

## 1.2. Informationsmaße

Ziel: Vergleich verschiedener Wahrscheinlichkeitsverteilungen bezüglich ihres Informationsgehaltes.

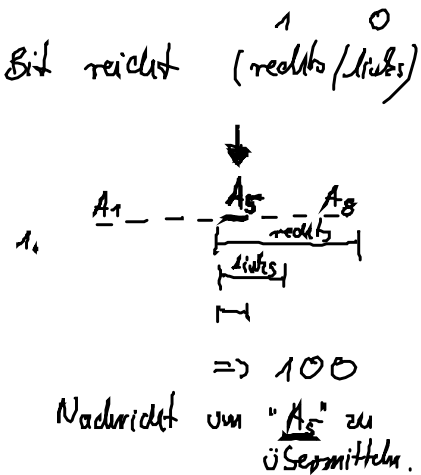
Frage: Wie lang muss eine Nachricht sein um ein eingetretenes Ergebnis zu übermitteln?

Bsp. ①  $\mathcal{A} = \{A_1, A_2\}$   $\rightarrow$  ein Bit reicht (rechts/links)

②  $\mathcal{A} = \{A_1, A_2, \dots, A_N\}$   $N = 2^n$

$\rightarrow n$  Alternativenentscheidungen

$$b(N) = \log_2 N$$



▷ Informationsmaß der Nachricht falls keine Vorkenntnis vorhanden ist:  $b(N) = \log_2 N$

Verallgemeinerung auf W.-vert.  $P_i$

Falls der Beobachter die  $P_i$  kennt  $\Rightarrow$  muss nur noch fehlende Information übertragen werden.

Bitsatz  $b(P_i)$

Postulate für die Konstruktion von  $b(P_i)$

(i)  $b(P)$  ist universelle Fkt., hängt nur über  $P(A)$  von  $A$  ab.

(ii) für 2 unkorrelierte sample sets  $\{A_i\}$ ,  $\{A'_i\}$  ist die fehlende info des Gesamtsystems:

$$b(P'') = b(P) + b(P')$$

wobei gilt  $P''(A_i; A_i') = P(A_i) \cdot P'(A_i')$ .

(iii)  $b(P) = 0$  für  $P = 1$  d.h. für das sichere Ereignis

$b(P) = \log_2 N$  für  $P = \frac{1}{N}$  d.h. bei Gleichverteilung

(iv)  $b(P)$  ist stetig und wohldefiniert für  $0 \leq P \leq 1$

Definiere  $b(P) = f(\log P)$   $f$  noch zu bestimmen!

$$(i) + (ii) \Rightarrow f(\log P'') = f(\log P + \log P') \\ \stackrel{!}{=} f(\log P) + f(\log P')$$

$\rightarrow$  linear in  $\log P$

$$f(\log P) = k \cdot \log P \quad k \text{ unbekannt.}$$

Aus (iii) folgt:  $b(P) = k \cdot \log P = -k \log N \stackrel{!}{=} \log_2 N$

für  $P = \frac{1}{N}$

$\Rightarrow k = -1$   
 $\log = \log_2 \rightarrow$  Konvention für Einheit eines Bits

$$\ln 2 = \frac{\ln P}{\log_2 P}$$

$$b(P_i) = -\ln P_i$$

Informationsmaß für die Nachricht, dass  $A_i$  eingetreten ist, falls  $P_i = P(A_i)$  bekannt ist.

Informationsmaß einer

$\Omega$ -wert  $\{P_i\}$   $\therefore$  Mittelung

über verschiedene Nachrichtenlängen

$$\langle b \rangle = - \sum_{i=1}^N P_i \ln P_i$$

mittlere benötigte Information (oder fehlend) pro Ereignis

Def.: Shannon-Information einer Verteilung  $\{P_i\}$

$$I(P) = \sum_{i=1}^N P_i \ln P_i$$

$$P = (P_1, \dots, P_N)$$

$I$  ist ein Funktional der Vert.f.  
 $b$  ist Funktion  $P_i$

$$I(P) \leq 0$$

Maximum:  $I(P) = 0$  für  $P_i = \delta_{ij}$  scharfe Verteilung

Minimum: Variation der  $P_i$  um  $\delta P_i$  unter  
 der Nebenbedingung  $\sum_i \delta P_i = 0$   
 (wegen Normierung  $\sum_i P_i = 1$ )

$$\delta I = \sum_i (\ln P_i + 1) \delta P_i = 0$$

Addition der NB  $\sum_i \delta P_i = 0$  mit Lagrange Multiplikator  $\lambda$

$$\sum_i (\ln P_i + 1 + \lambda) \delta P_i = 0$$

• unabhängige Variation der  $\delta P_i \rightarrow \ln P_i = -(1 + \lambda) = \text{const.}$   $\otimes$

• Normierung  $\sum_i P_i = N P_i = 1$

$$P_i = \frac{1}{N}$$

Gleichverteilung

Kontinuierliche Ereignismenge ( $x \in \mathbb{R}^d$ ,  $g(x)$ )

Zelleneinteilung des  $\mathbb{R}^d$  in Zellen  $i$  mit  $\Delta^d x$

Wahrscheinlichkeit für Ereignis in Zelle  $i$ :  $P_i = g(x^i) \Delta^d x$

$$\rightarrow I(P) = \sum_i \Delta^d x g(x^i) \ln g(x^i) + \underbrace{\sum_i \Delta^d x g(x^i) \ln \Delta^d x}_{\left( \sum_i g(x^i) \cdot \Delta^d x \right) \ln \Delta^d x}$$

1

weglassen da  
const. für jede  
Zellengröße

$$\Delta^d x \rightarrow 0 \quad \boxed{I(\rho) = \int d^d x \rho \ln \rho}$$

Informationsgehalt einer  
kont. Verteilung

Bemerkung: (i) nur Kenntnis bzgl. der Frage: "Welches Ereignis tritt ein?", keine Unterscheidung woher ich  $\rho$  kenne (z.B. geraten oder durch Messung bestätigt)

(ii) Später: Statistisches Informationsmaß des Nichtwissens

$$S(\rho) = -k \int d^d x \rho \ln \rho$$

k... Boltzmann  
Konstante

Interpretation als Entropie in der  
Thermodynamik.

(iii) Verallgemeinerte Informationsmaße (Rényi)

$$I_q = -\frac{1}{1-q} \ln \left( \sum_i p_i^q \right) \quad q=1,2,\dots$$

$q \rightarrow 1$  ergibt  
Shannon Info

### Informationsgewinn:

Maß für die Zusatzinformation einer W.-vert.  $\{P_i\}$  im Vergleich zu einer Referenzverteilung  $\{P_i^r\}$  über der gleichen Ereignismenge.

$$b(P_i^r) - b(P_i) = \ln \frac{P_i}{P_i^r}$$

notwendige Bitzahl um  
 $P_i^r$  in  $P_i$  zu verwandeln  
durch eine Nachricht

Mittelung über  $P_i$ :

$$K(P, P') = \sum_{i=1}^N P_i \ln \frac{P_i}{P'_i}$$

Informationsgewinn

Kullback-Leibler Information

→ Welche Information geht verloren wenn  $g'(x)$  verwendet wird um  $g(x)$  anzunähern:  $K(g, g')$


→ (Wieviel Platz wird verschwendet wenn wir  $P_i$  codiert wird was  $P_i$  verteilt ist.)

Bemerkungen:

(i) Asymmetrisch bzgl.  $P \leftrightarrow P'$

(ii) es gilt  $K(P, P') \geq 0$

$$\sum P_i \ln \frac{P_i}{P'_i} \geq \sum_i P_i \left(1 - \frac{P'_i}{P_i}\right) = \sum_{i=1}^N P_i - \sum_{i=1}^N P'_i = 0$$

$$\left( \ln x \geq 1 - \frac{1}{x} \text{ für } x > 0 \right)$$


(iii)  $P'_i = 0$  ist auszuschließen, damit  $K < \infty$

(iv) Für  $P'_i = \frac{1}{N}$

$$\rightarrow K(P, P') = \underbrace{\sum_{i=1}^N P_i \ln P_i}_{I(P)} + \sum_{i=1}^N P_i \ln N = I(P) - I\left(\frac{1}{N}\right)$$

(v) Minimum von  $K$  ?

Variation unter Nebenbedingungen .....

$$\rightarrow p_i = p_i'$$

$$\rightarrow K=0$$