

# Kapitel 4

## Allgemeine Likelihoodtheorie

Es sei  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Modell mit dem Stichprobenraum  $(E, \mathcal{E})$ . Die Wahrscheinlichkeitsverteilung der Stichprobe  $X$  unter dem Wahrscheinlichkeitsmaß  $\mathbb{P}_\vartheta$  ist gegeben durch

$$\mathbb{P}_\vartheta^X(B) := \mathbb{P}_\vartheta(X \in B), \quad B \in \mathcal{E}.$$

Im Fall, daß man stochastische Prozesse studiert, ist der Stichprobenraum  $E$  in der Regel ein Funktionenraum, z.B. der Raum  $\mathbb{C}([0, T])$  aller stetigen Funktionen auf dem Beobachtungsintervall  $[0, T]$ .

In diesem allgemeinen Fall gibt es keine ausgezeichnete „gleichmäßige Verteilung“ wie das Lebesguemaß im  $\mathbb{R}^n$ , bezüglich der man Dichten  $f_\vartheta^X(x)$  bilden kann. Einen Ausweg bietet das Theorem von Radon-Nikodym aus der Maßtheorie, das in bestimmten Fällen die Existenz von Funktionen sichert, die die Rolle von Dichten im klassischen Fall übernehmen.

### 4.1 Das Theorem von Radon-Nikodym

Wir beginnen mit einem fundamentalen Satz über die Darstellung eines Maßes  $\mu$  als Integral über eine Funktion  $f$  bezüglich eines anderen Maßes  $\nu$ , dem *Satz von Radon-Nikodym*.

**Definition 4.1.** Es seien  $\mu$  und  $\nu$  zwei  $\sigma$ -finite Maße auf einem meßbaren Raum  $(F, \mathcal{F})$ . Man sagt,  $\mu$  sei *absolutstetig bezüglich*  $\nu$ , falls für jedes  $A \in \mathcal{F}$  mit  $\nu(A) = 0$  auch  $\mu(A) = 0$  gilt.

Symbolisch schreibt man dafür  $\mu \ll \nu$ . Offenbar folgt aus  $\mu \ll \nu$  und  $\nu \ll \lambda$  auch  $\mu \ll \lambda$  (Transitivität). Gilt sowohl  $\mu \ll \nu$  als auch  $\nu \ll \mu$ , so heißen  $\mu$  und  $\nu$  *äquivalent*, im Zeichen:  $\mu \equiv \nu$ .

**Beispiel 4.1.** Es sei  $(F, \mathcal{F})$  ein meßbarer Raum. Ist  $f$  eine  $\mathcal{F}$ -meßbare reellwertige, nicht-negative Funktion auf  $F$ , so wird durch

$$\mu(A) := \int_A f(x) \nu(dx), \quad A \in \mathcal{F}$$

ein  $\sigma$ -finites Maß  $\mu$  auf  $\mathcal{F}$  definiert mit  $\mu \ll \nu$ .

**Aussage 4.1 (Satz von Radon-Nikodym).** *Es seien  $\mu$  und  $\nu$  zwei  $\sigma$ -finite Maße auf  $(F, \mathcal{F})$ . Ist  $\mu \ll \nu$ , d.h., folgt für alle  $A \in \mathcal{F}$  mit  $\nu(A) = 0$  auch  $\mu(A) = 0$ , so existiert eine nichtnegative Funktion  $f$  auf  $F$  mit folgenden Eigenschaften:*

1.  $f$  ist  $\mathcal{F}$ -meßbar,
2.  $\mu(A) = \int_A f(x) \nu(dx) \quad \forall A \in \mathcal{F}$ .

Die Funktion  $f$  ist  $\nu$ -f.ü. eindeutig bestimmt, d.h., für jede  $\mathcal{F}$ -meßbare Funktion  $g$  mit  $\int_A f d\nu = \int_A g d\nu, \quad \forall A \in \mathcal{F}$ , gilt  $f = g$   $\nu$ -f.ü.

*Beweis:*

Siehe Bauer, H. (1992) Maß- und Integrationstheorie, de Gruyter-Verlag, Kapitel 17.  $\square$

Die Funktion  $f$  aus dem Satz von Radon-Nikodym heißt *Radon-Nikodym-Ableitung von  $\mu$  nach  $\nu$*  und wird mit  $\frac{d\mu}{d\nu}$  bezeichnet. Damit kann man die Eigenschaft 2. in der Aussage 4.1 schreiben als:

$$\mu(A) = \int_A \frac{d\mu}{d\nu}(x) \nu(dx), \quad A \in \mathcal{F}. \quad (4.1)$$

### Eigenschaften der Radon-Nikodym-Ableitung

Es gilt ( $x$  ist hier stets Element aus  $F$ )

$$\text{Falls } \mu \ll \nu, \quad \text{so gilt } \frac{d\mu}{d\nu}(x) > 0 \quad \mu\text{-f.ü.} \quad (4.2)$$

$$\text{Falls } \mu \ll \nu \text{ und } \nu \ll \lambda, \quad \text{so haben wir } \frac{d\mu}{d\lambda}(x) = \frac{d\mu}{d\nu}(x) \cdot \frac{d\nu}{d\lambda}(x) \quad \lambda\text{-f.ü.} \quad (4.3)$$

$$\text{Gilt } \nu \equiv \mu, \quad \text{so ist } \frac{d\nu}{d\mu}(x) = \left( \frac{d\mu}{d\nu}(x) \right)^{-1} \quad \mu\text{- und } \nu\text{-f.ü.} \quad (4.4)$$

*Beweis:*

$$1. \mu\left(\left\{x : \frac{d\mu}{d\nu}(x) = 0\right\}\right) = \int_{\left\{\frac{d\mu}{d\nu} = 0\right\}} \frac{d\mu}{d\nu} d\nu = 0$$

2.

Wegen  $\nu(A) = \int_A \frac{d\nu}{d\lambda}(x)\lambda(dx)$ ,  $A \in \mathcal{F}$ , gilt für jede nichtnegative

$$\text{Funktion } g : \int_F g(x)\nu(dx) = \int_F g(x)\frac{d\nu}{d\lambda}(x)\lambda(dx).$$

(Man überlege sich die Gleichung für Indikatorfunktionen, für Linearkombinationen von Indikatorfunktionen und approximiere die erwähnten  $g$  durch monotone Folgen solcher Linearkombinationen. Danach wende man den Satz über monotone Konvergenz an.)

$$\text{Speziell für } g = \frac{d\mu}{d\nu}\mathbf{1}_A \text{ gilt: } \mu(A) = \int_A \frac{d\mu}{d\nu}(x)\nu(dx) = \int_A \frac{d\mu}{d\nu}(x)\frac{d\nu}{d\lambda}(x)\lambda(dx).$$

Die Behauptung folgt auf Grund der  $\lambda$ -fast sicheren Eindeutigkeit der Radon-Nikodym-Ableitung.

$$3. \text{ folgt aus 2. mit } \lambda = \mu : \frac{d\nu}{d\mu} \cdot \frac{d\mu}{d\nu} = 1 \quad \mu\text{- und } \nu\text{-f.ü.} \quad \square$$

### **Bemerkung:**

Wir nennen die Vorgehensweise im Punkt 2. die „Approximationsmethode“ und werden sie später noch mehrfach verwenden.

### **Zum Begriff „Absolutstetigkeit von Maßen und Funktionen“**

**Aussage 4.2.** *Es gilt folgende Äquivalenz für je zwei endliche Maße  $\mu$  und  $\nu$  auf einem meßbaren Raum  $(\Omega, \mathcal{A})$ :*

$$\mu \ll \nu, \text{ d.h. } \nu(A) = 0 \implies \mu(A) = 0 \quad \forall A \in \mathcal{A}$$

*ist äquivalent mit*

$$\forall \epsilon > 0 : \exists \delta > 0 : \forall A \text{ mit } \mu(A) < \delta \text{ folgt } \nu(A) < \epsilon.$$

*Beweis:*

Hinlänglichkeit der Bedingung: Gilt  $\nu(A) = 0$ , so ist  $\nu(A) < \delta$  für alle  $\delta > 0$ , also auch  $\mu(A) < \epsilon$  für alle  $\epsilon > 0$ , somit gilt  $\mu(A) = 0$ .

Notwendigkeit: Angenommen, die Bedingung gilt nicht. Dann gibt es ein  $\epsilon > 0$  und eine Folge  $A_n \in \mathcal{A}$  mit  $\nu(A_n) \leq 2^{-n}$  und  $\mu(A_n) \geq \epsilon$ . Wir setzen  $A = \limsup_{n \rightarrow \infty} A_n$ . Dann gilt  $\nu(A) = 0$  (Borel-Cantelli). Andererseits ist  $\mu(A_n) = \int_{\Omega} \mathbf{1}_{A_n} d\mu$  und

$$\mu(A) = \int_{\Omega} \limsup_{n \rightarrow \infty} \mathbf{1}_{A_n} d\mu \geq \limsup_{n \rightarrow \infty} \int_{\Omega} \mathbf{1}_{A_n} d\mu \geq \epsilon \quad (\text{Fatousches Lemma})$$

Widerspruch zur Annahme. □

**Definition 4.2.** Eine Verteilungsfunktion  $F$  auf  $\mathbb{R}$  heißt *absolutstetig bezüglich dem Lebesguemaß*  $\lambda$  auf  $\mathbb{R}$ , falls das von ihr erzeugte Wahrscheinlichkeitsmaß  $\mathbb{P}_F$  absolutstetig bezüglich dem Lebesguemaß  $\lambda$  ist.

In diesem Fall gibt es auf Grund des Radon-Nikodym-Theorems eine Borelmeßbare Funktion  $f$  mit

$$\mathbb{P}_F(A) = \int_A f d\lambda, \quad A \in \mathcal{B}, \quad \text{insbesondere gilt} \quad F(x) = \int_{(-\infty, x]} f(s) ds, \quad x \in \mathbb{R}.$$

Nicht jede stetige Funktion  $F$  ist absolutstetig (z.B. die Cantorsche Funktion).

Eine Verteilungsfunktion  $F$  ist absolutstetig genau dann, wenn für alle  $\epsilon > 0$  ein  $\delta > 0$  existiert, so daß für jede endliche Menge  $\{[\alpha_k, \beta_k], k = 1, 2, \dots, m\}$  paarweise disjunkter Teilintervalle mit  $\sum_{k=1}^m (\beta_k - \alpha_k) < \delta$  die Ungleichung  $\sum_{k=1}^m F(\beta_k) - F(\alpha_k) < \epsilon$  gilt.

Ist  $F$  absolutstetig, so ist  $F$  Lebesgue-fast überall differenzierbar, und es gilt

$$\frac{dF}{dx} = f(x) \quad \lambda\text{-f.ü.},$$

d.h. die Ableitung von  $F$  ist  $\lambda$ -f.ü. gleich der Radon-Nikodym-Ableitung von  $\mathbb{P}_F$  nach  $\lambda$ .

Außerdem gilt somit für jede absolutstetige Verteilungsfunktion  $F$

$$F(x) = \int_{(-\infty, x]} \frac{dF}{ds} ds, \quad \text{d.h. } F \text{ hat eine Dichte } f(s) = \frac{dF}{ds}.$$

Literatur: Natanson, I.P., Theorie der Funktionen einer reellen Veränderlichen, Akademie-Verlag Berlin, 1961

**Beispiel 4.2.** Es seien  $F$  und  $G$  zwei absolutstetige Verteilungsfunktionen auf  $\mathbb{R}$  mit den Dichten  $f$  bzw.  $g$  bezüglich dem Lebesguemaß  $\lambda$ . Es bezeichnen  $\mathbb{P}_F$  und  $\mathbb{P}_G$  die durch  $F$  bzw.  $G$  erzeugten Wahrscheinlichkeitsmaße auf  $\mathcal{B}$ , d.h. es gilt

$$\mathbb{P}_F((a, b]) = F(b) - F(a) = \int_a^b f(s) ds \quad \text{und}$$

$$\mathbb{P}_G((a, b]) = G(b) - G(a) = \int_a^b g(s) ds$$

für alle  $a, b$  mit  $a < b$ . Dann haben wir die

**Aussage 4.3.** a)  $\mathbb{P}_F(B) = 0 \iff \lambda(\{f > 0\} \cap B) = 0$  (für alle Borelmengen  $B$  aus  $\mathbb{R}$ ).  
Analoges gilt für  $\mathbb{P}_G$  und  $g$  anstelle von  $\mathbb{P}_F$  und  $f$ .

b)  $\mathbb{P}_F \ll \mathbb{P}_G \iff \{x \in \mathbb{R} \mid f(x) > 0\} \stackrel{\lambda\text{-f.ü.}}{\subseteq} \{x \in \mathbb{R} \mid g(x) > 0\}$  im Sinne von

$$\lambda(\{f > 0\} \setminus \{g > 0\}) = 0. \quad (4.5)$$

c) In diesem Fall ist

$$\frac{d\mathbb{P}_F}{d\mathbb{P}_G}(x) = \frac{f(x)}{g(x)} \quad \text{für } \mathbb{P}_G\text{-fast alle } x \in \mathbb{R}. \quad (4.6)$$

*Beweis:*

a) Es gilt

$$\mathbb{P}_F(B) = 0 \iff \int_B f(s) ds = 0 \iff \int_{B \cap \{f > 0\}} f(s) ds = 0 \iff \lambda(B \cap \{f > 0\}) = 0.$$

b) Es gelte  $\mathbb{P}_F \ll \mathbb{P}_G$ . Dann gilt  $\mathbb{P}_G(\{g = 0\}) = 0$  und folglich  $\mathbb{P}_F(\{g = 0\}) = 0$ , somit haben wir mit a)

$$\lambda(\{g = 0\} \cap \{f > 0\}) = 0, \quad \text{d.h.} \quad \lambda(\{f > 0\} \setminus \{g > 0\}) = 0.$$

Gilt dagegen (4.5) und ist  $\mathbb{P}_G(B) = 0$ , so haben wir (siehe a))  $\lambda(B \cap \{g > 0\}) = 0$  und somit wegen

$$\{f > 0\} \cap B = (\{f > 0\} \cap \{g > 0\} \cap B) \cup (\{f > 0\} \cap \{g = 0\} \cap B)$$

auch

$$\lambda(\{f > 0\} \cap B) \leq \lambda(\{g > 0\} \cap B) + \lambda(\{f > 0\} \setminus \{g > 0\}) = 0.$$

Das bedeutet  $\mathbb{P}_F(B) = 0$ .

c) Weiterhin gilt (mit  $\frac{0}{0} := 0$ )

$$\mathbb{P}_F(B) = \int_B f d\lambda = \int_{B \cap \{f > 0\}} f d\lambda = \int_{B \cap \{f > 0\}} \frac{f(s)}{g(s)} g(s) ds. \quad (\text{wegen } \{f > 0\} \subseteq \{g > 0\} \text{ } \lambda\text{-f.ü.})$$

Bekanntlich gilt für alle nichtnegativen Borelmeßbaren Funktionen  $h$ :

$$\int_{\mathbb{R}} h(x) \mathbb{P}_G(dx) = \int_{\mathbb{R}} h(x)g(x) dx$$

Folglich ist

$$\mathbb{P}_F(B) = \int_{B \cap \{f > 0\}} \frac{f(s)}{g(s)} \mathbb{P}_G(ds) = \int_B \frac{f(s)}{g(s)} \mathbb{P}_G(ds),$$

d.h.  $\frac{d\mathbb{P}_F}{d\mathbb{P}_G}(s) = \frac{f(s)}{g(s)}$   $\mathbb{P}_G$ -f.s. bzw.  $\lambda$ -f.ü. auf  $\{g > 0\}$ .

□

**Beispiel 4.3.** Es sei  $\mathbb{P}$  eine diskrete Wahrscheinlichkeitsverteilung auf  $E = \{e_1, e_2, \dots, e_m, \dots\}$  mit

$$\mathbb{P}(\{e_k\}) =: p_k \geq 0, \quad \sum_{k=1}^{\infty} p_k = 1, \quad \mathcal{E} = \wp(E).$$

Es sei weiterhin  $Q$  ein  $\sigma$ -finites Maß auf  $\mathcal{E}$ . Dann kann man die Absolutstetigkeit an Hand der Einzelwahrscheinlichkeiten prüfen:

**Aussage 4.4.** *Es gilt*

- a)  $\mathbb{P} \ll Q \iff \{e_k : p_k > 0\} \subseteq \{e_k : q_k > 0\}$
- b)  $\frac{d\mathbb{P}}{dQ}(e_k) = \frac{p_k}{q_k}$  für alle  $k$  mit  $q_k > 0$ .  
 (Für  $e_k$  mit  $q_k = 0$  kann  $\frac{d\mathbb{P}}{dQ}(e_k)$  beliebig gewählt werden.)

*Beweis:*

Es gilt

$$\mathbb{P}(\{e_k\}) = \frac{p_k}{q_k} q_k; \quad P(B) = \sum_{k: e_k \in B} \frac{p_k}{q_k} q_k, \quad B \subseteq E.$$

□

$Q$  bezeichne das *Zählmaß* auf  $E$ , d.h. es gelte

$$Q(\{e_k\}) = 1, \quad \forall k, \quad Q(B) = \sum_{k: e_k \in B} \mathbf{1}, \quad B \subseteq E.$$

Damit ist  $\mathbb{P} \ll Q$  ( $Q(B) = 0$  impliziert  $B = \emptyset$ ) und es gilt

$$\frac{d\mathbb{P}}{dQ}(e_k) = p_k, \quad k \geq 1.$$

## 4.2 Likelihood-Funktionen für dominierte statistische Räume

Es sei  $(\Omega, \mathcal{A}, \mathcal{P})$  mit  $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  ein statistischer Raum.

**Definition 4.3.** Gilt für ein  $\sigma$ -finites Maß  $\mu$  auf  $(\Omega, \mathcal{A})$  die Beziehung  $\mathbb{P}_\vartheta \ll \mu$  für alle  $\vartheta \in \Theta$ , so heißt die Familie  $\mathcal{P}$  durch das Maß  $\mu$  dominiert und  $\mu$  ein dominierendes Maß für  $\mathcal{P}$ .

### Bemerkung:

Auf der reellen Achse  $\mathbb{R}$  oder im  $\mathbb{R}^n$  ist häufig das Lebesguemaß ein dominierendes Maß für eine gegebene Familie  $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  von Wahrscheinlichkeitsverteilungen, z.B. für die Familie aller eindimensionalen Normalverteilungen  $\mathcal{N}(\mu, \sigma^2)$  mit  $\vartheta = (\mu, \sigma^2)^T \in \mathbb{R} \times (0, \infty) =: \Theta$ . Jede Familie  $\mathbb{P}_\vartheta$ ,  $\vartheta \in \Theta$  diskreter Verteilungen auf einer höchstens abzählbar unendlichen Menge  $\{a_1, a_2, \dots, a_m, \dots\}$  ist dominiert durch das sogenannte „Zählmaß“, definiert durch  $\mu(\{a_m\}) \equiv 1$ .

**Aussage 4.5.** Ist  $\mu$  ein dominierendes Maß für  $\mathcal{P}$ , so gibt es ein zu  $\mu$  äquivalentes Wahrscheinlichkeitsmaß  $\mu_0$ , das  $\mathcal{P}$  ebenfalls dominiert.

*Beweis:*

Da  $\mu$   $\sigma$ -finit ist, gibt es nämlich eine Zerlegung von  $\Omega$  in meßbare Mengen  $Z_k$ ,  $k \geq 1$ , mit  $\mu(Z_k) \in (0, \infty)$ . Wir setzen

$$\mu_0(A) = \sum_{k=1}^{\infty} 2^{-k} \frac{\mu(A \cap Z_k)}{\mu(Z_k)}, \quad A \in \mathcal{A}.$$

□

Es sei  $(\Omega, \mathcal{A}, \mathcal{P})$  ein statistisches Experiment, dominiert durch ein  $\sigma$ -finites Maß  $\mu$ . Für jedes  $\vartheta \in \Theta$  definieren wir durch

$$L(\vartheta; \mathcal{A}) := \frac{d\mathbb{P}_\vartheta}{d\mu}$$

eine Zufallsgröße auf  $(\Omega, \mathcal{A})$ . Sie ist

1. meßbar bezüglich  $\mathcal{A}$  und
2. es gilt  $\mathbb{P}_\vartheta(A) = \int_A L(\vartheta; \mathcal{A})(\omega) \mu(d\omega)$  für alle  $A \in \mathcal{A}$ .

**Definition 4.4.** Als Funktion von  $\vartheta$  heißt  $\vartheta \longrightarrow L(\vartheta; \mathcal{A})(\omega)$  die *Likelihoodfunktion der Familie  $\mathcal{P}$  bezüglich  $\mu$  oder einfach von  $\mathcal{P}$  bezüglich  $\mu$ .*

**Beispiel 4.4.** Im Fall der Familie der Normalverteilungen  $\mathcal{N}(\mu, \sigma^2)$ , ( $\mu \in \mathbb{R}$ ,  $\sigma^2 > 0$ ) auf  $\mathbb{R}$  erhält man für  $\vartheta = (\mu, \sigma^2)^T$

$$L(\vartheta; \mathcal{B})(\omega) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(\omega - \mu)^2}{2\sigma^2} \right\}, \quad \omega \in \mathbb{R}$$

für das dominierende Lebesguemaß  $\lambda$ .

**Beispiel 4.5.** Ist  $\Omega$  eine abzählbare Menge,  $\Omega = \{\omega_k : k \geq 1\}$  und  $\{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  eine durch die Einzelwahrscheinlichkeiten  $p_k(\vartheta) = \mathbb{P}_\vartheta(\{\omega_k\})$  definierte Wahrscheinlichkeitsverteilung auf  $(\Omega, \wp(\Omega))$ , so ist wie bereits erwähnt, das Zählmaß  $\mu$ , definiert durch  $\mu(\{\omega_k\}) \equiv 1$ , ein die Familie  $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  dominierendes Maß. Es gilt

$$L(\vartheta; \wp(\Omega))(\omega_k) = \frac{p_k(\vartheta)}{\mu(\{\omega_k\})} = p_k(\vartheta), \quad k \geq 1.$$

### 4.3 Stochastische Likelihoodfunktionen

**Definition 4.5.** Es sei  $(\Omega, \mathcal{A}, \mathcal{P})$  ein statistischer Raum mit  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$  und es sei  $\mathcal{H}$  eine Teil- $\sigma$ -Algebra von  $\mathcal{A}$ . Es gelte  $\mathbb{P}_\vartheta|_{\mathcal{H}} \ll \mu$  für ein  $\sigma$ -finites Maß  $\mu$  auf  $\mathcal{H}$ . ( $\mathbb{P}_\vartheta|_{\mathcal{H}}$  bezeichnet die Einschränkung von  $\mathbb{P}_\vartheta$  auf die Teil- $\sigma$ -Algebra  $\mathcal{H}$  von  $\mathcal{A}$ .)

Dann heißt

$$L(\vartheta; \mathcal{H})(\omega) := \frac{d\mathbb{P}_\vartheta|_{\mathcal{H}}}{d\mu}(\omega),$$

die *stochastische Likelihoodfunktion von  $\mathcal{P}$  bezüglich  $\mu$  und  $\mathcal{H}$ .*

Ist  $\mathcal{H} = \mathcal{A}$ , so handelt es sich um die in Abschnitt 4.2 definierte Likelihoodfunktion von  $\mathcal{P}$  bezüglich  $\mu$ .

Nach Definition ist  $\vartheta \longrightarrow L(\vartheta; \mathcal{H})$  eine Funktion, deren Werte Zufallsgrößen über  $(\Omega, \mathcal{A})$  sind, mit folgenden zwei Eigenschaften:

1. Für jedes  $\vartheta \in \Theta$  ist  $L(\vartheta; \mathcal{H})$  eine  $\mathcal{H}$ -meßbare Zufallsgröße,
2.  $\int_H L(\vartheta; \mathcal{H}) d\mu = \mathbb{P}_\vartheta(H) \quad \forall H \in \mathcal{H}, \forall \vartheta \in \Theta$

Die Eigenschaften 1. und 2. bestimmen  $L(\vartheta; \mathcal{H})$  eindeutig in dem Sinne, daß für jede  $\mathcal{H}$ -meßbare Funktion  $L_1(\vartheta; \mathcal{H})$  auf  $\Omega$  mit der Eigenschaft 2,  $L(\vartheta, \cdot) = L_1(\vartheta, \cdot)$   $\mu$ -f.ü., für alle  $\vartheta \in \Theta$  gilt.

**Aussage 4.6.** Ist  $\mathcal{H}'$  eine weitere  $\sigma$ -Algebra mit  $\mathcal{H} \subseteq \mathcal{H}' \subseteq \mathcal{A}$ , und ist  $(\mathbb{P}_\vartheta |_{\mathcal{H}'}, \vartheta \in \Theta)$  dominiert durch ein Wahrscheinlichkeitsmaß  $\mathbb{P}$  auf  $\mathcal{H}'$ , so ist (natürlich) auch  $(\mathbb{P}_\vartheta |_{\mathcal{H}}, \vartheta \in \Theta)$  dominiert durch  $\mathbb{P}$ , und es gilt

$$L(\vartheta; \mathcal{H}) = \mathbb{E}_{\mathbb{P}}(L(\vartheta; \mathcal{H}') | \mathcal{H}). \quad (4.7)$$

*Beweis:*

Nach Definition ist  $L(\vartheta; \mathcal{H})$  eine  $\mathcal{H}$ -meßbare Funktion mit

$$\int_H L(\vartheta; \mathcal{H}) d\mathbb{P} = \mathbb{P}_\vartheta(H), \quad H \in \mathcal{H}, \vartheta \in \Theta,$$

und da  $\mathcal{H} \subseteq \mathcal{H}'$  gilt, ist auch

$$\mathbb{P}_\vartheta(H) = \int_H L(\vartheta; \mathcal{H}') d\mathbb{P}, \quad H \in \mathcal{H}, \vartheta \in \Theta.$$

Somit gilt

$$\int_H L(\vartheta; \mathcal{H}) d\mathbb{P} = \int_H L(\vartheta; \mathcal{H}') d\mathbb{P}, \quad H \in \mathcal{H}, \vartheta \in \Theta.$$

Daraus ergibt sich die Behauptung auf Grund der Definition der bedingten Erwartung.  $\square$

**Folgerung 4.6 (Martingaleigenschaft der Likelihoodfunktion).** Ist  $(\mathcal{H}_n, n \geq 1)$  eine wachsende Folge von Teil- $\sigma$ -Algebren von  $\mathcal{A}$ , d.h. gilt  $\mathcal{H}_1 \subseteq \mathcal{H}_2 \subseteq \dots \subseteq \mathcal{H}_n \subseteq \mathcal{A}$ , ( $n \geq 1$ ), so ist für jedes  $\vartheta \in \Theta$  die Folge  $(L(\vartheta; \mathcal{H}_n), \mathcal{H}_n)_{n \geq 1}$  ein nichtnegatives Martingal bezüglich  $\mathbb{P}$ .

Auf Grund des Martingalkonvergenzsatzes (siehe z.B. Shiryaev) folgt: Der Grenzwert  $\lim_{n \rightarrow \infty} L_n(\omega) =: L_\infty$  existiert  $\mathbb{P}$ -fast sicher und es gilt  $\mathbb{E}_{\mathbb{P}}(L_\infty) \leq \overline{\lim}_{n \rightarrow \infty} \mathbb{E}_{\mathbb{P}}(L_n) = 1$ . (Fatou),  $L_\infty$  ist  $\mathcal{H}_\infty := \bigvee_{n=1}^{\infty} \mathcal{H}_n$  meßbar. Hier wurde  $L_n = L(\vartheta; \mathcal{H}_n)$  gesetzt.

Frage: Sind die Wahrscheinlichkeitsmaße  $\mathbb{P}_\vartheta |_{\mathcal{H}_\infty}$  auch absolutstetig bezüglich  $\mathbb{P} |_{\mathcal{H}_\infty}$ ? Dieser Frage werden wir später (im Abschnitt 4.7) nachgehen.

## 4.4 Deterministische Likelihoodfunktionen

Im allgemeinen beobachtet man nicht den Ausgang  $\omega$  des zufälligen Experiments  $(\Omega, \mathcal{A}, \mathcal{P})$  als Ganzes, sondern nur Teile davon, z.B. Temperaturmessungen oder Aktienkurse, zu diskreter Zeit (d.h. täglich, wöchentlich, monatlich), im Gegensatz zu kontinuierlicher, also

zeitstetiger Beobachtung.

Dieser Sachverhalt wird durch eine Stichprobe  $X(\omega)$  modelliert: man beobachtet  $X(\omega)$  anstelle von  $\omega$ .

Folglich hat man nach der Ausführung des Experimentes auch nicht die volle Information, welche der Ereignisse  $A \in \mathcal{A}$  eingetreten sind und welche nicht, sondern man weiß es nur von Ereignissen der Form  $\{X \in B\} = X^{-1}(B)$  mit  $B \in \mathcal{E}$ . Da man  $X$  beobachtet, kann man entscheiden, ob der beobachtete Wert zu  $B$  gehört, d.h., ob  $\{X \in B\}$  eingetreten ist. Die relevante  $\sigma$ -Algebra von Ereignissen ist  $\mathcal{A}^X := X^{-1}(\mathcal{E}) \subseteq \mathcal{A}$ .

Wir können also auf der Grundlage unserer beobachteten Stichprobe  $X$  i.a. die Likelihoodfunktion  $L(\vartheta; \mathcal{A})(\omega)$  nicht bestimmen. Der Ausweg liegt in der Einführung der Likelihoodfunktion  $L(\vartheta; \mathcal{A}^X)$ . Da  $L(\vartheta; \mathcal{A}^X)$  eine  $\mathcal{A}^X$ -meßbare Zufallsgröße ist, muß es für jedes  $\vartheta \in \Theta$  eine meßbare Funktion  $\Psi_\vartheta$  von  $(E, \mathcal{E})$  in  $(R, \mathcal{B})$  geben mit

$$L(\vartheta; \mathcal{A}^X)(\omega) = \Psi_\vartheta(X(\omega)), \quad \mathbb{P}_\vartheta\text{-f.s.}$$

(Siehe z.B. Bauer, Wahrscheinlichkeitstheorie und Grundzüge der Maßtheorie)

Diese Funktion  $\Psi_\vartheta(x)$  werden wir hier im Folgenden berechnen.

Vorbereitungen:

a) DIE VON  $X$  ERZEUGTE  $\sigma$ -ALGEBRA  $\mathcal{A}^X$

Es seien  $(\Omega, \mathcal{A})$  und  $(E, \mathcal{E})$  meßbare Räume und  $X$  eine meßbare Abbildung von  $(\Omega, \mathcal{A})$  in  $(E, \mathcal{E})$ , es gelte also  $\mathcal{A}^X := X^{-1}(\mathcal{E}) \subseteq \mathcal{A}$ .

Das Mengensystem  $\mathcal{A}^X = X^{-1}(\mathcal{E})$  ist eine  $\sigma$ -Algebra von Teilmengen von  $\Omega$ , und zwar die kleinste  $\sigma$ -Algebra  $\mathcal{H}$ , bezüglich der  $X$  ( $\mathcal{H}$ - $\mathcal{E}$ )-meßbar ist. Sie heißt *die von  $X$  in  $\Omega$  erzeugte  $\sigma$ -Algebra* und wird auch mit  $\sigma(X)$  bezeichnet.

Die Elemente von  $\mathcal{A}^X$  sind genau die Urbilder  $X^{-1}(B) = \{\omega \in \Omega \mid X(\omega) \in B\}$ ,  $B \in \mathcal{E}$ , mit anderen Worten,

$$A \in \mathcal{A}^X \iff \exists B \in \mathcal{E} : A = X^{-1}(B). \quad (4.8)$$

b) DIE VON  $X$  ERZEUGTE FAMILIE  $\mathcal{P}^X$

Es sei  $\nu$  ein  $\sigma$ -finites Maß auf  $\mathcal{A}^X$ . Dann ist durch  $\nu^X(B) := \nu(A)$  mit  $A := X^{-1}(B) \in \mathcal{A}^X$  ein  $\sigma$ -finites Maß  $\nu^X$  auf  $\mathcal{E}$  definiert.

Es seien nun  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Modell mit dem Stichprobenraum  $(E, \mathcal{E})$

und  $\nu$  ein  $\sigma$ -finites Maß auf  $\mathcal{A}$ . Wir setzen  $\mathcal{P}|_{\mathcal{A}^X} := (\mathbb{P}_\vartheta|_{\mathcal{A}^X} : \vartheta \in \Theta)$  und  $\mathcal{P}^X := (\mathbb{P}_\vartheta^X : \vartheta \in \Theta)$ . Hierbei bezeichnet  $Q|_{\mathcal{A}^X}$  für jedes Maß  $Q$  auf  $\mathcal{A}$  die Einschränkung von  $Q$  auf  $\mathcal{A}^X$ .

**Lemma 4.7.** *Genau dann dominiert  $\nu|_{\mathcal{A}^X}$  die Familie  $\mathcal{P}|_{\mathcal{A}^X}$ , wenn  $\nu^X$  die Familie  $\mathcal{P}^X$  dominiert.*

*Beweis:*

Es sei  $A \in \mathcal{A}^X$  und  $B \in \mathcal{E}$  derart, daß  $A = X^{-1}(B)$  gilt. Angenommen,  $\nu|_{\mathcal{A}^X}$  dominiert  $\mathcal{P}|_{\mathcal{A}^X}$  und es sei  $\nu^X(B) = 0$ .

Dann folgt

$$\nu(A) = \nu(X^{-1}(B)) = \nu^X(B) = 0, \text{ folglich } \mathbb{P}_\vartheta(A) = 0 \text{ für alle } \vartheta \in \Theta.$$

Somit gilt  $\mathbb{P}_\vartheta^X(B) = 0$ ,  $\vartheta \in \Theta$ . Also dominiert  $\nu^X$  die Familie  $\mathcal{P}^X$ . Die Umkehrung zeigt man analog.  $\square$

Nehmen wir an, daß  $\nu^X$  die Familie  $\mathcal{P}^X$  dominiert, so haben wir insbesondere die Likelihoodfunktion

$$L^X(\vartheta; x) := \frac{d\mathbb{P}_\vartheta^X}{d\nu^X}(x), \quad x \in E, \vartheta \in \Theta$$

von  $\mathcal{P}^X$  bezüglich  $\nu^X$ . Sie ist nach Definition  $\mathcal{E}$ -meßbar. Da die Elemente  $x \in E$  als konkrete Stichproben angesehen werden, die nichtzufällig sind, bezeichnen wir  $L^X(\vartheta; x)$  als *deterministische Likelihoodfunktion von  $\mathcal{P}^X$  bezüglich  $\nu^X$* . Setzt man in  $L^X(\vartheta; x)$  an die Stelle  $x$  die mathematische Stichprobe  $X$  ein, so erhält man eine Zufallsgröße  $L^X(\vartheta; X(\omega))$ , für die folgende Aussage gilt:

**Aussage 4.7.** *Es gilt für jedes  $\vartheta \in \Theta$*

$$L(\vartheta; \mathcal{A}^X)(\omega) = L^X(\vartheta; X(\omega)), \quad \text{für } \nu\text{-fast alle } \omega. \quad (4.9)$$

*Beweis:*

Nach Definition ist für jedes  $B \in \mathcal{E}$

$$\nu^X(B) := \nu(X^{-1}(B)), \quad \text{also} \quad \int_{\Omega} \mathbf{1}_B(X(\omega))\nu(d\omega) = \int_E \mathbf{1}_B(x)\nu^X(dx).$$

Damit gilt für alle  $\mathcal{E}$ -meßbaren nichtnegativen Funktionen  $g$  (Beweis mit der Approximationsmethode aus Kapitel 4.1),

$$\int_{\Omega} g(X(\omega))\nu(d\omega) = \int_E g(x)\nu^X(dx) \text{ (Substitutionsformel).}$$

Wir setzen  $g(x) := L^X(\vartheta; x)\mathbf{1}_B(x)$  und erhalten für jedes  $B \in \mathcal{E}$  die Gleichung

$$\int_{X^{-1}(B)} L^X(\vartheta, X(\omega))\nu(d\omega) = \int_B L^X(\vartheta; x)\nu^X(dx) = \mathbb{P}_\vartheta^X(B) = \mathbb{P}_\vartheta(X^{-1}(B)).$$

Da  $\mathcal{A}^X = \{X^{-1}(B) \mid B \in \mathcal{E}\}$  gilt, ist die Aussage 4.7 bewiesen. Dabei haben wir benutzt, daß  $\omega \rightarrow L^X(\vartheta; X(\omega))$   $\mathcal{A}^X$ -meßbar ist.  $\square$

**Folgerung 4.8.** *Ist  $Y$  eine Zufallsgröße über  $(\Omega, \mathcal{A})$  mit Werten in  $(F, \mathcal{F})$ , und ist  $Y = \Psi(X)$  für eine meßbare Abbildung  $\Psi$  von  $(E, \mathcal{E})$  in  $(F, \mathcal{F})$ , so gilt  $\mathcal{A}^Y \subseteq \mathcal{A}^X$  (wegen  $\mathcal{A}^Y = Y^{-1}(\mathcal{F}) = X^{-1}(\Psi^{-1}(\mathcal{F})) \subseteq X^{-1}(\mathcal{E}) = \mathcal{A}^X$ )*

*Folglich gilt (siehe Aussage 4.6):*

$$\begin{aligned} L(\vartheta; \mathcal{A}^Y) &= \mathbb{E}_{\mathbb{P}}(L(\vartheta; \mathcal{A}^X) \mid \mathcal{A}^Y), \text{ oder anders ausgedrückt,} \\ L^Y(\vartheta; Y(\omega)) &= \mathbb{E}_{\mathbb{P}}(L^X(\vartheta; X) \mid Y)(\omega) \quad \mathbb{P}\text{-f.s.} \end{aligned} \quad (4.10)$$

Diese sehr allgemeinen Folgerungen aus dem Satz von Radon-Nikodym bilden den allgemeinen Rahmen für die Likelihoodtheorie stochastischer Prozesse mit diskreter oder auch mit stetiger Zeit.

## 4.5 Ausflug in die Welt der Stochastischen Prozesse

Unser statistisches Modell umfaßt insbesondere auch Fälle, bei denen die Stichprobe  $X$  aus Trajektorien zeitstetiger stochastischer Prozesse besteht. Der Stichprobenraum  $E$  ist also ein Funktionenraum. Die Wahl einer geeigneten  $\sigma$ -Algebra  $\mathcal{E}$  von Teilmengen von  $E$  erfolgt in Analogie des Falles  $E = \mathbb{R}^n$ . Wir erinnern uns daran, daß  $\mathcal{B}^n$  die kleinste  $\sigma$ -Algebra ist, die alle Rechtecke  $B_1 \times \dots \times B_n$  mit  $B_k \in \mathcal{B}$ ,  $k = 1, \dots, n$ , enthält. Die Rechtecke werden im Funktionenraum durch die sogenannten Zylindermengen ersetzt. Doch zunächst einige Vorbereitungen.

Es seien  $(\Omega, \mathcal{A}, \mathbb{P})$  ein Wahrscheinlichkeitsraum und  $X := (X(t), t \in [0, T])$  ein reellwertiger stochastischer Prozeß über  $(\Omega, \mathcal{A}, \mathbb{P})$ . Für  $\mathbb{P}$ -fast alle  $\omega \in \Omega$  seien die Trajektorien  $t \rightarrow X(t, \omega)$  von  $X$  an jeder Stelle  $t \in [0, T)$  rechtsstetig und für jedes  $t \in (0, T]$  existiere der Grenzwert von links und sei endlich. (Praktisch alle gegenwärtig in Anwendungen und in der Theorie vorkommenden stochastischen Prozesse haben diese Eigenschaft.)

Der Vektorraum  $E_T := \mathbb{D}([0, T])$  aller reellwertigen Funktionen  $x = (x_s, s \leq T)$  mit den genannten Eigenschaften (cadlag = continues a droite, limites a gauche) ist metrisierbar mit einer Metrik  $d$  zu einem vollständigen metrischen Raum  $(E_T, d)$ . Mit  $\mathcal{E}_T$  bezeichnen wir die  $\sigma$ -Algebra der Borelmengen von  $(E_T, d)$ .

**Aussage 4.8.**  $\mathcal{E}_T$  ist identisch mit der kleinsten  $\sigma$ -Algebra  $\sigma(x_s, s \in [0, T])$ , bezüglich der alle Abbildungen  $x \rightarrow x_s, x \in E_T, s \in [0, T]$ , Borelmeßbar sind.

*Beweis:* (Siehe Billingsley, Convergence of Probability Measures)

Für die komplizierte und nicht unmittelbar zugängliche  $\sigma$ -Algebra  $\mathcal{E}_T$  gibt es ein Erzeugendensystem  $\mathcal{Z}$ , das aus speziellen Teilmengen von  $E_T$ , den sogenannten Zylindermengen, besteht.

**Definition 4.9.** Eine Teilmenge  $Z$  von  $E_T$  heißt eine *Zylindermenge*, falls es ein  $m \geq 1$ , Zeitpunkte  $t_0, t_1, \dots, t_m$  mit  $0 = t_0 < t_1 < \dots < t_m = T$  und ein  $B \in \mathcal{B}^{m+1}$  gibt, mit

$$Z = \{x = (x_s) \in E_T \mid (x_{t_0}, x_{t_1}, \dots, x_{t_m}) \in B\}$$

Mitunter werden wir auch die Notation  $Z = Z_{t_1, t_2, \dots, t_m; B}$  verwenden; mit  $\mathcal{Z}$  werde die Menge aller Zylindermengen aus  $E_T$  bezeichnet.

**Lemma 4.10.**  $\mathcal{Z}$  ist eine *Semialgebra* von Teilmengen aus  $E_T$ .

*Beweis:* Übungsaufgabe

Wegen der Aussage 4.8 gilt  $\{x_s \in B\} \in \mathcal{E}$  für alle  $B \in \mathcal{B}$  und  $s \in [0, T]$ . Daraus ergibt sich (ohne Beweis)  $\mathcal{Z} \subseteq \mathcal{E}_T$  und somit auch  $\sigma(\mathcal{Z}) \subseteq \mathcal{E}_T$ . (Mit  $\sigma(\mathcal{Z})$  bezeichnen wir die kleinste  $\sigma$ -Algebra von Teilmengen von  $E_T$ , in der  $\mathcal{Z}$  enthalten ist.) Mittels der obigen Aussage 4.8 erhalten wir  $\sigma(\mathcal{Z}) = \mathcal{E}_T$ .

Um die Wahrscheinlichkeitsverteilung  $\mathbb{P}^X$  von  $X$  auf  $\mathcal{E}_T$  zu bestimmen, genügt es, sie auf  $\mathcal{Z}$  anzugeben, da jede  $\sigma$ -additive  $\sigma$ -finite Mengenfunktion  $Q$  auf  $\mathcal{Z}$  auf eindeutige Weise von  $\mathcal{Z}$  auf  $\sigma(\mathcal{Z})$  fortgesetzt werden kann.

Für  $Z \in \mathcal{Z}$  gilt offenbar

$$\mathbb{P}^X(Z) := \mathbb{P}(X \in Z) = \mathbb{P}((X(t_0), \dots, X(t_m)) \in B),$$

wobei  $Z$  von der Gestalt

$$Z = \{x = (x_s) \mid (x_{t_0}, \dots, x_{t_m}) \in B\} \text{ für ein } B \in \mathcal{B}^{m+1}$$

sei.

Wir sehen also, daß die Verteilung  $\mathbb{P}^X$  von  $X$  auf  $\mathcal{E}_T$  eindeutig bestimmt ist durch die Wahrscheinlichkeitsverteilungen aller möglichen endlichdimensionalen Vektoren  $(X(t_0), \dots, X(t_m))$  mit  $\{t_0, t_1, \dots, t_m\} \subseteq [0, T]$ , wobei o.B.d.A.  $t_0 = 0$  und  $t_m = T$  gesetzt werden und  $0 < t_1 < \dots < t_m$  gefordert werden kann.

**Definition 4.11.** Für jede Auswahl  $\mathcal{T}_n := \{t_0, t_1, \dots, t_m\} \subseteq [0, T]$  mit den eben angegebenen Eigenschaften, ist durch

$$\Phi_{\mathcal{T}_n}(B) := \mathbb{P}((X(t_0), \dots, X(t_m)) \in B), \quad B \in \mathcal{B}^{m+1}$$

eine Wahrscheinlichkeitsverteilung  $\Phi_{\mathcal{T}_n}$  auf  $\mathcal{B}^{m+1}$  definiert, die zu  $\mathcal{T}_n$  gehörende sogenannte *endlichdimensionale Verteilung von  $X$* .

Die endlichdimensionalen Verteilungen stochastischer Prozesse lassen sich in vielen Fällen explizit bestimmen.

**Beispiel 4.6.** Poissonscher Prozess  $(N(t), t \geq 0)$  mit Intensitätsparameter  $\vartheta > 0$ .

**Definition 4.12.** Ein stochastischer Prozess  $N = (N(t), t \geq 0)$  auf einem Grundraum  $(\Omega, \mathcal{F}, \mathbb{P})$  heißt *Poissonscher Prozess mit Intensitätsparameter  $\vartheta > 0$* , falls gilt:

1.  $N(0) = 0$   $\mathbb{P}$ -f.s.,
2. für  $0 = t_0 < t_1 < \dots < t_m = T$  sind  $(N(t_k) - N(t_{k-1}))$ ,  $k = 1, 2, \dots, m$  unabhängig,
3. für  $0 \leq s < t$  ist  $N(t) - N(s)$  Poissonverteilt zum Parameter  $\vartheta(t - s)$ ,
4. Jede Funktion  $t \rightarrow N(t, \omega)$  ist stückweise konstant, ihre Sprungpunkte  $T_k$ ,  $k \geq 1$ , häufen sich nicht im Endlichen und es gilt

$$N(T_k) = N(T_k + 0) = N(T_k - 0) + 1.$$

(Aus 1. - 3. folgt bereits, daß es eine Version von  $N$  gibt, die die Eigenschaft 4. besitzt.)

Es sei  $0 = t_0 < t_1 < t_2 < \dots < t_n = T$ . Dann ist  $\Phi_{n; t_1, t_2, \dots, t_n}^{N, \vartheta}$  eine diskrete Verteilung auf  $N^n$  mit  $N = \{0, 1, 2, \dots\}$  und ihre Einzelwahrscheinlichkeiten sind

$$\begin{aligned} \Phi_{n; t_1, t_2, \dots, t_n}^{N, \vartheta}((i_1, i_2, \dots, i_n)) &= \mathbb{P}_{\vartheta}(N(t_1) = i_1, \dots, N(t_n) = i_n) \\ &= \frac{(\vartheta t_1)^{i_1}}{i_1!} e^{-\lambda t_1} \frac{(\vartheta(t_2 - t_1))^{i_2 - i_1}}{(i_2 - i_1)!} e^{-\lambda(t_2 - t_1)} \dots \frac{(\vartheta(t_n - t_{n-1}))^{i_n - i_{n-1}}}{(i_n - i_{n-1})!} e^{-\lambda(t_n - t_{n-1})} \\ &= \vartheta^{i_n} e^{-\vartheta t_n} \nu((i_1, \dots, i_n)) \end{aligned} \tag{4.11}$$

mit

$$\nu((i_1, \dots, i_n)) = \prod_{k=1}^n \frac{((t_k - t_{k-1}))^{i_k - i_{k-1}}}{(i_k - i_{k-1})!}.$$

**Beispiel 4.7.** Wienerprozess  $(W(t), t \geq 0)$  mit Drift  $\mu$  und Diffusion  $\sigma^2 > 0$ .

**Definition 4.13.** Ein stochastischer Prozess  $W = (W(t), t \geq 0)$  auf einem Grundraum  $(\Omega, \mathcal{F}, \mathbb{P})$  heißt *Wienerprozess mit den Parametern  $\mu, \sigma^2$* , wenn gilt:

1.  $W(0) = 0$   $\mathbb{P}$ -f.s.,
2. für  $0 = t_0 < t_1 < \dots < t_m = T$  sind  $(W(t_k) - W(t_{k-1}))$ ,  $k = 1, 2, \dots, m$  unabhängig,
3. für  $0 \leq s < t$  ist  $W(t) - W(s) \sim \mathcal{N}(\mu(t-s), \sigma^2(t-s))$ -verteilt,
4.  $t \rightarrow W(t, \omega)$  ist stetig für  $\mathbb{P}$ -fast alle  $\omega \in \Omega$ .  
(Aus 1. - 3. folgt bereits, daß es eine Version von  $W$  gibt, die die Eigenschaft 4. besitzt.)

$\mu$  und  $\sigma^2$  heißen *Drift* bzw. *Diffusion* von  $W$ .

Einen Wienerprozess  $W$  mit Drift  $\mu = 0$  und Diffusion  $\sigma^2 = 1$  nennen wir *Standard-Wienerprozess* und bezeichnen ihn mit  $W^0$ .

**Bemerkung:** Ist  $W^0$  ein Standard-Wienerprozess, so bildet

$$W(t) = \mu t + \sigma W^0(t), \quad t \geq 0$$

einen Wienerprozess mit Drift  $\mu$  und Diffusion  $\sigma^2$ .

Es sei  $W = (W(t), t \geq 0)$  ein Wiener-Prozess mit dem Parameter  $\vartheta = (\mu, \sigma^2) \in \mathbb{R} \times (0, \infty) =: \Theta$ . Es sei  $0 = t_0 < t_1 < \dots < t_m = T$ . Wir setzen

$$X := (W(t_1), \dots, W(t_m)), \quad E = \mathbb{R}^m, \quad \mathcal{E} = \mathcal{B}^m.$$

Für die Wahrscheinlichkeitsdichte von  $X$  gilt

**Aussage 4.9.**  $X$  hat die Dichte bezüglich des Lebesguemaßes

$$\varphi_{t_1, \dots, t_m}^{\vartheta}(x_1, \dots, x_m) = \prod_{k=1}^m \varphi_{t_k - t_{k-1}}^{\vartheta}(x_k - x_{k-1}), \quad (4.12)$$

wobei  $\varphi_t^{\vartheta}(x) := (2\pi\sigma^2 t)^{-\frac{1}{2}} \exp\left\{-\frac{(x - \mu t)}{2\sigma^2 t}\right\}$ ,  $x \in \mathbb{R}$ ,  $t > 0$  gesetzt wurde.

*Beweis:*

Es sei  $Z := (W(t_1) - W(t_0), \dots, W(t_m) - W(t_{m-1}))$  mit  $t_0 = 0$ .  $Z$  hat nach Definition des Wiener-Prozesses die Dichte

$$f_Z(z_1, z_2, \dots, z_m) = \prod_{k=1}^m \varphi_{t_k - t_{k-1}}^\vartheta(z_k).$$

Es gilt weiter  $X = A \cdot Z$  mit der Matrix  $A = (e_{ij})_{i,j=1,\dots,m}$ ,  $e_{ij} = 1$  für  $i \geq j$ ,  $e_{ij} = 0$  für  $i < j$ . Folglich ist für  $x = (x_1, \dots, x_m)$ ,  $\varphi_{t_1, \dots, t_m}(x_1, \dots, x_m) = f_Z(A^{-1}x) \cdot |\det A^{-1}|$ , woraus sich wegen

$$A^{-1} = (f_{ij})_{i,j=1,\dots,m}, \quad f_{ij} = \begin{cases} 1 & \text{für } i=j \\ -1 & \text{für } i=j+1 \\ 0 & \text{sonst} \end{cases}$$

die Behauptung ergibt. □

## 4.6 Likelihood am Beispiel des Wienerprozesses

Es seien  $(\Omega, \mathcal{A}, \mathcal{P})$  ein statistisches Modell mit  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$ ,  $\Theta = \mathbb{R} \times (0, \infty)$ ,  $\vartheta = (\mu, \sigma^2)^T \in \Theta$  und  $W = (W(t), t \geq 0)$  sei ein reellwertiger stochastischer Prozess auf  $(\Omega, \mathcal{A})$ , der für jedes  $\vartheta = (\mu, \sigma^2)^T \in \Theta$  bezüglich  $\mathbb{P}_\vartheta$  ein Wienerprozess mit Drift  $\mu$  und Diffusion  $\sigma^2$  ist. Wir nehmen an,  $\mu$  und  $\sigma^2$  seien unbekannt.

Ziel ist es, auf der Grundlage der Beobachtung  $X = (W(t), t \in [0, T])$  des Wienerprozesses bis zur Zeit  $T < \infty$  Schätzungen für  $\mu$  und  $\sigma^2$  vorzunehmen. Wir konzentrieren uns hier auf die Likelihoodmethode.

Beginnen wir mit dem Fall diskreter Beobachtung, d.h., wir kennen  $W$  nur zu den Zeitpunkten  $t_1 < \dots < t_m = T$ . Die Menge  $\mathcal{T}$  sei die Menge dieser Zeitpunkte:  $\mathcal{T} = \{t_1, t_2, \dots, t_m\}$ . Als Stichprobe liegt uns dann der Vektor  $X = (W(t_1), \dots, W(t_m))$  vor.

Die Verteilung  $\mathbb{P}_\vartheta^X$  von  $X$  ist eine Normalverteilung mit der Dichte bezüglich des Lebesguemaßes  $\lambda_m$  (vgl. (4.12))

$$\varphi_{\mathcal{T}}^\vartheta(x_1, \dots, x_m) = \prod_{k=1}^m \frac{1}{\sqrt{2\pi\sigma^2(t_k - t_{k-1})}} \exp \left\{ -\frac{(x_k - x_{k-1} - \mu(t_k - t_{k-1}))^2}{2(t_k - t_{k-1})\sigma^2} \right\}, \quad (4.13)$$

$$x = (x_1, \dots, x_m) \in \mathbb{R}^m.$$

Da  $\varphi_{\mathcal{F}}^{\vartheta}$  eine streng positive Dichte für  $\mathbb{P}_{\vartheta}^X$  ist, sind  $\mathbb{P}_{\vartheta}^X$  und das Lebesguemaß  $\lambda_m$  auf  $\mathbb{R}^m$  äquivalente Maße, für jedes  $\vartheta \in \Theta$ .

Somit sind für je zwei  $\vartheta, \vartheta_0 \in \Theta$  die Wahrscheinlichkeitsmaße  $\mathbb{P}_{\vartheta}^X$  und  $\mathbb{P}_{\vartheta_0}^X$  äquivalent. Daraus ergibt sich (siehe (4.3) und (4.4)) :

$$\frac{d\mathbb{P}_{\vartheta}^X}{d\mathbb{P}_{\vartheta_0}^X} = \frac{d\mathbb{P}_{\vartheta}^X}{d\lambda} \cdot \frac{d\lambda}{d\mathbb{P}_{\vartheta_0}^X} = \frac{d\mathbb{P}_{\vartheta}^X}{d\lambda} \cdot \left( \frac{d\mathbb{P}_{\vartheta_0}^X}{d\lambda} \right)^{-1}.$$

Das bedeutet für die deterministische Likelihoodfunktion

$$\begin{aligned} L^X(\vartheta; x) &= \frac{d\mathbb{P}_{\vartheta}^X}{d\mathbb{P}_{\vartheta_0}^X}(x) = \frac{\varphi_{\mathcal{F}}^{\vartheta}(x)}{\varphi_{\mathcal{F}}^{\vartheta_0}(x)} = \\ &= \left( \frac{\sigma^2}{\sigma_0^2} \right)^{-\frac{m}{2}} \exp \left\{ -\frac{1}{2} (\sigma^{-2} - \sigma_0^{-2}) \sum_{k=1}^m \frac{(x_k - x_{k-1})^2}{t_k - t_{k-1}} + \left( \frac{\mu}{\sigma^2} - \frac{\mu_0}{\sigma_0^2} \right) x_m - \frac{1}{2} \left( \frac{\mu^2}{\sigma^2} - \frac{\mu_0^2}{\sigma_0^2} \right) T \right\}. \end{aligned}$$

Da  $\vartheta_0$  beliebig aus  $\Theta$  gewählt werden kann, setzen wir  $\mu_0 = 0$ .

Unter Beachtung von  $t_m = T$  folgt

$$L^X(\vartheta; x) = \left( \frac{\sigma^2}{\sigma_0^2} \right)^{-\frac{m}{2}} \exp \left\{ -\frac{1}{2} (\sigma^{-2} - \sigma_0^{-2}) \sum_{k=1}^m \frac{(x_k - x_{k-1})^2}{t_k - t_{k-1}} + \frac{\mu}{\sigma^2} x_m - \frac{1}{2} \frac{\mu^2}{\sigma^2} T \right\}$$

mit  $x = (x_1, x_2, \dots, x_m)$ .

Für die stochastische Likelihoodfunktion ergibt sich (siehe (4.9)):

$$\begin{aligned} L(\vartheta; \mathcal{A}^X)(\omega) &= L^X(\vartheta; X(\omega)) = \frac{d\mathbb{P}_{\vartheta} |_{\mathcal{A}^X}}{d\mathbb{P}_{\vartheta_0} |_{\mathcal{A}^X}} = \\ &= \left( \frac{\sigma^2}{\sigma_0^2} \right)^{-\frac{m}{2}} \exp \left\{ -\frac{1}{2} (\sigma^{-2} - \sigma_0^{-2}) \sum_{k=1}^m \frac{(W(t_k) - W(t_{k-1}))^2}{t_k - t_{k-1}} + \frac{\mu}{\sigma^2} W(T) - \frac{1}{2} \frac{\mu^2}{\sigma^2} T \right\} \end{aligned}$$

Der Maximum-Likelihood-Schätzer für  $\vartheta = (\mu, \sigma^2)^T$  ergibt sich aus den Maximum-Likelihood-Gleichungen

$$\begin{aligned} \frac{\partial}{\partial \mu} \log L(\vartheta; \mathcal{A}^X)(\omega) &= 0 \quad \text{und} \\ \frac{\partial}{\partial \sigma^2} \log L(\vartheta; \mathcal{A}^X)(\omega) &= 0. \end{aligned}$$

Wir erhalten  $\hat{\vartheta}_{\mathcal{F}} = (\hat{\mu}_{\mathcal{F}}, \hat{\sigma}_{\mathcal{F}}^2)^T$  mit

$$\begin{aligned} \hat{\mu}_{\mathcal{F}} &= \frac{W(T)}{T}, \quad \text{unabhängig von der konkreten Gestalt von } \mathcal{F}, \text{ und} \\ \hat{\sigma}_{\mathcal{F}}^2 &= \frac{1}{m} \sum_{k=1}^m \frac{(W(t_k) - W(t_{k-1}))^2}{t_k - t_{k-1}} - \frac{1}{m} \frac{W_T^2}{T}. \end{aligned}$$

Wir berechnen den Erwartungswert dieser Schätzer und untersuchen ihre Streuung. Aus der Definition des Prozesses  $(W(t), t \geq 0)$  folgt sofort:

$$\begin{aligned}\mathbb{E}_{\vartheta}(\hat{\mu}_{\mathcal{F}}) &= \mu, & D_{\vartheta}^2 \hat{\mu}_{\mathcal{F}} &= \frac{\sigma^2 T}{T^2} = \frac{\sigma^2}{T}, & (\hat{\mu}_{\mathcal{F}} \text{ ist erwartungstreu}) \\ \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}}^2) &= \left(1 - \frac{1}{m}\right) \sigma^2 + \frac{\mu^2 T}{m}.\end{aligned}$$

$\hat{\sigma}_{\mathcal{F}}^2$  ist ein verfälschter (biased) Schätzer für  $\sigma^2$  mit dem Bias

$$\mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}}^2) - \sigma^2 =: b(\vartheta, T, \mathcal{F}) = \frac{\mu^2 T - \sigma^2}{m}.$$

Es gilt

$$D_{\vartheta}^2 \hat{\sigma}_{\mathcal{F}}^2 \leq 2D_{\vartheta}^2 \left( \frac{1}{m} \sum_{k=1}^m \frac{(W(t_k) - W(t_{k-1}))^2}{t_k - t_{k-1}} \right) + 2D_{\vartheta}^2 \left( \frac{1}{m} \frac{W(T)^2}{T} \right). \quad (4.14)$$

(Zum Beweis beachte man  $(a + b)^2 \leq 2(a^2 + b^2)$ ,  $a, b \in \mathbb{R}$ .)

UNTERSUCHUNG DES ASYMPTOTISCHEN VERHALTENS DES SCHÄTZERS  $\hat{\sigma}_{\mathcal{F}}^2$  FÜR  $m \rightarrow \infty$ ,  $T = \text{const}$ .

Es seien für jedes  $n \geq 1$

$$\mathcal{F}_n := \{0 = t_0^{(n)} < t_1^{(n)} < \dots < t_{m_n}^{(n)} = T\} \quad \text{und}$$

$\hat{\mu}_{\mathcal{F}_n}$ ,  $\hat{\sigma}_{\mathcal{F}_n}^2$  die eben konstruierten ML-Schätzer für  $(\mu, \sigma^2)$ .

Voraussetzung: Die Anzahl der Beobachtungszeitpunkte nimmt unbegrenzt zu:

$$\lim_{n \rightarrow \infty} m_n = \infty.$$

**Bemerkung:** Erwartungswert und Streuung von  $\hat{\mu}_{\mathcal{F}_n}$  bleiben konstant bei wachsendem  $n$  und hängen nicht von der expliziten Form von  $\mathcal{F}_n$  ab. Der Schätzer  $\hat{\mu}_{\mathcal{F}_n}$  hängt nur vom letzten Beobachtungswert  $W(T)$  ab, seine Streuung läßt sich durch häufigere Beobachtung innerhalb des Zeitraumes  $[0, T]$  nicht verkleinern.

Für  $\mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2)$  gilt offenbar  $\lim_{n \rightarrow \infty} \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2) = \sigma^2$ , d.h.,  $\hat{\sigma}_{\mathcal{F}_n}^2$  ist asymptotisch erwartungstreu.

**Aussage 4.10.** *Es gilt für jedes  $\vartheta = (\mu, \sigma^2)^T \in \Theta$*

$$\begin{aligned} \lim_{n \rightarrow \infty} D_{\vartheta}^2 \hat{\sigma}_{\mathcal{F}_n}^2 &= 0 \quad \text{und insbesondere} \\ \mathbb{P}_{\vartheta}(|\hat{\sigma}_{\mathcal{F}_n}^2 - \sigma^2| > \epsilon) &\xrightarrow{n \rightarrow \infty} 0 \quad \text{für jedes } \epsilon > 0. \end{aligned}$$

Falls  $\sum_{n=1}^{\infty} \frac{1}{m_n} < \infty$ , so haben wir sogar

$$\lim_{n \rightarrow \infty} \hat{\sigma}_{\mathcal{F}_n}^2(\omega) = \sigma^2, \quad \mathbb{P}_{\vartheta} \text{ -f.s. für jedes } \vartheta \in \Theta.$$

*Beweis:*

Aus (4.14) erhalten wir

$$D_{\vartheta}^2 \hat{\sigma}_{\mathcal{F}_n}^2 \leq 2D_{\vartheta}^2 \left( \frac{1}{m_n} \sum_{k=1}^{m_n} \frac{\left( W(t_k^{(n)}) - W(t_{k-1}^{(n)}) \right)^2}{t_k^{(n)} - t_{k-1}^{(n)}} \right) + 2D_{\vartheta}^2 \left( \frac{1}{m_n} \frac{W(T)^2}{T} \right) \quad (4.15)$$

Wir untersuchen beide Summanden auf der rechten Seite. Offenbar ist

$$D_{\vartheta}^2 \left( \frac{1}{m_n} \frac{W(T)^2}{T} \right) = \frac{1}{m_n^2 T^2} D_{\vartheta}^2 (W(T)^2) \longrightarrow 0 \quad \text{für } m_n \rightarrow \infty$$

Wir setzen

$$Z_k^{(n)} := \frac{W(t_k^{(n)}) - W(t_{k-1}^{(n)})}{(t_k^{(n)} - t_{k-1}^{(n)})^{\frac{1}{2}}}.$$

Dann gilt nach Definition des Wiener'schen Prozesses  $Z_k^{(n)} \sim \mathcal{N} \left( \mu \left( t_k^{(n)} - t_{k-1}^{(n)} \right)^{\frac{1}{2}}, \sigma^2 \right)$  und die  $Z_1^{(n)}, Z_2^{(n)}, \dots, Z_{m_n}^{(n)}$  sind voneinander unabhängig. Folglich haben wir

$$\frac{1}{m_n^2} D_{\vartheta}^2 \left( \sum_{k=1}^{m_n} \frac{\left( W(t_k^{(n)}) - W(t_{k-1}^{(n)}) \right)^2}{t_k^{(n)} - t_{k-1}^{(n)}} \right) = \frac{1}{m_n^2} D_{\vartheta}^2 \left( \sum_{k=1}^{m_n} (Z_k^{(n)})^2 \right).$$

Wir zeigen, daß die rechte Seite dieser Gleichung für  $m_n \rightarrow \infty$  gegen Null konvergiert.

**Lemma 4.14.** *Ist  $X$  eine normalverteilte Zufallsvariable,  $X \sim \mathcal{N}(\mu, \sigma^2)$ , so gilt*

$$D^2 X^2 = \mathbb{E}(X^4) - (\mathbb{E}(X^2))^2 = 4\sigma^2 \mu^2 + 2\sigma^4.$$

*Beweis:*

Für jede  $\mathcal{N}(\mu, \sigma^2)$ -verteilte Zufallsgröße  $X$  haben wir

$$\mathbb{E} \left( \frac{(X - \mu)^4}{\sigma^4} \right) = 3 \text{ und } \mathbb{E} ((X - \mu)^3) = 0.$$

$$\text{Damit erhalten wir } \mathbb{E}(X^3) = \mu^3 + 3(\sigma^2 + \mu^2)\mu - 3\mu^3 = \mu^3 + 3\sigma^2\mu$$

$$\text{und } \mathbb{E}(X^4) = 4\mu \mathbb{E}(X^3) - 6\mu^2(\mu^2 + \sigma^2) + 4\mu^4 - \mu^4 + 3\sigma^4 = \mu^4 + 6\sigma^2\mu^2 + 3\sigma^4.$$

$$\text{Mit } (\mathbb{E}(X^2))^2 = (\mu^2 + \sigma^2)^2 = \mu^4 + \sigma^4 + 2\mu^2\sigma^2 \text{ gilt}$$

$$D^2 X^2 = \mathbb{E}(X^4) - (\mathbb{E}(X^2))^2 = 4\sigma^2\mu^2 + 2\sigma^4.$$

□

Wendet man Lemma 4.14 auf die Zufallsvariablen  $Z_k^{(n)}$  an, so erhält man mit

$$D_{\vartheta}^2 (Z_k^{(n)})^2 = 2\sigma^4 + 4\mu^2\sigma^2(t_k^{(n)} - t_{k-1}^{(n)}) = 2\sigma^2(\sigma^2 + 2\mu^2(t_k^{(n)} - t_{k-1}^{(n)}))$$

für den ersten Summanden in (4.15):

$$\begin{aligned} \frac{1}{m_n^2} D_{\vartheta}^2 \left( \sum_{k=1}^{m_n} \frac{(W(t_k^{(n)}) - W(t_{k-1}^{(n)}))^2}{t_k^{(n)} - t_{k-1}^{(n)}} \right) &= \frac{2\sigma^2}{m_n^2} \left( \sum_{k=1}^{m_n} \sigma^2 + 2\mu^2(t_k^{(n)} - t_{k-1}^{(n)}) \right) = \\ &= \frac{2\sigma^4}{m_n} + \frac{4\mu^2\sigma^2}{m_n^2} \leq \frac{K}{m_n} \end{aligned} \quad (4.16)$$

für eine Konstante  $K > 0$ .

Folglich gilt  $D_{\vartheta}^2 \hat{\sigma}_{\mathcal{F}_n}^2 \xrightarrow{n \rightarrow \infty} 0$ . Somit haben wir mittels (4.16)

$$\begin{aligned} \mathbb{P}_{\vartheta} (|\hat{\sigma}_{\mathcal{F}_n}^2 - \sigma^2| > \epsilon) &= \mathbb{P}_{\vartheta} (|\hat{\sigma}_{\mathcal{F}_n}^2 - \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2) + \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2) - \sigma^2| > \epsilon) \\ &\leq \mathbb{P}_{\vartheta} (|\hat{\sigma}_{\mathcal{F}_n}^2 - \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2)| + |\mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2) - \sigma^2| > \epsilon) \\ &\leq \mathbb{P}_{\vartheta} (|\hat{\sigma}_{\mathcal{F}_n}^2 - \mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2)| > \frac{\epsilon}{2}) \leq \frac{4K}{m_n \epsilon^2} \end{aligned}$$

falls  $n$  so groß ist, daß  $\frac{|\mathbb{E}_{\vartheta}(\hat{\sigma}_{\mathcal{F}_n}^2) - \sigma^2|}{m_n} = \frac{|\mu^2 T - \sigma^2|}{m_n} < \frac{\epsilon}{2}$  gilt.

Mit Hilfe der Tschebyschevchen Ungleichung ergibt sich die Behauptung. Ist nun  $\sum_{n \geq 1} \frac{1}{m_n} < \infty$ , so folgt für jedes  $\epsilon > 0$

$$\mathbb{P}_{\vartheta} (\limsup_{n \rightarrow \infty} A_n^{\epsilon}) = 0 \text{ mit } A_n^{\epsilon} = \{\omega : |\hat{\sigma}_{\mathcal{F}_n}^2(\omega) - \sigma^2| > \epsilon\}. \quad (\text{Borel-Cantelli-Lemma})$$

Das bedeutet  $\hat{\sigma}_{\mathcal{F}_n}^2 \rightarrow \sigma^2$   $\mathbb{P}_{\vartheta}$ -f.s. für jedes  $\vartheta \in \Theta$ . □

**Folgerungen:**

- a) Bei unbegrenztem Wachstum der Zahl  $m_n$  der Beobachtungspunkte läßt sich  $\sigma^2$  aus  $\mathbb{P}_\vartheta$ - fast jeder Trajektorie  $(W(t), t \in [0, T])$  beliebig genau bestimmen ( $\vartheta = (\mu, \sigma^2)^T$ ). Das gilt für jedes  $T > 0$  (!).
- b) Gilt  $\sigma^2 = \sigma_0^2$ , so ist

$$L^X(\mu; X) = \exp \left\{ \frac{\mu}{\sigma^2} W(T) - \frac{\mu^2}{\sigma^2} T \right\}$$

für jede Stichprobe  $X = (W(t_1), \dots, W(t_m))^T$  mit  $t_m = T$ .

Es gilt also

$$\mathbb{P}_\vartheta(A) = \int_A \exp \left\{ \frac{\mu}{\sigma^2} W(T) - \frac{\mu^2}{\sigma^2} T \right\} d\mathbb{P}_{\vartheta_0} \quad \text{mit } \vartheta = (\mu, \sigma^2)^T, \vartheta_0 = (0, \sigma^2)^T \quad (4.17)$$

für jedes Ereignis  $A$  der Form  $A = \{\omega : (W(t_1), \dots, W(t_m)) \in B\}$ ,  $B \in \mathcal{B}^m$ , mit  $t_m = T$ , d.h. (4.17) ist gültig für jede Zylindermenge  $Z = Z_{t_1, \dots, t_m; B}$  mit  $0 < t_1 < \dots < t_m = T$ , und somit für jedes  $A$  aus  $\mathcal{B}(\mathbb{C}([0, T]))$ .

Damit haben wir für die Familie

$$\mathcal{P}_{\sigma^2} := (\mathbb{P}_\vartheta, \vartheta = (\mu, \sigma^2)^T, \mu \in \mathbb{R})$$

bei fixiertem  $\sigma^2 > 0$  erhalten, daß alle  $\mathbb{P}_\vartheta^T := \mathbb{P}_\vartheta \big|_{\mathcal{B}(\mathbb{C}([0, T]))}$  zueinander äquivalent sind, und daß die Likelihoodfunktion

$$L(\vartheta; \mathcal{A}_T) = \frac{\mathbb{P}_\vartheta^T}{\mathbb{P}_{\vartheta_0}^T} \quad \text{für } \vartheta = (\mu, \sigma^2)^T, \vartheta_0 = (0, \sigma^2)^T$$

die Form

$$L(\vartheta; \mathcal{A}_T) = \exp \left\{ \frac{\mu}{\sigma^2} W(T) - \frac{\mu^2}{\sigma^2} T \right\}$$

besitzt. Hierbei haben wir die Notation

$$\mathbb{P}_\vartheta^T := \mathbb{P}_\vartheta \big|_{\mathcal{A}_T}, \quad \text{mit } \mathcal{A}_T := \sigma(W(s), s \in [0, T])$$

verwendet.