.6

Zwei Spieler A und B spielen eine Partie Schach. Das Recht auf den ersten Zug wird durch Münzwurf entschieden. Die Quelle \mathcal{X} mit $X = \{A, B\}$ gebe das Ergebnis des Münzwurfs an, die Quelle \mathcal{Y} mit $Y = \{A, B, R\}$ (A gewinnt, B gewinnt, Remis) den Ausgang der Schachpartie. Die Verbundquelle $(\mathcal{X}, \mathcal{Y})$ hat die Verbundwahrscheinlichkeit

$$\begin{array}{lll} p_{\mathcal{X},\mathcal{Y}}(A, A) = 0,25 & p_{\mathcal{X},\mathcal{Y}}(A, B) = 0,15 & p_{\mathcal{X},\mathcal{Y}}(A, R) = 0,1 \\ p_{\mathcal{X},\mathcal{Y}}(B, A) = 0,15 & p_{\mathcal{X},\mathcal{Y}}(B, B) = 0,25 & p_{\mathcal{X},\mathcal{Y}}(B, R) = 0,1. \end{array}$$

2.5 Verbundentropie

Definition 2.4

Wird in Definition 2.2 $p_X(x)$ durch die Verbundwahrscheinlichkeit $p_{\mathcal{X},\mathcal{Y}}(x, y)$ ersetzt, erhält man die *Verbundentropie*

$$H(\mathcal{X}, \mathcal{Y}) = - \sum_{x \in X} \sum_{y \in Y} p_{\mathcal{X},\mathcal{Y}}(x, y) \text{ld}(p_{\mathcal{X},\mathcal{Y}}(x, y)). \quad (2.11)$$

Beispiel 2.7

Für die Verbundquelle aus Beispiel 2.6 ergibt sich

$$H(\mathcal{X}, \mathcal{Y}) = -2 \cdot 0,25 \cdot \text{ld} 0,25 - 2 \cdot 0,15 \cdot \text{ld} 0,15 - 2 \cdot 0,1 \cdot \text{ld} 0,1 \approx 2,486.$$

Für die Wahrscheinlichkeiten der Einzelquellen gilt $p_X(x) = \sum_{y \in Y} p_{\mathcal{X},\mathcal{Y}}(x, y)$ bzw. $p_Y(y) = \sum_{x \in X} p_{\mathcal{X},\mathcal{Y}}(x, y)$, also

$$p_X(A) = p_X(B) = 0,5 \quad \text{und} \quad p_Y(A) = p_Y(B) = 0,4, \quad p_Y(R) = 0,2,$$

was auf die Einzelentropien $H(\mathcal{X}) = 1$ und $H(\mathcal{Y}) \approx 1,522$ führt.

Satz 2.2

Mit obigen Definitionen gilt

$$H(\mathcal{X}, \mathcal{Y}) \leq H(\mathcal{X}) + H(\mathcal{Y}) \quad (2.12)$$

mit Gleichheit g.d.w. \mathcal{X} und \mathcal{Y} unabhängig sind.

Für den Beweis benötigen wir

Lemma 2.1

Seien $p_1, \dots, p_N, q_1, \dots, q_N \geq 0$ mit $\sum_{i=1}^N p_i = 1$ und $\sum_{i=1}^N q_i = 1$, so gilt

$$-\sum_{i=1}^N p_i \operatorname{ld}(p_i) \leq -\sum_{i=1}^N p_i \operatorname{ld}(q_i) \quad (2.13)$$

mit Gleichheit g.d.w. $p_i = q_i$ für $i = 1, \dots, N$.

Beweis von Lemma 2.1.

Wir nutzen $\ln(x) = \operatorname{ld}(x) \ln(2)$ und beweisen

$$-\sum_{i=1}^N p_i \ln(p_i) \leq -\sum_{i=1}^N p_i \ln(q_i). \quad (2.14)$$

Ausgehend von $\ln x \leq x - 1$ mit Gleichheit nur für $x = 1$ ergibt sich durch Ersetzen

$$\ln\left(\frac{q_i}{p_i}\right) \leq \frac{q_i}{p_i} - 1 \quad \text{mit Gleichheit nur für } p_i = q_i. \quad (2.15)$$

Multiplikation mit p_i und Summieren über $i = 1, \dots, N$ führt auf

$$\sum_{i=1}^N p_i \ln\left(\frac{q_i}{p_i}\right) \leq \sum_{i=1}^N (q_i - p_i) = \sum_{i=1}^N q_i - \sum_{i=1}^N p_i = 1 - 1 = 0, \quad (2.16)$$

also

$$\sum_{i=1}^N p_i (\ln(q_i) - \ln(p_i)) = \sum_{i=1}^N p_i \ln(q_i) - \sum_{i=1}^N p_i \ln(p_i) \leq 0 \quad (2.17)$$

mit Gleichheit nur für $p_i = q_i$. □

Beweis von Satz 2.2.

$$H(\mathcal{X}) = - \sum_{x \in \mathcal{X}} p_{\mathcal{X}}(x) \text{ld}(p_{\mathcal{X}}(x)) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{\mathcal{X},\mathcal{Y}}(x, y) \text{ld}(p_{\mathcal{X}}(x)) \quad (2.18)$$

$$H(\mathcal{Y}) = - \sum_{y \in \mathcal{Y}} p_{\mathcal{Y}}(y) \text{ld}(p_{\mathcal{Y}}(y)) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{\mathcal{X},\mathcal{Y}}(x, y) \text{ld}(p_{\mathcal{Y}}(y)) \quad (2.19)$$

$$H(\mathcal{X}) + H(\mathcal{Y}) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{\mathcal{X},\mathcal{Y}}(x, y) (\text{ld}(p_{\mathcal{X}}(x)) + \text{ld}(p_{\mathcal{Y}}(y))) \quad (2.20)$$

$$= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{\mathcal{X},\mathcal{Y}}(x, y) \text{ld}(p_{\mathcal{X}}(x) \cdot p_{\mathcal{Y}}(y)) \quad (2.21)$$

$$H(\mathcal{X}, \mathcal{Y}) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{\mathcal{X},\mathcal{Y}}(x, y) \text{ld}(p_{\mathcal{X},\mathcal{Y}}(x, y)) \leq H(\mathcal{X}) + H(\mathcal{Y}) \quad (2.22)$$

nach Lemma 2.1, mit Gleichheit nur für $p_{\mathcal{X},\mathcal{Y}}(x, y) = p_{\mathcal{X}}(x) \cdot p_{\mathcal{Y}}(y)$, also Unabhängigkeit. □

Korollar 2.1

Für die spezielle Verbundentropie $H(\mathcal{X}, \mathcal{X}) = H(\mathcal{X}^2)$ gilt unter der Voraussetzung voneinander unabhängiger Einzelereignisse

$$H(\mathcal{X}^2) = 2H(\mathcal{X}) \quad (2.23)$$

und über Induktion folgt

$$H(\mathcal{X}^k) = k \cdot H(\mathcal{X}). \quad (2.24)$$

Werden mehrere Symbole auf einmal betrachtet, bleibt die Entropie pro Symbol konstant.

2.6 Bedingte Entropie

Definition 2.5

Der Ausdruck

$$H(\mathcal{Y}|\mathcal{X}) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_X(x) p_{Y|X}(y|x) \text{ld} (p_{Y|X}(y|x)) \quad (2.25)$$

wird als *bedingte Entropie* bezeichnet.

Die bedingte Entropie $H(\mathcal{Y}|\mathcal{X})$ gibt an, wie viel zusätzliche Information die Kenntnis von \mathcal{Y} bei bereits bekanntem \mathcal{X} bringt.

Satz 2.3

Mit obigen Definitionen gilt

$$H(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) + H(\mathcal{Y}|\mathcal{X}) = H(\mathcal{Y}) + H(\mathcal{X}|\mathcal{Y}). \quad (2.26)$$

Beweis.

$$H(\mathcal{X}, \mathcal{Y}) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{X,Y}(x, y) \text{ld} (p_{X,Y}(x, y)) \quad (2.27)$$

$$= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_X(x) p_{Y|X}(y|x) \text{ld} (p_X(x) p_{Y|X}(y|x)) \quad (\text{Bayes}) \quad (2.28)$$

$$= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_X(x) p_{Y|X}(y|x) \text{ld} (p_X(x)) \quad (2.29)$$

$$- \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_X(x) p_{Y|X}(y|x) \text{ld} (p_{Y|X}(y|x)) \quad (2.30)$$

$$= - \sum_{x \in \mathcal{X}} p_X(x) \text{ld} (p_X(x)) \underbrace{\sum_{y \in \mathcal{Y}} p_{Y|X}(y|x)}_{=1} + H(\mathcal{Y}|\mathcal{X}) \quad (2.31)$$

$$= H(\mathcal{X}) + H(\mathcal{Y}|\mathcal{X}) \quad (2.32)$$

□

Korollar 2.2

Mit Satz 2.2 ($H(\mathcal{X}, \mathcal{Y}) \leq H(\mathcal{X}) + H(\mathcal{Y})$) folgt unmittelbar $H(\mathcal{Y}|\mathcal{X}) \leq H(\mathcal{Y})$.

Beispiel 2.8

Für die Verbundquelle aus Beispiel 2.6 gilt

$$\begin{array}{lll} p_{X|Y}(A|A) = 0,625 & p_{X|Y}(A|B) = 0,375 & p_{X|Y}(A|R) = 0,5 \\ p_{X|Y}(B|A) = 0,375 & p_{X|Y}(B|B) = 0,625 & p_{X|Y}(B|R) = 0,5 \end{array}$$

und

$$\begin{array}{ll} p_{Y|X}(A|A) = 0,5 & p_{Y|X}(A|B) = 0,3 \\ p_{Y|X}(B|A) = 0,3 & p_{Y|X}(B|B) = 0,5 \\ p_{Y|X}(R|A) = 0,2 & p_{Y|X}(R|B) = 0,2. \end{array}$$

Damit ergeben sich

$$H(\mathcal{Y}|\mathcal{X}) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_X(x) p_{Y|X}(y|x) \text{ld}(p_{Y|X}(y|x)) \approx 1,486$$

und

$$H(\mathcal{X}|\mathcal{Y}) = - \sum_{y \in \mathcal{Y}} \sum_{x \in \mathcal{X}} p_Y(y) p_{X|Y}(x|y) \text{ld}(p_{X|Y}(x|y)) \approx 0,964.$$

Damit gilt $H(\mathcal{X}) + H(\mathcal{Y}|\mathcal{X}) \approx 1 + 1,486 = 2,486 \approx H(\mathcal{X}, \mathcal{Y})$ bzw.

$H(\mathcal{Y}) + H(\mathcal{X}|\mathcal{Y}) \approx 1,522 + 0,964 = 2,486 \approx H(\mathcal{X}, \mathcal{Y})$.

2.7 Transinformation

- $H(\mathcal{X})$: Wieviel Information trägt \mathcal{X} ?
 - $H(\mathcal{X}|\mathcal{Y})$: Wieviel zusätzliche Information trägt \mathcal{X} , wenn \mathcal{Y} bekannt ist?
- $\Rightarrow H(\mathcal{X}) - H(\mathcal{X}|\mathcal{Y})$: Wieviel Information trägt \mathcal{Y} über \mathcal{X} ?

Definition 2.6

$$I(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) - H(\mathcal{X}|\mathcal{Y}) \quad (2.33)$$

wird als *Transinformation* von \mathcal{X} und \mathcal{Y} bezeichnet.

Die Transinformation ist eine allgemeinere Methode, um statistische Abhängigkeiten zu untersuchen, als die in der Signalverarbeitung gern verwendete Korrelation.

Satz 2.4

Es gilt

$$I(\mathcal{X}, \mathcal{Y}) \geq 0. \quad (2.34)$$

folgt unmittelbar aus Korollar 2.2 ($H(\mathcal{X}|\mathcal{Y}) \leq H(\mathcal{X})$).

Satz 2.5

Es gilt

$$I(\mathcal{X}, \mathcal{Y}) = I(\mathcal{Y}, \mathcal{X}). \quad (2.35)$$

Beweis.

Unter Ausnutzung von Satz 2.3 folgt

$$I(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) - H(\mathcal{X}|\mathcal{Y}) \quad (2.36)$$

$$= H(\mathcal{X}, \mathcal{Y}) - H(\mathcal{Y}|\mathcal{X}) - H(\mathcal{X}|\mathcal{Y}) \quad (2.37)$$

$$= H(\mathcal{Y}) - H(\mathcal{Y}|\mathcal{X}) = I(\mathcal{Y}, \mathcal{X}). \quad (2.38)$$

□


Beispiel 2.9

Nochmals seien die Schachspieler aus Beispiel 2.6 betrachtet:

$$I(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) - H(\mathcal{X}|\mathcal{Y}) \approx 1 - 0,964 = 0,036$$

$$I(\mathcal{Y}, \mathcal{X}) = H(\mathcal{Y}) - H(\mathcal{Y}|\mathcal{X}) \approx 1,522 - 1,486 = 0,036$$

2.8 Darstellung als Venn-Diagramm



2.9 Zusammenfassung

- Die Entropie $H(\mathcal{X}) = -\sum p_X(x) \text{Id } p_X(x)$ misst den durchschnittlichen Informationsgehalt eines Symbols der Quelle \mathcal{X} .
- Gleichverteilte Quelle mit N Symbolen erreicht die maximale Entropie $H(\mathcal{X}) = \text{Id } N$.
- Die Verbundentropie $H(\mathcal{X}, \mathcal{Y})$ misst den Informationsgehalt der Kombination von Symbolen der Quellen \mathcal{X} und \mathcal{Y} , es gilt $H(\mathcal{X}, \mathcal{Y}) \leq H(\mathcal{X}) + H(\mathcal{Y})$.
- Für den Spezialfall einer erweiterten Quelle gilt bei Unabhängigkeit der Symbole $H(\mathcal{X}^n) = n \cdot H(\mathcal{X})$.
- Die bedingte Entropie $H(\mathcal{Y}|\mathcal{X})$ gibt an, wieviel zusätzliche Information \mathcal{Y} liefert, wenn \mathcal{X} bekannt ist. Es gilt $H(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) + H(\mathcal{Y}|\mathcal{X})$ und $H(\mathcal{Y}|\mathcal{X}) \leq H(\mathcal{Y})$.
- Die Transinformation $I(\mathcal{X}, \mathcal{Y}) = H(\mathcal{X}) - H(\mathcal{X}|\mathcal{Y}) = H(\mathcal{Y}) - H(\mathcal{Y}|\mathcal{X})$ gibt an, wieviel Information \mathcal{X} und \mathcal{Y} übereinander tragen.