

1.2. Informationsmaße

Ziel: Vergleich verschiedener Wahrscheinlichkeitsverteilungen bezüglich ihres Informationsgehaltes.

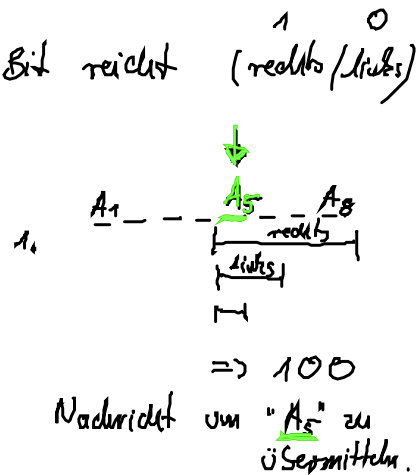
Frage: Wie lang muss eine Nachricht sein um ein eingetretenes Ergebnis zu übermitteln?

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 Alternativenbescheidungen

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



\triangleright 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

Ω -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

\Rightarrow 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 δP_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 λ

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

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

• Normierung $\sum_i P_i \stackrel{\otimes}{=} N P_i = 1$

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

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 : $P_i = g(x^i) \Delta^d x$

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

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 ρ kenne (z.B. geraten oder durch Messung bestätigt)

(ii) Später: Statistisches Informationsmaß des Nichtwissens k... Boltzmann Konstante

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

Interpretation als Entropie in der Thermodynamik.

(iii) Verallgemeinerte Informationsmaße (Reyi)

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

$q \rightarrow 1$ 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

$$\rightarrow p_i = p_i'$$

$$\rightarrow K=0$$