

*Stochastik I*  
Gliederung zur Vorlesung  
im Sommersemester 2009

Markus Reiß  
Humboldt-Universität zu Berlin

Vorläufige Version vom 17. Juli 2009

## Inhaltsverzeichnis

<b>1</b>	<b>Wahrscheinlichkeitsräume</b>	<b>1</b>
1.1	Ereignisse und Wahrscheinlichkeiten . . . . .	1
1.2	Wahrscheinlichkeitsmaße im $\mathbb{R}^d$ . . . . .	3
1.3	Bedingte Wahrscheinlichkeiten und Unabhängigkeit . . . . .	5
<b>2</b>	<b>Zufallsvariablen und ihre Momente</b>	<b>7</b>
2.1	Zufallsvariablen und ihre Verteilungen . . . . .	7
2.2	Erwartungswert, Varianz und Kovarianz . . . . .	9
2.3	Mehrdimensionale Normalverteilung . . . . .	13
<b>3</b>	<b>Einführung in statistische Tests</b>	<b>13</b>
3.1	Hypothesentests . . . . .	13
3.2	Der $\chi^2$ -Anpassungstest . . . . .	15
<b>4</b>	<b>Grenzwertsätze</b>	<b>16</b>
4.1	Gesetze der großen Zahlen . . . . .	16
4.2	Der zentrale Grenzwertsatz . . . . .	17
4.3	Asymptotik der empirischen Verteilung . . . . .	18
<b>5</b>	<b>Einführung in die Schätztheorie</b>	<b>18</b>

Markus Reiß  
Vorlesung  
*Stochastik I*  
Sommersemester 2009



## Ein paar Literaturempfehlungen

- Hans-Otto Georgii, *Stochastik*, de Gruyter: exzellentes Lehrbuch inkl. Maßtheorie, verfügbar als E-Book: <http://www.reference-global.com/isbn/978-3-11-019349-7>
- Ulrich Krengel, *Einführung in die Wahrscheinlichkeitstheorie und Statistik*, Vieweg: Klassiker mit vielen Beispielen und Diskussionen, ohne Maßtheorie
- Herold Dehling, Beate Haupt, *Einführung in die Wahrscheinlichkeitstheorie und Statistik*, Springer: Lehrbuch mit vielen erklärenden Skizzen und Diagrammen, ohne Maßtheorie
- William Feller, *An introduction to probability theory and its applications I*, Wiley: das alte Testament, eine Fundgrube, immer noch Standardreferenz
- Kai Lai Chung, *A Course in Probability Theory*, Academic Press: Englisch-sprachiges Standardwerk, besonders empfehlenswert für char. Funktionen und Konvergenzresultate
- Achim Klenke, *Wahrscheinlichkeitstheorie*, Springer: Lehrbuch für Stochastik I und II, aus Vorlesungen entstanden
- Jürgen Elstrodt, *Maß- und Integrationstheorie*, Springer: mit viel Liebe und historischen Anmerkungen verfasstes, ausführliches Maßtheoriebuch
- Heinz Bauer, *Wahrscheinlichkeitstheorie*, de Gruyter: umfassendes deutsches Standardwerk, auf dem Maßtheoriebuch des Autors aufbauend
- Albert N. Shiryaev, *Probability*, Springer: umfassendes Lehrbuch, gut als Nachschlagewerk für Stochastik I und II
- Jean Jacod, Philip Protter, *Probability Essentials*, Springer: alle wichtigen Ergebnisse auf hohem Niveau, kurz und knapp
- John A. Rice, *Mathematical Statistics and Data Analysis*, Thomson: gutes einführendes Lehrbuch in die mathematische Statistik, viele Beispiele
- Jun Shao, *Mathematical Statistics*, Springer: deckt weite Themen der math. Statistik ab, gut für den Überblick und zum Nachschlagen

# 1 Wahrscheinlichkeitsräume

## 1.1 Ereignisse und Wahrscheinlichkeiten

**1.1 Definition.** Mit  $\Omega$  werde die nichtleere Menge der möglichen Versuchsausgänge oder Ergebnismenge bezeichnet. Ein Teilmengensystem  $\mathcal{F} \subseteq \mathcal{P}(\Omega)$  heißt Menge der interessierenden Ereignisse oder mathematisch  $\sigma$ -Algebra, falls gilt:

- (a)  $\Omega \in \mathcal{F}$ ;
- (b)  $A \in \mathcal{F} \Rightarrow A^c \in \mathcal{F}$ ;
- (c)  $A_n \in \mathcal{F}, n \in \mathbb{N} \Rightarrow \bigcup_{n \in \mathbb{N}} A_n \in \mathcal{F}$ .

Die Elemente von  $\mathcal{F}$  heißen Ereignisse. Ein Wahrscheinlichkeitsmaß  $P$  (auch Wahrscheinlichkeitsverteilung genannt) auf  $\mathcal{F}$  ist eine Abbildung  $P : \mathcal{F} \rightarrow [0, 1]$  mit

- (a)  $P(\Omega) = 1$  (Normierung);
- (b) für  $A_n \in \mathcal{F}, n \in \mathbb{N}$ , paarweise disjunkt gilt

$$P\left(\bigcup_{n \in \mathbb{N}} A_n\right) = \sum_{n \in \mathbb{N}} P(A_n) \text{ (\sigma-Additivitat).}$$

Ein Wahrscheinlichkeitsraum ist ein Tripel  $(\Omega, \mathcal{F}, P)$ , bestehend aus einer Ergebnismenge  $\Omega$ , einer  $\sigma$ -Algebra  $\mathcal{F}$  über  $\Omega$  sowie einem Wahrscheinlichkeitsmaß  $P$  auf  $\mathcal{F}$ .

**1.2 Lemma.** Für jede  $\sigma$ -Algebra  $\mathcal{F}$  gilt:

- (a)  $\emptyset \in \mathcal{F}$ ;
- (b)  $A_1, A_2 \in \mathcal{F} \Rightarrow A_1 \cup A_2 \in \mathcal{F}$ ;
- (c)  $A_n \in \mathcal{F}, n \in \mathbb{N} \Rightarrow \bigcap_{n \in \mathbb{N}} A_n, A_1 \cap A_2 \in \mathcal{F}$ .

**1.3 Lemma.** Für jedes Wahrscheinlichkeitsmaß  $P : \mathcal{F} \rightarrow [0, 1]$  gilt:

- (a)  $P(\emptyset) = 0$ ;
- (b)  $A, B \in \mathcal{F}, A \subseteq B \Rightarrow P(A) \leq P(B)$ ;
- (c)  $\forall A, B \in \mathcal{F} : P(A \cup B) = P(A) + P(B) - P(A \cap B)$ ;
- (d)  $\forall A_n \in \mathcal{F}, n \geq 1 : P(\bigcup_{n \geq 1} A_n) \leq \sum_{n \geq 1} P(A_n)$  (Subadditivitat);
- (e) Für  $A_n \in \mathcal{F}, n \geq 1$ , mit  $A_n \uparrow A$  (d.h.  $A_n \subseteq A_{n+1}, \bigcup_n A_n = A$ ) gilt  $P(A) = \lim_{n \rightarrow \infty} P(A_n)$  ( $\sigma$ -Stetigkeit).

**1.4 Definition.** Ist  $\Omega$  eine endliche oder abzahlbar unendliche Menge und  $P$  ein Wahrscheinlichkeitsmaß auf  $\mathcal{F} = \mathcal{P}(\Omega)$ , so heißt  $(\Omega, \mathcal{F}, P)$  diskreter Wahrscheinlichkeitsraum.

### 1.5 Lemma.

- (a) Ist  $(\Omega, \mathcal{F}, P)$  ein diskreter Wahrscheinlichkeitsraum, so ist  $P$  eindeutig durch seine Zähldichte  $p : \Omega \rightarrow [0, 1]$  mit  $p(\omega) := P(\{\omega\})$  festgelegt.
- (b) Ist andererseits  $\Omega$  eine endliche oder abzählbar unendliche Menge und besitzt  $p : \Omega \rightarrow [0, 1]$  die Eigenschaft  $\sum_{\omega \in \Omega} p(\omega) = 1$ , so wird durch

$$P(A) := \sum_{\omega \in A} p(\omega), \quad A \subseteq \Omega,$$

ein Wahrscheinlichkeitsmaß  $P$  auf  $\mathcal{F} = \mathcal{P}(\Omega)$  definiert, dessen Zähldichte  $p$  ist.

**1.6 Definition.** Folgende Zähldichten beschreiben wichtige Verteilungen:

**Laplace-/Gleich-Verteilung:**  $p_{Lap(\Omega)}(\omega) = \frac{1}{|\Omega|}$ ,  $\omega \in \Omega$ , für  $|\Omega| < \infty$ ;

**hypergeometrische Verteilung:** Parameter  $0 \leq n \leq N$ ,  $0 \leq W \leq N$

$$p_{HyP(N,W,n)}(w) = \frac{\binom{N-W}{n-w} \binom{W}{w}}{\binom{N}{n}}, \quad w \in \{0, \dots, W\}.$$

**Bernoulli-Schema:** Länge  $n \in \mathbb{N}$ , Erfolgswahrscheinlichkeit  $p \in [0, 1]$

$$p_{Bern(n,p)}(\omega) = p^{\sum_{i=1}^n \omega_i} (1-p)^{n-\sum_{i=1}^n \omega_i}, \quad \omega = (\omega_1, \dots, \omega_n) \in \{0, 1\}^n.$$

**Binomialverteilung:** Länge  $n \in \mathbb{N}$ , Erfolgswahrscheinlichkeit  $p \in [0, 1]$

$$p_{Bin(n,p)}(k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k \in \{0, 1, \dots, n\}.$$

**Geometrische Verteilung:** Erfolgswahrscheinlichkeit  $p \in (0, 1]$

$$p_{Geo(p)}(k) = (1-p)^{k-1} p, \quad k \in \mathbb{N}.$$

**Poissonverteilung:** Parameter  $\lambda > 0$

$$p_{Pois(\lambda)}(k) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k \in \mathbb{N}_0.$$

**1.7 Satz** (Poissonscher Grenzwertsatz). *Es seien  $p_n \in [0, 1]$  gegeben mit  $\lim_{n \rightarrow \infty} np_n = \lambda > 0$ . Dann gilt für alle  $k \in \mathbb{N}_0$*

$$\lim_{n \rightarrow \infty} p_{Bin(n,p_n)}(k) = p_{Pois(\lambda)}(k).$$

**1.8 Satz** (Vitali, 1903). *Sei  $\Omega = \{0, 1\}^{\mathbb{N}}$  der Ergebnisraum des unendlich oft wiederholten Münzwurfs. Dann gibt es kein Wahrscheinlichkeitsmaß  $P$  auf der Potenzmenge  $\mathcal{P}(\omega)$ , das folgender Invarianzeigenschaft genügt:*

$$\forall A \subseteq \Omega, n \in \mathbb{N} : P(T_n(A)) = P(A),$$

wobei  $T_n(\omega) = T_n(\omega_1, \omega_2, \dots) = (\omega_1, \dots, \omega_{n-1}, 1 - \omega_n, \omega_{n+1}, \dots)$  das Ergebnis des  $n$ -ten Wurfs umkehrt.

## 1.2 Wahrscheinlichkeitsmaße im $\mathbb{R}^d$

**1.9 Lemma.** Es sei  $\mathcal{E} \subseteq \mathcal{P}(\Omega)$  ein System von Teilmengen von  $\Omega$ . Dann gibt es eine kleinste  $\sigma$ -Algebra  $\mathcal{F}$ , die  $\mathcal{E}$  enthält.

**1.10 Definition.** In der Situation des vorigen Lemmas sagt man, dass die  $\sigma$ -Algebra  $\mathcal{F}$  von  $\mathcal{E}$  erzeugt wird.  $\mathcal{E}$  heißt Erzeuger von  $\mathcal{F}$  und man schreibt  $\mathcal{F} = \sigma(\mathcal{E})$ .

**1.11 Definition.** Es sei  $(S, d)$  ein metrischer Raum. Dann heißt  $\mathfrak{B}_S := \sigma(\{O \subseteq S \mid O \text{ offen}\})$  Borel- $\sigma$ -Algebra über  $S$ .

### 1.12 Satz.

(a) Die Borel- $\sigma$ -Algebra  $\mathfrak{B}_{\mathbb{R}}$  über  $\mathbb{R}$  wird auch erzeugt von folgenden Mengensystemen:

- (i)  $\mathcal{E}_1 := \{(a, b) \mid a, b \in \mathbb{R}\}$ ;
- (ii)  $\mathcal{E}_2 := \{[a, b] \mid a, b \in \mathbb{R}\}$ ;
- (iii)  $\mathcal{E}_3 := \{(a, b] \mid a, b \in \mathbb{R}\}$ ;
- (iv)  $\mathcal{E}_4 := \{(-\infty, b] \mid b \in \mathbb{R}\}$ ;
- (v)  $\mathcal{E}_5 := \{(-\infty, b) \mid b \in \mathbb{R}\}$ .

(b) Die Borel- $\sigma$ -Algebra  $\mathfrak{B}_{\mathbb{R}^d}$  über  $\mathbb{R}^d$  wird auch erzeugt von folgenden Mengensystemen:

- (i)  $\mathcal{E}_1^d := \{(a_1, b_1) \times \cdots \times (a_d, b_d) \mid a_k, b_k \in \mathbb{R}, k = 1, \dots, d\}$ ;
- (ii)  $\mathcal{E}_2^d := \{[a_1, b_1] \times \cdots \times [a_d, b_d] \mid a_k, b_k \in \mathbb{R}, k = 1, \dots, d\}$ ;
- (iii)  $\mathcal{E}_3^d := \{(a_1, b_1] \times \cdots \times (a_d, b_d] \mid a_k, b_k \in \mathbb{R}, k = 1, \dots, d\}$ ;
- (iv)  $\mathcal{E}_4^d := \{(-\infty, b_1] \times \cdots \times (-\infty, b_d] \mid b_k \in \mathbb{R}, k = 1, \dots, d\}$ ;
- (v)  $\mathcal{E}_5^d := \{(-\infty, b_1) \times \cdots \times (-\infty, b_d) \mid b_k \in \mathbb{R}, k = 1, \dots, d\}$ .

**1.13 Definition.** Es sei  $\Omega$  eine nichtleere Menge. Dann heißt  $\mathcal{A} \subseteq \mathcal{P}(\Omega)$  Algebra über  $\Omega$ , falls gilt:

- (a)  $\Omega \in \mathcal{A}$ ;
- (b)  $A \in \mathcal{A} \Rightarrow A^c \in \mathcal{A}$ ;
- (c)  $A, B \in \mathcal{A} \Rightarrow A \cup B \in \mathcal{A}$ .

Eine Abbildung  $\mu : \mathcal{A} \rightarrow [0, \infty]$  heißt Prämaß über  $\mathcal{A}$ , falls

- (a)  $\mu(\emptyset) = 0$ ;
- (b) für  $A_n \in \mathcal{A}$ ,  $n \in \mathbb{N}$ , paarweise disjunkt mit  $\bigcup_n A_n \in \mathcal{A}$  gilt

$$\mu\left(\bigcup_{n \in \mathbb{N}} A_n\right) = \sum_{n \in \mathbb{N}} \mu(A_n) \quad (\sigma\text{-Additivität}).$$

$\mu$  heißt Maß, falls  $\mathcal{A}$  bereits eine  $\sigma$ -Algebra ist. Ein Maß  $\mu$  heißt  $\sigma$ -endlich, falls es  $A_n \in \mathcal{A}$ ,  $n \in \mathbb{N}$ , gibt mit  $\mu(A_n) < \infty$  und  $\Omega = \bigcup_n A_n$ . Konsistent mit obiger Definition heißt ein Maß  $\mu$  Wahrscheinlichkeitsmaß, falls  $\mu(\Omega) = 1$  gilt.

**1.14 Satz** (Maßerweiterungssatz von Carathéodory, 1917). *Jedes Prämaß  $\mu$  auf einer Algebra  $\mathcal{A}$  kann zu einem Maß  $\tilde{\mu}$  auf der von  $\mathcal{A}$  erzeugten  $\sigma$ -Algebra  $\mathcal{F} = \sigma(\mathcal{A})$  fortgesetzt werden, d.h.  $\tilde{\mu}$  ist ein Maß auf  $\mathcal{F}$  mit  $\tilde{\mu}(A) = \mu(A)$  für alle  $A \in \mathcal{A}$ .*

**1.15 Satz** (Eindeutigkeitsatz). *Es seien  $\mu$  und  $\nu$   $\sigma$ -endliche Maße auf  $(\Omega, \mathcal{F})$  und es gebe  $A_n \in \mathcal{F}$ ,  $n \in \mathbb{N}$ , mit  $\mu(A_n) = \nu(A_n) < \infty$  und  $\bigcup_n A_n = \Omega$ . Stimmen  $\mu$  und  $\nu$  auf einem Erzeuger  $\mathcal{E}$  von  $\mathcal{F}$  überein, der in dem Sinne  $\cap$ -stabil ist, dass  $A, B \in \mathcal{E} \Rightarrow A \cap B \in \mathcal{E}$  gilt, so stimmen  $\mu$  und  $\nu$  auf der ganzen  $\sigma$ -Algebra  $\mathcal{F}$  überein. Insbesondere ist ein Wahrscheinlichkeitsmaß durch seine Werte auf einem  $\cap$ -stabilen Erzeuger eindeutig festgelegt.*

**1.16 Lemma.** *Es sei  $\mu$  ein Maß auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ . Dann ist*

$$F(x) := \begin{cases} \mu((0, x]), & x > 0 \\ 0, & x = 0 \\ -\mu((x, 0]), & x < 0 \end{cases}$$

*eine monoton wachsende, rechtsstetige Funktion.*

**1.17 Definition.** Für ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  ist die zugehörige Verteilungsfunktion gegeben durch  $F(x) := P((-\infty, x])$ ,  $x \in \mathbb{R}$ .

**1.18 Korollar.** *Jede Verteilungsfunktion  $F$  ist monoton wachsend, rechtsstetig und erfüllt  $\lim_{x \rightarrow -\infty} F(x) = 0$ ,  $\lim_{x \rightarrow \infty} F(x) = 1$ .*

**1.19 Satz.** *Es sei  $F : \mathbb{R} \rightarrow \mathbb{R}$  eine monoton wachsende, rechtsstetige Funktion. Dann existiert ein Maß  $\mu$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit*

$$\mu((a, b]) = F(b) - F(a), \quad a, b \in \mathbb{R}.$$

*$\mu$  ist eindeutig durch  $F$  definiert und heißt Lebesgue-Stieltjes-Maß zu  $F$ .*

**1.20 Korollar.** *Es gibt genau ein Maß  $\lambda$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit  $\lambda((a, b]) = b - a$ , das Lebesguemaß.*

**1.21 Korollar.** *Ist  $F : \mathbb{R} \rightarrow [0, 1]$  monoton wachsend und rechtsstetig mit  $\lim_{x \rightarrow -\infty} F(x) = 0$ ,  $\lim_{x \rightarrow \infty} F(x) = 1$ , so existiert genau ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit  $P((a, b]) = F(b) - F(a)$  für alle  $a < b$ . Insbesondere ist  $F$  die Verteilungsfunktion von  $P$ .*

**1.22 Definition.** Ist  $f : \mathbb{R}^d \rightarrow [0, \infty)$  eine (Lebesgue-)integrierbare Funktion mit  $\int_{\mathbb{R}^d} f(x) dx = 1$ , so heißt  $f$  Wahrscheinlichkeitsdichte oder kurz Dichte auf  $\mathbb{R}^d$ .

**1.23 Korollar.** *Jede Wahrscheinlichkeitsdichte  $f$  auf  $\mathbb{R}$  erzeugt mittels*

$$P_f((a, b]) = \int_a^b f(x) dx, \quad a, b \in \mathbb{R}, a < b,$$

*ein eindeutiges Wahrscheinlichkeitsmaß  $P_f$  auf  $\mathfrak{B}_{\mathbb{R}}$ .*

**1.24 Definition.** Folgende Wahrscheinlichkeitsdichten beschreiben wichtige Verteilungen auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ :

**Gleichverteilung:**  $f_{U(G)}(x) = \frac{1}{\lambda(G)} \mathbf{1}_G(x)$  für  $G \in \mathfrak{B}_{\mathbb{R}}$  mit Lebesguemaß  $\lambda(G) \in (0, \infty)$ ;

**Exponentialverteilung:**  $f_{Exp(\lambda)}(x) = \lambda e^{-\lambda x} \mathbf{1}_{\mathbb{R}^+}(x)$  mit Parameter  $\lambda > 0$ ;

**Normalverteilung:**  $f_{N(\mu, \sigma^2)}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$  mit Parametern  $\mu \in \mathbb{R}$ ,  $\sigma > 0$ .

**1.25 Lemma.**

- (a) Ist  $f$  die Dichte eines Wahrscheinlichkeitsmaßes  $P$  auf  $\mathfrak{B}_{\mathbb{R}}$  mit Verteilungsfunktion  $F$ , so gilt  $F(x) = \int_{-\infty}^x f(y) dy$  für alle  $x \in \mathbb{R}$ .
- (b) Ist die Verteilungsfunktion  $F$  eines Wahrscheinlichkeitsmaßes  $P$  auf  $\mathfrak{B}_{\mathbb{R}}$  differenzierbar, so ist  $f(x) := F'(x)$  die zugehörige Wahrscheinlichkeitsdichte.

**1.26 Satz.** Jede Wahrscheinlichkeitsdichte  $f$  auf  $\mathbb{R}^d$  erzeugt mittels

$$P_f((a_1, b_1] \times \cdots \times (a_d, b_d]) = \int_{a_1}^{b_1} \cdots \int_{a_d}^{b_d} f(x_1, \dots, x_d) dx_d \cdots dx_1$$

für  $a_k, b_k \in \mathbb{R}$  mit  $a_k < b_k$  ein eindeutiges Wahrscheinlichkeitsmaß  $P_f$  auf  $\mathfrak{B}_{\mathbb{R}^d}$ .

**1.27 Definition.** Sind  $f_1, \dots, f_d$  Wahrscheinlichkeitsdichten auf  $\mathbb{R}$ , so heißt

$$f(x_1, \dots, x_d) = \prod_{k=1}^d f_k(x_k), \quad x_1, \dots, x_d \in \mathbb{R},$$

Produktdichte der  $(f_k)_{k=1, \dots, d}$  im  $\mathbb{R}^d$ . Insbesondere ist die  $d$ -dimensionale Standard-Normalverteilung  $N(0, E_d)$  im  $\mathbb{R}^d$  definiert über die Dichte

$$f(x) = (2\pi)^{-d/2} e^{-|x|^2/2}, \quad x \in \mathbb{R}^d, \quad \text{mit } |x|^2 = \sum_{i=1}^d x_i^2.$$

### 1.3 Bedingte Wahrscheinlichkeiten und Unabhängigkeit

**1.28 Definition.** Es seien  $A$  und  $B$  Ereignisse mit  $P(B) > 0$ . Dann wird mit

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

die bedingte Wahrscheinlichkeit von  $A$  gegeben (oder: unter)  $B$  bezeichnet.

**1.29 Satz.** Auf dem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P)$  sei  $B$  ein Ereignis mit  $P(B) > 0$ . Dann gilt:

- (a) Durch  $Q(A) := P(A | B)$  wird ein Wahrscheinlichkeitsmaß  $Q$  auf  $\mathcal{F}$  definiert.

(b) (Formel von der totalen Wahrscheinlichkeit) Es sei  $B = \bigcup_{i=1}^N B_i$  Vereinigung paarweise disjunkter Ereignisse  $B_i$  mit  $P(B_i) > 0$ . Dann folgt für jedes Ereignis  $A$

$$P(A \cap B) = \sum_{i=1}^N P(B_i)P(A | B_i).$$

(c) (Bayesformel) Für jedes Ereignis  $A$  und jede Zerlegung  $\Omega = \bigcup_{i=1}^N B_i$  von  $\Omega$  in paarweise disjunkte Ereignisse  $B_i$  mit  $P(B_i) > 0$  gilt

$$P(B_i | A) = \frac{P(B_i)P(A | B_i)}{\sum_{j=1}^N P(B_j)P(A | B_j)}.$$

In (b) und (c) kann auch  $N = \infty$  gesetzt werden.

**1.30 Lemma** (Multiplikationsformel/Pfadregel). Für Ereignisse  $A_1, \dots, A_n$  mit  $P(A_1 \cap \dots \cap A_{n-1}) > 0$  gilt

$$P(A_1 \cap \dots \cap A_n) = P(A_1)P(A_2 | A_1)P(A_3 | A_1 \cap A_2) \cdots P(A_n | A_1 \cap \dots \cap A_{n-1}).$$

**1.31 Definition.**

- (a) Zwei Ereignisse  $A$  und  $B$  heißen (stochastisch) unabhängig (unter  $P$ ), falls  $P(A \cap B) = P(A)P(B)$  gilt.
- (b) Eine Familie  $(A_i)_{i \in I}$  von Ereignissen,  $I \neq \emptyset$  beliebige Indexmenge, heißt (stochastisch) unabhängig, falls für jede endliche Teilmenge  $J \subseteq I$  gilt

$$P\left(\bigcap_{j \in J} A_j\right) = \prod_{j \in J} P(A_j).$$

**1.32 Definition.** Für eine Folge  $(A_n)_{n \geq 1}$  von Ereignissen setze

$$\limsup_{n \rightarrow \infty} A_n := \bigcap_{m \geq 1} \bigcup_{n \geq m} A_n = \{\omega \in \Omega \mid \omega \in A_n \text{ für unendlich viele } n\},$$

$$\liminf_{n \rightarrow \infty} A_n := \bigcup_{m \geq 1} \bigcap_{n \geq m} A_n = \{\omega \in \Omega \mid \omega \in A_n \text{ für alle, bis auf endlich viele } n\}.$$

**1.33 Satz** (Lemma von Borel-Cantelli). Für eine Folge  $(A_n)_{n \geq 1}$  von Ereignissen gilt:

- (a) Aus  $\sum_{n \geq 1} P(A_n) < \infty$  folgt  $P(\limsup_{n \rightarrow \infty} A_n) = 0$ .
- (b) Gilt  $\sum_{n \geq 1} P(A_n) = \infty$  und ist die Folge  $(A_n)_{n \geq 1}$  unabhängig, so folgt  $P(\limsup_{n \rightarrow \infty} A_n) = 1$ .

**1.34 Definition.** Es seien  $\mathcal{M}_i \subseteq \mathcal{F}$ ,  $i \in I$ , Mengen von Ereignissen. Dann heißt  $(\mathcal{M}_i)_{i \in I}$  unabhängig, falls für jede beliebige Auswahl von Ereignissen  $A_i \in \mathcal{M}_i$  die Familie  $(A_i)_{i \in I}$  unabhängig ist.

**1.35 Lemma.** Sind  $(A_i)_{i \in I}$  unabhängige Ereignisse, so sind auch die erzeugten  $\sigma$ -Algebren  $\mathcal{F}_i := \{\emptyset, \Omega, A_i, A_i^c\}$ ,  $i \in I$ , unabhängig.

## 2 Zufallsvariablen und ihre Momente

### 2.1 Zufallsvariablen und ihre Verteilungen

**2.1 Definition.** Es sei  $(\Omega, \mathcal{F}, P)$  ein Wahrscheinlichkeitsraum und  $(S, \mathcal{S})$  ein Messraum. Dann heißt eine Funktion  $g : \Omega \rightarrow S$  messbar (bzgl.  $(\mathcal{F}, \mathcal{S})$ ), falls

$$\forall A \in \mathcal{S} : g^{-1}(A) \in \mathcal{F}$$

gilt. Jede solche messbare Funktion heißt  $(S, \mathcal{S})$ -wertige Zufallsvariable. Für  $S = \mathbb{R}^d$  wird kanonisch  $\mathcal{S} = \mathfrak{B}_{\mathbb{R}^d}$  gewählt, und man spricht bloß von einer Zufallsvariablen ( $d = 1$ ) bzw. einem Zufallsvektor ( $d \geq 2$ ).

Die Verteilung einer  $(S, \mathcal{S})$ -wertigen Zufallsvariablen  $X$  ist das Wahrscheinlichkeitsmaß (!)

$$P^X(A) := P(X \in A) = P(X^{-1}(A)), \quad A \in \mathcal{S}.$$

Die Verteilung  $P^X$  von  $X$  ist also das Bildmaß von  $P$  unter  $X$ . Mit der Verteilungsfunktion (Dichte, Zähldichte) von  $X$  meinen wir stets die zu  $P^X$  gehörige Größe.

Wir schreiben kurz  $\{X \in A\} := \{\omega \in \Omega \mid X(\omega) \in A\}$ ,  $\{X = x\} := \{\omega \in \Omega \mid X(\omega) = x\}$ ,  $P(X \in A) := P(\{X \in A\})$ ,  $P(X = x) := P(\{X = x\})$  etc.

**2.2 Lemma.** Eine Funktion  $g : \Omega \rightarrow S$  ist bereits  $(\mathcal{F}, \mathcal{S})$ -messbar, falls für einen Erzeuger  $\mathcal{E}$  von  $\mathcal{S}$  gilt

$$\forall A \in \mathcal{E} : g^{-1}(A) \in \mathcal{F}.$$

### 2.3 Korollar.

- (a) Jede stetige Funktion  $g : S \rightarrow T$  zwischen metrischen Räumen  $(S, d_S)$  und  $(T, d_T)$  ist Borel-messbar, d.h.  $(\mathfrak{B}_S, \mathfrak{B}_T)$ -messbar.
- (b) Jede Funktion  $g : \Omega \rightarrow \mathbb{R}$  mit  $\{g \leq y\} \in \mathcal{F}$  für alle  $y \in \mathbb{R}$  ist  $(\mathcal{F}, \mathfrak{B}_{\mathbb{R}})$ -messbar.
- (c) Falls  $g_n : \Omega \rightarrow \mathbb{R}$   $(\mathcal{F}, \mathfrak{B}_{\mathbb{R}})$ -messbar sind für alle  $n \geq 1$ , so auch  $\inf_n g_n$ ,  $\sup_n g_n$ ,  $\limsup_n g_n$ ,  $\liminf_n g_n$ , sofern diese Funktionen endlich sind. Falls der punktweise Grenzwert  $\lim_n g_n$  überall existiert, so ist auch dieser  $(\mathcal{F}, \mathfrak{B}_{\mathbb{R}})$ -messbar.
- (d) Sind  $g_1, \dots, g_d : \Omega \rightarrow \mathbb{R}$   $(\mathcal{F}, \mathfrak{B}_{\mathbb{R}})$ -messbar und ist  $h : \mathbb{R}^d \rightarrow \mathbb{R}^k$  Borel-messbar, so ist  $\omega \mapsto h(g_1(\omega), \dots, g_d(\omega))$   $(\mathcal{F}, \mathfrak{B}_{\mathbb{R}^k})$ -messbar; insbesondere sind also messbar:  $(g_1, \dots, g_d)$ ,  $g_1 + g_2$ ,  $g_1 - g_2$ ,  $g_1 \bullet g_2$ ,  $g_1/g_2$  (falls überall wohldefiniert),  $\max(g_1, g_2)$ ,  $\min(g_1, g_2)$ .
- (e) Ist  $g : \Omega \rightarrow S$   $(\mathcal{F}, \mathcal{S})$ -messbar und  $h : S \rightarrow T$   $(\mathcal{S}, \mathcal{T})$ -messbar, so ist die Komposition  $h \circ g$   $(\mathcal{F}, \mathcal{T})$ -messbar.

**2.4 Definition.** Eine Familie  $(X_i)_{i \in I}$  von  $(S_i, \mathcal{S}_i)$ -wertigen Zufallsvariablen heißt unabhängig, falls für jede beliebige Wahl von  $A_i \in \mathcal{S}_i$  die Familie von Ereignissen  $(\{X_i \in A_i\})_{i \in I}$  unabhängig ist.

**2.5 Satz.** Es seien  $(X_i)_{i \in I}$  eine Familie von Zufallsvariablen mit Werten in  $(S_i, \mathcal{S}_i)$  und  $\mathcal{E}_i \cap$ -stabile Erzeuger von  $\mathcal{S}_i$ . Dann ist  $(X_i)_{i \in I}$  bereits unabhängig, falls  $(\{X_i \in A_i\})_{i \in I}$  unabhängig ist für beliebige  $A_i \in \mathcal{E}_i$ .

**2.6 Korollar.** Es seien  $X_1, \dots, X_n$  Zufallsvariablen auf  $(\Omega, \mathcal{F}, P)$ .

(a) Hat jedes  $X_k$  Werte in  $(S_k, \mathcal{P}(S_k))$  mit abzählbarem  $S_k$  (diskreter Fall), so sind  $X_1, \dots, X_n$  genau dann unabhängig, wenn gilt

$$P(X_1 = s_1, \dots, X_n = s_n) = \prod_{k=1}^n P(X_k = s_k) \text{ für alle } s_k \in S_k.$$

(b) Hat jedes  $X_k$  Werte in  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ , so sind  $X_1, \dots, X_n$  genau dann unabhängig, wenn gilt

$$P(X_1 \leq b_1, \dots, X_n \leq b_n) = \prod_{k=1}^n P(X_k \leq b_k) \text{ für alle } b_k \in \mathbb{R}.$$

**2.7 Satz.** Es sei  $X = (X_1, \dots, X_n)$  ein Zufallsvektor auf  $(\Omega, \mathcal{F}, P)$  mit Dichte  $f^X : \mathbb{R}^n \rightarrow [0, \infty)$ . Dann gilt

(a) Jedes  $X_k$  besitzt eine Dichte, die sogenannte Randdichte

$$f^{X_k}(x_k) := \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, \dots, x_n) dx_1 \dots dx_{k-1} dx_{k+1} \dots dx_n, \quad x_k \in \mathbb{R}.$$

(b) Die Zufallsvariablen  $X_1, \dots, X_n$  sind genau dann unabhängig, wenn gilt

$$f^X(x_1, \dots, x_n) = \prod_{k=1}^n f^{X_k}(x_k) \text{ für Lebesgue-fast alle } x_1, \dots, x_n \in \mathbb{R}.$$

**2.8 Definition.** Es seien  $(\Omega_k, \mathcal{F}_k, P_k)$ ,  $1 \leq k \leq n$ , Wahrscheinlichkeitsräume. Setze  $\Omega := \Omega_1 \times \dots \times \Omega_n$  und definiere über  $\Omega$  die Produkt- $\sigma$ -Algebra

$$\mathcal{F} := \mathcal{F}_1 \otimes \dots \otimes \mathcal{F}_n := \sigma(\{A_1 \times \dots \times A_n \mid A_1 \in \mathcal{F}_1, \dots, A_n \in \mathcal{F}_n\}).$$

Gilt für ein Wahrscheinlichkeitsmaß  $P$  auf  $\mathcal{F}$

$$\forall A_1 \in \mathcal{F}_1, \dots, A_n \in \mathcal{F}_n : P(A_1 \times \dots \times A_n) = \prod_{k=1}^n P_k(A_k),$$

so heißt  $P$  Produktmaß, Schreibweise  $P = P_1 \otimes \dots \otimes P_n$ .

**2.9 Lemma.** Ist  $(\Omega_1 \times \dots \times \Omega_n, \mathcal{F}_1 \otimes \dots \otimes \mathcal{F}_n, P_1 \otimes \dots \otimes P_n)$  ein Produkt-Wahrscheinlichkeitsraum, so sind die Koordinatenabbildungen  $\pi_k(\omega) = \pi_k(\omega_1, \dots, \omega_n) := \omega_k$ ,  $k = 1, \dots, n$ , unabhängige  $(\Omega_k, \mathcal{F}_k)$ -wertige Zufallsvariablen auf dem Produkt-Wahrscheinlichkeitsraum mit Verteilung  $P^{X_k} = P_k$ .

**2.10 Definition.** Es seien  $(\Omega_i, \mathcal{F}_i, P_i)_{i \in I}$ ,  $I$  beliebige Indexmenge, Wahrscheinlichkeitsräume. Setze  $\Omega := \prod_{i \in I} \Omega_i$  (kartesisches Produkt) und definiere mittels der Koordinatenprojektionen  $\pi_i : \Omega \rightarrow \Omega_i$  über  $\Omega$  die Produkt- $\sigma$ -Algebra

$$\mathcal{F} := \bigotimes_{i \in I} \mathcal{F}_i := \sigma \left( \bigcup_{i \in I} \{ \pi_i^{-1}(A_i) \mid A_i \in \mathcal{F}_i \} \right).$$

Gilt für ein Wahrscheinlichkeitsmaß  $P$  auf  $\mathcal{F}$

$$\forall J \subseteq I \text{ endlich, } A_i \in \mathcal{F}_i : P \left( \bigcap_{i \in J} \pi_i^{-1}(A_i) \right) = \prod_{i \in J} P_i(A_i),$$

so heißt  $P$  Produktmaß, Schreibweise  $P = \bigotimes_{i \in I} P_i$ .

**2.11 Satz.** *Ein solches Produktmaß existiert stets und ist eindeutig.*

**2.12 Korollar.** *Zu vorgegebenen Wahrscheinlichkeitsmaßen  $P_i$  auf  $(\Omega_i, \mathcal{F}_i)$ ,  $i \in I$ , existiert ein Wahrscheinlichkeitsraum mit einer Familie unabhängiger  $(\Omega_i, \mathcal{F}_i)$ -wertiger Zufallsvariablen  $(X_i)_{i \in I}$ , deren Verteilung  $P_i$  ist.*

**2.13 Definition.** Es sei  $(X_k)_{k \geq 1}$  eine Folge von Zufallsvariablen auf  $(\Omega, \mathcal{F}, P)$  mit Werten in  $(S_k, \mathcal{S}_k)$ . Ein Ereignis  $A \in \mathcal{F}$  heißt asymptotisch bezüglich  $(X_k)$ , falls es für alle  $n \geq 1$  nur von  $(X_k, k \geq n)$  abhängt in dem Sinne, dass  $A \in \mathcal{A}_X$  gilt. Hierbei ist die asymptotische  $\sigma$ -Algebra  $\mathcal{A}_X$  definiert als

$$\mathcal{A}_X := \bigcap_{n \geq 1} \sigma \left( \bigcup_{k \geq n} \{ \{X_k \in A_k\} \mid A_k \in \mathcal{S}_k \} \right).$$

**2.14 Satz** (0-1-Gesetz von Kolmogorov). *Es seien  $(X_k)_{k \geq 1}$  unabhängige Zufallsvariablen auf  $(\Omega, \mathcal{F}, P)$ . Dann gilt für jedes bezüglich  $(X_k)$  asymptotische Ereignis  $A$ :  $P(A) = 0$  oder  $P(A) = 1$ .*

**2.15 Lemma.** *Es seien  $(X_i)_{i \in I}$  eine Familie unabhängiger Zufallsvariablen mit Werten in  $(S_i, \mathcal{S}_i)$  und  $I = I_1 \cup I_2$  eine disjunkte Zerlegung von  $I$ . Dann sind die  $\sigma$ -Algebren  $\mathcal{F}_1 := \sigma(\bigcup_{i \in I_1} \{ \{X_i \in A_i\} \mid A_i \in \mathcal{S}_i \})$  und  $\mathcal{F}_2 := \sigma(\bigcup_{i \in I_2} \{ \{X_i \in A_i\} \mid A_i \in \mathcal{S}_i \})$  unabhängig.*

## 2.2 Erwartungswert, Varianz und Kovarianz

**2.16 Definition.** Eine reellwertige Zufallsvariable  $X$  auf  $(\Omega, \mathcal{F}, P)$  heißt einfach, falls sie nur endlich viele Werte annimmt, d.h es folgende Darstellung gibt:

$$X = \sum_{i=1}^m \alpha_i \mathbf{1}_{A_i} \text{ mit } m \in \mathbb{N}, \alpha_i \in \mathbb{R}, A_i \in \mathcal{F}.$$

Für eine solche Zufallsvariable definieren wir ihren Erwartungswert als

$$\mathbb{E}[X] := \sum_{i=1}^m \alpha_i P(A_i).$$

**2.17 Lemma.** *Für eine einfache Zufallsvariable  $X$  auf  $(\Omega, \mathcal{F}, P)$  gilt:*

(a)  $\mathbb{E}[X] = \sum_{x \in X(\Omega)} xP(X = x)$ ; insbesondere hängt der Erwartungswert nur von der Verteilung  $P^X$  von  $X$  ab.

(b) Der Erwartungswert ist linear und monoton: ist  $Y$  eine weitere einfache Zufallsvariable und sind  $\alpha, \beta \in \mathbb{R}$ , so gilt

$$\mathbb{E}[\alpha X + \beta Y] = \alpha \mathbb{E}[X] + \beta \mathbb{E}[Y];$$

aus  $X \leq Y$  (d.h.  $\forall \omega \in \Omega : X(\omega) \leq Y(\omega)$ ) folgt  $\mathbb{E}[X] \leq \mathbb{E}[Y]$ .

(c) Falls  $X$  und  $Y$  unabhängige einfache Zufallsvariablen sind, so gilt  $\mathbb{E}[X \cdot Y] = \mathbb{E}[X] \cdot \mathbb{E}[Y]$ .

(d) Für jedes  $A \in \mathcal{F}$  gilt  $\mathbb{E}[\mathbf{1}_A] = P(A)$ .

**2.18 Definition.** Es sei  $X \geq 0$  eine nichtnegative Zufallsvariable. Sind dann  $X_n$  einfache nichtnegative Zufallsvariablen mit  $X_n(\omega) \uparrow X(\omega)$  für  $n \rightarrow \infty$  und alle  $\omega \in \Omega$ , so definiere den Erwartungswert

$$\mathbb{E}[X] := \lim_{n \rightarrow \infty} \mathbb{E}[X_n] \in [0, +\infty]$$

(man kann zeigen, dass dies nicht von der Auswahl der  $X_n$  abhängt).

Betrachte nun auf dem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P)$  die Menge der Zufallsvariablen

$$\mathcal{L}^1 := \mathcal{L}^1(\Omega, \mathcal{F}, P) := \{X : \Omega \rightarrow \mathbb{R} \text{ messbar} \mid \mathbb{E}[|X|] < \infty\}.$$

Dann definiere für  $X \in \mathcal{L}^1$  mit  $X_+ := \max(X, 0)$ ,  $X_- := \max(-X, 0)$  den Erwartungswert als

$$\mathbb{E}[X] := \mathbb{E}[X_+] - \mathbb{E}[X_-] \in \mathbb{R}.$$

Man schreibt auch  $\mathbb{E}[X] = \int_{\mathbb{R}} x P^X(dx) = \int_{\Omega} X(\omega) P(d\omega)$  sowie  $\int_A X dP = \int_{\Omega} X(\omega) \mathbf{1}_A(\omega) P(d\omega)$  für  $A \in \mathcal{F}$ .

**2.19 Satz.** Für  $X \in \mathcal{L}^1(\Omega, \mathcal{F}, P)$  gilt:

(a)  $\mathbb{E}[X] = \int_{\mathbb{R}} x P^X(dx)$ ; insbesondere hängt der Erwartungswert nur von der Verteilung  $P^X$  von  $X$  ab.

(b) Der Erwartungswert ist linear und monoton: ist  $Y$  eine weitere Zufallsvariable in  $\mathcal{L}^1$  und sind  $\alpha, \beta \in \mathbb{R}$ , so gilt

$$\mathbb{E}[\alpha X + \beta Y] = \alpha \mathbb{E}[X] + \beta \mathbb{E}[Y];$$

aus  $X \leq Y$  folgt  $\mathbb{E}[X] \leq \mathbb{E}[Y]$ .

(c) Falls  $X, Y \in \mathcal{L}^1$  unabhängig sind, so gilt  $X \cdot Y \in \mathcal{L}^1$  und  $\mathbb{E}[X \cdot Y] = \mathbb{E}[X] \cdot \mathbb{E}[Y]$ .

**2.20 Korollar.**

(a) Ist  $X$  eine Zufallsvariable mit abzählbarem Wertebereich  $X(\Omega) \subseteq \mathbb{R}$ , so gilt  $X \in \mathcal{L}^1$  genau dann, wenn  $\sum_{x \in X(\Omega)} |x| P(X = x)$  endlich ist. In diesem Fall gilt für den Erwartungswert

$$\mathbb{E}[X] = \sum_{x \in X(\Omega)} x P(X = x).$$

(b) Ist  $X$  eine Zufallsvariable mit Dichte  $f^X : \mathbb{R} \rightarrow [0, \infty)$ , so gilt  $X \in \mathcal{L}^1$  genau dann, wenn  $\int_{\mathbb{R}} |x| f^X(x) dx$  endlich ist. In diesem Fall gilt für den Erwartungswert

$$\mathbb{E}[X] = \int_{\mathbb{R}} x f^X(x) dx.$$

**2.21 Satz.** Es seien  $X$  ein Zufallsvektor mit Dichte  $f^X : \mathbb{R}^d \rightarrow [0, \infty)$  sowie  $h : \mathbb{R}^d \rightarrow \mathbb{R}$  Borel-messbar. Dann gilt:

$$h(X) \in \mathcal{L}^1 \iff \int_{\mathbb{R}^d} |h(x)| f^X(x) dx < \infty.$$

In diesem Fall erhalten wir

$$\mathbb{E}[h(X)] = \int_{\mathbb{R}^d} h(x) f^X(x) dx.$$

**2.22 Definition.** Wir sagen, dass eine Zufallsvariable  $X$  in  $\mathcal{L}^p$  liegt für  $p > 0$ , falls  $|X|^p \in \mathcal{L}^1$ , also  $\mathbb{E}[|X|^p] < \infty$  gilt. Für  $X \in \mathcal{L}^p$  und  $p \in \mathbb{N}$  heißt  $\mathbb{E}[X^p]$  das  $p$ -te Moment von  $X$ .

**2.23 Lemma.** Für  $0 < p \leq q$  gilt  $\mathcal{L}^q \subseteq \mathcal{L}^p$ .

**2.24 Definition.** Für eine Zufallsvariable  $X \in \mathcal{L}^2$  bezeichnet

$$\text{Var}(X) := \mathbb{E}[(X - \mathbb{E}[X])^2]$$

die Varianz von  $X$ .  $\sigma(X) := \sqrt{\text{Var}(X)}$  heißt Standardabweichung von  $X$ .

**2.25 Satz** (Eigenschaften der Varianz). Für  $X, Y \in \mathcal{L}^2$  gilt:

- (a)  $\text{Var}(X) = 0 \iff P(X = \mathbb{E}[X]) = 1$ ;
- (b)  $\forall a, b \in \mathbb{R} : \text{Var}(aX + b) = a^2 \text{Var}(X)$ ;
- (c)  $\text{Var}(X) = \mathbb{E}[X^2] - \mathbb{E}[X]^2$ ;
- (d)  $\text{Var}(X + Y) \leq 2 \text{Var}(X) + 2 \text{Var}(Y)$ ;
- (e) falls  $X, Y$  unabhängig sind, so gilt  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .

**2.26 Satz** (Beste lineare Vorhersage). Es seien  $X, Y$  Zufallsvariablen in  $\mathcal{L}^2$  sowie

$$L_X := \{aX + b \mid a, b \in \mathbb{R}\} \subseteq \mathcal{L}^2$$

die Menge der auf linearen Funktionen von  $X$  basierenden Zufallsvariablen. Dann nimmt die mittlere quadratische Abweichung

$$\varphi : L_X \rightarrow [0, \infty), \quad \varphi(Z) := \mathbb{E}[(Y - Z)^2]$$

ihr Minimum bei  $Z = a^*X + b^*$  an mit

$$a^* = \frac{\mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]}{\text{Var}(X)}, \quad b^* = \mathbb{E}[Y] - a^* \mathbb{E}[X]$$

( $a^*$  beliebig falls  $\text{Var}(X) = 0$ ). Für  $\text{Var}(X) > 0$  gilt  $\varphi(a^*X + b^*) = \text{Var}(Y) - \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]^2 / \text{Var}(X)$ .

**2.27 Definition.** Für Zufallsvariablen  $X, Y \in \mathcal{L}^2$  definiert

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$$

die Kovarianz zwischen  $X$  und  $Y$ . Falls  $\sigma(X) > 0$  und  $\sigma(Y) > 0$  gilt, so heißt

$$\rho(X, Y) := \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}$$

die Korrelation zwischen  $X$  und  $Y$ . Falls  $\text{Cov}(X, Y) = 0$  gilt, heißen  $X$  und  $Y$  unkorreliert.

**2.28 Satz** (Eigenschaften von Kovarianz und Korrelation). Für  $X, Y, Z \in \mathcal{L}^2$  gilt:

- (a)  $\text{Cov}(X, Y) = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]$ ,  $\text{Cov}(X, X) = \text{Var}(X)$ ;
- (b)  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2\text{Cov}(X, Y)$ ;
- (c)  $\forall a, b \in \mathbb{R} : \text{Cov}(aX + b, Y) = a\text{Cov}(X, Y)$ ;
- (d)  $\text{Cov}(X + Y, Z) = \text{Cov}(X, Z) + \text{Cov}(Y, Z)$ ;
- (e) falls  $X, Y$  unabhängig sind, so sind  $X, Y$  unkorreliert;
- (f)  $|\text{Cov}(X, Y)| \leq \sigma(X)\sigma(Y)$  und  $\rho(X, Y) \in [-1, +1]$ .

**2.29 Definition.** Sind  $P, Q$  Wahrscheinlichkeitsmaße auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ , so ist die Faltung  $P * Q$  definiert als das Wahrscheinlichkeitsmaß(!)

$$P * Q(B) = \int_{\mathbb{R}} P(B - \{x\}) Q(dx), \quad B \in \mathfrak{B}_{\mathbb{R}}, \quad \text{mit } B - \{x\} = \{b - x \mid b \in B\}.$$

**2.30 Lemma.** Es seien  $X$  und  $Y$  unabhängige reellwertige Zufallsvariablen. Dann besitzt  $X + Y$  die Verteilung  $P^{X+Y} = P^X * P^Y$ .

**2.31 Korollar.** Die Faltung ist kommutativ und assoziativ.

**2.32 Korollar.** Besitzen  $P$  und  $Q$  Zähldichten  $p$  bzw.  $q$  auf  $\mathbb{Z}$  (auf  $\mathbb{N}_0$ ), so besitzt  $P * Q$  die Zähldichte  $(p * q)(k) := \sum_{m \in \mathbb{Z}} p(k - m)q(m)$  (auf  $\mathbb{N}_0$ :  $(p * q)(k) := \sum_{m=0}^k p(k - m)q(m)$ ).

**2.33 Satz.** Es seien  $X$  und  $Y$  unabhängige reellwertige Zufallsvariablen und  $X$  besitze eine Dichte  $f^X$ . Dann besitzt  $X + Y$  die Dichte

$$f^{X+Y}(z) = \int_{\mathbb{R}} f^X(z-y) P^Y(dy), \quad z \in \mathbb{R}.$$

Falls auch  $Y$  eine Dichte besitzt, so gilt

$$f^{X+Y}(z) = f^X * f^Y(z) := \int_{\mathbb{R}} f^X(z-y) f^Y(y) dy, \quad z \in \mathbb{R}.$$

### 2.3 Mehrdimensionale Normalverteilung

**2.34 Definition.** Es seien  $\mu \in \mathbb{R}^d$  sowie  $\Sigma \in \mathbb{R}^{d \times d}$  eine symmetrische, positiv semi-definite Matrix. Ein Zufallsvektor  $X$  im  $\mathbb{R}^d$  ist  $N(\mu, \Sigma)$ -verteilt, falls  $X = \mu + \Sigma^{1/2}Y$  gilt mit einem standard-normalverteilten Zufallsvektor  $Y$  im  $\mathbb{R}^d$ .  $N(\mu, \Sigma)$  heißt  $d$ -dimensionale Normalverteilung mit Mittelwertvektor  $\mu$  und Kovarianzmatrix  $\Sigma$ .

**2.35 Lemma.** Für einen  $N(\mu, \Sigma)$ -verteilten Zufallsvektor  $X = (X_1, \dots, X_d)$  und  $1 \leq k, \ell \leq d$  gilt

$$\mathbb{E}[X_k] = \mu_k, \quad \text{Cov}(X_k, X_\ell) = \Sigma_{k\ell}.$$

**2.36 Lemma.** Ist  $\Sigma \in \mathbb{R}^{d \times d}$  symmetrisch und strikt positiv definit, so besitzt die  $N(\mu, \Sigma)$ -Verteilung eine Dichte im  $\mathbb{R}^d$ , nämlich

$$\varphi_{\mu, \Sigma}(x) = (2\pi)^{-d/2} \det(\Sigma)^{-1/2} \exp\left(-\frac{1}{2}\langle \Sigma^{-1}(x-\mu), x-\mu \rangle\right), \quad x \in \mathbb{R}^d.$$

**2.37 Korollar.** Sind  $X_1, \dots, X_n$  gemeinsam normalverteilt (d.h.  $(X_1, \dots, X_n)$  ist  $n$ -dimensional normalverteilt) und sind  $X_1, \dots, X_n$  (paarweise) unkorreliert, so sind  $X_1, \dots, X_n$  sogar unabhängig.

**2.38 Lemma.** Ist  $O \in \mathbb{R}^{d \times d}$  eine orthogonale Matrix, so gilt für einen standard-normalverteilten Zufallsvektor  $X$  im  $\mathbb{R}^d$ , dass auch  $OX$  standard-normalverteilt ist.

**2.39 Satz.** Ist  $X$  ein  $N(\mu, \Sigma)$ -verteilter Zufallsvektor im  $\mathbb{R}^d$  und ist  $A \in \mathbb{R}^{m \times d}$  eine Matrix, so ist  $Y = AX$  ein  $N(A\mu, A\Sigma A^\top)$ -verteilter Zufallsvektor im  $\mathbb{R}^m$ .

**2.40 Korollar.** Sind  $X$  und  $Y$  unabhängig und gemäß  $N(\mu_X, \sigma_X^2)$  bzw.  $N(\mu_Y, \sigma_Y^2)$  verteilt mit  $\mu_X, \mu_Y \in \mathbb{R}$ ,  $\sigma_X, \sigma_Y > 0$ , so ist  $X + Y$  gemäß  $N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2)$  verteilt.

## 3 Einführung in statistische Tests

### 3.1 Hypothesentests

**3.1 Definition.** Ein statistisches Modell ist ein Tripel  $(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  bestehend aus einer Menge  $\mathcal{X}$  mit einer  $\sigma$ -Algebra  $\mathcal{F}$  (dem Stichprobenraum) und einer Familie  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  von Wahrscheinlichkeitsmaßen auf  $\mathcal{F}$ . Die mindestens zwei-elementige Menge  $\Theta$  heißt Parametermenge und jedes  $\vartheta \in \Theta$  Parameter.

**3.2 Definition.** Aufbau eines Testverfahrens:

- (a) Wahl eines statistischen Modells  $(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$
- (b) Formulierung von Hypothese und Alternative:  $\Theta = \Theta_0 \dot{\cup} \Theta_1$   
 $\vartheta \in \Theta_0$ :  $\vartheta$  entspricht der Hypothese  $H_0$   
 $\vartheta \in \Theta_1$ :  $\vartheta$  entspricht der Alternative  $H_1$
- (c) Wahl eines Irrtumsniveaus  $\alpha \in (0, 1)$  für den Fehler erster Art, sich bei Vorliegen der Hypothese für die Alternative zu entscheiden.
- (d) Konstruktion eines (randomisierten) Tests  $\varphi : \mathcal{X} \rightarrow [0, 1]$  zum Niveau  $\alpha$ :  
 $\varphi(x) = 0$ : Entscheidung für  $H_0$ ,  
 $\varphi(x) = 1$ : Entscheidung für  $H_1$ ,  
 $\varphi(x) \in (0, 1)$ : Entscheidung mit Wahrscheinlichkeit  $\varphi(x)$  für  $H_1$ ,  
 $\sup_{\vartheta \in \Theta_0} \mathbb{E}_\vartheta[\varphi] \leq \alpha$ .
- (e) Durchführen des Experiments

**3.3 Definition.** Weitere Begriffsbildungen:

- (a) Jede Zufallsvariable  $\varphi$  auf  $\mathcal{X}$  mit Werten in  $[0, 1]$  heißt Test.
- (b) Gilt  $\varphi(x) \in \{0, 1\}$  für alle  $x \in \mathcal{X}$ , so heißt der Test  $\varphi$  nicht-randomisiert.
- (c) Ist  $\varphi$  ein nicht-randomisierter Test, so heißt  $\{x \in \mathcal{X} : \varphi(x) = 1\}$  Ablehnungsbereich oder kritischer Bereich des Tests.
- (d) Die Funktion  $G_\varphi : \Theta \rightarrow [0, 1]$  mit  $G_\varphi(\vartheta) = \mathbb{E}_\vartheta[\varphi]$  heißt Gütefunktion des Tests  $\varphi$ . Ist  $\varphi$  ein Test vom Niveau  $\alpha$ , so gilt  $G_\varphi(\vartheta_0) \leq \alpha$  für alle  $\vartheta_0 \in \Theta_0$ . Für  $\vartheta_1 \in \Theta_1$  heißt  $G_\varphi(\vartheta_1)$  die Macht oder Schärfe von  $\varphi$  bei  $\vartheta_1$  und  $\beta_\varphi(\vartheta_1) = 1 - G_\varphi(\vartheta_1)$  bezeichnet die Wahrscheinlichkeit für den Fehler 2. Art der Entscheidung für  $H_0$ , obwohl  $\vartheta_1 \in \Theta_1$  vorliegt.

**3.4 Definition.**

Ein Test  $\varphi$  von  $H_0 : \vartheta \in \Theta_0$  gegen  $H_1 : \vartheta \in \Theta_1$  heißt gleichmäßig bester Test zum Niveau  $\alpha$ , falls  $\varphi$  ein Test zum Niveau  $\alpha$  ist und für jeden anderen Test  $\psi$  zum Niveau  $\alpha$  gilt:

$$\forall \vartheta_1 \in \Theta_1 : \mathbb{E}_{\vartheta_1}[\varphi] \geq \mathbb{E}_{\vartheta_1}[\psi].$$

**3.5 Definition.** Der Likelihood-Quotient von  $\mathbb{P}_1$  bezüglich  $\mathbb{P}_0$  ist im diskreten Fall mit Zähldichten  $p_1(x)$  und  $p_0(x)$  gegeben durch

$$R(x) := \begin{cases} p_1(x)/p_0(x), & \text{falls } p_0(x) > 0, \\ +\infty, & \text{falls } p_0(x) = 0, \\ \text{beliebig,} & \text{falls } p_0(x) = p_1(x) = 0. \end{cases}$$

Im Fall von Dichten  $f_0(x)$  und  $f_1(x)$  im  $\mathbb{R}^d$  ist  $R(x)$  entsprechend definiert, indem  $p_0, p_1$  jeweils durch  $f_0, f_1$  ersetzt werden.

Jeder Test  $\varphi$  der Form

$$\varphi(x) = \begin{cases} 1, & \text{falls } R(x) > c, \\ 0, & \text{falls } R(x) < c, \\ \gamma, & \text{falls } R(x) = c \end{cases}$$

mit beliebigem  $c \geq 0$  und  $\gamma \in [0, 1]$  heißt ein Neyman-Pearson-Test.

**3.6 Satz.** Für das Testen von  $H_0 : \vartheta = 0$  gegen  $H_1 : \vartheta = 1$  gilt:

- (a) Ist  $\varphi^*$  ein Neyman-Pearson-Test, so gilt  $\mathbb{E}_1[\varphi^*] \geq \mathbb{E}_1[\varphi]$  für jeden beliebigen Test  $\varphi$  mit  $\mathbb{E}_0[\varphi] \leq \mathbb{E}_0[\varphi^*]$ .
- (b) Für jedes Niveau  $\alpha \in (0, 1)$  existiert ein Neyman-Pearson-Test  $\varphi^*$  mit exakt  $\mathbb{E}_0[\varphi^*] = \alpha$ .
- (c) Ein (gleichmäßig) bester Test zum Niveau  $\alpha$  ist gegeben durch einen Neyman-Pearson-Test  $\varphi^*$  mit  $\mathbb{E}_0[\varphi^*] = \alpha$ .

### 3.2 Der $\chi^2$ -Anpassungstest

Wir betrachten als statistisches Modell  $\Theta = \{\vartheta \in (0, 1)^r : \vartheta_1 + \dots + \vartheta_r = 1\}$ ,  $\mathcal{X} = \{x \in \{0, \dots, n\}^r : x_1 + \dots + x_r = n\}$  und  $\text{Mult}(n; \vartheta_1, \dots, \vartheta_r)$ , die Multinomialverteilung mit  $n$  Versuchen und Wahrscheinlichkeiten  $\vartheta_1, \dots, \vartheta_r$  für die Klassen  $1, \dots, r$ . Es soll die Hypothese  $H_0 : \vartheta = \bar{\vartheta}$  gegen die Alternative  $H_1 : \vartheta \neq \bar{\vartheta}$  getestet werden.

**3.7 Definition.** Für ein beliebiges zusammengesetztes Testproblem  $H_0 : \vartheta \in \Theta_0$  gegen  $H_1 : \vartheta \in \Theta_1$  auf einem diskreten statistischen Modell heißt jeder Test  $\varphi$  der Form

$$\varphi(x) = \begin{cases} 1, & \text{falls } R(x) > c, \\ 0, & \text{falls } R(x) < c, \\ \gamma, & \text{falls } R(x) = c \end{cases} \quad \text{mit } R(x) = \frac{\sup_{\vartheta \in \Theta_1} p_{\vartheta}(x)}{\sup_{\vartheta \in \Theta_0} p_{\vartheta}(x)}$$

Likelihood-Quotienten-Test. Entsprechendes gilt im Fall von Dichten statt Zähldichten.

**3.8 Lemma.** Für das vorliegende Testproblem gilt

$$\log(R(x)) = \sum_{i=1}^r x_i \log\left(\frac{x_i}{n\bar{\vartheta}_i}\right) \approx \frac{1}{2} V^2(x)$$

mit Pearsons  $\chi^2$ -Statistik

$$V^2(x) = \sum_{i=1}^r \frac{(x_i - n\bar{\vartheta}_i)^2}{n\bar{\vartheta}_i}.$$

**3.9 Satz.** Für alle  $v > 0$  gilt (mit Kenntlichmachung der Abhängigkeit von  $n$ ):

$$\lim_{n \rightarrow \infty} P_{\bar{\vartheta}}(V_n^2 \leq v) = \int_0^v f_{\chi_{r-1}^2}(x) dx,$$

wobei  $f_{\chi_m^2}$  die Dichte der  $\chi^2(m)$ -Verteilung bezeichnet. Ebenso gilt

$$\lim_{n \rightarrow \infty} P_{\bar{\vartheta}}(2 \log(R_n) \leq v) = \int_0^v f_{\chi_{r-1}^2}(x) dx.$$

## 4 Grenzwertsätze

### 4.1 Gesetze der großen Zahlen

**4.1 Satz** (Allgemeine Markov-Ungleichung). Es sei  $X$  eine Zufallsvariable und  $\varphi : [0, \infty) \rightarrow [0, \infty)$  monoton wachsend. Dann gilt für jedes  $K > 0$  mit  $\varphi(K) > 0$ :

$$P(|X| \geq K) \leq \frac{\mathbb{E}[\varphi(|X|)]}{\varphi(K)}.$$

**4.2 Korollar** (Tschebyschev-Ungleichung). Ist  $X$  eine Zufallsvariable in  $\mathcal{L}^2$ , so gilt für jedes  $\varepsilon > 0$

$$P(|X - \mathbb{E}[X]| \geq \varepsilon) \leq \frac{\text{Var}(X)}{\varepsilon^2}.$$

**4.3 Satz** (schwaches Gesetz der großen Zahlen). Es sei  $(X_i)_{i \geq 1}$  eine Folge unkorrelierter Zufallsvariablen in  $\mathcal{L}^2$  mit demselben Erwartungswert  $\mu \in \mathbb{R}$  und  $\sup_i \text{Var}(X_i) < \infty$ . Dann erfüllt das arithmetische Mittel

$$A_n := \frac{1}{n} \sum_{i=1}^n X_i$$

für jedes  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P(|A_n - \mu| > \varepsilon) = 0.$$

**4.4 Korollar.** (Weierstraßscher Approximationssatz) Zur stetigen Funktion  $f : [0, 1] \rightarrow \mathbb{R}$  definiere das zugehörige Bernstein-Polynom  $n$ -ten Grades

$$f_n(x) := \sum_{k=0}^n f\left(\frac{k}{n}\right) \binom{n}{k} x^k (1-x)^{n-k}, \quad x \in [0, 1].$$

Dann gilt  $\lim_{n \rightarrow \infty} \|f - f_n\|_{\infty} = 0$  mit  $\|g\|_{\infty} := \sup_{x \in [0, 1]} |g(x)|$ .

**4.5 Definition.** Es seien  $(X_n)_{n \geq 1}$  und  $X$  Zufallsvariablen auf demselben Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P)$ . Man sagt, dass  $X_n$  stochastisch (oder auch in  $P$ -Wahrscheinlichkeit) gegen  $X$  konvergiert für  $n \rightarrow \infty$ , falls für alle  $\varepsilon > 0$  gilt

$$\lim_{n \rightarrow \infty} P(|X - X_n| > \varepsilon) = 0.$$

Man sagt, dass  $X_n$   $P$ -fast sicher gegen  $X$  konvergiert, falls

$$P(\{\omega \in \Omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\}) = 1.$$

**4.6 Satz.** *Fast sichere Konvergenz impliziert stochastische Konvergenz, aber nicht umgekehrt.*

**4.7 Satz.** *(starkes Gesetz der großen Zahlen) Es sei  $(X_i)_{i \geq 1}$  eine Folge unkorrelierter Zufallsvariablen in  $\mathcal{L}^2$  mit demselben Erwartungswert  $\mu \in \mathbb{R}$  und  $\sup_i \text{Var}(X_i) < \infty$ . Dann konvergiert das arithmetische Mittel  $A_n = \frac{1}{n} \sum_{i=1}^n X_i$  fast sicher gegen  $\mu$ .*

**4.8 Satz** (Lévy's Äquivalenzsatz). *Es seien  $(X_i)_{i \geq 1}$  eine Folge unabhängiger Zufallsvariablen und  $S_n := \sum_{i=1}^n X_i$ ,  $n \geq 1$ . Dann sind für  $n \rightarrow \infty$  äquivalent:*

- (a)  $(S_n)_{n \geq 1}$  konvergiert fast sicher.
- (b)  $(S_n)_{n \geq 1}$  konvergiert stochastisch.

*Andernfalls divergiert  $(S_n)_{n \geq 1}$  mit Wahrscheinlichkeit Eins.*

**4.9 Lemma** (Ottaviani-Ungleichung). *Unter den Voraussetzungen des Satzes gilt für  $\alpha > 0$*

$$P\left(\max_{j=1, \dots, n} |S_j| \geq 2\alpha\right) \leq \frac{P(|S_n| \geq \alpha)}{1 - \max_{j=1, \dots, n} P(|S_n - S_j| \geq \alpha)}.$$

## 4.2 Der zentrale Grenzwertsatz

**4.10 Definition.** Die Zufallsvariablen  $(X_n)_{n \geq 1}$  konvergieren in Verteilung gegen die Zufallsvariable  $X$  (bzw.: die Verteilungen  $(P^{X_n})_{n \geq 1}$  konvergieren schwach gegen die Verteilung  $P^X$ ), falls für jede stetige beschränkte Funktion  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$  gilt

$$\lim_{n \rightarrow \infty} \mathbb{E}[\varphi(X_n)] = \mathbb{E}[\varphi(X)].$$

Notation:  $X_n \xrightarrow{d} X$  bzw.  $X_n \xrightarrow{d} P^X$ ,  $X_n \xrightarrow{\mathcal{L}} X$ ,  $X_n \Rightarrow X$ .

**4.11 Satz.** *Es sind äquivalent:*

- (a)  $X_n \xrightarrow{d} X$
- (b) Die Verteilungsfunktionen erfüllen  $F^{X_n}(x) \rightarrow F^X(x)$  für alle  $x \in \mathbb{R}$ , an denen  $F^X$  stetig ist (Stetigkeitspunkte von  $F^X$ ).

**4.12 Lemma.** *Stochastische Konvergenz impliziert Konvergenz in Verteilung, aber nicht umgekehrt.*

**4.13 Satz.** *(zentraler Grenzwertsatz) Es sei  $(X_i)_{i \geq 1}$  eine Folge unabhängiger identisch verteilter Zufallsvariablen in  $\mathcal{L}^2$ . Dann gilt für die standardisierten Summen*

$$S_n^* := \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - \mathbb{E}[X_i]}{\sigma(X_i)} \xrightarrow{d} N(0, 1).$$

*Insbesondere gilt für  $a < b$  also  $\mathbb{P}(a < S_n^* \leq b) \rightarrow \Phi(b) - \Phi(a)$  mit der Verteilungsfunktion  $\Phi$  der Standardnormalverteilung  $N(0, 1)$ .*

**4.14 Lemma** (Continuous mapping theorem). *Konvergiert  $X_n$  gegen  $X$  fast sicher (bzw. stochastisch bzw. in Verteilung) und ist  $g : \mathbb{R} \rightarrow \mathbb{R}$  stetig, so konvergiert auch  $g(X_n)$  gegen  $g(X)$  fast sicher (bzw. stochastisch bzw. in Verteilung).*

### 4.3 Asymptotik der empirischen Verteilung

**4.15 Definition.** Es seien  $X_1, \dots, X_n$  unabhängige, identisch verteilte Zufallsvariablen (*Beobachtungen*) mit Werten in  $\mathbb{R}$ . Dann heißt das Wahrscheinlichkeitsmaß  $\mu_n := \frac{1}{n} \sum_{i=1}^n \delta_{X_i}$  empirische Verteilung oder empirisches Maß sowie seine Verteilungsfunktion  $F_n(x) := \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{(-\infty, x]}(X_i)$ ,  $x \in \mathbb{R}$ , empirische Verteilungsfunktion.

**4.16 Satz.** Für alle  $x \in \mathbb{R}$  gilt  $\lim_{n \rightarrow \infty} F_n(x) = F^X(x)$  *P-fast sicher* mit  $F^X(x) = P(X_i \leq x)$ . Für alle  $x \in \mathbb{R}$  mit  $F^X(x) \in (0, 1)$  gilt

$$\sqrt{n}(F_n(x) - F^X(x)) \xrightarrow{d} N(0, F^X(x)(1 - F^X(x))).$$

**4.17 Satz** (Glivenko-Cantelli). Die empirische Verteilungsfunktion konvergiert gleichmäßig gegen die wahre Verteilungsfunktion:

$$\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n(x) - F^X(x)| = 0 \quad \text{P-f.s.}$$

## 5 Einführung in die Schätztheorie

**5.1 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  ein statistisches Modell sowie  $g : \Theta \rightarrow \mathbb{R}^d$ . Für jedes  $\vartheta \in \Theta$  wird  $g(\vartheta)$  abgeleiteter Parameter genannt. Jede messbare Funktion  $\hat{g} : \mathcal{X} \rightarrow \mathbb{R}^d$  heißt Schätzer von  $g(\vartheta)$ . Für eine Realisierung (konkrete Beobachtung, Stichprobe)  $x \in \mathcal{X}$  ist  $\hat{g}(x)$  der zugehörige Schätzwert.

**5.2 Definition.** Der mittlere quadratische Fehler MSE (*mean squared error*) eines Schätzers  $\hat{g}$  von  $g(\vartheta)$  ist gegeben durch

$$R(\hat{g}, \vartheta) := \mathbb{E}_\vartheta[|\hat{g} - g(\vartheta)|^2], \quad \vartheta \in \Theta.$$

Liegt  $|\hat{g}|$  in  $\mathcal{L}^1(P_\vartheta)$ , so heißt

$$B(\hat{g}, \vartheta) := \mathbb{E}_\vartheta[\hat{g} - g(\vartheta)], \quad \vartheta \in \Theta, \quad (\text{koordinatenweise Erwartung})$$

Verzerrung oder Bias von  $\hat{g}$ . Gilt  $B(\hat{g}, \vartheta) = 0$  für alle  $\vartheta \in \Theta$ , so ist  $\hat{g}$  ein erwartungstreuer Schätzer von  $g(\vartheta)$ .

**5.3 Lemma** (Bias-Varianz-Zerlegung). Für jeden Schätzer  $\hat{g}$  von  $g(\vartheta)$  mit  $R(\hat{g}, \vartheta) < \infty$  gilt

$$R(\hat{g}, \vartheta) := |B(\hat{g}, \vartheta)|^2 + \mathbb{E}_\vartheta[|\hat{g} - \mathbb{E}_\vartheta[\hat{g}]|^2].$$

**5.4 Satz** (Cramer-Rao-Ungleichung). Im statistischen Modell  $(\mathbb{R}^d, \mathfrak{B}_{\mathbb{R}^d}, (P_\vartheta)_{\vartheta \in \Theta})$  seien  $\Theta \subseteq \mathbb{R}$  offen,  $g : \Theta \rightarrow \mathbb{R}^d$  differenzierbar und  $\hat{g}$  ein erwartungstreuer Schätzer von  $g(\vartheta)$ . Weiterhin besitze jedes  $P_\vartheta$  eine Dichte  $f_\vartheta$ , so dass  $\frac{d}{d\vartheta} f_\vartheta(x)$  für Lebesgue-fast alle  $x \in \mathbb{R}^d$  existiert und folgende Vertauschungen erlaubt sind:

$$\frac{d}{d\vartheta} \int_{\mathbb{R}^d} h(x) f_\vartheta(x) dx = \int_{\mathbb{R}^d} h(x) \frac{d}{d\vartheta} f_\vartheta(x) dx \quad \text{für } h(x) = 1, h(x) = \hat{g}(x).$$

Dann folgt

$$\forall \vartheta \in \Theta : R(\hat{g}, \vartheta) \geq \frac{g'(\vartheta)^2}{I(\vartheta)} \quad \text{mit } I(\vartheta) := \mathbb{E}_{\vartheta} \left[ \left( \frac{d}{d\vartheta} f_{\vartheta} \right)^2 \right],$$

sofern die Fisher-Information  $I(\vartheta)$  endlich ist.

Ein vollkommen analoges Resultat gilt im Fall von Verteilungen  $P_{\vartheta}$  mit Zähl-dichten  $p_{\vartheta}$ .