

# Mustererkennung: Wahrscheinlichkeitstheorie

**Wahrscheinlichkeitsraum** –  $(\Omega, \sigma, P)$ , mit

$\Omega$  – Die Grundmenge, die Menge der elementaren Ereignisse,

$\sigma$  –  $\sigma$ -Algebra,

$P$  – Wahrscheinlichkeitsmaß.

$\sigma$ -Algebra über die Grundmenge  $\Omega$  ist das System von Teilmengen von  $\Omega$ , d.h.  $\sigma \subseteq \mathcal{P}(\Omega)$  ( $\mathcal{P}$  ist die Potenzmenge) mit:

$$\Omega \in \sigma$$

$$A \in \sigma \Rightarrow \Omega/A \in \sigma$$

$$A_i \in \sigma, i = 1, \dots, n \Rightarrow \bigcup_{i=1}^n A_i \in \sigma$$

$\sigma$  ist bezüglich Komplement-Bildung und abzählbarer Vereinigung abgeschlossen. Daraus folgt:  $\emptyset \in \sigma$ , abzählbarer Schnitt  $\in \sigma$  (über De Morganschen Gesetz).

Beispiele:

- $\sigma = \{\emptyset, \Omega\}$  (kleinste) und  $\sigma = \mathcal{P}(\Omega)$  (größte)  $\sigma$ -Algebren über  $\Omega$
- Die minimale  $\sigma$ -Algebra über  $\Omega$ , die  $A \subset \Omega$  enthält ist  $\{\emptyset, A, \Omega/A, \Omega\}$
- $\Omega$  – diskret und endlich,  $\sigma = 2^\Omega$
- $\Omega = \mathbb{R}$ , die  $\sigma$ -Algebra der Borelschen Teilmengen (enthält u.a. alle Intervalle).

## Definitionen (axiomatisch)

Wahrscheinlichkeitsmaß  $P : \sigma \rightarrow [0, 1]$  ist ein „Maß“ ( $\Pi$ ) mit Normierung:

$$P(\Omega) = 1$$

$\sigma$ -Additivität: sei  $A_i \in \sigma$  paarweise disjunkt, d.h.  $A_i \cap A_{i'} = \emptyset$ . Dann

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

Achtung! Es gibt Mengen, für die kein „Maß“ existiert.

Beispiele: Menge irrationaler Zahlen, Funktionsräume  $\mathbb{R}^\infty$  (?) etc.

Banach-Tarski-Paradoxon

---

Definitionen (menschlich) – praktisch relevante Spezialfälle:

- Menge der elementaren Ereignisse  $\Omega$  ist „gutartig“, z.B.  $\mathbb{R}^n$ , endlich usw.,  $\sigma = \mathcal{P}(\Omega)$
- Ein (zusammengesetztes) Ereignis  $A \subseteq \Omega$  (Vereinigung der elementaren Ereignisse)
- Wahrscheinlichkeit

$$P(A) = \sum_{\omega \in A} P(\omega)$$

Allgemein: eine statistische Größe  $\xi$  ist eine Abbildung  $\xi : \Omega \rightarrow E$  ( $E$  ist der Beobachtungsraum) mit bestimmten Eigenschaften.

Spezialfall – eine reellwertige statistische Größe  $\xi$  für einen Wahrscheinlichkeitsraum  $(\Omega, \sigma, P)$  ist eine Abbildung  $\xi : \Omega \rightarrow \mathbb{R}$  wenn

$$\{\omega : \xi(\omega) \leq r\} \in \sigma \quad \forall r \in \mathbb{R}$$

(immer erfüllt, wenn  $\sigma = \mathcal{P}(\Omega)$ ).

**Verteilungsfunktion** einer statistischen Größe  $\xi$  ist

$$F_{\xi}(r) = P(\{\omega : \xi(\omega) \leq r\})$$

**Wahrscheinlichkeitsverteilung** einer diskreten statistischen Größe  $\xi : \Omega \rightarrow \mathbb{Z}$  ist

$$p_{\xi}(r) = P(\{\omega : \xi(\omega) = r\})$$

**Wahrscheinlichkeitsdichte** einer kontinuierlichen statistischen Größe  $\xi : \Omega \rightarrow \mathbb{R}$  ist

$$p_{\xi}(r) = \frac{\partial F_{\xi}(r)}{\partial r}$$

Bemerkung: Elementare Ereignisse sind keine Zahlen!!!

Im Gegensatz dazu kann man statistische Größen addieren, multiplizieren usw.

**Mittelwert** einer statistischen Größe:

$$\mathbb{E}_P(\xi) = \sum_{\omega \in \Omega} P(\omega) \cdot \xi(\omega) = \sum_r \sum_{\omega: \xi(\omega)=r} P(\omega) \cdot r = \sum_r p_\xi(r) \cdot r$$

---

Beispiel: Augenzahl eines Würfels.

Grundmenge (6 Facetten)  $\Omega = \{a, b, c, d, e, f\}$

Wahrscheinlichkeitsmaß  $P(\{a\}) = 1/6$ ,  $P(\{c, f\}) = 1/3$  ...

Statistische Größe (Augenzahl)  $\xi(a) = 1$ ,  $\xi(b) = 2$  ...  $\xi(f) = 6$ .

Verteilungsfunktion  $F_\xi(3) = 1/2$ ,  $F_\xi(4.5) = 2/3$  ...

Wahrscheinlichkeitsverteilung  $p_\xi(1) = p_\xi(2) = \dots = p_\xi(6) = 1/6$

Erwartungswert  $\mathbb{E}_P(\xi) = 3.5$

Eine andere statistische Größe (Augenzahl<sup>2</sup>)  $\xi'(a) = 1$ ,  $\xi'(b) = 4$  ...  $\xi'(f) = 36$

Erwartungswert  $\mathbb{E}_P(\xi') = 15\frac{1}{6}$

Beispiel: Augenzahlen der zwei (unabhängigen) Würfel.

Grundmenge (6 Facetten  $\times$  6 Facetten)  $\Omega = \{a, b, c, d, e, f\} \times \{a, b, c, d, e, f\}$

Wahrscheinlichkeitsmaß  $P(\{ab\}) = 1/36$ ,  $P(\{cd, fa\}) = 1/18 \dots$

Zwei statistischen Größen:

Augenzahl des ersten Würfels  $\xi_1(ab) = 1$ ,  $\xi_1(ac) = 1 \dots \xi_1(ef) = 5 \dots$

Augenzahl des zweiten Würfels  $\xi_2(ab) = 2$ ,  $\xi_2(ac) = 3 \dots \xi_2(ef) = 6 \dots$

Wahrscheinlichkeitsverteilungen:

$$p_{\xi_1}(1) = p_{\xi_1}(2) = \dots = p_{\xi_1}(6) = 1/6$$

$$p_{\xi_2}(1) = p_{\xi_2}(2) = \dots = p_{\xi_2}(6) = 1/6$$

Die neue statistische Größe (summe der Augenzahlen)  $\xi = \xi_1 + \xi_2$

Die Wahrscheinlichkeitsverteilung  $p_\xi$  ist nicht mehr gleichwahrscheinlich :-)

$$p_\xi \sim (1, 2, 3, 4, 5, 6, 5, 4, 3, 2, 1)$$

Erwartungswert  $\mathbb{E}_P(\xi) = 7$

Generell für Erwartungswerte:

$$\mathbb{E}_P(\xi_1 + \xi_2) = \sum_{\omega \in \Omega} P(\omega) \cdot (\xi_1(\omega) + \xi_2(\omega)) = \mathbb{E}_P(\xi_1) + \mathbb{E}_P(\xi_2)$$

Mehrdimensionale (reellwertige) statistische Größen –  $\xi : \Omega \rightarrow \mathbb{R}^n$

Äquivalent (Einfachheit halber  $n = 2$ ):  $\xi = (\xi_1, \xi_2)$  mit  $\xi_1 : \Omega \rightarrow \mathbb{R}$  und  $\xi_2 : \Omega \rightarrow \mathbb{R}$

Verteilungsfunktion:

$$F_\xi(r, s) = P(\{\omega : \xi_1(\omega) \leq r\} \cap \{\omega : \xi_2(\omega) \leq s\})$$

Verbundwahrscheinlichkeitsverteilung (diskret):

$$p_{\xi=(\xi_1, \xi_2)}(r, s) = P(\{\omega : \xi_1(\omega) = r\} \cap \{\omega : \xi_2(\omega) = s\})$$

Verbundwahrscheinlichkeitsdichte (kontinuierlich):

$$p_{\xi=(\xi_1, \xi_2)}(r, s) = \frac{\partial F_\xi(r, s)}{\partial r \partial s}$$

## Weitere Definitionen

Zwei Ereignisse  $A \subset \Omega$  und  $B \subset \Omega$  sind **unabhängig**, wenn

$$P(A \cap B) = P(A) \cdot P(B)$$

Interessant: Ereignisse  $A$  und  $\bar{B} = \Omega/B$  sind unabhängig, falls  $A$  und  $B$  unabhängig sind.

**Bedingte Wahrscheinlichkeit:**

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Eine andere Definition der Unabhängigkeit:  $A$  und  $B$  sind unabhängig, wenn

$$P(A|B) = P(A) \quad \text{bzw.} \quad P(B|A) = P(B)$$

(äquivalent, wenn  $P(B) \neq 0$  bzw.  $P(A) \neq 0$ ).

Zwei statistische Größen sind unabhängig, wenn

$$F_{\xi=(\xi_1, \xi_2)}(r, s) = F_{\xi_1}(r) \cdot F_{\xi_2}(s) \quad \forall r, s$$

---

**Bayessche Formel:**

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

## Weitere Definitionen (für statistische Größen)

Kürzel:  $p(x, y) \equiv p_{\xi}(x, y)$

**Marginale Wahrscheinlichkeit:**

$$p(x) = \sum_y p(x, y)$$

**Bedingte Wahrscheinlichkeit:**

$$p(x|y) = \frac{p(x, y)}{p(y)}$$

Merke:  $\sum_x p(x|y) = 1$ .

**Unabhängige Wahrscheinlichkeitsverteilungen:**

$$p(x, y) = p(x) \cdot p(y)$$

oder (analog zu Ereignissen)

$$p(x|y) = p(x)$$

Interessant: In das Intervall  $[0, 1]$  werden zufällig und nacheinander 3 Punkte geworfen. Wie groß ist die Wahrscheinlichkeit, dass die Koordinate des dritten Punktes größer ist, als die der beiden ersten?

## Das Modell:

Gegeben sei zwei statistische Größen.

Typischerweise ist eine davon diskret (d.h.  $k \in K$ ) und heißt „Klasse“.

Die andere ist allgemein (sehr oft kontinuierlich, d.h.  $x \in \mathbb{R}^n$ ) und heißt „Beobachtung“.

„Gegeben“ sei die Verbundwahrscheinlichkeitsverteilung  $p(x, k)$ .

Da die  $k$  diskret ist, wird oft  $p(x, k)$  durch  $p(x, k) = p(k) \cdot p(x|k)$  spezifiziert.

## Die Erkennungsaufgabe:

man beobachtet  $x$ , man sage etwas über  $k$

– „welche Klasse hat die Beobachtung  $x$  verursacht“.

Schwierigkeiten (Fragen):

- Wie ist  $k$  anhand der  $x$  zu wählen?
- Die Wahrscheinlichkeitsverteilung ist oft nicht explizit angegeben  
→ dafür sorgen, dass das eine Wahrscheinlichkeitsverteilung ist.
- Die Menge  $K$  ist manchmal sehr groß (erinnere an Hopfield-Netze).

## Das Lernen:

Das Wahrscheinlichkeitsmodell ist oft bis auf unbekannte freie Parameter definiert.

Wie sind diese zu wählen?