

*Stochastik I*  
Gliederung zur Vorlesung  
im Sommersemester 2016

Markus Reiß  
Humboldt-Universität zu Berlin

Vorläufige Version vom 14. September 2016

## Inhaltsverzeichnis

|          |  |           |
|----------|--|-----------|
| <b>1</b> | <b>Wahrscheinlichkeitsräume</b>                                    | <b>1</b>  |
| 1.1      | Ereignisse, Wahrscheinlichkeiten und Zufallsvariablen . . . . .    | 1         |
| 1.2      | Diskrete Verteilungen . . . . .                                    | 3         |
| 1.3      | Maßtheorie und Wahrscheinlichkeitsmaße im $\mathbb{R}^d$ . . . . . | 5         |
| <b>2</b> | <b>Bedingte Wahrscheinlichkeiten und Unabhängigkeit</b>            | <b>10</b> |
| 2.1      | Bedingte Wahrscheinlichkeiten und Bayes-Formel . . . . .           | 10        |
| 2.2      | Unabhängige Ereignisse und Lemma von Borel-Cantelli . . . . .      | 11        |
| 2.3      | Unabhängige Zufallsvariablen und $\sigma$ -Algebren . . . . .      | 12        |
| 2.4      | Faltung . . . . .  | 14        |
| <b>3</b> | <b>Erwartungswert, Varianz und Kovarianz</b>                       | <b>15</b> |
| 3.1      | Erwartungswert und Momente . . . . .                               | 15        |
| 3.2      | Varianz, Kovarianz und Korrelation . . . . .                       | 18        |
| 3.3      | Mehrdimensionale Normalverteilung . . . . .                        | 20        |
| <b>4</b> | <b>Grenzwertsätze</b>  | <b>21</b> |
| 4.1      | Gesetze der großen Zahlen . . . . .                                | 21        |
| 4.2      | Konvergenz in Verteilung . . . . .                                 | 23        |
| 4.3      | Charakteristische Funktionen und Zentrale Grenzwertsätze . . . . . | 25        |
| <b>5</b> | <b>Einführung in die Schätztheorie</b>                             | <b>28</b> |
| 5.1      | Grundlagen . . . . .   | 28        |
| 5.2      | Cramér-Rao-Ungleichung und Fisher-Information . . . . .            | 29        |



## Ein paar Literaturempfehlungen

- Hans-Otto Georgii, *Stochastik*, de Gruyter: exzellentes Lehrbuch inkl. Maßtheorie
- 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 charakteristische Funktionen und Konvergenzresultate
- Richard Dudley, *Real Analysis and Probability*, Cambridge University Press: ausgezeichnetes und recht anspruchsvolles Lehrbuch zu Maßtheorie, Analysis und W-Theorie, insbesondere für Konvergenzarten und charakteristische Funktionen
- 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, Wahrscheinlichkeiten und Zufallsvariablen

### 1.1 Beispiele.

- (a) Würfeln mit zwei unterscheidbaren Würfeln wird durch die Grundmenge  $\Omega = \{1, 2, 3, 4, 5, 6\}^2$  beschrieben. Interpretation ist, dass Versuchsausgang  $(n_1, n_2) \in \Omega$  bedeutet Augenzahl des 1. Würfels =  $n_1$ , des 2. Würfels =  $n_2$ . Ereignisse sind z.B.  $A_1 = \text{es wird ein Pasch gewürfelt}$ ,  $A_2 = \text{die Augensumme ist 7}$ ,  $A_3 = \text{es tritt keine 1 auf}$ . Ereignisse werden als Teilmengen von  $\Omega$  modelliert:  $A_1 = \{(1, 1), (2, 2), (3, 3), (4, 4), (5, 5), (6, 6)\}$ ,  $A_2 = \{(n_1, n_2) \in \Omega \mid n_1 + n_2 = 7\}$ ,  $A_3 = \{(n_1, n_2) \in \Omega \mid n_1 \neq 1 \text{ und } n_2 \neq 1\}$ . Sind alle Versuchsausgänge gleichwahrscheinlich, so ist die Wahrscheinlichkeit eines Ereignisses  $A \subseteq \Omega$  gleich der Anzahl aller für  $A$  günstiger Versuchsausgänge geteilt durch die Anzahl aller möglichen Versuchsausgänge, d.h.  $P(A) = \frac{|A|}{|\Omega|}$ . Wir erhalten  $P(A_1) = \frac{1}{6}$ ,  $P(A_2) = \frac{1}{6}$ ,  $P(A_3) = \frac{25}{36}$ .
- (b) Beim  $n$ -fachen Wurf einer Münze setzen wir  $\Omega = \{0, 1\}^n$  mit Interpretation  $(b_1, \dots, b_n) \in \Omega$  kodiert Ergebnis in den Würfeln 1 bis  $n$  via  $b_i = 1$  für Kopf im  $i$ -ten Wurf,  $b_i = 0$  für Zahl im  $i$ -ten Wurf. Wir betrachten die Ereignisse  $A_1 = \{(1, \dots, 1)\}$  ( $n$ -mal Kopf),  $A_2 = \{b \in \Omega \mid b_1 + \dots + b_n = n-1\}$  ( $(n-1)$ -mal Kopf),  $A_3 = \{b \in \Omega \mid b_1 + \dots + b_n \leq n-1\}$  (mindestens einmal Zahl). Sind alle Versuchsausgänge gleichwahrscheinlich, so erhalten wir  $P(A_1) = 2^{-n}$ ,  $P(A_2) = n2^{-n}$ ,  $P(A_3) = 1 - 2^{-n}$ . Beachte, dass  $A_3 = A_1^c$  und  $P(A_1) + P(A_3) = 1$  gilt.  $A_1$  und  $A_3$  heißen auch komplementäre Ereignisse oder Gegenereignisse.
- (c) Wir nehmen nun an, dass die Münze beliebig oft hintereinander geworfen wird. Die Versuchsausgänge modellieren wir dann durch 0-1-Folgen  $B = (b_n)_{n \in \mathbb{N}} = (b_1, b_2, \dots)$ , d.h.  $\Omega = \{0, 1\}^{\mathbb{N}}$ . Ereignisse sind dann  $A_1 = \{(1, 1, \dots)\}$  (immer nur Kopf),  $A_2 = \{b \in \Omega \mid \forall M \in \mathbb{N} \exists k \in \mathbb{N} : b_k = b_{k+1} = \dots = b_{k+M-1} = 1\}$  (für jedes  $M \in \mathbb{N}$  gibt es einen Kopf-run der Länge  $M$ ). Wegen  $|\Omega| = \infty$  gibt es keine Gleichverteilung auf den Versuchsausgängen. Intuitiv würden wir aus (b) schließen  $P(A_1) = \lim_{n \rightarrow \infty} 2^{-n} = 0$ , während  $P(A_2)$  nicht klar ist. Es fehlt eine mathematisch formale Einführung des Wahrscheinlichkeitsmaßes  $P$  und seiner Eigenschaften.

**1.2 Definition.** Mit  $\Omega$  werde die nichtleere Menge der möglichen Versuchsausgänge oder Ergebnismenge, Grundmenge 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  $P : \mathcal{F} \rightarrow [0, 1]$ , die den *Kolmogorowschen Axiomen* (1933) genügt:

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

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

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  $\mathcal{F}$ .

**1.3 Beispiele.** Auf jeder nichtleeren Ergebnismenge  $\Omega$  existieren die triviale  $\sigma$ -Algebra  $\{\emptyset, \Omega\}$  sowie die Potenzmenge  $\mathcal{P}(\Omega)$  als  $\sigma$ -Algebren. Für  $\omega_0 \in \Omega$  ist das Einpunkt- oder Diracmaß  $\delta_{\omega_0}(A) = \mathbf{1}(\omega_0 \in A)$ ,  $A \in \mathcal{F}$ , ein Wahrscheinlichkeitsmaß auf jeder  $\sigma$ -Algebra  $\mathcal{F}$  über  $\Omega$ . Sind  $(P_n)_{n \geq 1}$  Wahrscheinlichkeitsmaße auf einer  $\sigma$ -Algebra  $\mathcal{F}$ , so auch jede Konvexkombination  $\sum_{n \geq 1} w_n P_n$  mit  $w_n \geq 0$  und  $\sum_{n \geq 1} w_n = 1$ . Die Einpunktmaße bilden Extrempunkte der konvexen Menge aller Wahrscheinlichkeitsmaße auf  $\mathcal{F}$ .

**1.4 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)  $A_n \in \mathcal{F}, n \in \mathbb{N} \Rightarrow \bigcap_{n \in \mathbb{N}} A_n, A_1 \cap A_2 \in \mathcal{F}$ .

**1.5 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)  $\forall A_n \in \mathcal{F}, n \geq 1 : P(\bigcup_{n \geq 1} A_n) \leq \sum_{n \geq 1} P(A_n)$  (*Subadditivität*);
- (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*).

Andererseits ist jede normierte, additive Mengenfunktion  $Q : \mathcal{F} \rightarrow [0, 1]$  (d.h.  $Q(\Omega) = 1, Q(A \cup B) = Q(A) + Q(B)$  für alle disjunkten  $A, B \in \mathcal{F}$ ), die  $\sigma$ -stetig ist, auch  $\sigma$ -additiv und damit ein Wahrscheinlichkeitsmaß.

**1.6 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  $\mathcal{S} = \mathfrak{B}_{\mathbb{R}^d}$  (Borel- $\sigma$ -Algebra, siehe unten) 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  $X$  werden wir stets die zu  $P^X$  gehörige Größe meinen.

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.

### 1.7 Beispiele.

- (a) Beim Würfeln mit 2 Würfeln interessiert uns die Augensumme  $X$  als abgeleiteter Parameter. Formal betrachten wir  $\Omega = \{1, 2, 3, 4, 5, 6\}^2$ ,  $X : \Omega \rightarrow \mathbb{R}$  mit  $X((n_1, n_2)) = n_1 + n_2$ . Das Ereignis  $\{X = 7\}$  ist dann kurz für  $\{\omega \in \Omega : \mid X(\omega) = 7\} = X^{-1}(\{7\}) = \{(1, 6), (2, 5), (3, 4), (4, 3), (5, 2), (6, 1)\} \subseteq \Omega$  und  $\{X \text{ ist gerade}\} = \{\omega \in \Omega \mid X(\omega) \in \{2, 4, 6, 8, 10, 12\}\}$ .

$X$  transportiert das Wahrscheinlichkeitsmaß  $P$  auf  $\Omega$  nach  $\mathbb{R}$ :  $P^X(A) := P(X^{-1}(A)) = P(\{\omega \in \Omega \mid X(\omega) \in A\}) = P(X \in A)$  für  $A \subseteq \mathbb{R}$ . Beachte, dass hier jede Funktion  $X : \Omega \rightarrow \mathbb{R}$  messbar und damit Zufallsvariable ist, da  $\Omega$  mit der Potenzmenge  $\mathcal{P}(\Omega)$  als  $\sigma$ -Algebra versehen ist, so dass  $P^X$  sogar auf  $\mathcal{P}(\mathbb{R})$  wohldefiniert ist.

- (b) Auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P)$  ist die Indikatorfunktion  $X(\omega) = \mathbf{1}_A(\omega) = \mathbf{1}(\omega \in A)$ ,  $\omega \in \Omega$ , genau dann eine reellwertige Zufallsvariable, wenn  $A \in \mathcal{F}$  gilt. Für ihre Verteilung gilt  $P^X = P(A^c)\delta_0 + P(A)\delta_1$ .

## 1.2 Diskrete Verteilungen

**1.8 Definition.** Ist  $\Omega$  eine abzählbare (d.h. endliche oder abzählbar unendliche) Menge und  $P$  ein Wahrscheinlichkeitsmaß auf  $\mathcal{F} = \mathcal{P}(\Omega)$ , so heißt  $(\Omega, \mathcal{F}, P)$  diskreter Wahrscheinlichkeitsraum. Man nennt eine  $S$ -wertige Zufallsvariable  $X$  diskret verteilt, falls sie bezüglich  $\mathcal{P}(S)$  messbar ist und einen diskreten Wahrscheinlichkeitsraum  $(S, \mathcal{P}(S), P^X)$  generiert. Ist  $X$  eine diskrete  $S$ -wertige Zufallsvariable und  $S \subseteq \mathbb{R}^d$  ( $S$  abzählbar und somit  $\mathcal{P}(S) \subseteq \mathfrak{B}_{\mathbb{R}^d}$ ), so bezeichnet man  $X$  auch als diskrete  $\mathbb{R}^d$ -wertige Zufallsvariable.

**1.9 Beispiel.** Das Modell des Würfel- und des  $n$ -fachen Münzwurfs bildet einen diskreten Wahrscheinlichkeitsraum. Die Augensumme beim Münzwurf ist eine diskret verteilte Zufallsvariable.

### 1.10 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.

Ebenso legt bei einer diskret verteilten  $S$ -wertigen Zufallsvariablen  $X$  die zugehörige Zähldichte  $p^X(s) = P(X = s)$ ,  $s \in S$ , die Verteilung  $P^X$  eindeutig fest.

(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.

**1.11 Lemma** (Urnenmodelle). In einer Urne liegen  $N$  Kugeln mit den Aufschriften  $1, 2, \dots, N$ . Es werden  $n$  Kugeln gezogen. Dann gilt für die Anzahl verschiedener Versuchsausgänge:

**Mit Zurücklegen, mit Betrachtung der Reihenfolge:**

$$\Omega_1 = \{1, \dots, N\}^n, \quad |\Omega_1| = N^n.$$

**Ohne Zurücklegen, mit Betrachtung der Reihenfolge:**

$$\Omega_2 = \{(k_1, \dots, k_n) \mid k_1, \dots, k_n \in \{1, \dots, N\} \text{ paarweise verschieden}\},$$

$$|\Omega_2| = \frac{N!}{(N-n)!} \text{ für } n \leq N.$$

**Ohne Zurücklegen, ohne Betrachtung der Reihenfolge:**

$$\Omega_3 = \{A \subseteq \{1, \dots, N\} \mid |A| = n\}, \quad |\Omega_3| = \binom{N}{n} \text{ für } n \leq N.$$

**Mit Zurücklegen, ohne Betrachtung der Reihenfolge:**

$$\Omega_4 = \{(s_1, \dots, s_n) \mid 1 \leq s_1 \leq s_2 \leq \dots \leq s_n \leq N\}, \quad |\Omega_4| = \binom{N+n-1}{n}.$$

**1.12 Beispiel.** Wie groß ist die Wahrscheinlichkeit, dass in einem Raum mit  $n$  Personen keine zwei Personen am selben Tag Geburtstag haben? Geht man von 365 Tagen im Jahr aus, so ist die Menge aller Geburtstagskombinationen gerade  $\Omega_1$  mit  $N = 365$ . Das Ereignis, das keine zwei Personen am selben Tag Geburtstag haben, entspricht dann gerade  $\Omega_2$ . Unter der Annahme einer Gleichverteilung ergibt sich daher für die gesuchte Wahrscheinlichkeit  $\frac{N!}{N^n(N-n)!}$ . Approximativ ergibt sich  $\exp(-n(n-1)/(2N))$  und konkret 0,432 für  $n = 25$ ;  $4,4 \cdot 10^{-4}$  für  $n = 50$ ;  $2,2 \cdot 10^{-9}$  für  $n = 80$ ;  $2,7 \cdot 10^{-14}$  für  $n = 100$ .

**1.13 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  $\lambda > 0$

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

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

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

**1.15 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.

### 1.3 Maßtheorie und Wahrscheinlichkeitsmaße im $\mathbb{R}^d$

**1.16 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.*

**1.17 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  $\mathcal{F} = \sigma(\mathcal{E})$ .

**1.18 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  $S$ .

**1.19 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)  $\mathcal{E}_5^d := \{(-\infty, b_1) \times \cdots \times (-\infty, b_d) \mid b_k \in \mathbb{R}, k = 1, \dots, d\}.$

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

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

**1.21 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.

**1.22 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.

**1.23 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  $A \in \mathcal{A}$ .*

**1.24 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.*

**1.25 Definition.** Für ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  ist die zugehörige Verteilungsfunktion gegeben durch  $F(x) := P((-\infty, x])$ ,  $x \in \mathbb{R}$ ; für  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ -wertige Zufallsvariablen  $X$  wird durch  $F^X(x) := P^X((-\infty, x]) = P(X \leq x)$ ,  $x \in \mathbb{R}$ , die zugehörige Verteilungsfunktion definiert.

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

**1.27 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  $F$ .

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

**1.29 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  $P$ .*

**1.30 Beispiel.** Für eine reellwertige Zufallsvariable  $X$  mit Verteilungsfunktion  $F^X$  betrachte  $U = F^X(X)$ .  $F^X$  ist Borel-messbar und somit  $U$  eine Zufallsvariable mit Werten in  $[0, 1]$ . Ist  $F^X$  stetig, so gilt mit der Rechtsinversen  $(F^X)^{-1}(p) = \inf\{x \in \mathbb{R} \mid F(x) \geq p\}$ , dass  $U$  die Verteilungsfunktion  $F^U(u) = P(F^X(X) \leq u) = F^X((F^X)^{-1}(u)) = u$  für  $u \in (0, 1)$  besitzt und somit  $U((0, 1))$ -verteilt ist.

Ist andererseits  $U$  eine  $U((0, 1))$ -verteilte Zufallsvariable (oder eine Pseudozufallszahl in Anwendungen), so gilt für jede Verteilungsfunktion  $F$ , dass die Zufallsvariable  $X = F^{-1}(U)$  die Verteilungsfunktion  $F^X = F$  besitzt.  $F^{-1}$  heißt Quantilsfunktion und die Simulationsmethode Quantilstransformation. Eine einfache Anwendung ist die Erzeugung einer  $\text{Bin}(1, p)$ -verteilten Zufallsvariablen  $X$ : es gilt  $F^X(x) = (1 - p)\mathbf{1}(x \geq 0) + p\mathbf{1}(x \geq 1)$  und  $(F^X)^{-1}(y) = \mathbf{1}(y \geq 1 - p)$ ,  $y \in (0, 1)$ , so dass  $\mathbf{1}(U \geq 1 - p)$   $\text{Bin}(1, p)$ -verteilt ist für eine  $U((0, 1))$ -verteilte Zufallsvariable  $U$ .

**1.31 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  $\mathbb{R}^d$ .

**1.32 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  $\mathfrak{B}_{\mathbb{R}}$ .

**1.33 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  $\mathfrak{B}_{\mathbb{R}}$  (schwach) differenzierbar, so ist  $f(x) := F'(x)$  die zugehörige Wahrscheinlichkeitsdichte.

Vollkommen Analoges gilt für die Dichte  $f^X$ , die Verteilungsfunktion  $F^X$  und die Verteilung  $P^X$  einer reellwertigen Zufallsvariablen  $X$ .

**1.34 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  $\mathfrak{B}_{\mathbb{R}^d}$ , und es gilt  $P_f(B) = \int_B f(x) dx$ .

**1.35 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  $\mu \in \mathbb{R}$ ,  $\sigma > 0$ .

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

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

Produkt-dichte 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

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

**1.37 Satz (Dichtetransformationssatz).** *Es seien  $X$  ein  $d$ -dimensionaler Zufallsvektor mit Dichte  $f^X$  sowie  $Y = \varphi(X)\mathbf{1}(X \in U)$  für einen  $C^1$ -Diffeomorphismus  $\varphi : U \rightarrow V$  mit  $U, V \subseteq \mathbb{R}^d$  offen und  $P(X \in U) = 1$ . Dann ist  $Y$  ein Zufallsvektor mit Dichte*

$$f^Y(y) = f^X(\varphi^{-1}(y)) |\det(D(\varphi^{-1})(y))| \mathbf{1}(y \in V), \quad y \in \mathbb{R}^d.$$

Ist allgemeiner  $\varphi : U \rightarrow V$  und  $U = \bigcup_{i=1}^n U_i$  eine Zerlegung in offene Mengen  $U_i$  derart, dass  $P(X \in U) = 1$  und  $\varphi_i = \varphi|_{U_i} : U_i \rightarrow \varphi(U_i)$ ,  $i = 1, \dots, n$ , jeweils einen  $C^1$ -Diffeomorphismus definiert, so besitzt  $Y = \varphi(X)$  die Dichte  $f^Y = \sum_{i=1}^n g_i$  mit

$$g_i(y) = f^X(\varphi_i^{-1}(y)) |\det(D(\varphi_i^{-1})(y))| \mathbf{1}(y \in \varphi(U_i)), \quad y \in \mathbb{R}^d.$$

Konvention: setze  $A \bullet 0 := 0$  auch für Ausdrücke  $A$ , die nicht wohldefiniert sind.

**1.38 Korollar.**

- (a) Ist  $X$  eine reellwertige Zufallsvariable mit Dichte  $f^X$ , so besitzt  $Y = aX + b$  für  $a \in \mathbb{R} \setminus \{0\}$ ,  $b \in \mathbb{R}$  die Dichte  $f^Y(y) = |a|^{-1} f^X(a^{-1}(y - b))$ .
- (b) Ist  $X$  ein  $d$ -dimensionaler Zufallsvektor mit Dichte  $f^X$ , so besitzt  $Y = AX + b$  für  $A \in \mathbb{R}^{d \times d}$  invertierbar und  $b \in \mathbb{R}^d$  die Dichte  $f^Y(y) = |\det(A)|^{-1} f^X(A^{-1}(y - b))$ .

**1.39 Beispiele.**

- (a) Ist  $X$  eine  $N(0, 1)$ -verteilte Zufallsvariable, so ist  $Y = \mu + \sigma X$  eine  $N(\mu, \sigma^2)$ -verteilte Zufallsvariable mit  $\mu \in \mathbb{R}$ ,  $\sigma > 0$ . Weiterhin ist  $Z = X^2$  eine  $\chi^2(1)$ -verteilte Zufallsvariable, wobei die  $\chi^2$ -Verteilung mit einem Freiheitsgrad gegeben ist durch die Wahrscheinlichkeitsdichte  $f_{\chi^2(1)}(x) = \frac{1}{\sqrt{2\pi x}} e^{-x/2} \mathbf{1}_{\mathbb{R}^+}(x)$ ,  $x \in \mathbb{R}$ .
- (b) Sind  $X$  ein  $d$ -dimensionaler standard-normalverteilter Zufallsvektor sowie  $\mu \in \mathbb{R}^d$ ,  $A \in \mathbb{R}^{d \times d}$  mit  $\det(A) \neq 0$  deterministisch, so ist  $Y = \mu + AX$  ein  $d$ -dimensionaler Zufallsvektor mit Dichte

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

wobei  $\Sigma = A^\top A$  eine symmetrische positiv-definite Matrix ist.  $Y$  ist normalverteilt mit Mittelwertvektor  $\mu$  und Kovarianzmatrix  $\Sigma$ , kurz  $Y \sim N(\mu, \Sigma)$ .

## 2 Bedingte Wahrscheinlichkeiten und Unabhängigkeit

### 2.1 Bedingte Wahrscheinlichkeiten und Bayes-Formel

**2.1 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.

**2.2 Beispiel.** Beim Wurf von zwei Würfeln mit den Ereignissen  $A$  = „Pasch“ und  $B$  = „beide Augenzahlen ungerade“ gilt  $P(A|B) = \frac{3/36}{9/36} = \frac{1}{3} > \frac{1}{6} = P(A)$ .

**2.3 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  $A$  mit  $P(A) > 0$  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.

**2.4 Beispiel.** Eine seltene Krankheit kommt bei 0,5% der Bevölkerung vor. Ein Test führt bei 99% der Kranken zu einer positiven Reaktion, aber auch bei 2% der Gesunden. Die Wahrscheinlichkeit, dass eine zufällig ausgewählte Person mit positivem Testergebnis krank ist, beträgt dann nach der Bayesformel  $\frac{0,005 \cdot 0,99}{0,005 \cdot 0,99 + 0,995 \cdot 0,02} \approx 0,2$ , d.h. nur ca. 20%.

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

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

**2.6 Beispiel.** Beim Ziehen aus einer Urne mit  $W$  weißen und  $S$  schwarzen Kugeln ohne Zurücklegen und mit Beachtung der Reihenfolge ergibt sich mit  $N = S + W$  für das Ergebnis 'SSW' (d.h. 1. und 2. Kugel schwarz, 3. Kugel weiß) nach der Pfadregel die Wahrscheinlichkeit  $\frac{S}{N} \cdot \frac{S-1}{N-1} \cdot \frac{W}{N-2}$ . Dieselbe Wahrscheinlichkeit besitzen die Versuchsausgänge 'SWS' und 'WSS' (man nennt die Verteilung *austauschbar*).

**2.7 Beispiel** (Scheinkorrelationen). An einer Universität werden von 825/560/325 männlichen Bewerbern für Fach 1/2/3 jeweils 62%/63%/34% zugelassen, von 108/25/593 weiblichen Bewerberinnen hingegen 82%/68%/37%. Obwohl die Zulassungsquote in jedem Fach für Frauen höher war, ergibt sich nach der Formel von der totalen Wahrscheinlichkeit insgesamt eine Zulassungsquote von ca. 57% für Männer und von ca. 45% für Frauen, weil Letztere sich stärker für Fach 3 mit schwierigerer Zulassung beworben haben.

## 2.2 Unabhängige Ereignisse und Lemma von Borel-Cantelli

### 2.8 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

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

**2.9 Beispiel.** Beim Würfeln mit zwei Würfeln haben die Ereignisse „Augensumme ist 7“ und „erste Augenzahl ist 6“ jeweils Wahrscheinlichkeit  $1/6$  unter Gleichverteilung. Der Schnitt der beiden Ereignisse ist „erste Augenzahl ist 6, zweite Augenzahl ist 1“ und hat Wahrscheinlichkeit  $1/36$ , so dass die beiden Ereignisse (unter Gleichverteilung) unabhängig sind.

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

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

**2.11 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  $P(\limsup_{n \rightarrow \infty} A_n) = 1$ .

### 2.12 Beispiele.

- (a) Ist  $A$  ein Ereignis mit  $P(A) \in (0, 1)$ , so gilt  $\sum_{n \geq 1} P(A_n) = \infty$  für  $A_n := A$ , jedoch  $P(\limsup_{n \rightarrow \infty} A_n) = P(A) < 1$ . Auf die Unabhängigkeit in Teil (b) des Lemmas von Borel-Cantelli kann also nicht verzichtet werden.
- (b) Im unendlichen Münzwurfexperiment bezeichne  $A_n^M := \{\omega \in \Omega \mid \omega_n = \omega_{n+1} = \dots = \omega_{n+M-1} = 1\}$  das Ereignis eines  $M$ -runs von Einsen ('Kopf') ab Wurf  $n$ . Dann ist die Familie  $(A_{kM}^M)_{k \geq 1}$  unabhängig (auf dem entsprechenden Münzwurfmodell in den Übungen) mit  $P(A_{kM}^M) = 2^{-M}$ . Aus Teil (b) des Lemmas von Borel-Cantelli

folgt daher  $P(\limsup_{k \rightarrow \infty} A_{kM}^M) = 1$  für jedes  $M \in \mathbb{N}$ . Dies impliziert  $P(\limsup_{n \rightarrow \infty} A_n^M) = 1$ . Es gilt sogar  $P(\bigcap_{M \geq 1} \limsup_{n \rightarrow \infty} A_n^M) = 1$  („Abzählbarer Schnitt von Einsmengen ist wiederum Einsmenge“).

**2.13 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.

### 2.3 Unabhängige Zufallsvariablen und $\sigma$ -Algebren

**2.14 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. Äquivalent ist die Familie  $(X_i)_{i \in I}$  unabhängig, falls die von  $X_i$  erzeugten  $\sigma$ -Algebren  $\mathcal{F}^{X_i} = \{X_i^{-1}(A) \mid A \in \mathcal{S}_i\}$ ,  $i \in I$ , unabhängig sind.

**2.15 Lemma.** Sind  $(X_i)_{i \in I}$  eine Familie unabhängiger  $(S_i, \mathcal{S}_i)$ -wertiger Zufallsvariablen und  $g_i : S_i \rightarrow T_i$   $(\mathcal{S}_i, \mathcal{T}_i)$ -messbare Funktionen, so besteht auch die Familie  $(g_i(X_i))_{i \in I}$  aus unabhängigen Zufallsvariablen.

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

**2.17 Beispiel.** Ist  $(A_i)_{i \in I}$  eine Familie unabhängiger Ereignisse, so sind  $X_i = \mathbf{1}_{A_i}$ ,  $i \in I$ , unabhängige  $\{0, 1\}$ -wertige Zufallsvariablen. Zum Nachweis reicht es, jeweils den  $\cap$ -stabilen Erzeuger  $\mathcal{E} = \{1\}$  der Potenzmenge  $\mathcal{P}(\{0, 1\})$  zu betrachten.

**2.18 Korollar.** 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.

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

(a) Sind  $X_k$  diskret-verteilte  $S_k$ -wertige Zufallsvariablen, so sind  $X_1, \dots, X_n$  genau dann unabhängig, wenn gilt

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

(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

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

**2.20 Beispiel.** Beim Würfelwurf mit zwei Würfeln sind  $X_i : \Omega \rightarrow \{1, \dots, 6\}$  mit  $X_i(\omega_1, \omega_2) = \omega_i$  für  $i \in \{1, 2\}$  unabhängige Zufallsvariablen (unter Gleichverteilung). Dazu reicht es, für  $k_1, k_2 \in \{1, \dots, 6\}$  für die entsprechenden Zähl-dichten  $p^{X_1}(k_1) = p^{X_2}(k_2) = 1/6$  sowie  $p^{(X_1, X_2)}(k_1, k_2) = 1/36$  nachzuprüfen und Teil (a) des Korollars anzuwenden.

**2.21 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

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

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

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

**2.22 Beispiel.** Sind  $f_1, \dots, f_n$  Dichten auf  $\mathbb{R}$ , so definiert die Produktdichte  $f(x) = \prod_{i=1}^n f_i(x_i)$  ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}^n, \mathcal{B}_{\mathbb{R}^n})$ . Die Koordinatenprojektionen  $X_i : \mathbb{R}^n \rightarrow \mathbb{R}$  mit  $X_i(x_1, \dots, x_n) = x_i$ ,  $i = 1, \dots, n$ , sind Borel-messbar, also Zufallsvariablen. Ihre Verteilung  $P^{X_i}$  ist gegeben durch die Dichte  $f_i$ , ihre gemeinsame Verteilung  $P^{(X_1, \dots, X_n)}$  durch die Dichte  $f$ . Wir haben damit einen Wahrscheinlichkeitsraum konstruiert mit unabhängigen Zufallsvariablen  $(X_i)_{1 \leq i \leq n}$ , deren Verteilung  $P^{X_i}$  jeweils durch  $f_i$  bestimmt ist.

Die Konstruktion einer Folge  $(X_i)_{i \in \mathbb{N}}$  unabhängiger Zufallsvariablen mit vorgeschriebener Randverteilung ist hingegen mit größerem Aufwand verbunden.

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

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

Die Produkt- $\sigma$ -Algebra  $\bigotimes_{i \in I} \mathcal{F}_i$  ist also die kleinste  $\sigma$ -Algebra, so dass alle  $\pi_i$  messbar sind.

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

$$\forall J \subseteq I \text{ endlich, } A_j \in \mathcal{F}_j : P\left(\bigcap_{j \in J} \pi_j^{-1}(A_j)\right) = \prod_{j \in J} P_j(A_j),$$

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

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

**2.25 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.

**2.26 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

$$\mathcal{A}_X := \bigcap_{n \geq 1} \sigma\left(\bigcup_{k \geq n} \mathcal{F}^{X_k}\right).$$

**2.27 Beispiel.** Es seien  $X_k, k \in \mathbb{N}$ , reellwertige Zufallsvariablen sowie  $A$  das Ereignis, dass  $\lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{X_k}{k}$  existiert. Dann gilt nach dem Cauchy-Kriterium

$$A = \bigcap_{\varepsilon > 0, \varepsilon \in \mathbb{Q}} \bigcup_{N \in \mathbb{N}} B_N \text{ mit } B_N = \bigcap_{m \geq n \geq N} \left\{ \sum_{k=n}^m \frac{X_k}{k} \in (-\varepsilon, \varepsilon) \right\}.$$

Nun ist  $B_N \subseteq B_{N+1}$  sowie  $B_N \in \sigma(\bigcup_{k \geq N} \mathcal{F}^{X_k})$ . Daher gilt  $\bigcup_{N=1}^{N_{max}} B_N = B_{N_{max}} \in \sigma(\bigcup_{k \geq n} \mathcal{F}^{X_k})$  für alle  $N_{max} \geq n$ . Dies impliziert  $\bigcup_{N=1}^{\infty} B_N \in \sigma(\bigcup_{k \geq n} \mathcal{F}^{X_k})$  für alle  $n \in \mathbb{N}$  und somit, dass  $A$  ein asymptotisches Ereignis ist. Insbesondere ist  $\mathcal{A}_X$  nicht leer.

**2.28 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  $P(A) = 1$ .*

**2.29 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  $\mathcal{F}_1 := \sigma(\bigcup_{i \in I_1} \mathcal{F}^{X_i})$  und  $\mathcal{F}_2 := \sigma(\bigcup_{i \in I_2} \mathcal{F}^{X_i})$  unabhängig.*

**2.30 Beispiel** (Harmonische Reihe mit zufälligen Vorzeichen). Sind  $(X_k)_{k \geq 1}$  unabhängige  $\{-1, 1\}$ -wertige Zufallsvariablen, so konvergiert die Reihe  $\sum_{k=1}^{\infty} X_k \frac{1}{k}$  entweder mit Wahrscheinlichkeit 1 oder sie divergiert mit Wahrscheinlichkeit 1. Diese Aussage gilt für jede beliebige Randverteilung  $P^{X_k}$  der Zufallsvariablen  $X_k, k \in \mathbb{N}$ .

## 2.4 Faltung

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

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

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

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

**2.34 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  $\mathbb{N}_0$ :  $(p * q)(k) := \sum_{m=0}^k p(k - m)q(m)$ ).*

**2.35 Beispiel.** Ist  $X$  Poiss( $\lambda_x$ )- und  $Y$  Poiss( $\lambda_y$ )-verteilt und sind  $X$  und  $Y$  unabhängig, so ist  $X + Y$  Poiss( $\lambda_x + \lambda_y$ )-verteilt.

**2.36 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

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

**2.37 Beispiel.** Für  $\lambda, p > 0$  definiere die Gamma-Verteilung  $\Gamma(\lambda, p)$  über die Dichte

$$f_{\lambda,p}(x) = \frac{\lambda^p}{\Gamma(p)} x^{p-1} e^{-\lambda x} \mathbf{1}_{(0,\infty)}(x), \quad x \in \mathbb{R},$$

mit der Gamma-Funktion  $\Gamma(p) = \int_0^\infty t^{p-1} e^{-t} dt$ , so dass  $\Gamma(n+1) = n!$  für  $n \in \mathbb{N}_0$  und  $\Gamma(1/2) = \sqrt{\pi}$ . Spezialfälle sind  $\Gamma(\lambda, 1) = \text{Exp}(\lambda)$ ,  $\Gamma(1/2, 1/2) = \chi^2(1)$ .

Setzt man zusätzlich  $\Gamma(\lambda, 0) = \delta_0$ , so bildet  $(\Gamma(\lambda, p))_{p \geq 0}$  für festes  $\lambda > 0$  eine Faltungshalbgruppe, d.h. es gilt  $\Gamma(\lambda, p_1) * \Gamma(\lambda, p_2) = \Gamma(\lambda, p_1 + p_2)$ . Insbesondere ist die Summe von  $n$  unabhängigen  $\chi^2(1)$ -verteilten Zufallsvariablen (äquivalent: die quadrierte Norm  $\|Z\|^2$  eines standard-normalverteilten Zufallsvektors  $Z \sim N(0, E_n)$  im  $\mathbb{R}^n$ ) gemäß  $\chi^2(n) := \Gamma(1/2, n/2)$ -verteilt ( $\chi^2$ -Verteilung mit  $n$  Freiheitsgraden). Im Spezialfall  $n = 2$  ergibt sich  $\chi^2(2) = \text{Exp}(1/2)$ , was für die Box-Müller-Methode zur Simulation der Normalverteilung genutzt wird.

### 3 Erwartungswert, Varianz und Kovarianz

#### 3.1 Erwartungswert und Momente

**3.1 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

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

**3.2 Beispiel.** Beim Würfeln mit zwei fairen Würfeln ergibt sich für die Augensumme  $S$

$$\mathbb{E}[S] = 2P(S = 2) + 3P(S = 3) + \dots + 12P(S = 12) = 7.$$

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

- (a)  $\mathbb{E}[X] = \sum_{x \in X(\Omega)} x P(X = x)$ ; 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  $\mathbb{E}[X \bullet Y] = \mathbb{E}[X] \bullet \mathbb{E}[Y]$ .
- (d) Für jedes  $A \in \mathcal{F}$  gilt  $\mathbb{E}[\mathbf{1}_A] = P(A)$ .

**3.4 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 eine solche Folge  $(X_n)$  stets existiert und  $\mathbb{E}[X]$  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

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

Der Erwartungswert  $\mathbb{E}[X]$  ist also das Lebesgueintegral von  $X$  bezüglich  $P$ , und man schreibt  $\mathbb{E}[X] = \int X dP = \int_{\Omega} X(\omega) P(d\omega)$  sowie  $\int_A X dP = \int_{\Omega} X(\omega) \mathbf{1}_A(\omega) P(d\omega)$  für  $A \in \mathcal{F}$ .

**3.5 Definition.** Ist  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum, so heißt eine messbare Funktion  $f : \Omega \rightarrow [0, \infty)$   $\mu$ -Dichte oder genauer  $\mu$ -Wahrscheinlichkeitsdichte, falls  $\int_{\Omega} f d\mu = 1$  gilt. Für Maße  $\mu, \nu$  auf  $(\Omega, \mathcal{F})$  heißt  $\nu$  absolut-stetig bezüglich  $\mu$  (Notation:  $\nu \ll \mu$ ), falls  $\mu(A) = 0$  für  $A \in \mathcal{F}$  impliziert  $\nu(A) = 0$ .

**3.6 Lemma.** Ist  $f$   $\mu$ -Dichte auf  $(\Omega, \mathcal{F}, \mu)$ , so definiert  $P(A) = \int_A f d\mu$ ,  $A \in \mathcal{F}$ , ein Wahrscheinlichkeitsmaß mit  $P \ll \mu$ . Ist  $\mu$  das Zählmaß auf  $\Omega$ , so sind  $\mu$ -Dichten gerade Zähldichten; ist  $\mu$  das Lebesguemaß auf dem  $\mathbb{R}^d$ , so sind  $\mu$ -Dichten gerade Dichtefunktionen im  $\mathbb{R}^d$ .

**3.7 Satz.** Es sei  $X$  ein Zufallsvariable mit Werten in  $(S, \mathcal{S})$  und  $h : S \rightarrow \mathbb{R}$  Borel-messbar. Dann gilt

(a)  $h(X) \in \mathcal{L}^1 \iff \int_S |h(x)| P^X(dx) < \infty.$

(b) Für  $h(X) \in \mathcal{L}^1$  gilt

$$\mathbb{E}[h(X)] = \int_S h(x) P^X(dx).$$

(c) Ist  $X$  ein Zufallsvektor im  $\mathbb{R}^d$  mit Dichte  $f^X$ , so gilt  $h(X) \in \mathcal{L}^1 \iff \int_{\mathbb{R}^d} |h(x)| f^X(x) dx < \infty$ . In dem Fall ist

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

(d) Ist  $X$  diskret verteilt auf  $\mathbb{Z}$  mit Zähldichte  $p^X$ , so gilt  $h(X) \in \mathcal{L}^1 \iff \sum_{k \in \mathbb{Z}} |h(k)| p^X(k) < \infty$ . In dem Fall ist

$$\mathbb{E}[h(X)] = \sum_{k \in \mathbb{Z}} h(k) p^X(k).$$

**3.8 Beispiel.** Für  $X \sim N(0, 1)$  gilt mit partieller Integration unter Benutzung von  $(e^{-x^2/2})' = -xe^{-x^2/2}$

$$\mathbb{E}[X^2] = \int_{\mathbb{R}} x^2 P^X(dx) = \frac{-1}{\sqrt{2\pi}} \int_{\mathbb{R}} x(-xe^{-x^2/2})dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{-x^2/2} dx = 1.$$

Alternativ verwende man, dass  $Y = X^2$   $\chi^2(1)$ -verteilt ist, so dass  $\mathbb{E}[X^2] = \int_0^\infty y(2\pi y)^{-1/2} e^{-y/2} dy = 1$ .

**3.9 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: ist  $Y$  eine weitere Zufallsvariable in  $\mathcal{L}^1$  und sind  $\alpha, \beta \in \mathbb{R}$ , so gilt

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

(c) Der Erwartungswert ist monoton: ist  $Y$  eine weitere Zufallsvariable in  $\mathcal{L}^1$  mit  $X \leq Y$ , so gilt  $\mathbb{E}[X] \leq \mathbb{E}[Y]$ . Aus  $X \leq Y$  und  $\mathbb{E}[X] = \mathbb{E}[Y]$  folgt  $P(X = Y) = 1$ .

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

**3.10 Definition.** Wir sagen, dass eine Zufallsvariable  $X$  in  $\mathcal{L}^p = \mathcal{L}^p(P)$  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  $X$ ; für  $X \in \mathcal{L}^p$  und  $p > 0$  heißt  $\mathbb{E}[|X|^p]$  das  $p$ -te absolute Moment von  $X$ .

**3.11 Satz.** Für  $X \in \mathcal{L}^p$  und  $Y \in \mathcal{L}^q$  mit  $\frac{1}{p} + \frac{1}{q} = 1$  gelten  $XY \in \mathcal{L}^1$  und die Hölder-Ungleichung

$$|\mathbb{E}[XY]| \leq \mathbb{E}[|X|^p]^{1/p} \mathbb{E}[|Y|^q]^{1/q}.$$

Insbesondere gelten  $XY \in \mathcal{L}^1(P)$  für  $X, Y \in \mathcal{L}^2(P)$  und die Cauchy-Schwarz-Ungleichung

$$|\mathbb{E}[XY]| \leq \mathbb{E}[X^2]^{1/2} \mathbb{E}[Y^2]^{1/2}.$$

**3.12 Korollar.** Für  $0 < p \leq q$  gelten  $\mathcal{L}^q \subseteq \mathcal{L}^p$  und  $\mathbb{E}[|X|^p] \leq \mathbb{E}[|X|^q]^{p/q}$  für  $X \in \mathcal{L}^q$ .

**3.13 Satz.** Für eine Zufallsvariable  $X \in \mathcal{L}^2$  gilt die Bias-Varianz-Zerlegung

$$\forall x \in \mathbb{R} : \mathbb{E}[(X - x)^2] = \underbrace{(\mathbb{E}[X] - x)^2}_{\text{Bias}^2} + \underbrace{\mathbb{E}[(X - \mathbb{E}[X])^2]}_{\text{Varianz}}.$$

Die Funktion  $\varphi(x) = \mathbb{E}[(X - x)^2]$  nimmt ihr Minimum auf  $\mathbb{R}$  genau bei  $x = \mathbb{E}[X]$  an.

**3.14 Definition.** Es sei  $I \subseteq \mathbb{R}$  ein (ggf. auch unendliches) Intervall. Eine Funktion  $\varphi : I \rightarrow \mathbb{R}$  heißt konvex, falls

$$\forall x, y \in I, \alpha \in [0, 1] : \varphi(\alpha x + (1 - \alpha)y) \leq \alpha\varphi(x) + (1 - \alpha)\varphi(y).$$

**3.15 Beispiel.** Ist  $\varphi : I \rightarrow \mathbb{R}$  stetig differenzierbar mit monoton wachsender Ableitung  $\varphi'$  (z.B. wenn  $\varphi'' \geq 0$  auf  $I$ ), so ist  $\varphi$  konvex. Insbesondere sind  $\varphi(x) = e^{\alpha x}$  für  $\alpha \in \mathbb{R}$  beliebig und  $\varphi(x) = |x|^p$  für  $p > 1$  konvex auf  $I = \mathbb{R}$ . Auch  $\varphi(x) = |x|$  ist konvex auf  $\mathbb{R}$ .

**3.16 Lemma.** Ist  $\varphi : I \rightarrow \mathbb{R}$  konvex, so existieren für alle  $x \in \text{int}(I)$  (Inneres von  $I$ ) die links- und rechtsseitigen Ableitungen  $\varphi'(x-)$ ,  $\varphi'(x+)$  mit  $\varphi'(x-) \leq \varphi'(x+)$ . Es gilt weiterhin

$$\forall x \in \text{int}(I), y \in I : \varphi(y) \geq \varphi(x) + \varphi'(x+)(y - x).$$

**3.17 Satz.** Es sei  $X \in \mathcal{L}^1$  mit Werten in einem offenen Intervall  $I$ . Dann gilt  $\mathbb{E}[X] \in I$ . Ist  $\varphi : I \rightarrow \mathbb{R}$  konvex und  $\varphi(X) \in \mathcal{L}^1$ , so gilt die Jensensche Ungleichung

$$\mathbb{E}[\varphi(X)] \geq \varphi(\mathbb{E}[X]).$$

**3.18 Beispiel.** Für  $q > p > 0$  ist  $\varphi(x) = |x|^{q/p}$  konvex, und die Jensensche Ungleichung liefert ebenfalls  $\mathbb{E}[|X|^p] \leq \mathbb{E}[|X|^q]^{p/q}$  für  $X \in \mathcal{L}^p \cap \mathcal{L}^q$ .

## 3.2 Varianz, Kovarianz und Korrelation

**3.19 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  $X$ .

**3.20 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  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .

**3.21 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 linear-affinen Funktionen von  $X$  basierenden Zufallsvariablen. Dann nimmt der mittlere quadratische Fehler

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

sein 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  $\text{Var}(X), \text{Var}(Y) > 0$  gilt

$$\varphi(a^*X + b^*) = \text{Var}(Y) - \text{Cov}(X, Y)^2 / \text{Var}(X) = \text{Var}(Y)(1 - \rho^2(X, Y))$$

mit nachfolgend definierter Kovarianz  $\text{Cov}(X, Y)$  und Korrelation  $\rho(X, Y)$ .

**3.22 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, 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.

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

- (a)  $\text{Cov}(X, Y) = \text{Cov}(Y, X) = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]$ ,  $\text{Cov}(X, X) = \text{Var}(X)$ ;
- (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)  $X, Y$  unabhängig  $\Rightarrow X, Y$  unkorreliert;
- (f)  $|\text{Cov}(X, Y)| \leq \sigma(X)\sigma(Y)$  und  $\rho(X, Y) \in [-1, +1]$ .

**3.24 Beispiele.**

- (a) Eine  $\text{Bin}(n, p)$ -verteilte Zufallsvariable  $X$  ergibt sich als  $X = \sum_{i=1}^n X_i$  mit einem Bernoullischema  $(X_i)$ , d.h.  $(X_i)_{i=1, \dots, n}$  unabhängig mit  $P(X_i = 1) = p$ ,  $P(X_i = 0) = 1 - p$ . Damit folgt  $X \in \mathcal{L}^2$  und  $\mathbb{E}[X] = \sum_{i=1}^n \mathbb{E}[X_i] = np$ ,  $\text{Var}(X) = \sum_{i=1}^n \text{Var}(X_i) = np(1 - p)$ . Da Erwartungswert und Varianz nur von der Verteilung abhängen, sagt man, dass die  $\text{Bin}(n, p)$ -Verteilung Erwartungswert  $np$  und Varianz  $np(1 - p)$  besitzt. Im Fall  $p \in \{0, 1\}$  gilt also  $\text{Var}(X) = 0$  sowie stets  $\text{Var}(X) \leq n/4$ . Die *relative Häufigkeit* von Erfolgen  $A = X/n$  erfüllt  $\mathbb{E}[A] = p$  (*Erwartungstreu*) und  $\text{Var}(A) = \frac{p(1-p)}{n}$ .
- (b) Für eine  $N(\mu, \sigma^2)$ -verteilte Zufallsvariable  $X$  mit  $\mu \in \mathbb{R}$ ,  $\sigma > 0$  gilt nach dem Dichtetransformationssatz, dass  $Z = (X - \mu)/\sigma$   $N(0, 1)$ -verteilt ist. Nun sind  $X, Z \in \mathcal{L}^2$  und wir schließen  $\text{Var}(X) = \text{Var}(\sigma Z + \mu) = \sigma^2 \text{Var}(Z) = \sigma^2$ .

- (c) Bezeichnen  $X_1$  und  $X_2$  die Augenzahlen beim Wurf zweier Würfel, so ist  $S = X_1 + X_2$  die Augensumme und  $D = X_1 - X_2$  die Augendifferenz. Es gilt

$$\text{Cov}(S, D) = \text{Var}(X_1) + \text{Cov}(X_2, X_1) - \text{Cov}(X_1, X_2) - \text{Var}(X_2) = 0,$$

und  $S$  und  $D$  sind unkorreliert (gilt allgemein für  $X_1, X_2 \in \mathcal{L}^2$  mit  $\text{Var}(X_1) = \text{Var}(X_2)$ ). Allerdings sind  $S$  und  $D$  *nicht* unabhängig; denn es gilt beispielsweise  $P(S = 2, D = 5) = 0$ , aber  $P(S = 2)P(D = 5) > 0$ . Die beste (nicht nur lineare) Vorhersage von  $D$  gegeben  $S$  ist gerade konstant  $\mathbb{E}[D] = 0$ , da  $D$  unter jeder Bedingung  $\{S = k\}$  symmetrisch um 0 verteilt ist:  $P(D = m | S = k) = P(D = -m | S = k)$ .

### 3.3 Mehrdimensionale Normalverteilung

**3.25 Definition.** Es seien  $\mu \in \mathbb{R}^d$  ein Vektor 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  $\Sigma$ . Im regulären Fall einer invertierbaren Matrix  $\Sigma$  besitzt  $N(\mu, \Sigma)$  nach obiger Herleitung die Dichte

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

**3.26 Beispiel.** Ist  $\Sigma$  nicht invertierbar, so auch  $\Sigma^{1/2}$ , und  $Y = \mu + \Sigma^{1/2}Y$  nimmt Werte in einem echten (affinen) Unterraum des  $\mathbb{R}^d$  an, dessen Lebesguemaß Null ist. In diesem Fall besitzt  $N(\mu, \Sigma)$  also keine Dichte. Im Eindimensionalen gilt  $N(\mu, 0) = \delta_\mu$ .

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

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

**3.28 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.

**3.29 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.

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

*Proof.* Wir müssen zeigen, dass sich  $Y$  darstellen lässt als  $Y = A\mu + (A\Sigma A^\top)^{1/2}Z$  mit einer geeigneten Zufallsvariablen  $Z \sim N(0, E_m)$ . Aus der

Darstellung  $X = \mu + \Sigma^{1/2}W$  mit  $W \sim N(0, E_d)$  ergibt sich die zu erfüllende Bedingung als

$$A(\mu + \Sigma^{1/2}W) = A\mu + (A\Sigma A^\top)^{1/2}Z, \text{ d.h. } A\Sigma^{1/2}W = (A\Sigma A^\top)^{1/2}Z.$$

Der Satz zur orthogonalen Normalform (z.B. in M. Koecher, Lineare Algebra und Analytische Geometrie, Seite 199) zeigt, dass es orthogonale Matrizen  $T_1 \in \mathbb{R}^{m \times m}, T_2 \in \mathbb{R}^{d \times d}$  und eine Diagonalmatrix  $D \in \mathbb{R}^{r \times r}, r \leq \min(m, d)$ , mit strikt positiven Diagonaleinträgen gibt, so dass in Blockmatrixnotation (beachte jeweils die Dimensionen!)  $A\Sigma^{1/2} = T_1 \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} T_2$  gilt. Dies impliziert

$$\begin{aligned} (A\Sigma A^\top)^{1/2} &= (A\Sigma^{1/2}(A\Sigma^{1/2})^\top)^{1/2} = \left( T_1 \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix}^\top T_1^\top \right)^{1/2} \\ &= T_1 \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} T_1^\top. \end{aligned}$$

Wir müssen also  $Z \sim N(0, E_m)$  finden mit  $\begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} T_1^\top Z = \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} T_2 W$ .

Setze  $Z := T_1 \left( \begin{pmatrix} E_r & 0 \\ 0 & 0 \end{pmatrix} T_2 W + W' \right)$  mit  $W' \sim N(0, \begin{pmatrix} 0 & 0 \\ 0 & E_{m-r} \end{pmatrix})$  unabhängig von  $W$ , ggf. definiert auf einem größeren Wahrscheinlichkeitsraum (bzw.  $W' = 0$  falls  $m = r$ ). Aus dem Lemma folgt  $T_2 W \sim N(0, E_d)$ , weil  $T_2$  orthogonale Matrix ist, und weiter, dass  $\begin{pmatrix} E_r & 0 \\ 0 & 0 \end{pmatrix} T_2 W$  ein  $N(0, \begin{pmatrix} E_r & 0 \\ 0 & 0 \end{pmatrix})$ -verteilter Vektor im  $\mathbb{R}^m$  ist (Projektion auf die ersten  $r$ -Koordinaten). Daher gilt  $\begin{pmatrix} E_r & 0 \\ 0 & 0 \end{pmatrix} T_2 W + W' \sim N(0, E_m)$ , und es folgt wieder nach dem Lemma  $Z \sim N(0, E_m)$ .

Schließlich ergibt sich für  $(A\Sigma A^\top)^{1/2}Z$

$$T_1 \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} \left( \begin{pmatrix} E_r & 0 \\ 0 & 0 \end{pmatrix} T_2 W + W' \right) = T_1 \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} T_2 W = A\Sigma^{1/2}W,$$

wie zu zeigen war. □

**3.31 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. Insbesondere bildet  $(N(\mu t, \sigma^2 t))_{t \geq 0}$  für jedes  $\mu \in \mathbb{R}, \sigma \geq 0$  eine Faltungshalbgruppe.*

## 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 Beispiel.** Für  $X \in \mathcal{L}^p$  gilt  $P(|X| \geq K) \leq \mathbb{E}[|X|^p]K^{-p}$ ,  $K > 0$ .

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

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

**4.4 Beispiel.** Eine faire Münze werde 1000-mal geworfen und  $X$  bezeichne die Anzahl der Würfe mit 'Kopf'. Dann gilt

$$P(X \geq 550) \leq P(|X - 500| \geq 50) \leq \frac{250}{50^2} = 0,1.$$

**4.5 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  $\varepsilon > 0$

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

**4.6 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  $\|g\|_\infty := \sup_{x \in [0, 1]} |g(x)|$ .*

**4.7 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

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

Notation:  $X_n \xrightarrow{P} X$ .

Man sagt, dass  $X_n$   $P$ -fast sicher gegen  $X$  konvergiert, kurz  $X_n \rightarrow X$   $P$ -f.s., falls

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

**4.8 Beispiel.** Im schwachen Gesetz der großen Zahlen gilt  $A_n \xrightarrow{P} \mu$ .

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

**4.10 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  $\mu$ .*

**4.11 Definition.** Identifiziert man  $X, Y \in \mathcal{L}^p(\Omega, \mathcal{F}, P)$  (Zusammenfassung in einer Äquivalenzklasse), wenn  $X = Y$   $P$ -fast sicher, d.h.  $P(X = Y) = 1$ , gilt, so erhält man den Vektorraum  $L^p(\Omega, \mathcal{F}, P)$ . Mit der Norm  $\|X\|_{L^p} = \mathbb{E}[|X|^p]^{1/p}$  wird  $L^p(\Omega, \mathcal{F}, P)$  für  $p \geq 1$  zum Banachraum und mit dem Skalarprodukt  $\langle X, Y \rangle = \mathbb{E}[XY]$  wird  $L^2(\Omega, \mathcal{F}, P)$  zum Hilbertraum (Beweis in Analysis!). Für eine Folge  $(X_n)$  in  $\mathcal{L}^p(\Omega, \mathcal{F}, P)$ ,  $p > 0$ , und ein  $X \in \mathcal{L}^p(\Omega, \mathcal{F}, P)$  sagen wir, dass  $X_n$  gegen  $X$  in  $L^p$  konvergiert, falls  $\mathbb{E}[|X_n - X|^p] \rightarrow 0$  für  $n \rightarrow \infty$  gilt.

**4.12 Lemma.** Konvergiert  $(X_n)$  gegen  $X$  in  $L^p$  für ein  $p > 0$ , so auch stochastisch:  $X_n \xrightarrow{L^p} X \Rightarrow X_n \xrightarrow{P} X$ .

**4.13 Beispiel** (Harmonische Reihe mit zufälligen Vorzeichen). Betrachte  $S_n = \sum_{k=1}^n X_k \frac{1}{k}$  mit  $(X_k)$  unabhängig und  $P(X_k = 1) = P(X_k = -1) = 1/2$ . Dann gilt  $\mathbb{E}[S_n] = 0$ ,  $\text{Var}(S_n) = \sum_{k=1}^n \frac{1}{k^2}$ . Wegen  $\text{Var}(S_n - S_m) \leq \sum_{k \geq m} \frac{1}{k^2}$  für  $n > m$  und  $\lim_{m \rightarrow \infty} \sum_{k \geq m} \frac{1}{k^2} = 0$  bildet  $(S_n)$  eine Cauchyfolge in  $L^2$ . Es gilt also  $S_n \rightarrow S_\infty$  in  $L^2$  und damit auch stochastisch für ein  $S_\infty \in L^2$ .

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

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

**4.15 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.

Zusatz: andernfalls divergiert  $(S_n)_{n \geq 1}$  mit Wahrscheinlichkeit Eins.

**4.16 Beispiel** (Harmonische Reihe mit zufälligen Vorzeichen).  $S_n = \sum_{k=1}^n X_k \frac{1}{k}$  mit  $(X_k)$  unabhängig und  $P(X_k = 1) = P(X_k = -1) = 1/2$  konvergiert sogar  $P$ -f.s.

## 4.2 Konvergenz in Verteilung

**4.17 Definition.** Die  $\mathbb{R}^d$ -wertigen Zufallsvektoren  $(X_n)_{n \geq 1}$  konvergieren in Verteilung gegen den  $\mathbb{R}^d$ -wertigen Zufallsvektor  $X$ , Notation  $X_n \xrightarrow{d} X$ , falls für jede stetige beschränkte Funktion  $\varphi : \mathbb{R}^d \rightarrow \mathbb{R}$  gilt

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

Wahrscheinlichkeitsmaße  $(P_n)_{n \geq 1}$  auf  $(\mathbb{R}^d, \mathfrak{B}_{\mathbb{R}^d})$  konvergieren schwach gegen ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}^d, \mathfrak{B}_{\mathbb{R}^d})$ , Notation  $P_n \xrightarrow{w} P$ , falls für jede stetige beschränkte Funktion  $\varphi : \mathbb{R}^d \rightarrow \mathbb{R}$  gilt

$$\lim_{n \rightarrow \infty} \int_{\mathbb{R}^d} \varphi(x) P_n(dx) = \int_{\mathbb{R}^d} \varphi(x) P(dx).$$

Man definiert Konvergenz in Verteilung mit einem Wahrscheinlichkeitsmaß  $P$  als Grenzwert allgemein durch  $X_n \xrightarrow{d} P : \iff P^{X_n} \xrightarrow{w} P$ .

**4.18 Beispiel.** Ist  $X$  ein Zufallsvektor und  $a_n \in \mathbb{R}$ ,  $b_n \in \mathbb{R}^d$  mit  $a_n \rightarrow a$ ,  $b_n \rightarrow b$ , so gilt  $a_n X + b_n \xrightarrow{d} aX + b$ : Stetigkeit von  $\varphi$  impliziert  $\varphi(a_n X(\omega) + b_n) \rightarrow \varphi(aX(\omega) + b)$  für alle  $\omega \in \Omega$ . Nun ist  $\|\varphi\|_\infty$  eine integrierbare Majorante und majorisierte (dominierte) Konvergenz zeigt  $\mathbb{E}[\varphi(a_n X + b_n)] \rightarrow \mathbb{E}[\varphi(aX + b)]$ . Beachte, dass  $P_n \xrightarrow{w} P$  nicht impliziert  $P_n(B) \rightarrow P(B)$  für alle  $B \in \mathfrak{B}_{\mathbb{R}^d}$ : setze  $a_n = a = 0$  oben und schließe  $\delta_{b_n} \xrightarrow{d} \delta_b$ , während für  $b_n \neq b$  gilt  $\delta_{b_n}(\{b\}) = 0 \neq 1 = \delta_b(\{b\})$ .

**4.19 Satz.** Konvergiert  $X_n$  gegen  $X$  stochastisch, so auch in Verteilung:  $X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{d} X$ .

**4.20 Beispiel.** Die Umkehrung gilt nicht: für  $X$   $N(0, 1)$ -verteilt ist auch  $Y = -X$   $N(0, 1)$ -verteilt, so dass  $X_n \xrightarrow{d} Y$  für  $X_n := X$  gilt, während  $P(|X_n - Y| > \varepsilon) = P(2|X| > \varepsilon)$  für  $\varepsilon > 0$  nicht gegen Null konvergiert.

**4.21 Satz.** Für reellwertige Zufallsvariablen 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  $F^X$ ).

**4.22 Beispiele.**

- (a) Sind  $X_n$   $N(0, \sigma_n^2)$ -verteilt mit  $\sigma_n \rightarrow 0$ , so gilt  $X_n \xrightarrow{d} \delta_0 = N(0, 0)$ .
- (b) Sind  $X_n, X$  diskrete Zufallsvariablen mit Werten in  $\mathbb{Z}$ , so gilt  $X_n \xrightarrow{d} X$  genau dann, wenn für die Zähldichten  $p^{X_n}(k) \rightarrow p^X(k)$  für alle  $k \in \mathbb{Z}$  gilt. Der Poissonsche Grenzwertsatz besagt insbesondere  $\text{Bin}(n, p_n) \xrightarrow{w} \text{Poiss}(\lambda)$  für  $np_n \rightarrow \lambda > 0$ .
- (c) Sind  $U_1, \dots, U_n$  unabhängige  $U([0, 1])$ -verteilte Zufallsvariablen, so besitzt  $X_n = n \min(U_1, \dots, U_n)$  die Verteilungsfunktion  $F^{X_n}(x) = 1 - (1 - x/n)_+^n$  für  $x \geq 0$ . Es folgt  $n \min(U_1, \dots, U_n) \xrightarrow{d} \text{Exp}(1)$ .

**4.23 Satz.** (Auswahlsatz von Helly) Ist  $(P_n)$  eine Folge von Wahrscheinlichkeitsmaßen auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit Verteilungsfunktionen  $(F_n)$ , so existiert eine Teilfolge  $(n_k)$  und eine monoton wachsende rechtsstetige Funktion  $F : \mathbb{R} \rightarrow [0, 1]$  mit  $\lim_{k \rightarrow \infty} F_{n_k}(x) = F(x)$  für alle Stetigkeitspunkte von  $F$ .

**4.24 Beispiele.**

- (a) Sind  $P_n$  Wahrscheinlichkeitsmaße auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit Verteilungsfunktionen  $F_n$ , so folgt aus  $P_n \xrightarrow{w} P$ , dass  $F_n(x) \rightarrow F(x)$  an den Stetigkeitspunkten  $x$  von  $F$  gerade für die Verteilungsfunktion  $F$  von  $P$  gilt.
- (b) Ist  $P_n = U([n, n + 1])$  mit Verteilungsfunktionen  $F_n$ , so gilt  $\lim_{n \rightarrow \infty} F_n(x) = 0$  sowie  $\lim_{n \rightarrow -\infty} F_n(x) = 1$  für alle  $x \in \mathbb{R}$ . Für  $P_n = N(0, n)$  gilt  $\lim_{n \rightarrow \infty} F_n(x) = 1/2$  für alle  $x \in \mathbb{R}$ . Die Funktion  $F$  im Satz von Helly ist hier jeweils keine Verteilungsfunktion.

**4.25 Definition.** Eine Folge von Wahrscheinlichkeitsmaßen  $(P_n)$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  heißt (gleichgradig) straff, falls für jedes  $\varepsilon > 0$  ein  $K_\varepsilon > 0$  existiert mit  $\sup_{n \geq 1} P_n([-K_\varepsilon, K_\varepsilon]^c) \leq \varepsilon$ .

**4.26 Beispiel.** Es gelte  $P_n \xrightarrow{w} P$  und  $F$  bezeichne die Verteilungsfunktion von  $P$ . Dann gibt es für  $\varepsilon > 0$  ein  $x > 0$  mit  $F(-x) \leq -\varepsilon/4$ ,  $F(x) \geq 1 - \varepsilon/4$  und  $F$  ist stetig bei  $x$  und  $-x$ . Dann folgt  $P_n((-x, x]) \rightarrow F(x) - F(-x) \geq 1 - \varepsilon/2$ . Wähle nun  $N \in \mathbb{N}$ , so dass  $P_n([-x, x]) \geq 1 - \varepsilon$  für alle  $n \geq N$  sowie  $y \geq x$  mit  $P_n([-y, y]) \geq 1 - \varepsilon$  für  $n = 1, \dots, N - 1$  (möglich wegen  $\sigma$ -Stetigkeit). Dann gilt  $P_n([-y, y]^c) \leq \varepsilon$  für alle  $n$ .  $(P_n)$  ist also straff.

**4.27 Korollar.** Ist  $(P_n)$  eine straffe Folge von Wahrscheinlichkeitsmaßen, so gibt es eine Teilfolge  $(n_k)$  und ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ , so dass  $P_{n_k} \xrightarrow{w} P$  gilt.

### 4.3 Charakteristische Funktionen und Zentrale Grenzwertsätze

**4.28 Definition.** Für eine reellwertige Zufallsvariable  $X$  bezeichnet

$$\varphi^X(u) := \mathbb{E}[e^{iuX}] = \mathbb{E}[\cos(uX)] + i \mathbb{E}[\sin(uX)], \quad u \in \mathbb{R},$$

die charakteristische Funktion von  $X$ . Entsprechend ist für ein Wahrscheinlichkeitsmaß  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$

$$\varphi^P(u) := \int_{\mathbb{R}} e^{iux} P(dx) = \int_{\mathbb{R}} \cos(ux) P(dx) + i \int_{\mathbb{R}} \sin(ux) P(dx), \quad u \in \mathbb{R},$$

die charakteristische Funktion von  $P$ .

**4.29 Beispiele.**

- (a)  $\varphi^{\text{Bin}(n,p)}(u) = (pe^{iu} + 1 - p)^n$ ;
- (b)  $\varphi^{\text{Pois}(\lambda)}(u) = \exp(\lambda(e^{iu} - 1))$ ;
- (c)  $\varphi^{N(0,1)}(u) = e^{-u^2/2}$ ,  $\varphi^{N(\mu,\sigma^2)}(u) = e^{iu\mu - \sigma^2 u^2/2}$ .

**4.30 Lemma.** Eine charakteristische Funktion  $\varphi$  erfüllt  $\varphi(0) = 1$ ,  $\sup_u |\varphi(u)| \leq 1$  und ist gleichmäßig stetig auf  $\mathbb{R}$ .

**4.31 Lemma.** Es gilt  $\varphi^{P_1 * P_2}(u) = \varphi^{P_1}(u) \varphi^{P_2}(u)$  bzw.  $\varphi^{X_1 + X_2}(u) = \varphi^{X_1}(u) \varphi^{X_2}(u)$  für unabhängige Zufallsvariablen  $X_1, X_2$ .

**4.32 Lemma.** Für eine Zufallsvariable  $X \in \mathcal{L}^m(\Omega, \mathcal{F}, P)$  mit  $m \in \mathbb{N}$  gilt  $\varphi^X \in C^m(\mathbb{R})$  mit Ableitungen  $(\varphi^X)^{(k)}(0) = i^k \mathbb{E}[X^k]$ ,  $k = 0, \dots, m$ . Weiterhin existiert eine Funktion  $r_m : \mathbb{R} \rightarrow \mathbb{C}$  mit  $\sup_{u \in \mathbb{R}} |r_m(u)| \leq 3 \mathbb{E}[|X|^m]$  und  $r_m(u) \rightarrow 0$  für  $u \rightarrow 0$ , so dass gilt

$$\varphi^X(u) = \sum_{k=0}^m \frac{(iu)^k}{k!} \mathbb{E}[X^k] + \frac{(iu)^m}{m!} r_m(u).$$

**4.33 Satz.** (Eindeutigkeitsatz) Für  $a < b$  gilt die Inversionsformel

$$P((a, b)) + \frac{1}{2}P(\{a, b\}) = \frac{1}{2\pi} \lim_{U \rightarrow \infty} \int_{-U}^U \frac{e^{-iua} - e^{-iub}}{iu} \varphi^P(u) du.$$

Insbesondere sind zwei Wahrscheinlichkeitsmaße mit derselben charakteristischen Funktion identisch.

**4.34 Satz.** (Stetigkeitssatz von Lévy) Sind  $(P_n)$  Wahrscheinlichkeitsmaße auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$  mit charakteristischen Funktionen  $(\varphi_n)$  und gilt  $\lim_{n \rightarrow \infty} \varphi_n(u) = \psi(u)$  für alle  $u \in \mathbb{R}$  und eine bei  $u = 0$  stetige Funktion  $\psi$ , so ist  $\psi = \varphi^P$ , die charakteristische Funktion eines Wahrscheinlichkeitsmaßes  $P$  auf  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}})$ , und es gilt  $P_n \xrightarrow{w} P$ .

**4.35 Beispiele.**

(a) Für  $p_n \in [0, 1]$  mit  $\lim_{n \rightarrow \infty} np_n = \lambda > 0$  folgt  $\varphi^{\text{Bin}(n, p_n)} \rightarrow \varphi^{\text{Poiss}(\lambda)}$  punktweise. Der Stetigkeitssatz von Lévy impliziert daher den Poissonischen Grenzwertsatz  $\text{Bin}(n, p_n) \xrightarrow{w} \text{Poiss}(\lambda)$ .

(b) Ist  $S_n$   $\text{Bin}(n, p)$ -verteilt mit  $p \in (0, 1)$ , so ist  $S_n^* = \frac{S_n - np}{\sqrt{np(1-p)}}$  zentriert mit Varianz 1 (standardisiert). Es gilt mit  $q = 1 - p$  für  $n \rightarrow \infty$

$$\varphi^{S_n^*}(u) = (pe^{iuq/\sqrt{npq}} + qe^{-iup/\sqrt{npq}})^n = (1 - u^2/(2n) + o(1/n))^n,$$

so dass  $\varphi^{S_n^*}$  punktweise gegen  $\varphi^{N(0,1)}$  konvergiert. Es folgt  $S_n^* \xrightarrow{d} N(0, 1)$ .

(c) Für unabhängige  $U([-1, 1])$ -verteilte Zufallsvariablen  $X_j$ ,  $j \in \mathbb{N}$ , gilt  $\mathbb{E}[X_j] = 0$ ,  $\text{Var}(X_j) = 1/3$ . Die standardisierte Summe  $S_n^* = \sqrt{\frac{3}{n}} \sum_{j=1}^n X_j$  hat charakteristische Funktion

$$\varphi^{S_n^*}(u) = \left( \frac{\sin(\sqrt{3}u/\sqrt{n})}{\sqrt{3}u/\sqrt{n}} \right)^n = (1 - u^2/(2n) + o(1/n))^n.$$

Es folgt wiederum  $S_n^* \xrightarrow{d} N(0, 1)$  für  $n \rightarrow \infty$ .

**4.36 Satz.** (Zentraler Grenzwertsatz) Ist  $(X_i)_{i \geq 1}$  eine Folge unabhängiger und identisch verteilter Zufallsvariablen (i.i.d.=independent and identically distributed) in  $\mathcal{L}^2$  mit  $\mu = \mathbb{E}[X_i]$ ,  $\sigma^2 = \text{Var}(X_i) > 0$ , so erfüllt ihre standardisierte Summe

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

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

**4.37 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).

**4.38 Beispiel.** Im zentralen Grenzwertsatz folgt aus  $S_n^* \xrightarrow{d} N(0, 1)$  mit  $g(x) = \sigma x$ , dass  $g(S_n^*) = \frac{1}{\sqrt{n}} \sum_{i=1}^n (X_i - \mu) \xrightarrow{d} N(0, \sigma^2)$  gilt.

**4.39 Definition.** Eine Familie  $(X_j^{(n)})_{1 \leq j \leq n, n \geq 1}$  von Zufallsvariablen in  $\mathcal{L}^2$  bildet ein standardisiertes Dreiecksschema, falls für jedes  $n \in \mathbb{N}$  die Zufallsvariablen  $X_1^{(n)}, \dots, X_n^{(n)}$  („in einer Zeile“) unabhängig sind sowie  $\mathbb{E}[X_j^{(n)}] = 0$ ,  $j = 1, \dots, n$ , und  $\sum_{j=1}^n \text{Var}(X_j^{(n)}) = 1$  gilt.  $(X_j^{(n)})_{1 \leq j \leq n, n \geq 1}$  genügt der Lindeberg-Bedingung, falls gilt

$$\forall \delta > 0 : \lim_{n \rightarrow \infty} \mathbb{E} \left[ (X_j^{(n)})^2 \mathbf{1}(|X_j^{(n)}| \geq \delta) \right] = 0.$$

**4.40 Beispiele.**

- (a) Ist  $(Y_j)_{j \geq 1}$  eine Folge unabhängiger, identisch verteilter (i.i.d.) Zufallsvariablen in  $\mathcal{L}^2$  mit  $\mu = \mathbb{E}[Y_j]$ ,  $\sigma^2 = \text{Var}(Y_j) > 0$ , so bildet  $X_j^{(n)} = (Y_j - \mu)/(\sigma\sqrt{n})$  ein standardisiertes Dreiecksschema, das der Lindeberg-Bedingung genügt.
- (b) Ist  $(X_j^{(n)})_{1 \leq j \leq n, n \geq 1}$  ein standardisiertes Dreiecksschema und gilt für ein  $p > 2$  die Lyapunov-Bedingung

$$\lim_{n \rightarrow \infty} \sum_{j=1}^n \mathbb{E} \left[ |X_j^{(n)}|^p \right] = 0,$$

so genügt  $(X_j^{(n)})_{1 \leq j \leq n, n \geq 1}$  auch der Lindeberg-Bedingung.

Ist insbesondere  $(Y_j)_{j \geq 1}$  eine Folge unabhängiger und standardisierter (d.h.  $\mathbb{E}[Y_j] = 0$ ,  $\text{Var}(Y_j) = 1$ ) Zufallsvariablen, die in  $L^p$  beschränkt ist (d.h.  $\sup_{j \geq 1} \mathbb{E}[|Y_j|^p] < \infty$ ) für ein  $p > 2$ , so ist  $X_j^{(n)} = Y_j/\sqrt{n}$  ein standardisiertes Dreiecksschema, das der Lyapunov- und somit auch der Lindeberg-Bedingung genügt:

$$\sum_{j=1}^n \mathbb{E} \left[ |X_j^{(n)}|^p \right] = n^{-p/2} \sum_{j=1}^n \mathbb{E}[|Y_j|^p] \leq n^{1-p/2} \sup_{j \geq 1} \mathbb{E}[|Y_j|^p] \xrightarrow{n \rightarrow \infty} 0.$$

- (c) In der harmonischen Reihe mit zufälligen Vorzeichen  $S_n = \sum_{j=1}^n \varepsilon_j/j$  mit  $(\varepsilon_j)_{j \geq 1}$  unabhängig,  $P(\varepsilon_j = 1) = P(\varepsilon_j = -1) = 1/2$ , bilden  $X_j^{(n)} = \varepsilon_j/(j\sigma_n)$  mit  $\sigma_n^2 = \sum_{j=1}^n j^{-2} \rightarrow \sigma_\infty^2 = \pi^2/6$  ein standardisiertes Dreiecksschema, das der Lyapunov-Bedingung *nicht* genügt; denn für  $\delta \in (0, \sigma_\infty^{-1})$  erhält man

$$\sum_{j=1}^n \mathbb{E}[(X_j^{(n)})^2 \mathbf{1}(|X_j^{(n)}| \geq \delta)] = \sum_{j=1}^n j^{-2} \sigma_n^{-2} \mathbf{1}(j\sigma_n \delta \leq 1) \geq \sigma_\infty^{-2} > 0.$$

**4.41 Satz** (Zentraler Grenzwertsatz nach Lindeberg, 1922). *Ist  $(X_j^{(n)})_{1 \leq j \leq n, n \geq 1}$  ein standardisiertes Dreiecksschema, das der Lindeberg-Bedingung genügt, so gilt für (die Zeilensummen)  $S_n^* = \sum_{j=1}^n X_j^{(n)}$  und  $n \rightarrow \infty$*

$$S_n^* \xrightarrow{d} N(0, 1).$$

**4.42 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.

**4.43 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

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

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

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

## 5 Einführung in die Schätztheorie

### 5.1 Grundlagen

**5.1 Definition.** Ein statistisches Modell ist ein Tripel  $(\Omega, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  bestehend aus einem Messraum  $(\Omega, \mathcal{F})$  (dem Stichprobenraum) und einer Familie  $(P_\vartheta)_{\vartheta \in \Theta}$  von Wahrscheinlichkeitsmaßen auf  $\mathcal{F}$ . Die nichtleere Menge  $\Theta$  heißt Parametermenge und jedes  $\vartheta \in \Theta$  Parameter.

**5.2 Beispiel** (Normalverteilungsmodell). Für ein  $n$ -fach wiederholtes physikalisches Experiment, wo die Messfehler als  $N(0, \sigma^2)$ -verteilt für ein  $\sigma > 0$  angenommen werden können, ist  $(\mathbb{R}^n, \mathfrak{B}_{\mathbb{R}^n}, (P_\vartheta)_{\vartheta \in \Theta})$  mit  $\Theta = \{(\mu, \sigma^2) \mid \mu \in \mathbb{R}, \sigma > 0\}$  und  $P_\vartheta = P_{(\mu, \sigma^2)} = N(\mu, \sigma^2)^{\otimes n} = N(\mu \mathbf{1}, \sigma^2 E_n)$  ein adäquates statistisches Modell für die Messergebnisse.

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

**5.4 Beispiel** (Normalverteilungsmodell). Im Normalverteilungsmodell ist häufig  $g(\vartheta) = g(\mu, \sigma^2) = \mu$  der einzig interessierende Parameter. Schätzer von  $\mu$  sind  $\hat{\mu}_1(\omega) = 15$ ,  $\hat{\mu}_2(\omega) = \omega_1$ ,  $\hat{\mu}_3(\omega) = \frac{1}{n} \sum_{i=1}^n \omega_i$ ,  $\hat{\mu}_4(\omega) = \text{Median}(\omega_1, \dots, \omega_n)$  für  $\omega \in \Omega = \mathbb{R}^n$ .

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

$$R(\hat{g}, \vartheta) := \mathbb{E}_\vartheta[(\hat{g} - g(\vartheta))^2] \in [0, \infty], \quad \vartheta \in \Theta.$$

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

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

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  $g(\vartheta)$ .

## 5.6 Beispiele.

- (a) Im Normalverteilungsmodell mit  $g(\vartheta) = \mu$  und  $\vartheta = (\mu, \sigma^2)$  gilt  $R(\hat{\mu}_1, \vartheta) = (15 - \mu)^2$ ,  $R(\hat{\mu}_2, \vartheta) = \sigma^2$ ,  $R(\hat{\mu}_3, \vartheta) = \sigma^2 n^{-1}$  und  $R(\hat{\mu}_4, \vartheta)$  ist nicht explizit berechenbar. Die Schätzer  $\hat{\mu}_2$ ,  $\hat{\mu}_3$  und  $\hat{\mu}_4$  (Letzterer aus Symmetriegründen) sind erwartungstreu. Der MSE von  $\hat{\mu}_2$  ist stets größer als der MSE von  $\hat{\mu}_3$ , aber je nach Parameterwert  $\vartheta$  kann der MSE von  $\hat{\mu}_1$  kleiner oder auch viel größer als der MSE von  $\hat{\mu}_3$  sein.
- (b) Im Bernoulli-Schema mit  $\Omega = \{0, 1\}^n$ ,  $\mathcal{F} = \mathcal{P}(\Omega)$  und der Verteilung  $P_p$  des Bernoullischemas mit Erfolgswahrscheinlichkeit  $p \in \Theta = (0, 1)$  ist die relative Häufigkeit  $\hat{p}(\omega) = \frac{1}{n} \sum_{i=1}^n \omega_i$  ein typischer Schätzer von  $g(p) = p$ .  $\hat{p}$  ist erwartungstreu mit MSE  $R(\hat{p}, p) = p(1-p)n^{-1}$ . Der MSE ist für  $p = 1/2$  mit  $(4n)^{-1}$  maximal und fällt für  $p \rightarrow 0$ ,  $p \rightarrow 1$  gegen Null.

Dies macht sich der Schätzer  $\hat{p}_\alpha = (1-\alpha)\hat{p} + \alpha \frac{1}{2}$  mit  $\alpha \in [0, 1]$  zunutze, indem er  $\hat{p}$  in Richtung  $\frac{1}{2}$  verzerrt.  $\hat{p}_\alpha$  besitzt den Bias  $B(\hat{p}_\alpha, p) = \alpha(\frac{1}{2} - p)$  und die Varianz  $\text{Var}_p(\hat{p}_\alpha) = (1-\alpha)^2 p(1-p)n^{-1}$ . Der MSE  $R(\hat{p}_\alpha, p) = \frac{(1-\alpha)^2}{4n} + (\alpha^2 - (1-\alpha)^2 n^{-1})(p - \frac{1}{2})^2$  hängt für  $\alpha_0 = (\sqrt{n} + 1)^{-1}$  nicht von  $p$  ab. Es gilt  $R(\hat{p}_{\alpha_0}, p) = \frac{1}{4(n+2\sqrt{n+1})}$ , und  $\hat{p}_{\alpha_0}$  hat kleineren maximalen MSE (über  $p \in (0, 1)$ ) als  $\hat{p}$ , ist aber nicht erwartungstreu.

## 5.2 Cramér-Rao-Ungleichung und Fisher-Information

**5.7 Definition.** Ein statistisches Modell  $(\Omega, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  heißt dominiert von einem Maß  $\mu$  auf  $\mathcal{F}$ , falls jedes  $P_\vartheta$  eine  $\mu$ -Dichte  $p_\vartheta : \Omega \rightarrow [0, \infty)$  besitzt. Fasst man  $p_\vartheta$  als Zufallsvariable auf, so heißt die (zufällige) Funktion  $L(\vartheta) = L(\vartheta, \omega) = p_\vartheta(\omega)$  auf  $\Theta$  Likelihood-Funktion. Mit  $\ell(\vartheta) = \log(L(\vartheta))$  wird die Loglikelihood-Funktion bezeichnet.

## 5.8 Beispiele.

- (a) Besitzen im Fall  $(\Omega, \mathcal{F}) = (\mathbb{R}^n, \mathfrak{B}_{\mathbb{R}^n})$  die  $P_\vartheta$  Lebesguedichten  $f_\vartheta$ , so gilt  $L(\vartheta, x) = f_\vartheta(x)$ ,  $\vartheta \in \Theta$ ,  $x \in \mathbb{R}^n$ . Bei Produktdichten  $f_\vartheta(x) = \prod_{i=1}^n f_{\vartheta,i}(x_i)$  ist die Loglikelihood-Funktion additiv:  $\ell(\vartheta, x) = \sum_{i=1}^n \log(f_{\vartheta,i}(x_i))$ . Im Normalverteilungsmodell  $(\mathbb{R}^n, \mathfrak{B}_{\mathbb{R}^n}, (N(\mu, \sigma^2)^{\otimes n})_{\mu \in \mathbb{R}, \sigma > 0})$  ergibt sich  $\ell(\mu, \sigma) = -\frac{n}{2} \log(2\pi\sigma) - \sum_{i=1}^n (x_i - \mu)^2 / (2\sigma^2)$ , wobei  $x = (x_1, \dots, x_n) \in \Omega = \mathbb{R}^n$  den Versuchsausgang angibt.
- (b) Im diskreten Fall mit  $\Omega$  abzählbar und  $\mathcal{F} = \mathcal{P}(\Omega)$  ist die Likelihood-Funktion bezüglich dem Zählmaß  $L(\vartheta)$  gerade die Zähldichte  $p_\vartheta$  von  $P_\vartheta$ . Im Binomialmodell  $(\text{Bin}(n, p))_{p \in (0, 1)}$  ergibt sich  $L(p) = \binom{n}{x} p^x (1-p)^{n-x}$ ,  $\ell(p) = n \log(1-p) + \log \binom{n}{x} + x \log(p/(1-p))$ , wobei  $x \in \Omega = \{0, \dots, n\}$  den Versuchsausgang angibt.

**5.9 Lemma** (Chapman-Robbins-Ungleichung). *Es sei  $(\Omega, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  ein dominiertes statistisches Modell mit Likelihood-Funktion  $L(\vartheta)$ . Ist  $\hat{g}$  ein erwartungstreuer Schätzer von  $g(\vartheta)$  für  $g : \Theta \rightarrow \mathbb{R}$ , so gilt für alle  $\vartheta, \vartheta_0 \in \Theta$  mit  $P_\vartheta \neq P_{\vartheta_0}$  und  $P_\vartheta \ll P_{\vartheta_0}$*

$$R(\hat{g}, \vartheta_0) = \text{Var}_{\vartheta_0}(\hat{g}) \geq \frac{(g(\vartheta) - g(\vartheta_0))^2}{\text{Var}_{\vartheta_0}(L(\vartheta)/L(\vartheta_0))}.$$

Im Fall  $L(\vartheta)/L(\vartheta_0) \notin \mathcal{L}^2(P_{\vartheta_0})$  sei die rechte Seite als Null definiert.

**5.10 Beispiel.** Im vom Lebesguemaß dominierten statistischen Modell  $(\mathbb{R}, \mathfrak{B}_{\mathbb{R}}, (\text{Exp}(\vartheta))_{\vartheta > 0})$  gilt  $L(\vartheta, x)/L(\vartheta_0, x) = \frac{\vartheta}{\vartheta_0} e^{-(\vartheta - \vartheta_0)x}$  für  $\vartheta, \vartheta_0 > 0$  und  $P_{\vartheta_0}$ -fast alle  $x \in \mathbb{R}$  (z.B.  $x \geq 0$ ). Für  $g(\vartheta) = \vartheta$  erhalten wir für erwartungstreue Schätzer  $\hat{\vartheta}$  von  $\vartheta$ :

$$R(\hat{\vartheta}, \vartheta_0) \geq \sup_{\vartheta > \vartheta_0/2} \frac{(\vartheta - \vartheta_0)^2}{\int_0^\infty (\vartheta \vartheta_0^{-1} e^{-(\vartheta - \vartheta_0)x} - 1)^2 \vartheta_0 e^{-\vartheta_0 x} dx} = \sup_{\vartheta > \vartheta_0/2} \vartheta_0 (2\vartheta - \vartheta_0) = \infty.$$

Es gibt also keinen erwartungstreuen Schätzer von  $\vartheta$  mit endlicher Varianz!

Für  $g(\vartheta) = \vartheta^{-1}$  und erwartungstreue Schätzer  $\hat{g}$  hingegen folgt

$$R(\vartheta_0, \hat{g}) \geq \sup_{\vartheta > \vartheta_0/2} \frac{2\vartheta - \vartheta_0}{\vartheta^2 \vartheta_0} = \vartheta_0^{-2}.$$

Die Identität  $\hat{g} = X$  als Schätzer erreicht genau diese Schranke, ist daher erwartungstreuer Schätzer von  $\vartheta^{-1}$  mit minimalem MSE (also minimaler Varianz). Analog gilt im Produktmodell von unabhängigen Beobachtungen  $X_1, \dots, X_n \sim \text{Exp}(\vartheta)$ , dass  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  erwartungstreuer Schätzer von  $\vartheta^{-1}$  mit minimaler Varianz  $n^{-1} \vartheta^{-2}$  ist. Das Supremum in der Chapman-Robbins-Ungleichung wird in beiden Fällen für  $\vartheta \rightarrow \vartheta_0$  erreicht, was auf eine differentielle Ungleichung, die Cramér-Rao-Ungleichung, führt.

**5.11 Definition.** Ein dominiertes statistisches Modell  $(\Omega, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  mit  $\Theta \subseteq \mathbb{R}$  offen und Loglikelihood-Funktion  $\ell$  heißt Cramér-Rao-regulär bei  $\vartheta_0 \in \Theta$ , falls

- (a)  $P_\vartheta \ll P_{\vartheta_0}$  für alle  $\vartheta$  in einer Umgebung von  $\vartheta_0$  gilt;
- (b)  $\vartheta \mapsto \ell(\vartheta, \omega)$  für  $P_{\vartheta_0}$ -fast alle  $\omega \in \Omega$  bei  $\vartheta_0$  differenzierbar ist mit Ableitung  $\dot{\ell}(\vartheta_0) \in \mathcal{L}^2(P_{\vartheta_0})$ ;
- (c)  $\lim_{\vartheta \rightarrow \vartheta_0} \mathbb{E}_{\vartheta_0} \left[ \left( \frac{\exp(\ell(\vartheta) - \ell(\vartheta_0)) - 1}{\vartheta - \vartheta_0} - \dot{\ell}(\vartheta_0) \right)^2 \right] = 0$  gilt.

Die zufällige Funktion  $\dot{\ell}$  heißt Score-Funktion und  $I(\vartheta_0) := \mathbb{E}_{\vartheta_0}[\dot{\ell}(\vartheta_0)^2]$  Fisher-Information des Modells bei  $\vartheta_0$ .

**5.12 Satz** (Cramér-Rao-Ungleichung). *Ist das statistische Modell  $(\Omega, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$  mit  $\Theta \subseteq \mathbb{R}$  offen bei  $\vartheta_0 \in \Theta$  Cramér-Rao-regulär mit Fisher-Information  $I(\vartheta_0) > 0$  und ist  $g : \Theta \rightarrow \mathbb{R}$  bei  $\vartheta_0$  differenzierbar, so gilt für jeden erwartungstreuen Schätzer  $\hat{g}$  von  $g(\vartheta)$*

$$R(\hat{g}, \vartheta_0) = \text{Var}_{\vartheta_0}(\hat{g}) \geq \frac{g'(\vartheta_0)^2}{I(\vartheta_0)}.$$

**5.13 Beispiel.** Im Normalverteilungsmodell  $(\mathbb{R}^n, \mathfrak{B}_{\mathbb{R}^n}, (N(\mu, \sigma^2)^{\otimes n})_{\mu \in \mathbb{R}})$  mit  $\sigma > 0$  bekannt ist für jeden Parameter  $\mu \in \mathbb{R}$  das Modell Cramér-Rao-regulär mit Score-Funktion  $\dot{\ell}(\mu) = -\sum_{i=1}^n (X_i - \mu)/\sigma^2$  und Fisher-Information  $I(\mu) = n/\sigma^2$ . Für erwartungstreue Schätzer  $\hat{\mu}$  von  $g(\mu) = \mu$  gilt daher

$\text{Var}_\mu(\hat{\mu}) \geq \sigma^2/n$ . Das Stichprobenmittel  $\bar{X}$  ist also erwartungstreuer Schätzer mit minimaler Varianz.

Auch im Binomialmodell lässt sich nachrechnen, dass das Stichprobenmittel (die relative Häufigkeit)  $\hat{p} = X/n$  erwartungstreuer Schätzer von minimaler Varianz für  $p$  ist.