

1 Wahrscheinlichkeitstheorie, Teil I

1.1 Wahrscheinlichkeitsraum, Zufallsvariablen, charakteristische Funktion und Unabhängigkeit

1.2 Wahrscheinlichkeitsraum und Zufallsvariable

Definition 1.1 Ein Tripel $(\Omega, \mathcal{F}, \mathbb{P})$ heißt "Wahrscheinlichkeitsraum", wenn Ω eine Menge, \mathcal{F} eine σ -Algebra von Teilmengen von Ω und \mathbb{P} ein Maß auf \mathcal{F} mit $\mathbb{P}(\Omega) = 1$ ist. Elemente $A \in \mathcal{F}$ werden auch "Ereignisse" genannt. Ein messbare Abbildung $X : (\Omega, \mathcal{F}) \rightarrow (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$, $d \in \mathbb{N}$, heißt "Zufallsvariable". Unter dem "Erwartungswert" $\mathbb{E}(X)$ einer Zufallsvariablen versteht man den Wert des Integrals

$$\mathbb{E}(X) = \int_{\Omega} X(\omega) \mathbb{P}(d\omega).$$

Das Bildmaß von \mathbb{P} unter der Abbildung X wird mit \mathbb{P}_X abgekürzt und heißt "Verteilung von X ". Allgemein nennt man ein Maß auf \mathbb{R}^d mit Gesamtmasse Eins eine Verteilung. Für zwei Zufallsvariablen X und Y bezeichnet man mit

$$\text{Cov}(X, Y) = \mathbb{E}\left((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))^t\right)$$

die "Kovarianzmatrix" und benutzt die Abkürzung $\text{Cov}(X) = \text{Cov}(X, X)$. Für eine reellwertige Zufallsvariable X bezeichnet man mit $\text{Var}(X) = \text{Cov}(X)$ die "Varianz" von X . Die Größe $\mathbb{E}(X^k)$, $k \in \mathbb{N}$, wird das "k-te Moment" der Zufallsvariablen X bzw. der Verteilung \mathbb{P}_X genannt.

Bemerkung: Wir werden Integratoren in der Form „ $d\mathbb{P}$ “ bzw. auch als „ $\mathbb{P}(d\omega)$ “.

Die folgenden Resultate sind der Integrationstheorie entnommen und in der Sprache der Wahrscheinlichkeitstheorie formuliert.

Satz 1.2 Seien $(\Omega, \mathcal{F}, \mathbb{P})$ wie oben und $X : \Omega \rightarrow \mathbb{R}$ eine Zufallsvariable. Dann gelten die folgenden Aussagen:

$$(1.1) \quad X \geq 0 \text{ } \mathbb{P}\text{-fast sicher} \quad \Rightarrow \quad \mathbb{P}(X \geq \lambda) \leq \frac{1}{\lambda} \mathbb{E}(X) \quad \forall \lambda > 0.$$

$$(1.2) \quad g : \mathbb{R} \rightarrow \mathbb{R} \text{ konvex und } X, g(X) \in L^1(\Omega, \mathbb{P}) \quad \Rightarrow \quad g(\mathbb{E}(X)) \leq \mathbb{E}(g(X)).$$

(1.3) Zu jedem Maß $\mu : \mathcal{B}(\mathbb{R}) \rightarrow \mathbb{R}$ mit $\mu(\mathbb{R}) = 1$ existiert ein Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$ und eine Zufallsvariable X mit $\mathbb{P}_X = \mu$.

(1.4) $f : \mathbb{R} \rightarrow \mathbb{R}$ beschränkt oder nicht-negativ $\Rightarrow \mathbb{E}(f(X)) = \int f(x) \mathbb{P}_X(dx)$.

(1.5) $X \geq 0$ \mathbb{P} -fast sicher $\Rightarrow \mathbb{E}(X^p) = \int_0^\infty p\lambda^{p-1} \mathbb{P}(X \geq \lambda) d\lambda \quad \forall p \geq 1$.

Bemerkung: Die Gleichung $\mathbb{E}(f(X)) = \int f(x) \mathbb{P}_X(dx)$ wird ständig benutzt werden und gilt auch für \mathbb{R}^d -wertige Zufallsvariablen X .

Beweis: Die erste Ungleichung ist nach Chebyshev¹ benannt und gilt aufgrund von

$$\mathbb{P}(X \geq \lambda) = \mathbb{E}(\mathbb{1}_{\{X \geq \lambda\}}) \leq \int_{\{X(\omega) \geq \lambda\}} \frac{X(\omega)}{\lambda} \mathbb{P}(d\omega) \leq \frac{1}{\lambda} \mathbb{E}(X).$$

Die zweiten Ungleichung heißt wird auch "Jensensche Ungleichung"² genannt. Da g konvex ist, gibt es zu $x_0 \in \mathbb{R}^d$ eine Konstante $c > 0$ mit $g(X(\omega)) \geq g(x_0) + c(X(\omega) - x_0) \quad \forall \omega \in \Omega$. Nun wählt man $x_0 = \mathbb{E}(X)$ und bildet rechts und links Erwartungswerte.

Zum Nachweis der dritten Behauptung wählt man $\Omega = [0, 1]$ versehen mit dem Lebesgue³-Maß $\mathbb{P} = \lambda^1$ und definiert dann $X : \Omega \rightarrow \mathbb{R}$ durch

$$X(\omega) = \inf\{t; \mu((-\infty, t]) \geq \omega\}.$$

Für alle $a \in \mathbb{R}$ gilt dann $\mathbb{P}_X((-\infty, a]) = \mathbb{P}(X \leq a) = \mu((-\infty, a])$ und somit folgt die Behauptung.

Die Gleichung $\mathbb{E}(f(X)) = \int f(x) \mathbb{P}_X(dx)$ beweist man zunächst für Funktionen des Typs $f(x) = \mathbb{1}_M(x)$, $M \in \mathcal{B}(\mathbb{R}^d)$, und verwendet dann ein Abschließungsargument. Schließlich gilt, da X nicht-negativ ist,

$$\int_{\Omega} X(\omega)^p \mathbb{P}(d\omega) = \int_0^\infty \int_{\Omega} \mathbb{1}_{\{X(\omega)^p \geq t\}} \mathbb{P}(d\omega) dt = p \int_0^\infty \lambda^{p-1} \int_{\Omega} \mathbb{1}_{\{X(\omega) \geq \lambda\}} \mathbb{P}(d\omega) d\lambda,$$

woraus auch die letzte Aussage folgt. ■

¹Pafnuty Lvovich Chebyshev, 1821 (Borovsk, Russland)-1894 (St. Petersburg)

²Johan Ludvig William Valdemar Jensen, 1859 (Nakskov, Dänemark) - 1925 (Kopenhagen)

³Henri Léon Lebesgue, 1875 (Beauvais, Picardie/Frankreich) - 1941 (Paris)

Definition 1.3 Seien $(\Omega, \mathcal{F}, \mathbb{P})$ und X wie in Definition (1.1). Dann bezeichnet man mit

$$\sigma(X) = \{(X \in A); A \in \mathcal{B}(\mathbb{R})\} = \{\{\omega; X(\omega) \in A\}; A \in \mathcal{B}(\mathbb{R})\}$$

die von X erzeugte σ -Algebra.

Man überlegt sich leicht, dass $\sigma(X)$ tatsächlich eine σ -Algebra ist.

1.3 Unabhängigkeit

Ein mächtiges Konzept der Wahrscheinlichkeitstheorie ist das Konzept der Unabhängigkeit. Dieses stellt die erste große Hürde für Mathematiker ohne Vorkenntnisse der Wahrscheinlichkeitstheorie dar. Sei \mathcal{F} eine σ -Algebra. Wir nennen die Ereignisse $A, B \in \mathcal{F}$ von einander "unabhängig", wenn die Wahrscheinlichkeit, dass A eintritt genauso groß ist wie die Wahrscheinlichkeit, dass A unter der zusätzlichen Annahme "B tritt ein" eintritt⁴. Genauer gilt:

Definition 1.4 Sei $(\Omega, \mathcal{F}, \mathbb{P})$ wie oben. Seien $A, B \in \mathcal{F}$. Dann heißt die Größe $\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}$ die "bedingte Wahrscheinlichkeit von A gegeben B". Man nennt A und B voneinander unabhängig, wenn

$$\mathbb{P}(A|B) = \mathbb{P}(A) \quad \text{oder hierzu gleichbedeutend} \quad \mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$$

gilt. Zwei σ -Algebren \mathcal{F} und \mathcal{B} heißen von einander unabhängig, wenn A und B von einander unabhängig sind für alle $A \in \mathcal{F}$ und alle $B \in \mathcal{B}$. Eine Zufallsvariable X und eine σ -Algebra \mathcal{F} heißen von einander unabhängig, wenn $\sigma(X)$ und \mathcal{F} von einander unabhängig sind.

Beispiel: Sei $(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1]^2, \mathcal{B}([0, 1]^2), dx \times dy)$. Dann sind die beiden Mengen $A = \{(x, y) \in \Omega, x \leq \frac{1}{2}\}$ und $B = \{(x, y) \in \Omega, \frac{1}{4} \leq x \leq \frac{3}{4}, \frac{1}{4} \leq y \leq \frac{3}{4}\}$ unabhängig voneinander. Stellen Sie sich vor, dass Sie sich im Wald Ω verlaufen haben. Sie wollen gerne wissen, wie groß die Wahrscheinlichkeit $\mathbb{P}(A)$ ist, dass Sie im Waldgebiet A sind, in dem es keine Bären gibt. Die Zusatzinformation, dass Sie im Waldgebiet B

⁴Auf gut Deutsch: Für die Wahrscheinlichkeit des Ereignisses A ist es schnurzpiepewurscht, ob B eintritt oder nicht.

sind, wo Steinpilze wachsen, hilft Ihnen leider nicht bei der Berechnung von $\mathbb{P}(A)$. Die Ereignisse A und B sind unabhängig.

Beispiel: Sei $(\Omega, \mathcal{F}, \mathbb{P}) = ([0, 1]^2, \mathcal{B}([0, 1]^2), dx \times dy)$. Seien $f, g : \mathbb{R} \rightarrow \mathbb{R}$ messbar. Dann sind die Zufallsvariablen $X(\omega) = X((x, y)) = f(x)$ und $Y(\omega) = Y((x, y)) = g(y)$ von einander unabhängig.

Wenn $(\Omega, \mathcal{F}, \mathbb{P})$ ein Wahrscheinlichkeitsraum und X, Y von einander unabhängige Zufallsvariablen und $f, g : \mathbb{R} \rightarrow \mathbb{R}$ messbar sind, so sind ebenfalls $f \circ X$ und $g \circ Y$ von einander unabhängig. Wir formulieren diesen Zusammenhang etwas allgemeiner in einem Lemma.

Lemma 1.5 *Seien $X_1, \dots, X_N : \Omega \rightarrow \mathbb{R}^d$ unabhängig und $f_j : \mathbb{R}^{d \times m_j} \rightarrow \mathbb{R}$, $j = 1, \dots, n$ messbare Funktionen mit $m_1 + \dots + m_n = N$. Wir definieren*

$$Y_1 = (X_1, \dots, X_{m_1}), \quad Y_2 = (X_{m_1+1}, \dots, X_{m_1+m_2}), \quad \dots, \quad Y_n = (X_{N-m_n+1}, \dots, X_N).$$

Dann sind die Zufallsvariablen $(f_j \circ Y_j)$, $j = 1, \dots, n$, unabhängig.

Man nennt eine Familie von Ereignissen $\{A_k\}$ unabhängig, wenn für jede endliche Indexmenge $\{k_1, k_2, \dots, k_N\} \subset \mathbb{N}$ $\mathbb{P}(A_{k_1} \cap A_{k_2} \cap \dots \cap A_{k_N}) = \prod_{j=1}^N \mathbb{P}(A_{k_j})$ gilt. Analoges gilt für Zufallsvariablen. Beachte, dass Unabhängigkeit einer Folge die paarweise Unabhängigkeit impliziert aber nicht umgekehrt.

Formal bedeutet die obige Definition von Unabhängigkeit von Zufallsvariablen folgendes: Die \mathbb{R}^d -wertigen Zufallsvariablen X_1, \dots, X_N sind unabhängig genau dann, wenn

$$(1.6) \quad \mathbb{P}_{(X_1, \dots, X_N)} = \prod_{j=1}^N \mathbb{P}_{X_j} \quad \text{gilt .}$$

Hierbei bezeichnet $\mathbb{P}_{(X_1, \dots, X_N)}$ die Verteilung der $(\mathbb{R}^d)^N$ -wertigen Zufallsvariablen (X_1, \dots, X_N) und $\prod_{j=1}^N \mathbb{P}_{X_j}$ das Produktmaß. Seien $B_1, \dots, B_N \in \mathcal{B}(\mathbb{R}^d)$. Dann folgt die behauptete Äquivalenz aus den beiden Beobachtungen

$$\begin{aligned} \mathbb{P}_{(X_1, \dots, X_N)}(B_1 \times \dots \times B_N) &= \mathbb{P}(X^{-1}(B_1) \cap \dots \cap X^{-N}(B_N)), \\ \left(\prod_{j=1}^N \mathbb{P}_{X_j} \right)(B_1 \times \dots \times B_N) &= \prod_{j=1}^N (\mathbb{P}(X_j^{-1}(B_j))). \end{aligned}$$

Um eine weitere wichtige Eigenschaft von unabhängigen Zufallsvariablen angeben zu können, erinnern wir kurz an die Faltung von Maßen. Seien μ und ν Maße auf \mathbb{R}^d . Dann definiert die Faltung

$$(\mu * \nu)(A) = \int_{\mathbb{R}^d} \nu(A - y) \mu(dy) = \int_{\mathbb{R}^d} \int_{\mathbb{R}^d} \mathbb{1}_A(x + y) \nu(dx) \mu(dy), \quad A \in \mathcal{B}(\mathbb{R}^d)$$

ein weiteres Maß auf \mathbb{R}^d . Diese Definition verträgt sich mit der bekannten Definition der Faltung zweier Funktionen f und g im folgenden Sinne. Wenn μ und ν Dichten f und g bezüglich des Lebesgue-Maßes haben, so hat das Maß $\mu * \nu$ die Dichte $h = f * g$, denn, wie man leicht nachrechnet, es gilt für beschränkte Funktionen $h : \mathbb{R}^d \rightarrow \mathbb{R}$

$$\int_{\mathbb{R}^d} h(z) (\mu * \nu)(dz) = \int_{\mathbb{R}^d} h(z) (f * g)(z) dz.$$

Lemma 1.6 *Für unabhängige Zufallsvariablen X_1, \dots, X_N gilt*

$$\mathbb{P}_{X_1} * \mathbb{P}_{X_2} * \dots * \mathbb{P}_{X_N} = \mathbb{P}_{X_1 + X_2 + \dots + X_N}.$$

Beweis: *Für $M \in \mathcal{B}(\mathbb{R}^d)$ gilt*

$$\begin{aligned} (\mathbb{P}_{X_1} * \mathbb{P}_{X_2} * \dots * \mathbb{P}_{X_N})(M) &= \int \dots \int \mathbb{1}_M(x_1 + x_2 + \dots + x_N) \mathbb{P}_{X_1} \dots \mathbb{P}_{X_N} \\ &= \int \dots \int \mathbb{1}_M(x_1 + x_2 + \dots + x_N) \mathbb{P}_{(X_1, \dots, X_N)} \\ &= \mathbb{E}(\mathbb{1}_M(X_1 + \dots + X_N)) = \mathbb{P}(X_1 + \dots + X_N \in M) \\ &= \mathbb{P}_{X_1 + X_2 + \dots + X_N}(M). \end{aligned}$$

■

Für zwei Funktionen $f, g : \Omega = (0, 1) \rightarrow \mathbb{R}$ gilt die Aussage $f \in L^1(\Omega)$, $g \in L^1(\Omega) \Rightarrow (fg) \in L^1(\Omega)$ natürlich im Allgemeinen nicht. Für unabhängige Zufallsvariablen ist ein solcher Schluss hingegen zulässig und charakteristisch.

Lemma 1.7 *Für unabhängige reellwertige Zufallsvariablen X_1, \dots, X_N mit $X_i \in L^1(\Omega) \forall i$ gelten*

$$\prod_{i=1}^N |X_i| \in L^1(\Omega) \quad \text{und} \quad \mathbb{E}\left(\prod_{i=1}^N X_i\right) = \prod_{i=1}^N \mathbb{E}(X_i).$$

Beweis: Es sei eine Funktion $f : \mathbb{R}^N \rightarrow \mathbb{R}$ durch $f(x_1, \dots, x_N) = |x_1| \cdot \dots \cdot |x_N|$ definiert. Mit Hilfe des Satzes von Fubini⁵ schließen wir dann

$$\mathbb{E}\left(\prod_{i=1}^N |X_i|\right) = \int_{\mathbb{R}^n} f \mathbb{P}_{(X_1, \dots, X_N)} = \prod_{i=1}^N \left(\int_{\mathbb{R}} |x_i| \mathbb{P}_{X_i}(dx_i) \right) = \prod_{i=1}^N \mathbb{E}(|X_i|).$$

Also gilt $\prod_{i=1}^N |X_i| \in L^1(\Omega)$. Die zweite Aussage beweist man, indem man den obigen Beweis wiederholt, nun aber die Betragsstriche fortlässt. ■

Die eben bewiesene Aussage sagt viel über die Struktur unabhängiger Zufallsvariablen aus. Seien X und Y reellwertig und unabhängig mit $\mathbb{E}(X) = 0$. Dann gilt für alle $f : \mathbb{R}^d \rightarrow \mathbb{R}$ mit $f \circ Y \in L^1(\Omega)$

$$\mathbb{E}(X(f \circ Y)) = \mathbb{E}(X)\mathbb{E}(f \circ Y) = 0.$$

Das bedeutet, dass $f \circ Y$ im L^2 -Sinn orthogonal zu X ist für alle zugelassenen f . Es ist also gar nicht so einfach, eine Folge unabhängiger Zufallsvariablen anzugeben.

Auf dem Wahrscheinlichkeitsraum $([0, 1], \mathcal{B}([0, 1]), \lambda^1)$ ist durch

$$A_0 = [0, 1), \quad A_1 = [0, \frac{1}{2}), \quad A_2 = [0, \frac{1}{4}) \cup [\frac{2}{4}, \frac{3}{4}), \quad \dots, \quad A_n = \bigcup_{k=0}^{(2^{n-1}-1)} \left[\frac{2k}{2^n}, \frac{2k+1}{2^n} \right)$$

eine Folge (A_k) unabhängiger Ereignisse definiert. Die Folge $(\mathbb{1}_{A_k})$ ist eine Folge unabhängiger Zufallsvariablen. Sehr häufig konstruiert man Folgen unabhängiger Zufallsvariablen, indem man Zufallsvariablen $X_j : \Omega_j \rightarrow \mathbb{R}^d$ betrachtet und dann die Folge auf dem unendlichen Produktraum $\Omega = \Omega_1 \times \Omega_2 \times \dots$ definiert. Die erforderliche Orthogonalität gilt dann automatisch.

Lemma 1.8 *Für unabhängige reellwertige Zufallsvariablen X_1, \dots, X_N mit $X_i \in L^2(\Omega) \forall i$ gilt*

$$\text{Var}\left(\sum_{j=1}^N X_j\right) = \sum_{j=1}^N \text{Var}(X_j).$$

Beweis: Setze $Y_j = X_j - \mathbb{E}(X_j)$. Da dann die Y_j unabhängig sind und $\mathbb{E}(Y_j) = 0 \forall j$ gilt, folgt mit obigem Lemma $\mathbb{E}(Y_j Y_k) = 0$ falls $j \neq k$. Somit können wir schließen

$$\text{Var}(X_1 + \dots + X_N) = \mathbb{E}((Y_1 + \dots + Y_N)^2) = \sum_{j,k=1}^N \mathbb{E}(Y_j Y_k) = \sum_{j=1}^N \mathbb{E}(Y_j^2),$$

⁵Guido Fubini, 1879 (Venedig) - 1943 (New York City)

woraus die Behauptung folgt. ■

Wir beweisen nun ein Hilfsresultat, das sich in vielen Situationen als sehr nützlich erweisen wird.

Definition 1.9 *Seien $(\Omega, \mathcal{F}, \mathbb{P})$ ein Wahrscheinlichkeitsraum und (A_k) eine Folge von Ereignissen. Dann bezeichnet man mit*

$$"A_k \text{ i.o.}" = \limsup_{k \rightarrow \infty} A_k = \bigcap_{k=1}^{\infty} \bigcup_{j=k}^{\infty} A_j = \{\omega; \omega \in A_k \text{ für unendlich viele } k\}$$

das sogenannte "terminale Ereignis".

Lemma 1.10 (Borel⁶-Cantelli⁷) *Sei (A_k) eine Folge von Ereignissen in $(\Omega, \mathcal{F}, \mathbb{P})$. Dann gilt*

$$(1.7) \quad \sum_{k=1}^{\infty} \mathbb{P}(A_k) < \infty \implies \mathbb{P}("A_k \text{ i.o.}") = 0.$$

Ist die Folge (A_k) unabhängig, so gilt auch die Umkehrung, d.h.

$$(1.8) \quad \sum_{k=1}^{\infty} \mathbb{P}(A_k) = \infty \implies \mathbb{P}("A_k \text{ i.o.}") = 1.$$

Dass (1.8) wirklich die Umkehrung von (1.7) ist, wird durch Lemma 1.25 klar.

Beweis: Die Folge $B_k = \bigcup_{j=k}^{\infty} A_j$ ist absteigend. Da \mathbb{P} ein Maß ist, folgt nach Voraussetzung für jedes k

$$\mathbb{P}("A_k \text{ i.o.}") = \mathbb{P}\left(\bigcap_{l=1}^{\infty} B_l\right) \leq \mathbb{P}\left(\bigcup_{j=k}^{\infty} A_j\right) \leq \sum_{j=k}^{\infty} \mathbb{P}(A_j),$$

womit (1.7) folgt wegen $\sum_{j=k}^{\infty} \mathbb{P}(A_j) \rightarrow 0$ für $k \rightarrow \infty$. Sei nun die Folge (A_k) unabhängig⁸. Unter Verwendung der Voraussetzung und mehrfacher Komplementbil-

⁶Félix Édouard Justin Émile Borel, 1871 (Saint-Affrique)-1956 (Paris), Mitbegründer der modernen Maßtheorie.

⁷Francesco Paolo Cantelli, 1875 (Palermo) - 1966 (Rom).

⁸Man kann die Annahme mit einem etwas aufwendigeren Beweis darauf reduzieren, dass die A_k nur paarweise unabhängig sind.

ung folgt

$$\begin{aligned} \mathbb{P}\left(\bigcup_{k \geq n} A_k\right) &= 1 - \mathbb{P}\left(\bigcap_{k \geq n} (A_k)^c\right) = 1 - \prod_{k \geq n} \mathbb{P}\left((A_k)^c\right) = 1 - \prod_{k \geq n} (1 - \mathbb{P}(A_k)) \\ &\geq 1 - \prod_{k \geq n} e^{-\mathbb{P}(A_k)} = 1 - e^{-\sum_{k \geq n} \mathbb{P}(A_k)} = 1, \end{aligned}$$

was den Beweis abschließt. ■

1.4 Die charakteristische Funktion

Definition 1.11 Sei \mathbb{P}_X die Verteilung einer Zufallsvariablen $X : \Omega \rightarrow \mathbb{R}^d$. Dann heißt die wie folgt definierte Abbildung $\varphi_X : \mathbb{R}^d \rightarrow \mathbb{C}$

$$\varphi_X(X) = \mathbb{E}(e^{i\langle y, X \rangle}) = \int_{\mathbb{R}^d} e^{i\langle y, x \rangle} \mathbb{P}_X(dx)$$

die "charakteristische Funktion" der Zufallsvariablen X bzw. der Verteilung \mathbb{P}_X .

Die obige Definition führt u.a. dazu, dass man Funktionen $\Omega \rightarrow \mathbb{R}$, $\omega \mapsto \mathbb{1}_M(\omega)$ für $M \subset \Omega$ nicht, wie in der Analysis üblich, als charakteristische Funktion sondern eher als "Indikatorfunktion" bezeichnet. Wir nennen solche Funktionen auch "Stufenfunktion", da Funktionen der Form $\omega \mapsto \sum_{j=1}^N c_j \mathbb{1}_{M_j}(\omega)$, $c_j \in \mathbb{R}$, $M_j \subset \Omega$, häufig "Treppenfunktionen" heißen.

Lemma 1.12 Seien $X_1, \dots, X_N : \Omega \rightarrow \mathbb{R}^d$ unabhängige Zufallsvariablen und $S_N = \sum_{j=1}^N X_j$. Dann gilt

$$\varphi_{S_N}(y) = \prod_{j=1}^N \varphi_{X_j}(y) \quad \forall y \in \mathbb{R}^d.$$

Bemerkung: Insbesondere gilt für unabhängige, identisch verteilte Zufallsvariablen $X_1, \dots, X_N : \Omega \rightarrow \mathbb{R}^d$ die Gleichung $\varphi_{S_N}(y) = \left(\varphi_{X_1}(y)\right)^N \quad \forall y \in \mathbb{R}^d$.

Beweis: Da $\varphi_{S_N}(y) = \mathbb{E}(\exp(i\langle y, S_N \rangle)) = \mathbb{E}(\prod_{j=1}^N \exp(i\langle y, X_j \rangle))$ gilt, folgt die Aussage aufgrund der Unabhängigkeit. ■

Lemma 1.13 Sei $X : \Omega \rightarrow \mathbb{R}$ eine reellwertige Zufallsvariable mit $\mathbb{E}(|X|^k) < \infty$ für $k \in \mathbb{N}$. Dann gilt $\varphi_X \in C^k(\mathbb{R})$ mit

$$(1.9) \quad \frac{d^j \varphi_X}{dy^j}(y) = \int_{\mathbb{R}} (ix)^j e^{ixy} \mathbb{P}_X(dx) \quad \forall y \in \mathbb{R}, \quad j = 0, 1, \dots, k.$$

Beweis: Wir beweisen die Aussage zuerst für $k = 1$. Zunächst zeigt man, dass für alle $y \in \mathbb{R}$ der Grenzwert $\lim_{h \rightarrow 0} \frac{\varphi_X(y+h) - \varphi_X(y)}{|h|}$ existiert. Er existiert wegen

$$\begin{aligned} \left| \frac{\varphi_X(y+h) - \varphi_X(y)}{|h|} \right| &= |h|^{-1} \left| \int_{\mathbb{R}} e^{ixy} (e^{ixh} - 1) \mathbb{P}_X(dx) \right| \\ &\leq |h|^{-1} \left| \int_{\mathbb{R}} |e^{ixy}| |xh| \mathbb{P}_X(dx) \right| \end{aligned}$$

und dem Satz von der majorisierten Konvergenz. Setzt man $(\varphi_X)'(y) = \int_{\mathbb{R}} (ix) e^{ixy} \mathbb{P}_X(dx)$ so sieht man, dass für alle $y \in \mathbb{R}$ $\lim_{h \rightarrow 0} \frac{\varphi_X(y+h) - \varphi_X(y)}{|h|} = (\varphi_X)'(y)$ gilt. Die Funktion $y \mapsto (\varphi_X)'(y)$ ist zudem stetig, was man durch eine weitere Anwendung des Satzes der majorisierten Konvergenz beweist. Den gesamten Schluss iteriert man nun und beweist so $\varphi_X \in C^k(\mathbb{R})$ und Gleichung (1.9) für $k \in \mathbb{N}$. ■

1.5 Gaußsche Zufallsvariablen

Definition 1.14 Eine Zufallsvariable $X : \Omega \rightarrow \mathbb{R}$ heißt "normal verteilt" oder "Gaußsche Zufallsvariable"⁹, wenn für alle $M \in \mathcal{B}(\mathbb{R})$

$$\mathbb{P}(X \in M) = \mathbb{P}_X(M) = \int_M \left(\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-m)^2}{2\sigma^2}} \right) dy$$

mit $m, \sigma \in \mathbb{R}$ und $\sigma > 0$ gilt. Die Verteilung \mathbb{P}_X wird in diesem Fall oft mit $\mathcal{N}(m, \sigma^2)$ bezeichnet und man schreibt: "X ist $\mathcal{N}(m, \sigma^2)$ -verteilt" bzw. " $X \sim \mathcal{N}(m, \sigma^2)$ ". Im Fall $m = 0, \sigma = 1$ nennt man X "standardisiert normal verteilt".

Dass die obige Definitionen sinnvoll sind, wird durch folgendes Lemma erläutert.

Lemma 1.15 Seien $m, \sigma \in \mathbb{R}$ mit $\sigma > 0$. Sei $f : \mathbb{R} \rightarrow \mathbb{R}$ durch $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-m)^2}{2\sigma^2}}$ definiert. Sei $X \sim \mathcal{N}(m, \sigma^2)$. Dann gilt

$$\int_{\mathbb{R}} f(x) dx = 1,$$

$$\mathbb{E}(X) = \int_{\mathbb{R}} x \mathcal{N}(m, \sigma^2)(dx) = m,$$

$$\text{Var}(X) = \int_{\mathbb{R}} (x - m)^2 \mathcal{N}(m, \sigma^2)(dx) = \sigma^2,$$

Der Beweis der drei Behauptungen beruht auf Standardtechniken wie der Substitution von Variablen und der Transformation auf Polarkoordinaten.

Lemma 1.16 Sei $X \sim \mathcal{N}(0, 1)$. Dann gilt für alle $x > 0$

$$\frac{x}{x^2 + 1} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \leq \mathbb{P}(X > x) \leq \frac{1}{x} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

Beweis: Wir beweisen zunächst die Abschätzung nach oben. Es gilt

$$\mathbb{P}(X > x) \leq \int_x^\infty \frac{s}{x} \frac{1}{\sqrt{2\pi}} e^{-\frac{s^2}{2}} ds = \frac{1}{x} \frac{1}{\sqrt{2\pi}} \left[-e^{-\frac{s^2}{2}} \right]_{s=x}^\infty,$$

woraus die gewünschte Abschätzung folgt. Sei nun $g : [0, \infty) \rightarrow \mathbb{R}$ definiert durch

$$g(x) = x e^{-x^2/2} - (x^2 + 1) \int_x^\infty e^{-s^2/2} ds.$$

Die Abschätzung nach unten ist bewiesen, wenn man gezeigt hat, dass $g(x) \leq 0 \forall x \geq 0$ gilt. Zunächst gelten $g(0) < 0$ und $\lim_{x \rightarrow \infty} g(x) = 0$. Ausreichend ist demnach zu zeigen $g'(x) \geq 0 \forall x \geq 0$. Es gilt

$$g'(x) = 2e^{-x^2/2} - 2x \int_x^\infty e^{-s^2/2} ds = 2x \left(\frac{1}{x} e^{-x^2/2} - \int_x^\infty e^{-s^2/2} ds \right),$$

⁹Carl Friedrich Gauß, 1777 (Braunschweig) - 1855 (Göttingen), Mathematischer Universalgelehrter

woraus die gewünschte Ungleichung folgt, wenn man die bereits bewiesene Abschätzung nach oben benutzt. ■

Lemma 1.17 *Für die charakteristische Funktion φ_X einer $\mathcal{N}(m, \sigma^2)$ -verteilten Zufallsvariablen X gilt*

$$\varphi_X(y) = e^{imy - \frac{\sigma^2 y^2}{2}}.$$

Wir betrachten nun mehrdimensionale Gaußsche Zufallsvariablen.

Definition 1.18 *Eine Zufallsvariable $X : \Omega \rightarrow \mathbb{R}^d$ heißt "standardisiert normal verteilt" bzw. "standardisierte Gaußsche Zufallsvariable", wenn unabhängige Zufallsvariablen $X_i \sim \mathcal{N}(0, 1)$, $i = 1, \dots, d$, existieren mit $X(\omega) = (X_1(\omega), \dots, X_d(\omega))^t$ $\forall \omega \in \Omega$. Eine Zufallsvariable $X : \Omega \rightarrow \mathbb{R}^d$ heißt "normal verteilt" bzw. "Gaußsche Zufallsvariable", wenn es einen Vektor $m \in \mathbb{R}^d$, eine $d \times n$ -Matrix A , $n \in \mathbb{N}$, und eine standardisiert normal verteilte Zufallsvariable $Y : \Omega \rightarrow \mathbb{R}^n$ gibt mit*

$$X(\omega) = A(Y(\omega)) + m \quad \forall \omega \in \Omega.$$

Ist $X : \Omega \rightarrow \mathbb{R}^d$ eine Gaußsche Zufallsvariable mit $\text{Cov}(X) = S$ und $\mathbb{E}(X) = m$, so schreibt man $X \sim \mathcal{N}(m, S)$, wobei die Verteilung $\mathcal{N}(m, S)$ das Bildmaß auf \mathbb{R}^d bezeichnet. Im Fall der obigen Definition gelten $\text{Cov}(X) = AA^t$ und $\mathbb{E}(X) = m$. Die $d \times d$ -Einheitsmatrix kürzen wir mit I_d ab und schreiben $X \sim \mathcal{N}(0, I_d)$ an Stelle von $X \sim \mathcal{N}(0, S)$ im Falle $S = I_d$. Wie wir weiter unten sehen sind $\mathcal{N}(0, I_d)$ verteilte Zufallsvariablen genau die standardisiert normal verteilte Zufallsvariablen $X : \Omega \rightarrow \mathbb{R}^d$.

Lemma 1.19 *Seien Θ eine orthogonale $d \times d$ -Matrix und $X \sim \mathcal{N}(0, I_d)$. Dann gilt auch $\Theta X \sim \mathcal{N}(0, I_d)$.*

Beweis: Zunächst prüft man nach, dass die Dichte von $\mathbb{P}_X = \mathcal{N}(0, I_d)$ durch $f : \mathbb{R}^d \rightarrow \mathbb{R}$, $f(x) = \frac{1}{(2\pi)^{d/2}} e^{-\frac{|x|^2}{2}}$ gegeben ist. Hierbei verwendet man die Unabhängigkeit der einzelnen Komponenten von X . Mit Hilfe der Variablensubstitution $y = \Theta^{-1}x$ sieht man, dass die Dichte von $\mathbb{P}_{\Theta X}$ ebenfalls durch f gegeben ist. Die Aussage ist damit bewiesen. ■

Korollar 1.20 Seien $X \sim \mathcal{N}(0, \sigma^2)$, $Y \sim \mathcal{N}(0, \sigma^2)$ unabhängig. Dann sind die beiden Zufallsvariablen $X+Y$ und $X-Y$ unabhängig mit $\mathbb{P}_{X+Y} = \mathbb{P}_{X-Y} = \mathcal{N}(0, 2\sigma^2)$.

Beweis: Die Matrix $M = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$ definiert eine orthogonale Abbildung $\Theta : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ mit $\Theta((x, y)^t) = \frac{1}{\sqrt{2}}(x+y, x-y)^t$. Die Behauptung folgt mit Lemma 1.19. ■

Das folgende Lemma rechtfertigt die Einschränkung der Notation $\mathcal{N}(m, S)$ auf zwei Parameter. Diese beiden reichen nämlich aus, um normal verteilte Zufallsvariablen festzulegen.

Lemma 1.21 Seien $X, Y : \Omega \rightarrow \mathbb{R}^d$ normal verteilte Zufallsvariablen mit $\mathbb{E}(X) = \mathbb{E}(Y)$ und $\text{Cov}(X) = \text{Cov}(Y)$. Dann gilt $\mathbb{P}_X = \mathbb{P}_Y$.

Beweis: Es ist ausreichend, den Fall $\mathbb{E}(X) = \mathbb{E}(Y)$ zu betrachten. Es existieren also eine Zufallsvariable $\tilde{X} : \Omega \rightarrow \mathbb{R}^{n_1}$, eine $d \times n_1$ -Matrix A , eine Zufallsvariable $\tilde{Y} : \Omega \rightarrow \mathbb{R}^{n_2}$ und eine $d \times n_2$ -Matrix B mit

$$X(\omega) = A(\tilde{X}(\omega)), \quad Y(\omega) = B(\tilde{Y}(\omega)) \quad \forall \omega \in \Omega.$$

Sei $k = \max\{n_1, n_2\}$. Durch Hinzufügen von Nullen können wir annehmen, dass die Matrizen A, B beide k Spalten und d Zeilen haben und die \tilde{X} sowie \tilde{Y} Werte in \mathbb{R}^k annehmen. Seien nun V_A und V_B die Vektorräume, welche von den Zeilenvektoren $A_j, B_j, j = 1, \dots, k$, der Matrizen A und B aufgespannt werden. Wir wählen $l \in \mathbb{N}$ so, dass die Vektoren A_1, A_2, \dots, A_l eine Basis von V_A bilden. Wir definieren nun eine Abbildung $\Theta : V_A \rightarrow V_B$ durch $\Theta(A_j) = B_j, j = 1, \dots, l$. Wir wollen zeigen, dass Θ ein Isomorphismus ist. Zunächst zeigen wir, dass Θ injektiv ist. Sei $v \in V_A$ mit $\Theta(v) = 0$, d.h. es gilt

$$\Theta(v_1 A_1 + \dots + v_l A_l) = 0.$$

Sei nun \tilde{v} definiert durch $\tilde{v}_j = v_j$ für $j = 1, \dots, l$ und $\tilde{v}_j = 0$ für $j = l+1, \dots, k$. Dann bedeutet die obige Zeile $\tilde{v}^t B = 0$, und es folgt

$$|\tilde{v}^t A|^2 = \tilde{v}^t A A^t \tilde{v}^t = \tilde{v}^t B B^t \tilde{v}^t = 0.$$

Also gilt $\tilde{v}^t A = 0$, woraus wir $v = 0$ schließen. Die Abbildung Θ ist also injektiv, und es gilt $\dim V_A \leq \dim V_B$. Wenn wir die Rollen von A und B anfangs vertauschen,

erhalten wir $\dim V_A \geq \dim V_B$, also ist Θ ein Isomorphismus.

Für alle $v, w \in V_A$ gilt außerdem $\langle v, w \rangle = \langle A^t v, A^t w \rangle = \langle B^t v, B^t w \rangle = \langle \Theta(v)^t, \Theta(w)^t \rangle$, also ist Θ auch eine orthogonale Abbildung von V_A nach V_B . Man setzt nun Θ wie üblich fort zu einer orthogonalen Abbildung $\tilde{\Theta}$ von \mathbb{R}^k nach \mathbb{R}^k , indem man das orthogonale Komplement von V_A orthogonal auf das orthogonale Komplement von V_B abbildet. Damit gilt nun

$$X(\omega) = A(\tilde{X}(\omega)), \quad Y(\omega) = B(\tilde{Y}(\omega)) = A(\Theta(\tilde{Y}(\omega))) \quad \forall \omega \in \Omega.$$

und die Aussage folgt nach Lemma 1.19, da $\tilde{X} \sim \mathcal{N}(0, I_k)$ und $\Theta(\tilde{Y}) \sim \mathcal{N}(0, I_k)$. ■

Mit Hilfe von Lemma 1.21 können wir $\mathcal{N}(0, I_d)$ -verteilte Zufallsvariablen mit standardisierten Gaußschen Zufallsvariablen identifizieren.

Korollar 1.22 *Sei $X : \Omega \rightarrow \mathbb{R}^d$ $\mathcal{N}(m, S)$ -verteilt. Dann sind die folgenden Aussagen äquivalent:*

- (i) *Die Komponenten X_1, \dots, X_d sind unabhängig.*
- (ii) *S ist eine Diagonalmatrix.*
- (iii) *Die Komponenten X_1, \dots, X_d sind paarweise unkorreliert, d.h. es gilt $\mathbb{E}(X_i X_j) = \mathbb{E}(X_i)\mathbb{E}(X_j)$ für $1 \neq j$.*

Beweis: Die Schlüsse (iii)→(ii) und (i)→(iii) gelten klarerweise. Der einzige beweisbedürftige Schluss ist (ii)→(i). Da man mit Hilfe von Lemma 1.21¹⁰ eine Zufallsvariable $Y : \Omega \rightarrow \mathbb{R}^d$ mit $Y \sim \mathcal{N}(m, S)$ und unabhängigen Komponenten Y_1, \dots, Y_d konstruieren kann, muss ebenfalls X unabhängige Komponenten haben. Denn zwei vektorwertige Zufallsvariablen mit derselben Verteilung haben entweder beide unabhängige Komponenten oder beide nicht. ■

¹⁰Seien $s_j^2; j = 1, \dots, d$, die Einträge von S auf der Diagonalen. Sei $\tilde{Y} : \Omega \rightarrow \mathbb{R}^d$ Gaußsch mit unabhängigen Komponenten $\tilde{Y}_1, \dots, \tilde{Y}_d$ und $\mathbb{E}(\tilde{Y}_j) = \frac{1}{s_j}\mathbb{E}(X_j)$, $\text{Var}(\tilde{Y}) = I_d$. Dann gilt für die Zufallsvariable $Y = (s_1\tilde{Y}_1, \dots, s_d\tilde{Y}_d)$ einerseits $\mathbb{E}(Y) = \mathbb{E}(X)$ und andererseits $\text{Cov}(Y) = \text{Cov}(X)$. Da Y Gaußsch ist, gilt nach Lemma 1.21, dass Y und X dieselbe Verteilung besitzen.

1.6 Stochastische Prozesse

Definition 1.23 Sei $(\Omega, \mathcal{F}, \mathbb{P})$ ein Wahrscheinlichkeitsraum. Sei $I = [0, \infty)$, $I = [0, b)$, $I = [0, b]$ mit $b \in \mathbb{R}_+$ oder $I = \mathbb{N}$. Eine Familie von Zufallsvariablen $\{X_t; t \in I, X_t : \Omega \rightarrow \mathbb{R}^d\}$ nennt man "stochastischer Prozess". Wir schreiben schlicht X ¹¹ für einen stochastischen Prozess. Die Abbildung $t \mapsto X_t(\omega)$ heißt Pfad¹², und in diesem Sinne kann man Ω als Raum der Pfade auffassen.

Seien X und Y zwei stochastische Prozesse auf ein und demselben Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$. Oftmals ist die Frage wichtig, wann man X und Y miteinander identifizieren kann bzw. wann und in welchem Sinne sie gleich sind. Gerade wenn man die Theorie des Lebesgue-Integrals verinnerlicht hat, ist man geneigt, die Bedeutung dieser Frage bei stochastischen Prozessen zu unterschätzen.

Definition 1.24 (Identifikation von stochastischen Prozessen) .

1) Wenn für alle $N \in \mathbb{N}$ und reelle Zahlen $0 \leq t_1 < t_2 < t_3 \dots < t_N$, $t_k \in I$ und alle Mengen $A \in \mathcal{B}(\mathbb{R}^d)$ gilt

$$\mathbb{P}((X_{t_1}, X_{t_2}, \dots, X_{t_N}) \in A) = \mathbb{P}((Y_{t_1}, Y_{t_2}, \dots, Y_{t_N}) \in A),$$

so sagt man: "X und Y haben dieselben endlich-dimensionalen Verteilungen".

2) X und Y heißen "Modifikationen" voneinander, wenn für alle $t \in I$

$$\mathbb{P}(X_t = Y_t) = 1.$$

3) X und Y heißen "ununterscheidbar", falls

$$\mathbb{P}(X_t = Y_t \forall t \in I) = 1.$$

Wenn X und Y ununterscheidbar sind, so sind sie trivialerweise Modifikationen voneinander. Wenn sie Modifikationen voneinander sind, so haben sie dieselben endlich-dimensionalen Verteilungen. Folgendes Beispiel illustriert, dass letztere Eigenschaft nicht die anderen impliziert.

Sei X ein stochastischer Prozess auf $(\Omega, \mathcal{F}, \mathbb{P})$ und dem Zeitintervall $I = [0, 1]$. Sei $T : \Omega \rightarrow [0, 1]$ eine Zufallsvariable. Wir stellen uns T als Wecker vor, der jedem

¹¹Die Schreibweise X_t für einen stochastischen Prozess ist weit verbreitet und genauso gut bzw. schlecht wie die Verwendung von $f(x)$ für eine Funktion $f : \mathbb{R} \rightarrow \mathbb{R}$.

¹²Man kann auch den Graphen $\{(t, X_t(\omega)); t \geq 0\}$ als Pfad bezeichnen.

Pfad einen Uhrzeit zuweist. Definiere nun einen neuen stochastischen Prozess Y auf $(\Omega, \mathcal{F}, \mathbb{P})$ durch

$$Y_t(\omega) = \begin{cases} X_t(\omega) & , t \neq T(\omega) , \\ 0 & , t = T(\omega) . \end{cases}$$

Dann besitzen X und Y dieselben endlich-dimensionalen Verteilungen, sind aber nicht ununterscheidbar. Wenn fast alle Pfade von X stetig und nicht trivial sind, so sind fast alle Pfade von Y unstetig. So etwas kann bei ununterscheidbaren Prozessen natürlich nicht auftreten. Wenn man im obigen Beispiel annimmt, dass T eine Verteilung mit einer stetigen Dichte hat, so sind X und Y Modifikationen, denn $\mathbb{P}(X_t = Y_t) = \mathbb{P}(T \neq t) = 1 \forall t$.

1.7 Ein Beispiel

1.A Anhang 1: Weitere Resultate

Eine Richtung in Lemma 1.10 wird noch besser verständlich, wenn man folgendes grundlegendes Resultat kennt.

Lemma 1.25 (Null-Eins-Gesetz von É. Borel) *Sei (A_k) eine Folge paarweise unabhängiger Ereignisse in \mathcal{F} . Dann gilt*

$$\mathbb{P}(A_k \text{ i.o.}) = 1 \quad \text{oder} \quad \mathbb{P}(A_k \text{ i.o.}) = 0 .$$

In späteren Versionen zu ergänzen: Eindeutigkeit der charakteristischen Funktion.

1.B Anhang 2: Folgen unabhängiger Zufallsvariablen und Grenzwertsätze

In späteren Versionen zu ergänzen: Sätze über die Konvergenz von Verteilungen, siehe das Buch von Dudley.

Lemma 1.26 (Lévy) *Sei $(X_n)_n$ eine Folge unabhängiger Zufallsvariablen. Dann sind die folgenden Aussagen äquivalent:*

1. $\sum_{n=1}^{\infty} X_n$ konvergiert \mathbb{P} -fast sicher.
2. $\sum_{n=1}^{\infty} X_n$ konvergiert dem Maß nach.
3. $\sum_{n=1}^{\infty} X_n$ konvergiert der Verteilung nach, d.h. die Verteilung $\mu_k = \mathbb{P}_{\sum_{n=1}^k X_n}$ konvergiert gegen ein Maß μ für $k \rightarrow \infty$.