

1.2) Informationsmaße

Die Informationstheorie (Shannon, Wiener) ^{→ Kybernetik} entstand im 2. Weltkrieg im Zusammenhang mit der Entschlüsselung codierter Nachrichten

Def. Ein Maß μ auf einer σ -Algebra \mathcal{A} ist eine Abb. $\mu: \mathcal{A} \rightarrow [0, \infty]$ mit den Eigenschaften

$$\mu(\emptyset) = 0$$

Für disjunkte Ereignisse A_i (d.h. $A_i \cap A_j = \emptyset$)

$$\mu\left(\bigcup_i A_i\right) = \sum_i \mu(A_i)$$

Im folgenden sei die Ereignisalgebra stets eine σ -Algebra


Bsp: Wahrscheinlichkeit P
(speziell $P(A_i) \leq 1$)


Idee der Informationsmaße:

Vergleich verschiedener Wahrscheinlichkeitsverteilungen einer Ereignisalgebra \mathcal{A}


Frage: Welche von zwei Verteilungen enthält mehr Information (Kenntnis) darüber, welches Ereignis eintreffen wird?

Beispiel: Hauptgewinn ist hinter einer von 3 Türen versteckt.





Gleichverteilung
(minimale Kennlinie)



Schiefe Verteilung
(maximale Kennlinie)
= Sicherheit

Bitzahl:

Ausgangspunkt: diskrete Ereignisalgebra $A = \{A_i\}$

Frage: Wie lang muss eine Nachricht sein, die einem Beobachter mitteilt, dass ein Ereignis eingetreten ist?

Beispiel: Auswahl eines Ereignisses aus $A = \{A_1, A_2, \dots, A_N\}$, falls der Beobachter keine Vorkenntnis hat.

- (i) $A = \{A_1, A_2\}$: einfache Alternative
= kleinste Informationseinheit
= 1 bit (binary digit) 1942

Nachricht: 0 oder 1

- (ii) $A =$ Menge mit $N = 2^m$ Elementen
 m Alternativentscheidungen $N = 2^m \mid \log_2$
z.B. $\underbrace{1100101}_{m \text{ Stellen}}$ $m = \log_2(N)$

Länge der Nachricht: $n = \log_2(N)$ (Bitzahl)

Def: Informationsmaß der Nachricht, falls keine Vorkenntnis vorhanden ist:

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

Verallgemeinerung auf Wahrscheinlichkeitsverteilungen P_i

Falls der Beobachter die P_i kennt, muss ihm nur die fehlende Information mitgeteilt werden $b(P_i)$

Postulate: für die Konstruktion von $b(P_i)$:

- (i) $b(P)$ ist universelle Fkt, d.h. hängt von t nur über $P(A)$ ab.
- (ii) Seien $\{A_i\}$ und $\{A'_j\}$ zwei verschiedene, disjunkte sample sets (z.B. 2 Subsys. eines zusammengesetzten Systems)

Für 2 unkorrelierte Subsysteme ist b additiv:

$$b(P^{\wedge}) = b(P) + b(P')$$

wobei nach Def. der Unkorreliertheit (stochastisch unabh.) gilt

$$P^{\wedge}(A_i A'_j) = P(A_i) P'(A'_j)$$

$$P_i = P(A_i)$$

- (iii) $P = 1$ $b(P) = 0$
sicheres Ereignis

$b(P) = \log_2 N$ für $P = \frac{1}{N}$ (Gleichverteilung)
Maximale Unbestimmtheit

(iv) $b(p)$ ist stetig und wohl definiert für
 $0 \leq p \leq 1$

Definiere $b(p) = f(\log p)$ mit noch zu bestimmender
Funktion f

Benutze (i) & (ii)

$$f(\log p^n) = f(\log p + \log p^i) \stackrel{!}{=} f(\log p) + f(\log p^i)$$

\Rightarrow lineare Fkt f

$$\Rightarrow \underline{f(\log p) = k \cdot \log p}$$

aus (iii) folgt für $p = \frac{1}{N}$

$$b(p) = b\left(\frac{1}{N}\right) = k \cdot \log \frac{1}{N} = \underline{-k \cdot \log N \stackrel{!}{=} \log_2(N)}$$

$$\Rightarrow k = -1$$

$$\log = \log_2$$

Konvention Einheit für 1 bit: $h_1 = \frac{\ln p}{\log_2 p}$ (bit)

$$\Rightarrow \boxed{b(p_i) = -h_1(p_i)}$$

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

Informationsmenge einer Wahrscheinlichkeitsverteilung $\{P_i\}$

Übermittlung vieler Nachrichten:

A_i tritt mit relativer Häufigkeit P_i auf
mittlere benötigte (da fehlende) Information pro

Ergebnis: $\langle b \rangle = -\sum_i^N P_i \ln P_i$

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

$$I(P) = \sum_i P_i \ln P_i \quad \nabla$$

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

I ist Funktional der Verteilung

b ist eine Funktion von P_i

① Es gilt stets $I(P) \leq 0$

② $I(P)$ für verschiedene Verteilungen

kontinuierliche Ergebnismenge ($x \in \mathbb{R}^d$, $g(x)$)

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

Wahrscheinlichkeit für ein Ereignis in der Zelle i :

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

$$I(P) = \sum_i \Delta^d x g(x^i) \ln[\Delta^d x g(x^i)]$$

$$= \sum_i \Delta^d x g(x^i) [\ln g(x^i) + \ln \Delta^d x]$$

$$= \sum \Delta^d x g(x^i) \ln g(x^i) + \underbrace{\sum \Delta^d x g(x^i) \ln \Delta^d x}_{1 \text{ const}}$$

$\Delta^d x \rightarrow 0$:

$$I(g) = \int d^d x g \ln g$$

(i) Shannon-Informationmaß misst die Kenntnis bzgl. der speziellen Frage: „welches Ereignis tritt ein?“

Keine Untersuchung, wie die Verteilung zustande kommt

z.B. bei Gleichverteilung

→ genaue Beobachtung

→ vorurteilsfreie Schätzung

Def: Statistisches Informationsmaß des Nichtwissens
(fehlende Information)

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

k - geeignete Einheit

→ spätere Interpretation in der Thermodynamik
als Entropie