

Grundbegriffe und Notation

1. Wahrscheinlichkeitsraum:

Ein *Wahrscheinlichkeitsraum* ist immer gegeben durch das Tripel (Ω, Σ, p) .

Eine Abbildung $X : \Omega \rightarrow \mathbb{R}$ heisst *Zufallsvariable* (ZV) falls für alle $r \in \mathbb{R}$ die Aussage $[X \leq r] \in \Sigma$ ist.

Für eine ZV X bedeutet z.B. $[X \leq r] = \{\omega \in \Omega : X(\omega) \leq r\}$, oder $[X = r] = \{\omega \in \Omega : X(\omega) = r\}$, oder $[X \in A] = \{\omega \in \Omega : X(\omega) \in A\}$.

2. Beschreibungen:

Eine Abbildung $d : \Omega \rightarrow \Sigma$ heisst *Beschreibung* falls $\omega \in d(\omega), \forall \omega \in \Omega$. Außerdem muss $p(d(\omega)) > 0, \forall \omega \in \Omega$ gelten.

Für eine Beschreibung d definieren wir die *Komplettierung* (oder *Vervollständigung*) \tilde{d} durch $\tilde{d}(\omega) := [d = d(\omega)] = \{\omega' \in \Omega : d(\omega') = d(\omega)\}$.

Eine Beschreibung d mit $d = \tilde{d}$ nennen wir *komplett* (oder *vollständig*).

Für eine ZV X definieren wir mit $\tilde{X} : \Omega \rightarrow \Sigma; \omega \mapsto [X = X(\omega)]$ die *Beschreibung durch X*.

3. Neuigkeit:

Für eine Aussage A definieren wir die *Neuigkeit* oder *Information* als $N(A) = I(A) := -\log_2 p(A)$.

Die *Neuigkeit einer Beschreibung* d ist eine ZV $N_d : \Omega \rightarrow \mathbb{R}_+; \omega \mapsto -\log_2 p(d(\omega)) \geq 0$. Wir schreiben $N(d) := E(N_d)$.

Die *bedingte Neuigkeit* $N_{c|d}$ einer Beschreibung c gegeben eine weitere Beschreibung d ist eine Zufallsvariable $N_{c|d} : \Omega \rightarrow \mathbb{R}_+$ mit $N_{c|d}(\omega) = -\log_2 p(c(\omega)|d(\omega)) \geq 0$. Wir schreiben wieder $N(c|d) := E(N_{c|d})$.

4. Information:

Wir definieren die *Information einer Beschreibung* d als $I(d) := N(\tilde{d})$, und die *Information einer ZV* X als $I(X) := N(\tilde{X})$.

Sätze Informationstheorie

1. Eigenschaften von Beschreibungen:

Für Beschreibungen c und d und deren Kompletterungen \tilde{c} und \tilde{d} gilt:

$$\tilde{c} \subseteq c \quad (1)$$

$$\tilde{c} \cap \tilde{d} \subseteq \widetilde{c \cap d} \quad (2)$$

Für ZVn X und Y bzw. für *komplette* Beschreibungen c, d gilt:

$$\tilde{c} \cap \tilde{d} = \widetilde{c \cap d} \quad (3)$$

$$\tilde{X} \cap \tilde{Y} = \widetilde{(X, Y)} \quad (4)$$

$$\tilde{X} = \widetilde{X^{\leq}} = \widetilde{X^{\geq}} \quad (5)$$

2. Eigenschaften von Neuigkeit:

Für Beschreibungen c und d gilt:

- Positivität:

$$N(c) \geq 0 \quad \text{und} \quad N(d|c) \geq 0 \quad (6)$$

- Monotonie:

$$c \subseteq d \Rightarrow N(c) \geq N(d) \quad (7)$$

- Additivität:

$$N(c \cap d) = N(c) + N(d|c) \quad (8)$$

$$N(c \cap d) \leq N(c) + N(d) \quad , \text{ falls } c \text{ und } d \text{ komplett} \quad (9)$$

$$N(c \cap d) = N(c) + N(d) \quad , \text{ falls } c \text{ und } d \text{ unabhängig} \quad (10)$$

3. Eigenschaften von Information:

Für Beschreibungen b, c und d und deren Kompletterungen \tilde{b}, \tilde{c} und \tilde{d} , sowie für ZVn X, Y und Z gilt:

- Bezug zur Neuigkeit:

$$I(c) := N(\tilde{c}) \geq N(c) \quad (11)$$

$$I(X) := N(\tilde{X}) \quad (12)$$

$$I(c|d) := N(\tilde{c}|\tilde{d}) \quad (13)$$

$$I(X|Y) := N(\tilde{X}|\tilde{Y}) \quad (14)$$

- Monotonie:

$$\tilde{c} \subseteq \tilde{d} \Rightarrow I(c) \geq I(d) \quad (15)$$

$$\tilde{c} \subseteq \tilde{d} \Rightarrow I(b|c) \leq I(b|d) \quad \text{und} \quad I(c|b) \geq I(d|b) \quad (16)$$

$$X \succeq Y \Rightarrow I(X) \geq I(Y) \quad (17)$$

$$X \succeq Y \Rightarrow I(Z|X) \leq I(Z|Y) \quad \text{und} \quad I(X|Z) \geq I(Y|Z) \quad (18)$$

($X \succeq Y$ bedeutet $\tilde{X} \subseteq \tilde{Y}$.)

- Additivität:

$$I(c \cap d) = I(c) + I(d|c) \leq I(c) + I(d) \quad (19)$$

$$I(c \cap d) = I(c) + I(d) \quad , \text{ falls } c \text{ und } d \text{ unabhängig} \quad (20)$$

$$I(X, Y) = I(X) + I(Y|X) \leq I(X) + I(Y) \quad (21)$$

$$I(X, Y) = I(X) + I(Y) \quad , \text{ falls } X \text{ und } Y \text{ unabhängig} \quad (22)$$

4. Subjektive Information und Information Gain

Für Wahrscheinlichkeitsraum (Ω, Σ, p) nimmt man neben der tatsächlichen Verteilung p die subjektive Verteilung q an: Dann kann man die *subjektive Neuigkeit* einer Beschreibung d als

$$N_q(d) := N_{pq} := E_p(-\log_2(q(d(\omega)))) \quad (23)$$

definieren. Ähnlich kann man für eine Beschreibung d bzw. eine ZV X die *subjektive Information* definieren:

$$I_q(d) := I_{pq}(d) := E_p(-\log_2(q(\tilde{d}(\omega)))) \quad (24)$$

$$I_q(X) := I_{pq}(X) := E_p(-\log_2(q(\tilde{X}(\omega)))) \quad (25)$$

Der *Information Gain* einer ZV X definiert man als

$$G_{p,q}(X) := I_{pq}(X) - I_{pp}(X) = I_q(X) - I(X) \quad (26)$$

Für $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ und $p_i = p(\omega_i)$ und $q_i = q(\omega_i)$ gilt

$$G_{p,q}(X) = G_{p,q} := \sum_{i=1}^n p_i \ln \frac{p_i}{q_i} \geq 0, \quad (27)$$

$$D_{p,q} := G_{p,q} + G_{q,p} \quad (\text{Kullback - Leibler - Distanz}). \quad (28)$$

5. Eigenschaften von Transinformation

Es gilt

$$T(X, Y) = \begin{cases} I(X) + I(Y) - I(X, Y) \\ I(X) - I(X|Y) \leq I(X) \\ I(Y) - I(Y|X) \leq I(Y) \end{cases} \quad (29)$$

$$T(X, Y) \geq 0 \quad (30)$$

$$T(X, Y) = 0 \Leftrightarrow X \text{ und } Y \text{ unabhängig.} \quad (31)$$

Definitionen und Sätze zu Kanälen und Kanalkapazität

1. Einfacher Kanal und Übergangswahrscheinlichkeit $P : \Omega_1 \rightsquigarrow \Omega_2$:

- Definition: Seien $(\Omega_1, \Sigma_1, p_1), (\Omega_2, \Sigma_2, p_2)$ zwei Wahrscheinlichkeitsräume.

$$P : \Omega_1 \times \Sigma_2 \rightarrow [0; 1]$$

heißt *Übergangswahrscheinlichkeit* (Ü.-W.), falls

$$P_\omega : \begin{cases} \Sigma_2 & \rightarrow [0, 1] \\ A & \mapsto P(\omega, A) \end{cases}$$

für jedes $\omega \in \Omega_1$ Wahrscheinlichkeit auf (Ω_2, Σ_2) ist, und falls

$$P_A : \begin{cases} \Omega_1 & \rightarrow [0, 1] \\ \omega & \mapsto P(\omega, A) \end{cases}$$

für jedes $A \in \Sigma_2$ ZV auf (Ω_1, Σ_1) ist.

Mit Hilfe einer Ü.-W. $P : \Omega_1 \rightsquigarrow \Omega_2$ und einer Wahrscheinlichkeit p auf Ω_1 kann man eine neue Wahrscheinlichkeit p' auf $\Omega_1 \times \Omega_2$ konstruieren: Für $A \in \Sigma_1$ und $B \in \Sigma_2$ ist

$$p'(A \times B) := E_{\Omega_1}(1_A \cdot P_B). \quad (32)$$

Die beiden Randverteilungen von p' sind

$$p'_1(A) = p'(A \times \Omega_2) = E_{\Omega_1}(1_A \cdot P_{\Omega_2}) = E(1_A) = p(A) \quad \text{für } A \in \Sigma_1 \quad (33)$$

$$p'_2(B) = p'(\Omega_2 \times A) = E_{\Omega_1}(1_{\Omega_1} \cdot P_B) = E(P_B) \quad \text{für } B \in \Sigma_2 \quad (34)$$

- Ein *einfacher Kanal* K kann mit einer Übergangswahrscheinlichkeit $K : A \rightsquigarrow B$: identifiziert werden. Seine Kapazität ist definiert als

$$C(K) := \max_X \{T(X; Y) : X : \Omega \rightarrow A, K : X \rightsquigarrow Y\}, \quad (35)$$

wobei X eine ZV mit Werten aus A ist und Y eine ZV mit Werten aus B ist die über K an X gekoppelt ist. Die Maximierung erfolgt über die Verteilung von X .

2. Blockcodierung und Informationsrate

Idee: Kodiere nicht nur ZV X , sondern X mehrfach wiederholt. Seien $(X_i)_{i \in \mathbb{N}_0}$ identisch verteilte (i.d.) diskrete ZVn, d.h. $p[X_i = x] = p[X_0 = x] \forall x \in W(X_0) \forall i \in \mathbb{N}$

- Die *Informationsrate* der *Informationsquelle* $\mathcal{X} = (X_i)_{i \in \mathbb{N}_0}$ ist definiert als

$$I_r(\mathcal{X}) := \lim_{n \rightarrow \infty} \frac{1}{n} I(X_1, X_2, \dots, X_n) \quad (36)$$

$$= \lim_{n \rightarrow \infty} I(X_n | X_1, X_2, \dots, X_{n-1}) \quad (37)$$

- Die *Transinformationsrate* zweier Prozesse $\mathcal{X} = (X_i)_{i \in \mathbb{N}_0}$ und $\mathcal{Y} = (Y_i)_{i \in \mathbb{N}_0}$ ist definiert als

$$T_r(\mathcal{X}; \mathcal{Y}) := \lim_{n \rightarrow \infty} \frac{1}{n} T((X_1, X_2, \dots, X_n); (Y_1, Y_2, \dots, Y_n)) \quad (38)$$

$$= I_r(\mathcal{X}) + I_r(\mathcal{Y}) - I_r(\mathcal{X}, \mathcal{Y}) \quad (39)$$

- Ein n -Block-Code für $(X_i)_{i \in \mathbb{N}_0}$ ist definiert als ein Code C für den ZVe (X_1, \dots, X_n) .
- Die "Länge pro Zeichen" L_r des n -Blockcodes C ist definiert als $L_r = L_c/n$.
- Satz: Sei $\mathcal{X} = (X_i)_i$ eine Informationsquelle. Für genügend großes n gibt es einen n -Blockcode mit

$$L_r \approx I_r(\mathcal{X}).$$

3. Kanal und Kapazität

- Einfacher Kanal (ohne Gedächtnis) ist gegeben durch eine Übergangswahrscheinlichkeit

$$K : A \rightsquigarrow B$$

- Kanal mit einfachem Gedächtnis gegeben durch

$$K : A \times A \rightsquigarrow B$$

- allgemeiner Kanal (beliebig langes Gedächtnis)

$$\mathcal{K} : A^{\mathbb{N}} \rightsquigarrow B^{\mathbb{N}}$$

Für $\mathcal{X} = (X_t)_{t \in \mathbb{N}}$ Prozess auf A und $\mathcal{Y} = (Y_t)_{t \in \mathbb{N}}$ durch \mathcal{K} an \mathcal{X} gekoppelter Prozess auf B schreibt man $\mathcal{K} : \mathcal{X} \rightsquigarrow \mathcal{Y}$, d.h.

$$p \left(\bigcap_{i=1}^n [X_i = a_i \wedge Y_i = b_i] \right) = p \left(\bigcap_{i=1}^n [X_i = a_i] \right) \cdot \mathcal{K}_{a_1 \dots a_n} \left(\bigcap_{i=1}^n [Y_i = b_i] \right). \quad (40)$$

Für einfaches Gedächtnis gilt

$$\mathcal{K}_{a_0 a_1 \dots a_n} \left(\bigcap_{i=1}^n [Y_i = b_i] \right) = \prod_{i=1}^n K_{a_{i-1} a_i} [Y_i = b_i], \quad (41)$$

und ohne Gedächtnis gilt

$$\mathcal{K}_{a_1 \dots a_n} \left(\bigcap_{i=1}^n [Y_i = b_i] \right) = \prod_{i=1}^n K_{a_i} [Y_i = b_i], \quad (42)$$

- Kanalkapazität

$$C(\mathcal{K}) := \sup_{\mathcal{X}} \{T_r(\mathcal{X}; \mathcal{Y}) : \mathcal{X} \text{ stationär, } \mathcal{K} : \mathcal{X} \rightsquigarrow \mathcal{Y}\}. \quad (43)$$

Satz: Für Kanal ohne Gedächtnis gilt $C(\mathcal{K}) = C(K)$.

4. Satz von Shannon:

Sei $K : A \rightsquigarrow B$ Kanal ohne Gedächtnis mit Kapazität c . Sei $(U_t)_{t \in \mathbb{N}}$ stationärer Prozess auf D mit Informationsrate $r < c$. Sei $\epsilon > 0$. Dann gibt es ein $n \in \mathbb{N}$ und Abbildungen $Q : D^n \rightarrow A^n$, $R : B^n \rightarrow D^n$, so daß

$$p[R \circ K \circ Q(U_1, \dots, U_n) \neq (U_1, \dots, U_n)] < \epsilon$$

Genau heißt das für $\mathcal{K} : (X_t)_{t \in \mathbb{N}} \rightsquigarrow (Y_t)_{t \in \mathbb{N}}$:

$$\sum_{d \in D^n} p[(U_1, \dots, U_n) = d] \cdot p[R(Y_1, \dots, Y_n) \neq d | (X_1, \dots, X_n) = Q(d)] < \epsilon.$$

Etwas mehr über stochastische Prozesse

1. Grundbegriffe:

Eine Familie $(X_t)_{t \in T}$ von ZVen mit $W(X_t) = W$ heißt *stochastischer Prozess* auf W mit Zeit T .

Typischerweise $T = \mathbb{N}, \mathbb{N}_0, \mathbb{Z}, \mathbb{R}, \mathbb{R}_+$ und W endlich oder $\subseteq \mathbb{R}$.

Wie geht man damit um?

- Man macht sich keine Sorgen um die Konstruktion der vielen ZVen (das geht).
- Man rechnet jeweils nur mit der gemeinsamen Verteilung von endlich vielen ZVen.

2. Eigenschaften von stochastischen Prozessen:

1. Identische Verteilung (i.d.):

$$\forall s, t : p[X_t \in A] = p[X_{t+s} \in A] \quad (44)$$

2. Stationarität:

$$\forall s, t_1, \dots, t_n : p[X_{t_1} \in A_1, \dots, X_{t_n} \in A_n] = p[X_{t_1+s} \in A_1, \dots, X_{t_n+s} \in A_n] \quad (45)$$

3. Unabhängigkeit:

$$\forall s, t_1, \dots, t_n : p[X_{t_1} \in A_1, \dots, X_{t_n} \in A_n] = \prod_{i=1}^n p[X_{t_i} \in A_i] \quad (46)$$

4. Markov Eigenschaft:

$$\forall t \geq t_1 \geq t_2 \geq \dots \geq t_n : p[X_t \in A | (X_{t_1}, \dots, X_{t_n})] = p[X_t \in A | X_{t_1}] \quad (47)$$

5. homogen Markov:

$$\forall t, t_1, s : p[X_t \in A | X_{t_1}] = p[X_{t+s} \in A | X_{t_1+s}] \quad (48)$$

3. Sätze darüber:

- (45) \Rightarrow (44)
- (46) \Rightarrow (47)
- (46) + (44) \Rightarrow (45) + (47) + (48)
- (47) + (45) \Rightarrow (48)
- (47) + (48) + (44) \Rightarrow (45)

4. typische Forderungen:

i.i.d. Prozess, d.h. (44) + (46)

⇒ stationärer Markov-Prozess, (45) + (47)

⇒ stationärer Prozess, (45)

⇒ i.d.-Prozess, (44)

5. Markov-Ketten:

Definition: Eine *Markov-Kette* ist ein homogener Markov-Prozess auf endlicher Menge $W = \{w_1, \dots, w_n\}$ mit Zeit \mathbb{N}_0 .

Die Markov-Kette $(X_t)_{t \in \mathbb{N}_0}$ ist bestimmt durch

- Startverteilung p mit $p_i = p[X_0 = w_i]$ und
- Übergangsmatrix P mit $P_{ij} = p[X_1 = w_i | X_0 = w_j]$

Daraus lassen sich die Verteilungen zu beliebigen Zeiten ableiten:

$$\begin{aligned} p_i^1 := p[X_1 = w_i] &= \sum_j p[X_0 = w_j, X_1 = w_i] = \sum_j p[X_0 = w_j] \cdot p[X_1 = w_i | X_0 = w_j] \\ &= \sum_j P_{ij} p_j = (Pp)_i \end{aligned}$$

Also $p^1 = Pp$, $p^2 = Pp^1 = P^2p$, $p^3 = P^3p$, u.s.w.