

1.2) Informationstheorie

Die Informationstheorie (Shannon, Wiener) ^{probabilistisch} 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 Informationstheorie:

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 Unkenntnis)



Schiefe Verteilung
(maximale Unkenntnis)
= Sicherheit

Bitzahl:

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

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

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

- (i) $\mathcal{A} = \{A_1, A_2\}$: einfache Alternative
= kleinste Informationseinheit
= 1 bit (binary digit) 1342

Nachricht: 0 oder 1

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

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

Def: Informationsmenge 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 x nur über $P(x)$ 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:

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

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

$$P^*(A_i A'_j) = P(A_i) P'(A'_j)$$

$$P_i = P(A_i)$$

(iii) $P = \tau$ $b(P) = 0$
sicheres Ereignis

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

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

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

Benutze (i) & (ii)

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

\Rightarrow lineare Fkt f

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

aus (iii) folgt für $P = \frac{1}{N}$

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

$$\Rightarrow k = -1$$

$$\log = \log_2$$

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

$$\Rightarrow \boxed{b(P_i) = -\ln(P_i)}$$

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

Informations) sind 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 :

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

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

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

$$= \sum \Delta^d x g(x^i) \ln g(x^i) + \underbrace{\sum \Delta^d x g(x^i)}_1 \ln \Delta^d x$$

const

$\Delta^d x \rightarrow 0$:

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

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

Keine Untersuchung, wie die Verteilung zustande kommt

z.B. bei Gleichverteilung

→ genaue Beobachtung

→ vorurteilsfreie Schätzung

Def: Statistische Informationstheorie des Nichtwissens
(folgende Information)

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

k -geeignete Einheit

→ spätere Interpretation in der Thermodynamik
als Entropie