



Albert-Ludwigs-Universität Freiburg

Vorlesungsskript

Mathematische Statistik

apl. Prof. Dr. Stefan Tappe

Wintersemester 2018/19



Abteilung für Mathematische Stochastik

Inhaltsverzeichnis

1	Punktschätzer	3
1.1	Statistische Modelle	3
1.2	Konsistenz von Schätzern	8
1.3	Momentenschätzer	13
1.4	Maximum-Likelihood-Schätzer	14
1.5	Mittlerer quadratischer Fehler	20
1.6	Die Informationsungleichung	26
1.7	Exponentielle Familien	32
1.8	Suffiziente Statistiken	42
1.9	Vollständige Statistiken	50
1.10	Mehrdimensionale exponentielle Familien	53
1.11	Die mehrdimensionale Informationsungleichung	59
1.12	Bayes'sche Schätzer	65
2	Bereichsschätzer	71
2.1	Definitionen und Eigenschaften	71
2.2	Bereichsschätzer in Gaußmodellen	73
3	Hypothesentests	79
3.1	Definitionen und grundlegende Eigenschaften	79
3.2	Das Neymann-Pearson-Lemma	85
3.3	Erweiterung auf allgemeinere Bereiche	87
3.4	Exponentielle Familien	89
3.5	Dualität zwischen Konfidenzmengen und Hypothesentests	91
4	Nichtparametrische Modelle	94
4.1	Der Satz von Glivenko-Cantelli	94
4.2	Der Kolmogorov-Smirnov-Anpassungstest	100
4.3	Mehrdimensionale Normalverteilungen	107
4.4	Multinomialverteilungen	108
4.5	Der χ^2 -Anpassungstest	111

4.6	Der χ^2 -Test auf Unabhängigkeit	113
5	Lineare Modelle	115
5.1	Einfache lineare Regression	115
5.2	Lineare Modelle mit koordinatengebundener Darstellung	117
5.3	Lineare Modelle mit koordinatenfreier Darstellung	121
5.4	Punktschätzer	125
5.5	Bereichsschätzer	134
5.6	Hypothesentests	136
5.7	Varianzanalyse	143

Kapitel 1

Punktschätzer

1.1 Statistische Modelle

Definition 1.1.1. *Es sei Θ eine Menge.*

(a) *Ein statistisches Modell ist ein Tripel $\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$ bestehend aus:*

- *Einer Menge Ω ; dem Stichprobenraum.*
- *Einer σ -Algebra \mathcal{F} über Ω ; der Algebra der Beobachtungen.*
- *Einer Familie von Wahrscheinlichkeitsmaßen $(\mathbb{P}_\vartheta : \vartheta \in \Theta)$ auf (Ω, \mathcal{F}) .*

(b) Θ *heißt der Parameterraum.*

(c) *Ist $\Theta \subset \mathbb{R}^d$, so sprechen wir von einem parametrischen Modell.*

Definition 1.1.2. *Ist $\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$ ein statistisches Modell, so ist das n -fache Produktmodell gegeben durch*

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta)).$$

Zur Erinnerung: Die Normalverteilung mit Parametern $\mu \in \mathbb{R}$ und $\sigma^2 > 0$ ist die absolutstetige Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right).$$

Wir bezeichnen sie mit $N(\mu, \sigma^2)$.

Beispiel 1.1.3 (Gauß-Produktmodell). *Wir betrachten das Gauß-Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = \mathbb{R} \times (0, \infty)$ und

$$\begin{aligned}\Omega &= \mathbb{R}, \\ \mathcal{F} &= \mathcal{B}(\mathbb{R}), \\ \mathbb{P}_\vartheta &= N(\mu, \sigma^2), \quad \vartheta = (\mu, \sigma^2) \in \Theta.\end{aligned}$$

Wir nennen das n -fache Produktmodell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2 das n -fache Gauß-Produktmodell.

Definition 1.1.4. Es sei (E, \mathcal{E}) ein messbarer Raum.

- (a) Eine messbare Abbildung $S : (\Omega, \mathcal{F}) \rightarrow (E, \mathcal{E})$ heißt eine Statistik.
- (b) Eine Abbildung $\tau : \Theta \rightarrow E$ heißt eine Kenngröße.
- (c) Eine Statistik $T : \Omega \rightarrow E$ nennen wir auch einen Schätzer für τ . Häufig benutzen wir die Notation $T = \hat{\tau}$.
- (d) Ist E ein endlich-dimensionaler Vektorraum, so heißt ein Schätzer T erwartungstreu für τ , falls

$$\mathbb{E}_\vartheta[T] = \tau(\vartheta) \quad \text{für alle } \vartheta \in \Theta.$$

Bemerkung 1.1.5. Wir bezeichnen mit X die Identität $X : \Omega \rightarrow \Omega$ gegeben durch $X(\omega) = \omega$ für alle $\omega \in \Omega$. Es gilt $X \sim \mathbb{P}_\vartheta$ unter \mathbb{P}_ϑ für alle $\vartheta \in \Theta$.

Satz 1.1.6. Es seien $X_1, \dots, X_n : \Omega \rightarrow \mathbb{R}$ Zufallsvariablen auf einem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$. Dann sind folgende Aussagen äquivalent:

- (i) Die Zufallsvariablen X_1, \dots, X_n sind unabhängig.
- (ii) Es gilt $\mathbb{P} \circ (X_1, \dots, X_n) = \otimes_{i=1}^n (\mathbb{P} \circ X_i)$.

Beispiel 1.1.7. Es sei $\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$ ein statistisches Modell mit $\Omega \subset \mathbb{R}$. Wir definieren folgende Statistiken auf dem Produktmodell $\mathcal{M}^{\otimes n}$:

- (a) Der arithmetische Mittelwert ist

$$(\Omega^n, \mathcal{F}^{\otimes n}) \rightarrow \mathbb{R}, \quad x \mapsto \bar{x} := \frac{1}{n} \sum_{i=1}^n x_i.$$

(b) Die Stichprobenvarianz ist

$$\hat{\sigma}^2 : (\Omega^n, \mathcal{F}^{\otimes n}) \rightarrow \mathbb{R}, \quad \hat{\sigma}^2(x) := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

(c) Die korrigierte Stichprobenvarianz ist

$$s^2 : (\Omega^n, \mathcal{F}^{\otimes n}) \rightarrow \mathbb{R}, \quad s^2(x) := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2.$$

Lemma 1.1.8. *Es gilt*

$$\begin{aligned} \hat{\sigma}^2(x) &= \frac{1}{n} \sum_{i=1}^n (x_i^2 - \bar{x}^2), \\ s^2(x) &= \frac{1}{n-1} \sum_{i=1}^n (x_i^2 - \bar{x}^2). \end{aligned}$$

Beweis. Übung. □

Zur Erinnerung: Die Bernoulli-Verteilung mit Parameter $p \in [0, 1]$ ist die diskrete Verteilung auf $E = \{0, 1\}$ mit stochastischem Vektor $\pi : E \rightarrow [0, 1]$ gegeben durch

$$\begin{aligned} \pi(0) &= 1 - p, \\ \pi(1) &= p. \end{aligned}$$

Wir bezeichnen sie mit $\text{Ber}(p)$.

Beispiel 1.1.9 (Münzwurf). *Wir nennen das statistische Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, 1)$ und

$$\begin{aligned} \Omega &= \{0, 1\}, \\ \mathcal{F} &= \mathfrak{P}(\Omega), \\ \mathbb{P}_\vartheta &= \text{Ber}(\vartheta), \quad \vartheta \in \Theta \end{aligned}$$

das Bernoulli-Modell.

Zur Erinnerung: Die Binomialverteilung mit Parametern $p \in [0, 1]$ und $n \in \mathbb{N}$ ist die diskrete Verteilung auf $E = \{0, 1, \dots, n\}$ mit stochastischem Vektor $\pi : E \rightarrow [0, 1]$ gegeben durch

$$\pi(k) = \binom{n}{k} p^k (1-p)^{n-k}.$$

Wir bezeichnen sie mit $\text{Bi}(n, p)$. Offensichtlich gilt $\text{Bi}(1, p) = \text{Ber}(p)$.

Beispiel 1.1.10 (Anzahl der Erfolge beim mehrfachen Münzwurf). *Wir nennen das statistische Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, 1)$ und

$$\begin{aligned}\Omega &= \{0, 1, \dots, n\}, \\ \mathcal{F} &= \mathfrak{P}(\Omega), \\ \mathbb{P}_\vartheta &= \text{Bi}(n, \vartheta), \quad \vartheta \in \Theta\end{aligned}$$

das Binomialmodell. Die Statistik

$$T : \Omega \rightarrow \mathbb{R}, \quad T(x) = \frac{x}{n}$$

ist ein erwartungstreuer Schätzer für die Kenngröße

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \vartheta.$$

In der Tat, es sei $\vartheta \in \Theta$ beliebig. Dann gilt $X \sim \text{Bi}(n, \vartheta)$ unter \mathbb{P}_ϑ , und daher $\mathbb{E}_\vartheta[X] = n\vartheta$. Es folgt

$$\mathbb{E}_\vartheta[T] = \frac{1}{n} \mathbb{E}_\vartheta[X] = \vartheta = \tau(\vartheta).$$

Beispiel 1.1.11 (Mehrfacher Münzwurf). *Es sei \mathcal{M} das Bernoulli-Modell aus Beispiel 1.1.9. Wir betrachten das n -fache Produktmodell*

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2. Weiterhin seien

$$\begin{aligned}E &= \{0, 1, \dots, n\}, \\ \mathcal{E} &= \mathfrak{P}(E)\end{aligned}$$

und $S : \Omega^n \rightarrow E$ die Statistik

$$S(x) = \sum_{i=1}^n x_i.$$

Wir setzen $\mathbb{Q}_\vartheta := \mathbb{P}_\vartheta^{\otimes n} \circ S$ für jedes $\vartheta \in \Theta$. Dann ist das statistische Modell

$$\mathcal{N} = (E, \mathcal{E}, (\mathbb{Q}_\vartheta : \vartheta \in \Theta))$$

das Binomialmodell aus Beispiel 1.1.10.

Zur Erinnerung: Die Exponentialverteilung mit Parameter $\lambda \in (0, \infty)$ ist die absolutstetige Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \lambda e^{-\lambda x} \mathbb{1}_{\mathbb{R}_+}(x).$$

Wir bezeichnen sie mit $\text{Exp}(\lambda)$. Für $X \sim \text{Exp}(\lambda)$ gilt bekanntlich

$$\mathbb{P}(X \geq s + t \mid X \geq s) = \mathbb{P}(X \geq t) \quad \text{für alle } s, t \in \mathbb{R}_+.$$

Beispiel 1.1.12 (Glühbirnen). Wir betrachten das statistische Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, \infty)$ und

$$\begin{aligned} \Omega &= \mathbb{R}, \\ \mathcal{F} &= \mathcal{B}(\mathbb{R}), \\ \mathbb{P}_\vartheta &= \text{Exp}(\vartheta), \quad \vartheta \in \Theta, \end{aligned}$$

und das zugehörige Produktmodell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2. Wir betrachten die Kenngröße

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \frac{1}{\vartheta}$$

und die Statistik

$$S : \Omega \rightarrow \mathbb{R}_+, \quad S(x) = \bar{x}.$$

Dann ist S ein erwartungstreuer Schätzer für τ . In der Tat, es sei $\vartheta \in \Theta$ beliebig. Dann gilt $\mathbb{E}_\vartheta[X_1] = \frac{1}{\vartheta}$, und daher

$$\mathbb{E}_\vartheta[S] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}_\vartheta[X_i] = \frac{1}{\vartheta} = \tau(\vartheta).$$

Zur Erinnerung: Die Gleichverteilung mit Parametern $a, b \in \mathbb{R}$ mit $a < b$ ist die absolutstetige Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{1}{b-a} \mathbb{1}_{(a,b)}(x).$$

Wir bezeichnen sie mit $\text{UC}(a, b)$.

Beispiel 1.1.13. *Wir betrachten das statistische Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, \infty)$ und

$$\begin{aligned}\Omega &= \mathbb{R}, \\ \mathcal{F} &= \mathcal{B}(\mathbb{R}), \\ \mathbb{P}_\vartheta &= \text{UC}(0, \vartheta), \quad \vartheta \in \Theta,\end{aligned}$$

und das zugehörige Produktmodell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2. *Wir betrachten die Kenngröße*

$$\tau : (0, \infty) \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \vartheta,$$

und die zwei Schätzer

$$\begin{aligned}L : \Omega^n &\rightarrow \mathbb{R}, & L(x) &= 2\bar{x}, \\ M : \Omega^n &\rightarrow \mathbb{R}, & M(x) &= \max\{x_1, \dots, x_n\}.\end{aligned}$$

Dann ist L ein erwartungstreuer Schätzer für τ , wohingegen

$$\mathbb{E}_\vartheta[M] = \frac{n}{n+1}\vartheta \neq \vartheta \quad \text{für alle } \vartheta \in \Theta.$$

Allerdings gilt

$$\lim_{n \rightarrow \infty} \frac{n}{n+1}\vartheta = \vartheta \quad \text{für alle } \vartheta \in \Theta.$$

1.2 Konsistenz von Schätzern

Es seien $(\mathcal{M}_n)_{n \in \mathbb{N}}$ eine Folge von statistischen Modellen der Form

$$\mathcal{M}_n = (\Omega_n, \mathcal{F}_n, (\mathbb{P}_\vartheta^n : \vartheta \in \Theta)).$$

Definition 1.2.1. Es seien $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße, und $(T_n)_{n \in \mathbb{N}}$ eine Folge von Schätzern $T_n : \Omega_n \rightarrow \mathbb{R}$. Die Folge $(T_n)_{n \in \mathbb{N}}$ heißt (schwach) konsistent für τ , falls

$$\mathbb{P}_\vartheta^n(|T_n - \tau(\vartheta)| > \epsilon) \xrightarrow{n \rightarrow \infty} 0 \quad \text{für alle } \epsilon > 0 \text{ und alle } \vartheta \in \Theta.$$

Beispiel 1.2.2. Es sei $(M_n)_{n \in \mathbb{N}}$ die gemäß Beispiel 1.1.13 gegebene Folge von Schätzern für $\tau(\vartheta) = \vartheta$. Die Verteilungsfunktionen $F_{M_n} : \mathbb{R} \rightarrow [0, 1]$ sind gegeben durch

$$F_{M_n}(x) = \frac{x^n}{\vartheta^n} \mathbb{1}_{(0, \vartheta)} + \mathbb{1}_{[\vartheta, \infty)}.$$

Also gilt für jedes $\epsilon > 0$

$$\mathbb{P}_\vartheta^n(|M_n - \vartheta| > \epsilon) = \mathbb{P}_\vartheta^n(\vartheta - M_n > \epsilon) = \mathbb{P}_\vartheta^n(M_n < \vartheta - \epsilon) = \left(\frac{\vartheta - \epsilon}{\vartheta}\right)^n \rightarrow 0.$$

Folglich ist $(M_n)_{n \in \mathbb{N}}$ konsistent für τ .

Satz 1.2.3. Wir nehmen an, dass für alle $\vartheta \in \Theta$ gilt

$$\begin{aligned} \mathbb{E}_{\mathbb{P}_\vartheta^n}[T_n] &\rightarrow \tau(\vartheta) \quad \text{für } n \rightarrow \infty, \\ \text{Var}_{\mathbb{P}_\vartheta^n}[T_n] &\rightarrow 0 \quad \text{für } n \rightarrow \infty. \end{aligned}$$

Dann ist $(T_n)_{n \in \mathbb{N}}$ konsistent für τ .

Beweis. Wir setzen für alle $n \in \mathbb{N}$ und $\vartheta \in \Theta$

$$\tau_n(\vartheta) := \mathbb{E}_{\mathbb{P}_\vartheta^n}[T_n].$$

Es sei $\epsilon > 0$ beliebig. Mit der Chebyshev-Ungleichung gilt

$$\begin{aligned} \mathbb{P}_\vartheta^n(|T_n - \vartheta| > \epsilon) &\leq \mathbb{P}_\vartheta^n\left(|T_n - \tau_n(\vartheta)| > \frac{\epsilon}{2}\right) + \mathbb{P}_\vartheta^n\left(|\tau_n(\vartheta) - \tau(\vartheta)| > \frac{\epsilon}{2}\right) \\ &= \mathbb{P}_\vartheta^n\left(|T_n - \tau_n(\vartheta)| > \frac{\epsilon}{2}\right) + \mathbb{1}_{\{|\tau_n(\vartheta) - \tau(\vartheta)| > \frac{\epsilon}{2}\}} \\ &\leq \left(\frac{2}{\epsilon}\right)^2 \text{Var}_{\mathbb{P}_\vartheta^n}[T_n] + \mathbb{1}_{\{|\tau_n(\vartheta) - \tau(\vartheta)| > \frac{\epsilon}{2}\}} \rightarrow 0 \end{aligned}$$

für $n \rightarrow \infty$. □

Definition 1.2.4. Es seien $(X_n)_{n \in \mathbb{N}}$ und X reellwertige Zufallsvariablen auf einem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$.

(a) Wir sagen, dass $(X_n)_{n \in \mathbb{N}}$ fast sicher gegen X konvergiert (und schreiben $X_n \xrightarrow{f.s.} X$), falls

$$\mathbb{P}(X_n \rightarrow X) = 1.$$

(b) Wir sagen, dass $(X_n)_{n \in \mathbb{N}}$ stochastisch (oder in Wahrscheinlichkeit) gegen X konvergiert (und schreiben $X_n \xrightarrow{\mathbb{P}} X$), falls für jedes $\epsilon > 0$ gilt

$$\mathbb{P}(|X_n - X| > \epsilon) \rightarrow 0 \quad \text{für } n \rightarrow \infty.$$

Satz 1.2.5. Es seien $(X_n)_{n \in \mathbb{N}}$ und X reellwertige Zufallsvariablen auf einem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$.

(a) Falls $X_n \xrightarrow{f.s.} X$, dann gilt auch $X_n \xrightarrow{\mathbb{P}} X$.

(b) Falls $X_n \xrightarrow{\mathbb{P}} X$, dann existiert eine Teilfolge $(n_k)_{k \in \mathbb{N}}$, so dass $X_{n_k} \xrightarrow{f.s.} X$ für $k \rightarrow \infty$.

Satz 1.2.6 (Starkes Gesetz der großen Zahlen von Kolmogorov). Es sei $(X_n)_{n \in \mathbb{N}} \subset \mathcal{L}^1$ eine Folge unabhängiger, identisch verteilter Zufallsvariablen auf einem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$. Dann gilt

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{f.s.} \mu \quad \text{für } n \rightarrow \infty,$$

wobei $\mu := \mathbb{E}[X_1]$.

Definition 1.2.7. Es seien $(\mu_n)_{n \in \mathbb{N}}$ und μ Wahrscheinlichkeitsmaße auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$. Wir sagen, dass $(\mu_n)_{n \in \mathbb{N}}$ schwach gegen μ konvergiert (und schreiben $\mu_n \xrightarrow{w} \mu$), falls

$$\int_{\mathbb{R}} f d\mu_n \rightarrow \int_{\mathbb{R}} f d\mu$$

für jede stetige, beschränkte Funktion $f : \mathbb{R} \rightarrow \mathbb{R}$.

Satz 1.2.8. Es seien $(X_n)_{n \in \mathbb{N}}$ und X Zufallsvariablen, so dass $X_n \xrightarrow{\mathbb{P}} X$. Dann gilt $\mathbb{P} \circ X_n \xrightarrow{w} \mathbb{P} \circ X$.

Satz 1.2.9 (Zentraler Grenzwertsatz). Es sei $(X_n)_{n \in \mathbb{N}} \subset \mathcal{L}^2$ eine Folge unabhängiger, identisch verteilter Zufallsvariablen mit $\mu := \mathbb{E}[X_1]$ und $\sigma^2 := \text{Var}[X_1] > 0$. Wir setzen

$$S_n := \sum_{i=1}^n X_i \quad \text{und} \quad Y_n := \frac{S_n - n\mu}{\sqrt{n\sigma^2}} \quad \text{für } n \in \mathbb{N}.$$

Dann gilt $\mathbb{P} \circ Y_n \xrightarrow{w} \mathbb{N}(0, 1)$.

Nun betrachten wir etwas spezieller ein statistisches Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Omega \subset \mathbb{R}$. Es sei $\Omega^{\mathbb{N}}$ der Raum aller Folgen mit Werten in Ω , versehen mit der Produkt- σ -Algebra

$$\mathcal{F}^{\otimes \mathbb{N}} := \sigma(X_n : n \in \mathbb{N}).$$

Hierbei ist $X_n : \Omega^{\mathbb{N}} \rightarrow \Omega$ die n -te Koordinatenabbildung. Nach dem Erweiterungssatz von Kolmogorov existiert für jedes $\vartheta \in \Theta$ ein eindeutig bestimmtes Wahrscheinlichkeitsmaß \mathbb{P}_ϑ auf $(\Omega^{\mathbb{N}}, \mathcal{F}^{\otimes \mathbb{N}})$, so dass

$$\mathbb{P}_\vartheta^{\otimes n} = \mathbb{P}_\vartheta \circ (X_1, \dots, X_n) \quad \text{für jedes } n \in \mathbb{N}.$$

Wir nehmen an, dass die statistischen Modelle $(\mathcal{M}_n)_{n \in \mathbb{N}}$ gegeben sind durch die konstante Folge

$$\mathcal{M}_n = (\Omega^{\mathbb{N}}, \mathcal{F}^{\otimes \mathbb{N}}, (\mathbb{P}_\vartheta : \vartheta \in \Theta)).$$

Definition 1.2.10. Es seien $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße, und $(T_n)_{n \in \mathbb{N}}$ eine Folge von Schätzern $T_n : \Omega^{\mathbb{N}} \rightarrow \mathbb{R}$.

(a) Die Folge $(T_n)_{n \in \mathbb{N}}$ heißt (schwach) konsistent für τ , falls

$$T_n \xrightarrow{\mathbb{P}_\vartheta} \tau(\vartheta) \quad \text{für alle } \vartheta \in \Theta.$$

(b) Die Folge $(T_n)_{n \in \mathbb{N}}$ heißt stark konsistent für τ , falls

$$T_n \xrightarrow{\text{f.s.}} \tau(\vartheta) \text{ bezüglich } \mathbb{P}_\vartheta \quad \text{für alle } \vartheta \in \Theta.$$

(c) Die Folge $(T_n)_{n \in \mathbb{N}}$ heißt asymptotisch normalverteilt, falls für jedes $\vartheta \in \Theta$ Folgen $(\mu_n(\vartheta))_{n \in \mathbb{N}} \subset \mathbb{R}$ und $(\sigma_n^2(\vartheta))_{n \in \mathbb{N}} \subset (0, \infty)$ existieren, so dass für

$$Y_n(\vartheta) := \frac{T_n - \mu_n(\vartheta)}{\sigma_n(\vartheta)}$$

gilt $\mathbb{P}_\vartheta \circ Y_n(\vartheta) \xrightarrow{w} N(0, 1)$ für alle $\vartheta \in \Theta$.

Bemerkung 1.2.11. Ist eine Folge $(T_n)_{n \in \mathbb{N}}$ von Schätzern asymptotisch normalverteilt, dann gilt für alle $\vartheta \in \Theta$

$$\mathbb{P}_\vartheta \circ T_n \approx N(\mu_n(\vartheta), \sigma_n^2(\vartheta)) \quad \text{für große } n \in \mathbb{N}.$$

Beispiel 1.2.12. Nun betrachten wir das Bernoulli-Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, 1)$ und

$$\begin{aligned}\Omega &= \{0, 1\}, \\ \mathcal{F} &= \mathfrak{P}(\Omega), \\ \mathbb{P}_\vartheta &= \text{Ber}(\vartheta), \quad \vartheta \in \Theta\end{aligned}$$

aus Beispiel 1.1.9. Wir definieren die Kenngröße

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \vartheta$$

und die Folge $(T_n)_{n \in \mathbb{N}}$ von Schätzern

$$T_n : \Omega^{\mathbb{N}} \rightarrow \mathbb{R}, \quad T_n = \frac{1}{n} \sum_{i=1}^n X_i.$$

- (a) Für jedes $n \in \mathbb{N}$ ist T_n ein erwartungstreuer Schätzer für τ .
- (b) Die Folge $(T_n)_{n \in \mathbb{N}}$ ist stark konsistent für τ .
- (c) Die Folge $(T_n)_{n \in \mathbb{N}}$ ist asymptotisch normalverteilt

Beweis. Es sei $\vartheta \in \Theta$ beliebig.

- (a) Für jedes $n \in \mathbb{N}$ gilt

$$\mathbb{E}_\vartheta[T_n] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}_\vartheta[X_i] = \vartheta = \tau(\vartheta).$$

- (b) Nach dem starken Gesetz der großen Zahlen (Satz 1.2.6) gilt

$$T_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{f.s.} \vartheta = \tau(\vartheta) \quad \text{bezüglich } \mathbb{P}_\vartheta.$$

- (c) Wir wählen

$$\mu_n(\vartheta) := \vartheta \quad \text{und} \quad \sigma_n^2(\vartheta) := \frac{\vartheta(1-\vartheta)}{n}.$$

Weiterhin setzen wir $S_n := \sum_{i=1}^n X_i$. Dann gilt

$$Y_n(\vartheta) := \frac{T_n - \mu_n(\vartheta)}{\sigma_n(\vartheta)} = \frac{\frac{S_n}{n} - \vartheta}{\sqrt{\frac{\vartheta(1-\vartheta)}{n}}} = \frac{S_n - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}},$$

und nach dem zentralen Grenzwertsatz (Satz 1.2.9) folgt $\mathbb{P}_\vartheta \circ Y_n(\vartheta) \xrightarrow{w} N(0, 1)$ für alle $\vartheta \in \Theta$.

□

1.3 Momentenschätzer

Wir betrachten ein statistisches Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Omega \subset \mathbb{R}$, und das zugehörige Produktmodell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2. Es sei $d \in \mathbb{N}$, so dass $X_1 \in \mathcal{L}^d$.

Definition 1.3.1. *Es sei $k \in \{1, \dots, d\}$ beliebig.*

(a) *Wir definieren das k -te Moment*

$$m_k : \Theta \rightarrow \mathbb{R}, \quad m_k(\vartheta) := \mathbb{E}_\vartheta[X_1^k].$$

(b) *Wir definieren das k -te Stichprobenmoment*

$$\hat{m}_k : \Omega^n \rightarrow \mathbb{R}, \quad \hat{m}_k(x) := \frac{1}{n} \sum_{i=1}^n x_i^k.$$

Lemma 1.3.2.

(a) *Es gilt $\bar{x} = \hat{m}_1(x)$.*

(b) *Es gilt $\hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2$.*

Beweis. Übung. □

Definition 1.3.3. *Es sei $\tau : \Theta \rightarrow \mathbb{R}^e$ eine Kenngröße der Form*

$$\tau = f \circ (m_1, \dots, m_d)$$

mit einer stetigen Funktion $f : D \rightarrow \mathbb{R}^e$, wobei $D \subset \mathbb{R}^d$. Wir nehmen hierbei an, dass

$$\begin{aligned} (m_1(\vartheta), \dots, m_d(\vartheta)) &\in D \quad \text{für alle } \vartheta \in \Theta \quad \text{und} \\ (\hat{m}_1(x), \dots, \hat{m}_d(x)) &\in D \quad \text{für alle } x \in \Omega^n. \end{aligned}$$

Dann nennen wir $T : \Omega^n \rightarrow \mathbb{R}^e$ gegeben durch

$$T := f \circ (\hat{m}_1, \dots, \hat{m}_d).$$

einen Momentenschätzer für τ .

Satz 1.3.4. *Momentenschätzer sind stark konsistent.*

Beweis. Es sei $\vartheta \in \Theta$ beliebig. Nach dem starken Gesetz der großen Zahlen (Satz 1.2.6) gilt für $n \rightarrow \infty$

$$\frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{\text{f.s.}} m_k(\vartheta) \quad \text{bezüglich } \mathbb{P}_\vartheta$$

für alle $k = 1, \dots, d$. Wegen der Stetigkeit von f folgt für $n \rightarrow \infty$

$$f\left(\left(\frac{1}{n} \sum_{i=1}^n X_i^k\right)_{k=1, \dots, d}\right) \xrightarrow{\text{f.s.}} \tau(\vartheta) \quad \text{bezüglich } \mathbb{P}_\vartheta.$$

□

Beispiel 1.3.5. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

das Gauß-Modell aus Beispiel 1.1.3, wobei $\Theta = \mathbb{R} \times (0, \infty)$. Wir betrachten das zugehörige n -fache Gauß-Produktmodell, und die Kenngröße

$$\tau : \Theta \rightarrow \mathbb{R}^2, \quad \tau(\mu, \sigma^2) = (\mu, \sigma^2).$$

Dann gilt $\tau = f \circ (m_1, m_2)$ mit

$$f : D \rightarrow \mathbb{R}^2, \quad f(x, y) = (x, y - x^2),$$

wobei $D \subset \mathbb{R}^2$ gegeben ist durch $D = \Theta$. Also ist der Momentenschätzer gegeben durch

$$T = (\hat{m}_1, \hat{m}_2 - \hat{m}_1^2) = (\bar{X}, \hat{\sigma}^2(X)).$$

1.4 Maximum-Likelihood-Schätzer

Definition 1.4.1. *Ein Maß μ auf einem messbaren Raum (Ω, \mathcal{F}) heißt σ -endlich, falls eine aufsteigende Folge $(B_n)_{n \in \mathbb{N}} \subset \mathcal{F}$ existiert, so dass $B_n \uparrow \Omega$ und $\mu(B_n) < \infty$ für alle $n \in \mathbb{N}$.*

Beispiele 1.4.2.

- (a) Für jede abzählbare Menge E ist das Zählmaß ζ auf $(E, \mathfrak{P}(E))$ ein σ -endliches Maß.
- (b) Das Lebesguemaß λ auf $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ ist σ -endlich.

Definition 1.4.3. Es seien (Ω, \mathcal{F}) ein messbarer Raum, und μ, ν zwei Maße auf (Ω, \mathcal{F}) .

(a) Wir nennen ν absolutstetig bezüglich μ (symbolisch $\nu \ll \mu$), falls

$$\nu(A) = 0 \quad \text{für alle } A \in \mathcal{F} \text{ mit } \mu(A) = 0.$$

(b) Wir nennen ν und μ äquivalent (symbolisch $\nu \approx \mu$), falls $\nu \ll \mu$ und $\mu \ll \nu$; das heißt, für jedes $A \in \mathcal{F}$ gilt $\mu(A) = 0$ genau dann, wenn $\nu(A) = 0$.

Satz 1.4.4 (Satz von Radon-Nikodym). Es seien μ ein σ -endliches Maß und ν ein Maß auf einem messbaren Raum (Ω, \mathcal{F}) . Dann sind folgende Aussagen äquivalent:

(i) Es gilt $\nu \ll \mu$.

(ii) Es existiert eine nichtnegative, messbare Funktion $f : \Omega \rightarrow \mathbb{R}_+$, so dass

$$\nu(A) = \int_A f d\mu \quad \text{für alle } A \in \mathcal{F}.$$

In diesem Fall ist die Funktion f fast sicher (bezüglich μ) eindeutig bestimmt, und wir bezeichnen Sie mit

$$f = \frac{d\nu}{d\mu}.$$

Lemma 1.4.5. Es seien μ, ν, ρ σ -endliche Maße auf einem messbaren Raum (Ω, \mathcal{F}) .

(a) Falls $\rho \ll \nu \ll \mu$, dann gilt

$$\frac{d\rho}{d\mu} = \frac{d\rho}{d\nu} \cdot \frac{d\nu}{d\mu}.$$

(b) Falls $\nu \approx \mu$, dann gilt

$$\frac{d\mu}{d\nu} = \left(\frac{d\nu}{d\mu} \right)^{-1}.$$

Definition 1.4.6.

(a) Ein statistisches Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

heißt ein Standardmodell, falls ein dominierendes Maß μ auf (Ω, \mathcal{F}) existiert; das heißt, μ ist σ -endlich und es gilt $\mathbb{P}_\vartheta \ll \mu$ für alle $\vartheta \in \Theta$.

(b) Die Funktion

$$L : \Theta \times \Omega \rightarrow \mathbb{R}_+, \quad L(\vartheta, \cdot) = \frac{d\mathbb{P}_\vartheta}{d\mu}$$

heißt Likelihood-Funktion des Parameters ϑ für die Beobachtung x .

(c) Gilt sogar $\mathbb{P}_\vartheta \approx \mu$ für alle $\vartheta \in \Theta$, so nennen wir

$$\ell : \Theta \times \Omega \rightarrow \mathbb{R}, \quad \ell(\vartheta, x) = \ln L(\vartheta, x)$$

die Log-Likelihood-Funktion.

Bemerkung 1.4.7. Es sei $\tilde{\mu}$ ein σ -endliches Maß auf (Ω, \mathcal{F}) , so dass $\tilde{\mu} \approx \mu$. Dann ist $\tilde{\mu}$ ebenfalls ein dominierendes Maß, und für die Likelihood-Funktion gilt

$$\tilde{L}(\vartheta, x) = L(\vartheta, x) \cdot h(x),$$

wobei

$$h = \frac{d\mu}{d\tilde{\mu}}.$$

Beispiele 1.4.8.

(a) Beim Binomialmodell aus Beispiel 1.1.10 erhalten wir bezüglich $\mu = \zeta$ die Likelihood-Funktion

$$L : (0, 1) \times \{0, 1, \dots, n\} \rightarrow (0, \infty), \quad L(\vartheta, x) = \binom{n}{x} \vartheta^x (1 - \vartheta)^{n-x}.$$

Die Log-Likelihood-Funktion ist

$$\ell(\vartheta, x) = \ln \binom{n}{x} + x \ln \vartheta + (n - x) \ln(1 - \vartheta).$$

(b) Beim statistischen Modell \mathcal{M} aus Beispiel 1.1.13 (mit der Gleichverteilung) erhalten wir bezüglich $\mu = \lambda$ die Likelihood-Funktion

$$L : (0, \infty) \times \mathbb{R} \rightarrow \mathbb{R}_+, \quad L(\vartheta, x) = \frac{1}{\vartheta} \mathbb{1}_{(0, \vartheta)}(x).$$

Definition 1.4.9. Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein Standardmodell mit Likelihood-Funktion $L : \Theta \times \Omega \rightarrow \mathbb{R}_+$. Ein Schätzer $T : \Omega \rightarrow \Theta$ für den Parameter ϑ heißt ein Maximum-Likelihood-Schätzer, falls

$$L(T(x), x) = \max_{\vartheta \in \Theta} L(\vartheta, x) \quad \text{für alle } x \in \Omega.$$

Bemerkung 1.4.10. *Unter geeigneten Voraussetzungen läßt sich beweisen, dass Maximum-Likelihood-Schätzer stark konsistent sind.*

Definition 1.4.11.

(a) Die Likelihood-Gleichung ist gegeben durch

$$\nabla_{\vartheta} L(\vartheta, x) = 0.$$

(b) Sofern $\mathbb{P}_{\vartheta} \approx \mu$ für alle $\vartheta \in \Theta$, so ist die Log-Likelihood-Gleichung gegeben durch

$$\nabla_{\vartheta} \ell(\vartheta, x) = 0$$

Beispiel 1.4.12. *Beim Binomialmodell lautet die Log-Likelihood-Gleichung*

$$\frac{x}{\vartheta} - \frac{n-x}{1-\vartheta} = 0.$$

Der Maximum-Likelihood-Schätzer ist

$$T = \frac{X}{n}.$$

Dies ist der Schätzer aus Beispiel 1.1.10.

Lemma 1.4.13. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_{\vartheta} : \vartheta \in \Theta))$$

ein Standardmodell mit Likelihood-Funktion $L : \Theta \times \Omega \rightarrow \mathbb{R}_+$ bezüglich μ .

(a) Das statistische Modell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_{\vartheta}^{\otimes n} : \vartheta \in \Theta))$$

ist ebenfalls ein Standardmodell, und zwar mit Likelihood-Funktion

$$L^{\otimes n} : \Theta \times \Omega^n \rightarrow \mathbb{R}_+, \quad L^{\otimes n}(\vartheta, x) = \prod_{i=1}^n L(\vartheta, x_i).$$

bezüglich $\mu^{\otimes n}$.

(b) Gilt sogar $\mathbb{P}_{\vartheta} \approx \mu$ für alle $\vartheta \in \Theta$, dann gilt auch $\mathbb{P}_{\vartheta}^{\otimes n} \approx \mu^{\otimes n}$, und die Log-Likelihood-Funktion ist gegeben durch

$$\ell^{\otimes n} : \Theta \times \Omega^n \rightarrow \mathbb{R}_+, \quad \ell^{\otimes n}(\vartheta, x) = \sum_{i=1}^n \ell(\vartheta, x_i).$$

Beweis. Übung. □

Beispiel 1.4.14. *Beim Gauß-Modell aus Beispiel 1.1.3 erhalten wir bezüglich $\mu = \lambda$ die Likelihood-Funktion*

$$L : (\mathbb{R} \times (0, \infty)) \times \mathbb{R} \rightarrow (0, \infty), \quad L((\mu, \sigma^2), x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right).$$

Die Log-Likelihood-Funktion ist gegeben durch

$$\ell : (\mathbb{R} \times (0, \infty)) \times \mathbb{R} \rightarrow (0, \infty), \quad \ell((\mu, \sigma^2), x) = \ln\left(\frac{1}{\sqrt{2\pi\sigma^2}}\right) - \frac{(x - \mu)^2}{2\sigma^2}.$$

Also ist die Log-Likelihood-Funktion beim n -fachen Gauß-Produktmodell gegeben durch

$$\begin{aligned} \ell^{\otimes n} : (\mathbb{R} \times (0, \infty)) \times \mathbb{R}^n &\rightarrow (0, \infty), \\ \ell^{\otimes n}((\mu, \sigma^2), x) &= n \cdot \ln\left(\frac{1}{\sqrt{2\pi\sigma^2}}\right) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}, \end{aligned}$$

Die Log-Likelihood-Gleichung lautet

$$\left(\sum_{i=1}^n \frac{x_i - \mu}{\sigma^2}, \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^4} - \frac{n}{2\sigma^2} \right) = 0.$$

Also ist der Maximum-Likelihood-Schätzer

$$T = (\bar{X}, \hat{\sigma}^2(X)).$$

Lemma 1.4.15. *Es gelten folgende Aussagen:*

- (a) $\overline{x + \mu \mathbb{1}} = \bar{x} + \mu$ für alle $x \in \mathbb{R}^n$ und $\mu \in \mathbb{R}$.
- (b) $\hat{\sigma}^2(x + \mu \mathbb{1}) = \hat{\sigma}^2(x)$ für alle $x \in \mathbb{R}^n$ und $\mu \in \mathbb{R}$.

Beweis. Übung. □

Zur Erinnerung: Die Gammaverteilung mit Parametern $\alpha, \lambda \in (0, \infty)$ ist die absolutstetige Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} \mathbb{1}_{(0, \infty)}(x).$$

Wir bezeichnen sie mit $\Gamma(\alpha, \lambda)$. Es gilt $\Gamma(1, \lambda) = \text{Exp}(\lambda)$.

Für $n \in \mathbb{N}$ nennen wir $\chi_n^2 = \Gamma(\frac{n}{2}, \frac{1}{2})$ eine Chi-Quadrat-Verteilung mit n Freiheitsgraden.

Lemma 1.4.16. *Es seien $X_1, \dots, X_n \sim N(0, 1)$ unabhängige, standardnormalverteilte Zufallsvariablen und $S := X_1^2 + \dots + X_n^2$. Dann gilt $S \sim \chi_n^2$.*

Satz 1.4.17. *Für das n -fache Gauß-Produktmodell gelten folgende Aussagen:*

(a) *Es gilt*

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \quad \text{und} \quad \frac{n}{\sigma^2} \hat{\sigma}^2(X) = \frac{n-1}{\sigma^2} s^2(X) \sim \chi_{n-1}^2.$$

(b) *\bar{X} und $\hat{\sigma}^2(X)$ sind unabhängig.*

(c) *\bar{X} ist ein erwartungstreuer Schätzer für μ .*

(d) *Für alle $\vartheta = (\mu, \sigma^2) \in \Theta$ gilt*

$$\mathbb{E}_{\vartheta}[\hat{\sigma}^2(X)] = \frac{n-1}{n} \sigma^2.$$

(e) *$s^2(X)$ ist ein erwartungstreuer Schätzer für σ^2 .*

Beweis. Es ist leicht nachzuweisen, dass \bar{X} ist ein erwartungstreuer Schätzer für μ ist, und dass

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right).$$

Nach Lemma 1.4.15 dürfen wir nun annehmen, dass $\mu = 0$. Wir setzen

$$v_1 := \frac{1}{\sqrt{n}} \mathbb{1} \in \mathbb{R}^n,$$

und wählen $v_2, \dots, v_n \in \mathbb{R}^n$, so dass $\{v_1, \dots, v_n\}$ eine ONB von \mathbb{R}^n ist. Wir definieren die orthogonale Matrix

$$A := \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{n}} & \cdots & \frac{1}{\sqrt{n}} \\ & v_2 & \\ & \vdots & \\ & v_n & \end{pmatrix} \in \mathbb{R}^{n \times n}.$$

Dann gilt $Av_i = e_i$ für alle $i = 1, \dots, n$. Wir setzen $Y := AX$. Dann sind $Y_1, \dots, Y_n \sim N(0, \sigma^2)$ unabhängig. (Kleine Übung.) Wir setzen $Z_1 := Y_1 \in \mathbb{R}$ und $Z_2 := (Y_2, \dots, Y_n) \in \mathbb{R}^{n-1}$. Es gilt

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{1}{\sqrt{n}} X_i = \frac{1}{\sqrt{n}} Z_1.$$

Weiterhin gilt

$$\begin{aligned}\|X - \bar{X}\mathbb{1}\|^2 &= \|A(X - \bar{X}\mathbb{1})\|^2 = \|Y - \bar{X}A\mathbb{1}\|^2 = \|Y - Z_1Av_1\|^2 \\ &= \|Y - Z_1e_1\|^2 = \|Y - (Z_1, 0)\|^2 = \|(0, Z_2)\|^2\end{aligned}$$

Wegen

$$\hat{\sigma}^2(X) = \frac{1}{n}\|X - \bar{X}\mathbb{1}\|^2 = \frac{1}{n}\|(0, Z_2)\|^2$$

folgt die Unabhängigkeit von \bar{X} und $\hat{\sigma}^2(X)$. Außerdem gilt für jedes $\vartheta \in \Theta$

$$\mathbb{E}_\vartheta[\|(0, Z_2)\|^2] = \sum_{i=2}^n \mathbb{E}_\vartheta[Y_i^2] = (n-1)\sigma^2,$$

und nach Lemma 1.4.16 gilt

$$\frac{\|(0, Z_2)\|^2}{\sigma^2} \sim \chi_{n-1}^2.$$

□

1.5 Mittlerer quadratischer Fehler

Definition 1.5.1. *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein Schätzer für τ .

(a) *Wir nennen*

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

*den systematischen Fehler (englisch: *bias*) des Schätzers T .*

(b) *Wir nennen*

$$\text{Var}_\vartheta[T] := \mathbb{E}_\vartheta[(T - \mathbb{E}_\vartheta[T])^2], \quad \vartheta \in \Theta$$

die Varianz (bzw. Streuung) von T .

(c) Wir nennen

$$\mathbb{F}_\vartheta(T) := \mathbb{E}_\vartheta[(T - \tau(\vartheta))^2], \quad \vartheta \in \Theta$$

den mittleren quadratischen Fehler (oder kurz Fehler) von T .

Lemma 1.5.2. Für alle $\vartheta \in \Theta$ gilt die Zerlegung

$$\mathbb{F}_\vartheta(T) = \text{Var}_\vartheta[T] + \mathbb{B}_\vartheta(T)^2.$$

Beweis. Es gilt

$$\begin{aligned} \mathbb{F}_\vartheta(T) &= \mathbb{E}_\vartheta[(T - \tau(\vartheta))^2] \\ &= \mathbb{E}_\vartheta[(T - \mathbb{E}_\vartheta[T] + \mathbb{E}_\vartheta[T] - \tau(\vartheta))^2] \\ &= \mathbb{E}_\vartheta[(T - \mathbb{E}_\vartheta[T] + \mathbb{B}_\vartheta(T))^2] \\ &= \mathbb{E}_\vartheta[(T - \mathbb{E}_\vartheta[T])^2 + 2(T - \mathbb{E}_\vartheta[T])\mathbb{B}_\vartheta(T) + \mathbb{B}_\vartheta(T)^2] \\ &= \text{Var}_\vartheta[T] + 2\mathbb{B}_\vartheta(T) \underbrace{\mathbb{E}_\vartheta[T - \mathbb{E}_\vartheta[T]]}_{=0} + \mathbb{B}_\vartheta(T)^2 \\ &= \text{Var}_\vartheta[T] + \mathbb{B}_\vartheta(T)^2. \end{aligned}$$

□

Lemma 1.5.3. Die folgenden Aussagen sind äquivalent:

- (i) T ist erwartungstreu.
- (ii) $\mathbb{B}_\vartheta(T) = 0$ für alle $\vartheta \in \Theta$.
- (iii) $\mathbb{F}_\vartheta(T) = \text{Var}_\vartheta[T]$ für alle $\vartheta \in \Theta$.

Beweis. Folgt aus Lemma 1.5.2. □

Beispiel 1.5.4. Wir betrachten das Binomialmodell aus Beispiel 1.1.10, die Kenngröße $\tau : \Theta = (0, 1) \rightarrow \mathbb{R}$, $\tau(\vartheta) = \vartheta$ und die Schätzer

$$T = \frac{X}{n} \quad \text{und} \quad S = \frac{X + 1}{n + 2}.$$

Dann ist T erwartungstreu für τ . Weiter gilt

$$\mathbb{F}_\vartheta(T) = \text{Var}_\vartheta[T] = \frac{1}{n^2} \text{Var}_\vartheta[X] = \frac{1}{n^2} n\vartheta(1 - \vartheta) = \frac{\vartheta(1 - \vartheta)}{n}.$$

Also gilt auf alle Fälle

$$F_\vartheta \leq \frac{1}{4n} \quad \text{für alle } \vartheta \in \Theta.$$

Weiterhin gilt

$$\mathbb{B}_\vartheta(S) = \mathbb{E}_\vartheta \left[\frac{X+1}{n+2} \right] - \vartheta = \frac{1}{n+2} (\mathbb{E}_\vartheta[X] + 1) - \vartheta = \frac{n\vartheta + 1}{n+2} - \vartheta = \frac{1-2\vartheta}{n+2}.$$

Also ist S nicht erwartungstreu. Außerdem gilt

$$\begin{aligned} \text{Var}_\vartheta[S] &= \text{Var}_\vartheta \left[\frac{X+1}{n+2} \right] = \frac{1}{(n+2)^2} \text{Var}_\vartheta[X] \\ &= \frac{1}{(n+2)^2} \cdot n\vartheta(1-\vartheta). \end{aligned}$$

Also folgt

$$\mathbb{F}_\vartheta(S) = \text{Var}_\vartheta[T] + \mathbb{B}_\vartheta(T)^2 = \frac{n\vartheta(1-\vartheta)}{(n+2)^2} + \left(\frac{1-2\vartheta}{n+2} \right)^2.$$

Es gibt ein Intervall $I_n \subset \Theta = (0, 1)$, so dass

$$\mathbb{F}_\vartheta(S) \leq \mathbb{F}_\vartheta(T) \quad \text{für alle } \vartheta \in I_n.$$

Lemma 1.5.5. *Es seien $p \in (0, \infty)$ und $X \geq 0$ eine nichtnegative Zufallsvariable. Dann gilt*

$$\mathbb{E}[X^p] = \int_0^\infty p\lambda^{p-1} \mathbb{P}(X > \lambda) d\lambda.$$

Beweis. Mit Hilfe des Satzes von Fubini erhalten wir

$$\begin{aligned} \mathbb{E}[X^p] &= \mathbb{E} \left[\int_0^X p\lambda^{p-1} d\lambda \right] = \mathbb{E} \left[\int_0^\infty p\lambda^{p-1} \mathbb{1}_{\{X > \lambda\}} d\lambda \right] \\ &= \int_0^\infty p\lambda^{p-1} \mathbb{E}[\mathbb{1}_{\{X > \lambda\}}] d\lambda = \int_0^\infty p\lambda^{p-1} \mathbb{P}(X > \lambda) d\lambda. \end{aligned}$$

□

Beispiel 1.5.6. *Wie in Beispiel 1.1.13 betrachten wir das statistische Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = (0, \infty)$ und

$$\begin{aligned} \Omega &= \mathbb{R}, \\ \mathcal{F} &= \mathcal{B}(\mathbb{R}), \\ \mathbb{P}_\vartheta &= \text{UC}(0, \vartheta), \quad \vartheta \in \Theta, \end{aligned}$$

und das zugehörige Produktmodell

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

gemäß Definition 1.1.2. Wir betrachten die Kenngröße

$$\tau : (0, \infty) \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \vartheta.$$

Dann gilt $\tau = f \circ m_1$ mit

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = 2x.$$

Also ist der Momentenschätzer gegeben durch

$$L = 2\widehat{m}_1 = 2\bar{X}.$$

Die Likelihood-Funktion bezüglich $\mu = \lambda$ ist

$$L : \Theta \times \Omega \rightarrow \mathbb{R}_+, \quad L(\vartheta, x) = \frac{1}{\vartheta^n} \prod_{i=1}^n \mathbb{1}_{[0, \vartheta]}(x_i).$$

Also ist der Maximum-Likelihood-Schätzer gegeben durch

$$M = \max\{X_1, \dots, X_n\}.$$

Es gilt

$$\text{Var}_\vartheta[X_1] = \frac{\vartheta^2}{12}.$$

Da L erwartungstreu ist, folgt

$$\mathbb{F}_\vartheta(L) = \text{Var}_\vartheta[L] = \text{Var}_\vartheta\left[\frac{2}{n} \sum_{i=1}^n X_i\right] = \frac{4}{n^2} \cdot n \cdot \frac{\vartheta^2}{12} = \frac{\vartheta^2}{3n}.$$

Wir hatten bereits gezeigt, dass

$$\mathbb{E}_\vartheta[M] = \frac{n}{n+1} \vartheta.$$

Also folgt

$$\mathbb{B}_\vartheta(M) = \mathbb{E}_\vartheta[M] - \tau(\vartheta) = \frac{n}{n+1} \vartheta - \vartheta = \frac{n}{n+1} \vartheta - \frac{n+1}{n+1} \vartheta = -\frac{\vartheta}{n+1}.$$

Außerdem gilt

$$\mathbb{P}_\vartheta^{\otimes n}(M > \lambda) = \left[1 - \left(\frac{\lambda}{\vartheta}\right)^n\right] \mathbb{1}_{[0, \vartheta]}(\lambda), \quad \lambda \in \mathbb{R}_+.$$

Mit Lemma 1.5.5 folgt

$$\begin{aligned} \mathbb{E}_\vartheta[M^2] &= 2 \int_0^\infty \lambda \mathbb{P}_\vartheta^{\otimes n}(X > \lambda) d\lambda = 2 \int_0^\vartheta \lambda \left[1 - \left(\frac{\lambda}{\vartheta}\right)^n\right] d\lambda \\ &= 2 \int_0^\vartheta \lambda d\lambda - 2 \int_0^\vartheta \frac{\lambda^{n+1}}{\vartheta^n} d\lambda = \vartheta^2 - \frac{2}{\vartheta^n} \frac{\vartheta^{n+2}}{n+2} \\ &= \frac{n+2}{n+2} \vartheta^2 - \frac{2}{n+2} \vartheta^2 = \frac{n}{n+2} \vartheta^2. \end{aligned}$$

Es folgt

$$\begin{aligned} \mathbb{F}_\vartheta(M) &= \text{Var}_\vartheta[M] + B_\vartheta(M)^2 \\ &= \mathbb{E}_\vartheta[M^2] - \mathbb{E}_\vartheta[M]^2 + B_\vartheta(M)^2 \\ &= \left(\frac{n}{n+2} - \frac{n^2}{(n+1)^2} + \frac{1}{(n+1)^2}\right) \vartheta^2 = \frac{2\vartheta^2}{(n+2)(n+1)}. \end{aligned}$$

Also gilt $\mathbb{F}_\vartheta(L) \xrightarrow{n \rightarrow \infty} 0$ linear, und $\mathbb{F}_\vartheta(M) \xrightarrow{n \rightarrow \infty} 0$ quadratisch. Sogesehen ist der Schätzer M vorzuziehen.

Beispiel 1.5.7. Wir betrachten das n -fache Gauß-Produktmodell mit Parameterraum $\Theta = \mathbb{R} \times (0, \infty)$.

(a) \bar{X} ist ein erwartungstreuer Schätzer für die Kenngröße μ , und es gilt

$$\mathbb{F}_\vartheta(\bar{X}) = \frac{\sigma^2}{n},$$

wobei $\vartheta = (\mu, \sigma^2) \in \Theta$.

(b) Für die Kenngröße σ^2 gilt

$$\begin{aligned} \mathbb{B}_\vartheta(\hat{\sigma}^2(X)) &= -\frac{\sigma^2}{n}, \\ \text{Var}_\vartheta[\hat{\sigma}^2(X)] &= \frac{2(n-1)}{n^2} \sigma^4, \\ \mathbb{F}_\vartheta(\hat{\sigma}^2(X)) &= \frac{2n-1}{n^2} \sigma^4. \end{aligned}$$

(c) $s^2(X)$ ist ein erwartungstreuer Schätzer für die Kenngröße σ^2 , und gilt

$$\mathbb{F}_\vartheta(s^2(X)) = \frac{2}{n-1}\sigma^4.$$

Beweis.

(a) Nach Satz 1.4.17 gilt

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right).$$

(b) Nach Satz 1.4.17 gilt

$$\mathbb{B}_\vartheta(\hat{\sigma}^2(X)) = \mathbb{E}_\vartheta[\hat{\sigma}^2(X)] - \sigma^2 = \frac{n-1}{n}\sigma^2 - \sigma^2 = -\frac{\sigma^2}{n}.$$

Für $Y \sim \chi_n^2$ gilt bekanntlich

$$\mathbb{E}[Y] = n \quad \text{und} \quad \text{Var}[Y] = 2n.$$

Also folgt weiter

$$\text{Var}_\vartheta[\hat{\sigma}^2(X)] = \frac{\sigma^4}{n^2} \underbrace{\text{Var}_\vartheta\left[\frac{n}{\sigma^2}\hat{\sigma}^2(X)\right]}_{=2(n-1)} = \frac{2(n-1)}{n^2}\sigma^4,$$

und damit

$$\mathbb{F}_\vartheta(\hat{\sigma}^2(X)) = \text{Var}_\vartheta[\hat{\sigma}^2(X)] + (\mathbb{B}_\vartheta(\hat{\sigma}^2(X)))^2 = \frac{2(n-1)}{n^2}\sigma^4 + \frac{\sigma^4}{n^2} = \frac{2n-1}{n^2}\sigma^4.$$

(c) Nach Satz 1.4.17 gilt

$$\mathbb{F}_\vartheta(s^2(X)) = \text{Var}_\vartheta[s^2(X)] = \frac{\sigma^4}{(n-1)^2} \underbrace{\text{Var}_\vartheta\left[\frac{n-1}{\sigma^2}s^2(X)\right]}_{=2(n-1)} = \frac{2}{n-1}\sigma^4.$$

□

Definition 1.5.8. *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann heißt T varianzminimierend (bzw. ein gleichmäßig bester Schätzer oder UMV für “uniformly minimizing variance”), wenn

$$\text{Var}_\vartheta[T] \leq \text{Var}_\vartheta[S] \quad \Leftrightarrow \quad \mathbb{F}_\vartheta(T) \leq \mathbb{F}_\vartheta(S)$$

für alle $\vartheta \in \Theta$ und für jeden erwartungstreuen Schätzer $S : \Omega \rightarrow \mathbb{R}$ für τ .

1.6 Die Informationsungleichung

Definition 1.6.1. *Ein Standardmodell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

heißt regulär, falls gilt:

- (a) $\Theta \subset \mathbb{R}$ ist ein offenes Intervall.
- (b) $\mathbb{P}_\vartheta \approx \mu$ für alle $\vartheta \in \Theta$.
- (c) Für jeden Schätzer $S : \Omega \rightarrow \mathbb{R}$ und jedes $\vartheta \in \Theta$ mit $S \in \mathcal{L}^1(\mathbb{P}_\vartheta) < \infty$ gilt

$$\frac{\partial}{\partial \vartheta} \int_{\Omega} S(x) L(\vartheta, x) \mu(dx) = \int_{\Omega} S(x) \frac{\partial}{\partial \vartheta} L(\vartheta, x) \mu(dx).$$

Bemerkung 1.6.2. *Es gilt*

$$\int_{\Omega} S(x) L(\vartheta, x) \mu(dx) = \mathbb{E}_\vartheta[S].$$

Definition 1.6.3. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein reguläres statistisches Modell.

- (a) Wir nennen

$$u : \Theta \times \Omega \rightarrow \mathbb{R}, \quad u(\vartheta, x) = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x) = \frac{\frac{\partial}{\partial \vartheta} L(\vartheta, x)}{L(\vartheta, x)}$$

die Einflussfunktion (oder Score-Funktion).

- (b) Wir nennen

$$I : \Theta \rightarrow \mathbb{R}_+, \quad I(\vartheta) = \mathbb{E}_\vartheta[u(\vartheta, X)^2]$$

die Fischer-Information.

Die Einflussfunktion gibt also Auskunft über den Einfluss von Veränderungen des Parameters. Die Fischer-Information ist der gemittelte quadratische Einfluss; siehe auch Lemma 1.6.5 weiter unten.

Bemerkung 1.6.4. Sowohl die Einflussfunktion als auch die Fischer-Information sind unabhängig von der Wahl des dominierenden Maßes. In der Tat, sei $\tilde{\mu}$ ein σ -endliches Maß auf (Ω, \mathcal{F}) , so dass $\tilde{\mu} \approx \mu$. Dann ist $\tilde{\mu}$ ebenfalls ein dominierendes Maß, und für die Likelihood-Funktion gilt

$$\tilde{L}(\vartheta, x) = L(\vartheta, x) \cdot h(x),$$

wobei

$$h = \frac{d\mu}{d\tilde{\mu}}.$$

Also gilt

$$\frac{\partial}{\partial \vartheta} \tilde{\ell}(\vartheta, x) = \frac{\frac{\partial}{\partial \vartheta} \tilde{L}(\vartheta, x)}{\tilde{L}(\vartheta, x)} = \frac{\frac{\partial}{\partial \vartheta} L(\vartheta, x)}{L(\vartheta, x)} = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x).$$

Lemma 1.6.5.

(a) Es gilt

$$\mathbb{E}_{\vartheta}[u(\vartheta, X)] = 0 \quad \text{für alle } \vartheta \in \Theta.$$

(b) Es gilt

$$I(\vartheta) = \text{Var}_{\vartheta}[u(\vartheta, X)] \quad \text{für alle } \vartheta \in \Theta.$$

Beweis.

(a) Es gilt

$$\begin{aligned} \mathbb{E}_{\vartheta}[u(\vartheta, X)] &= \int_{\Omega} u(\vartheta, x) L(\vartheta, x) \mu(dx) \\ &= \int_{\Omega} \frac{\partial}{\partial \vartheta} L(\vartheta, x) \mu(dx) = \frac{\partial}{\partial \vartheta} \underbrace{\int_{\Omega} L(\vartheta, x) \mu(dx)}_{=1} = 0. \end{aligned}$$

(b) Folgt aus Teil (a).

□

Wie wir gesehen haben, gilt $I(\vartheta) \geq 0$ für alle $\vartheta \in \Theta$.

Satz 1.6.6 (Informationsungleichung von Cramer-Rao). *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein reguläres statistisches Modell mit $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$. Weiterhin seien $\tau \in C^1(\Theta; \mathbb{R})$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann gilt

$$\text{Var}_\vartheta[T] \geq \frac{|\tau'(\vartheta)|^2}{I(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

Beweis. Es sei $\vartheta \in \Theta$ beliebig. Dann gilt

$$\begin{aligned} \tau'(\vartheta) &= \frac{\partial}{\partial \vartheta} \tau(\vartheta) = \frac{\partial}{\partial \vartheta} \mathbb{E}_\vartheta[T] = \frac{\partial}{\partial \vartheta} \int_{\Omega} T(x) L(\vartheta, x) \mu(dx) \\ &= \int_{\Omega} T(x) \frac{\partial}{\partial \vartheta} L(\vartheta, x) \mu(dx) = \int_{\Omega} T(x) u(\vartheta, x) L(\vartheta, x) \mu(dx) \\ &= \mathbb{E}_\vartheta[T u(\vartheta, \cdot)] = \text{Cov}_\vartheta(T, u(\vartheta, \cdot)). \end{aligned}$$

Nach der Ungleichung von Cauchy-Schwarz gilt

$$\text{Cov}_\vartheta(T, u(\vartheta, \cdot)) \leq \sqrt{\text{Var}_\vartheta[T]} \cdot \sqrt{\text{Var}_\vartheta[u(\vartheta, \cdot)]} = \sqrt{\text{Var}_\vartheta[T]} \cdot \sqrt{I(\vartheta)}.$$

Also gilt

$$|\tau'(\vartheta)|^2 \leq \text{Var}_\vartheta[T] \cdot I(\vartheta).$$

□

Definition 1.6.7. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein reguläres statistisches Modell mit $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$. Weiterhin seien $\tau \in C^1(\Theta; \mathbb{R})$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann heißt T Cramer-Rao-optimal, falls

$$\text{Var}_\vartheta[T] = \frac{|\tau'(\vartheta)|^2}{I(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

Bemerkung 1.6.8. *Ein Cramer-Rao-optimaler Schätzer ist ein gleichmäßig bester Schätzer.*

Wie der Beweis von Satz 1.6.6 zeigt, gilt auch ohne die Annahme $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$ die Ungleichung

$$|\tau'(\vartheta)|^2 \leq \text{Var}_\vartheta[T] \cdot I(\vartheta) \quad \text{für alle } \vartheta \in \Theta.$$

Also gilt die Implikation (i) \Rightarrow (ii) folgender Aussagen:

- (i) $\tau'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$.
- (ii) $\text{Var}_\vartheta[T] > 0$ und $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$.

Die Äquivalenz (i) \Leftrightarrow (ii) gilt, sofern

$$|\tau'(\vartheta)|^2 = \text{Var}_\vartheta[T] \cdot I(\vartheta) \quad \text{für alle } \vartheta \in \Theta.$$

Dies ist insbesondere bei einem Cramer-Rao-optimalen Schätzer T der Fall.

Beispiel 1.6.9. Wir betrachten das Binomialmodell mit bekanntem $n \in \mathbb{N}$; vergleiche Beispiel 1.1.10. Dann gilt $\Theta = (0, 1)$ und

$$\mathbb{P}_\vartheta = \text{Bi}(n, \vartheta), \quad \vartheta \in \Theta.$$

Wir erhalten die Log-Likelihood-Funktion

$$\ell(\vartheta, x) = \ln \binom{n}{x} + x \ln \vartheta + (n - x) \ln(1 - \vartheta),$$

siehe Beispiel 1.4.8(a). Es folgt

$$u(\vartheta, x) = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x) = \frac{x}{\vartheta} - \frac{n - x}{1 - \vartheta} = \frac{x(1 - \vartheta) - (n - x)\vartheta}{\vartheta(1 - \vartheta)} = \frac{x - n\vartheta}{\vartheta(1 - \vartheta)}.$$

Weiter folgt

$$I(\vartheta) = \text{Var}_\vartheta[u(\vartheta, X)] = \text{Var}_\vartheta \left[\frac{X}{\vartheta(1 - \vartheta)} \right] = \frac{1}{(\vartheta(1 - \vartheta))^2} \cdot n\vartheta(1 - \vartheta) = \frac{n}{\vartheta(1 - \vartheta)}.$$

Nach Satz 1.6.6 gilt für jeden erwartungstreuen Schätzer T für die Kenngröße ϑ , dass

$$\text{Var}_\vartheta[T] \geq \frac{\vartheta(1 - \vartheta)}{n}.$$

Für den Schätzer $T = \frac{X}{n}$ gilt

$$\text{Var}_\vartheta[T] = \frac{1}{n^2} \cdot n\vartheta(1 - \vartheta) = \frac{\vartheta(1 - \vartheta)}{n}.$$

Also ist T Cramer-Rao-optimal, und damit ein gleichmäßig bester Schätzer.

Lemma 1.6.10. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein reguläres statistisches Modell mit Fischer-Information $I : \Theta \rightarrow \mathbb{R}_+$.

(a) *Das statistische Modell*

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

ist ebenfalls regulär.

(b) *Die Fischer-Information $I^{\otimes n} : \Theta \rightarrow \mathbb{R}_+$ ist gegeben durch*

$$I^{\otimes n}(\vartheta) = n \cdot I(\vartheta), \quad \vartheta \in \Theta.$$

Beweis.

(a) Übung.

(b) Es gilt

$$\begin{aligned} I^{\otimes n}(\vartheta) &= \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}}[u^{\otimes n}(\vartheta, X)] = \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}} \left[\frac{\partial}{\partial \vartheta} \ell^{\otimes n}(\vartheta, X) \right] = \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}} \left[\sum_{i=1}^n \frac{\partial}{\partial \vartheta} \ell(\vartheta, X_i) \right] \\ &= \sum_{i=1}^n \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}} \left[\frac{\partial}{\partial \vartheta} \ell(\vartheta, X_i) \right] = \sum_{i=1}^n \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}} [u(\vartheta, X_i)] = \sum_{i=1}^n \text{Var}_\vartheta [u(\vartheta, X)] = n \cdot I(\vartheta). \end{aligned}$$

Schauen wir uns die vorletzte Gleichung noch etwas genauer an. Nach dem Satz von Fubini gilt für jedes $i = 1, \dots, n$

$$\begin{aligned} \text{Var}_{\mathbb{P}_\vartheta^{\otimes n}} [u(\vartheta, X_i)] &= \mathbb{E}_{\mathbb{P}_\vartheta^{\otimes n}} [u(\vartheta, X_i)^2] = \int_{\Omega^n} u(\vartheta, x_i)^2 \mathbb{P}_\vartheta^{\otimes n}(dx) \\ &= \int_{\Omega} \cdots \int_{\Omega} u(\vartheta, x_i)^2 \mathbb{P}_\vartheta(dx_1) \cdots \mathbb{P}_\vartheta(dx_n) = \int_{\Omega} u(\vartheta, x_i)^2 \mathbb{P}_\vartheta(dx_i) \\ &= \int_{\Omega} u(\vartheta, x)^2 \mathbb{P}_\vartheta(dx) = \mathbb{E}_\vartheta [u(\vartheta, X)^2] = \text{Var}_\vartheta [u(\vartheta, X)]. \end{aligned}$$

□

Beispiel 1.6.11. *Wir betrachten das Gaußmodell mit bekannter Varianz $\sigma^2 > 0$. Hierbei gilt $\Theta = \mathbb{R}$ und*

$$\mathbb{P}_\vartheta = N(\vartheta, \sigma^2), \quad \vartheta \in \Theta.$$

Wir erhalten die Log-Likelihood-Funktion

$$\ell(\vartheta, x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \vartheta)^2}{2\sigma^2}.$$

Es folgt

$$u(\vartheta, x) = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x) = \frac{x - \vartheta}{\sigma^2}.$$

Weiter folgt

$$I(\vartheta) = \text{Var}_\vartheta[u(\vartheta, X)] = \text{Var}_\vartheta \left[\frac{X - \vartheta}{\sigma^2} \right] = \frac{1}{\sigma^4} \text{Var}_\vartheta[X] = \frac{\sigma^2}{\sigma^4} = \frac{1}{\sigma^2}.$$

Für das n -fache Produktmodell folgt

$$I^{\otimes n}(\vartheta) = \frac{n}{\sigma^2}.$$

Nach Satz 1.6.6 gilt für jeden erwartungstreuen Schätzer T für die Kenngröße ϑ , dass

$$\text{Var}_\vartheta[T] \geq \frac{\sigma^2}{n}.$$

Für das arithmetische Mittel \bar{X} gilt (vergleiche Beispiel 1.5.7)

$$\text{Var}_\vartheta[\bar{X}] = \frac{\sigma^2}{n}.$$

Also ist \bar{X} Cramer-Rao-optimal, und damit ein gleichmäßig bester Schätzer.

Beispiel 1.6.12. Wir betrachten das Poisson-Modell. Hierbei gilt $\Theta = (0, \infty)$ und

$$\mathbb{P}_\vartheta = \text{Pois}(\vartheta), \quad \vartheta \in \Theta.$$

Wir erhalten die Likelihood-Funktion

$$L(\vartheta, x) = e^{-\vartheta} \frac{\vartheta^x}{x!} = \frac{1}{x!} \exp(x \ln \vartheta - \vartheta),$$

und die Log-Likelihood-Funktion

$$\ell(\vartheta, x) = \ln \left(\frac{1}{x!} \right) + x \ln \vartheta - \vartheta.$$

Es folgt

$$u(\vartheta, x) = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x) = \frac{x}{\vartheta} - 1.$$

Weiter folgt

$$I(\vartheta) = \text{Var}_{\vartheta}[u(\vartheta, X)] = \text{Var}_{\vartheta}\left[\frac{X}{\vartheta} - 1\right] = \frac{1}{\vartheta^2} \text{Var}_{\vartheta}[X] = \frac{\vartheta}{\vartheta^2} = \frac{1}{\vartheta}.$$

Für das n -fache Produktmodell folgt

$$I^{\otimes n}(\vartheta) = \frac{n}{\vartheta}.$$

Nach Satz 1.6.6 gilt für jeden erwartungstreuen Schätzer T für die Kenngröße ϑ , dass

$$\text{Var}_{\vartheta}[T] \geq \frac{\vartheta}{n}.$$

Für das arithmetische Mittel \bar{X} gilt

$$\text{Var}_{\vartheta}[\bar{X}] = \text{Var}_{\vartheta}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n^2} \sum_{i=1}^n \underbrace{\text{Var}_{\vartheta}[X_i]}_{=\vartheta} = \frac{\vartheta}{n}.$$

Also ist \bar{X} Cramer-Rao-optimal, und damit ein gleichmäßig bester Schätzer.

1.7 Exponentielle Familien

Definition 1.7.1. Ein reguläres Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_{\vartheta} : \vartheta \in \Theta))$$

heißt eine exponentielle Familie, falls messbare Funktionen $a, b : \Theta \rightarrow \mathbb{R}$ mit $a \in C^1(\Theta; \mathbb{R})$, eine Statistik $T : \Omega \rightarrow \mathbb{R}$ und eine messbare Funktion $h : \Omega \rightarrow (0, \infty)$ existieren, so dass

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

In diesem Fall nennen wir T eine kanonische Statistik.

Bemerkung 1.7.2. Es sei $\tilde{\mu}$ ein σ -endliches Maß auf (Ω, \mathcal{F}) , so dass $\tilde{\mu} \approx \mu$. Dann ist $\tilde{\mu}$ ebenfalls ein dominierendes Maß, und für die Likelihood-Funktion gilt

$$\tilde{L}(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot \tilde{h}(x),$$

wobei

$$\tilde{h} = h \cdot \frac{d\mu}{d\tilde{\mu}}.$$

Bemerkung 1.7.3. *Ein reguläres Modell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ist genau dann eine exponentielle Familie, wenn messbare Funktionen $a, b : \Theta \rightarrow \mathbb{R}$ mit $a \in C^1(\Theta; \mathbb{R})$, eine Statistik $T : \Omega \rightarrow \mathbb{R}$ und eine messbare Funktion $k : \Omega \rightarrow \mathbb{R}$ existieren, so dass

$$\ell(\vartheta, x) = a(\vartheta)T(x) - b(\vartheta) + k(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

Lemma 1.7.4. *Die Funktion $b : \Theta \rightarrow \mathbb{R}$ ist gegeben durch*

$$b(\vartheta) = \ln \left(\int_{\Omega} \exp(a(\vartheta)T(x))h(x)\mu(dx) \right).$$

Beweis. Es sei $\vartheta \in \Theta$ beliebig. Dann gilt

$$\begin{aligned} \exp(-b(\vartheta)) \int_{\Omega} \exp(a(\vartheta)T(x))h(x)\mu(dx) &= \int_{\Omega} \exp(a(\vartheta)T(x) - b(\vartheta))h(x)\mu(dx) \\ &= \int_{\Omega} L(\vartheta, x)\mu(dx) = 1. \end{aligned}$$

Daraus folgt

$$\exp(b(\vartheta)) = \int_{\Omega} \exp(a(\vartheta)T(x))h(x)\mu(dx).$$

□

Lemma 1.7.5. *Für jedes $\vartheta \in \Theta$ und jedes $S \in \mathcal{L}^1(\mathbb{P}_\vartheta)$ gilt*

$$\exp(b(\vartheta))\mathbb{E}_\vartheta[S] = \int_{\Omega} S(x) \exp(a(\vartheta)T(x))h(x)\mu(dx).$$

Beweis. Es gilt

$$\begin{aligned} \mathbb{E}_\vartheta[S] &= \int_{\Omega} S(x)L(\vartheta, x)\mu(dx) = \int_{\Omega} S(x) \exp(a(\vartheta)T(x) - b(\vartheta))h(x)\mu(dx) \\ &= \exp(-b(\vartheta)) \int_{\Omega} S(x) \exp(a(\vartheta)T(x))h(x)\mu(dx). \end{aligned}$$

□

Bemerkung 1.7.6. *Es gelte $a'(\vartheta_0) \neq 0$ für ein $\vartheta_0 \in \Theta$. Dann existiert ein $\epsilon > 0$, so dass a auf $U = (\vartheta_0 - \epsilon, \vartheta_0 + \epsilon) \subset \Theta$ injektiv ist, und es gilt*

$$L(a^{-1}(\eta), x) = \exp(\eta T(x) - \bar{b}(\eta)) \cdot h(x) \quad \text{für alle } \eta \in a(U),$$

wobei $\bar{b} = b \circ a^{-1}$.

Satz 1.7.7. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

eine exponentielle Familie mit Likelihood-Funktion

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x), \quad (\vartheta, x) \in \Theta \times \Omega,$$

so dass $a'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$.

(a) *Es gilt $b \in C^1(\Theta; \mathbb{R})$ mit*

$$b'(\vartheta) = a'(\vartheta)\mathbb{E}_\vartheta[T].$$

(b) *Für die Kenngröße $\tau : \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) := \mathbb{E}_\vartheta[T]$ gilt $\tau \in C^1(\Theta; \mathbb{R})$ mit*

$$\tau'(\vartheta) = a'(\vartheta)\text{Var}_\vartheta[T].$$

(c) *Es gilt $I(\vartheta) = a'(\vartheta) \cdot \tau'(\vartheta)$.*

Beweis. Nach Bemerkung 1.7.6 dürfen wir annehmen, dass $a(\vartheta) = \vartheta$ für alle $\vartheta \in \Theta$. Etwa für Teil (a) werden wir in dem Fall zeigen, dass

$$b'(\vartheta) = \mathbb{E}_\vartheta[T].$$

Nach Bemerkung 1.7.6 gilt dann für eine allgemeine exponentielle Familie

$$\bar{b}'(\eta) = \mathbb{E}_{a^{-1}(\eta)}[T] \quad \text{für alle } \eta \in a(U).$$

Also gilt

$$(b \circ a^{-1})'(\eta) = \mathbb{E}_{a^{-1}(\eta)}[T] \quad \text{für alle } \eta \in a(U).$$

Nach der Kettenregel erhalten wir

$$(b \circ a^{-1})'(\eta) = b'(a^{-1}(\eta))(a^{-1})'(\eta) = \frac{b'(a^{-1}(\eta))}{a'(a^{-1}(\eta))} \quad \text{für alle } \eta \in a(U).$$

Daraus folgt

$$\frac{b'(\vartheta)}{a'(\vartheta)} = \mathbb{E}_\vartheta[T] \quad \text{für alle } \vartheta \in U.$$

Nun sei S eine Statistik mit $S \in \mathcal{L}^1(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$. Wir definieren

$$u_S : \Theta \rightarrow \mathbb{R}, \quad u_S(\vartheta) := \exp(b(\vartheta))\mathbb{E}_\vartheta[S].$$

Nach Lemma 1.7.5 gilt

$$u_S(\vartheta) = \int_{\Omega} S(x) \exp(\vartheta T(x)) h(x) \mu(dx).$$

Es gilt $u_S \in C^\infty(\Theta; \mathbb{R})$ mit

$$u_S^{(k)}(\vartheta) = \exp(b(\vartheta)) \mathbb{E}[ST^k] \quad \text{für alle } k \in \mathbb{N}_0.$$

In der Tat, etwa für $k = 1$ gilt

$$\begin{aligned} \frac{\partial}{\partial \vartheta} u_S(\vartheta) &= \frac{\partial}{\partial \vartheta} \int_{\Omega} S(x) \exp(\vartheta T(x)) h(x) \mu(dx) \\ &= \int_{\Omega} S(x) \frac{\partial}{\partial \vartheta} \exp(\vartheta T(x)) h(x) \mu(dx) \\ &= \int_{\Omega} S(x) T(x) \exp(\vartheta T(x)) h(x) \mu(dx) = \exp(b(\vartheta)) \mathbb{E}[ST]. \end{aligned}$$

(a) Wir setzen $S = 1$. Nach Lemma 1.7.4 gilt

$$b(\vartheta) = \ln(u_1(\vartheta)).$$

Es folgt $b \in C^1(\Theta; \mathbb{R})$ mit

$$b'(\vartheta) = \frac{u_1'(\vartheta)}{u_1(\vartheta)} = \mathbb{E}_\vartheta[T].$$

(b) Nach Teil (a) gilt für $\tau : \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) := \mathbb{E}_\vartheta[T]$, dass $\tau \in C^1(\Theta; \mathbb{R})$ mit

$$\begin{aligned} u_1'(\vartheta) &= u_1(\vartheta) \mathbb{E}_\vartheta[T], \\ u_1''(\vartheta) &= u_1(\vartheta) \mathbb{E}_\vartheta[T^2]. \end{aligned}$$

Also folgt

$$\tau'(\vartheta) = b''(\vartheta) = \frac{u_1''(\vartheta)}{u_1(\vartheta)} - \left(\frac{u_1'(\vartheta)}{u_1(\vartheta)} \right)^2 = \mathbb{E}_\vartheta[T^2] - \mathbb{E}_\vartheta[T]^2 = \text{Var}_\vartheta[T].$$

(c) Wegen $b'(\vartheta) = \mathbb{E}_\vartheta[T]$ gilt

$$\begin{aligned} \frac{\partial}{\partial \vartheta} \mathbb{E}_\vartheta[S] &= \frac{\partial}{\partial \vartheta} [u_S(\vartheta) \exp(-b(\vartheta))] = [u_S'(\vartheta) - u_S(\vartheta) b'(\vartheta)] \exp(-b(\vartheta)) \\ &= \mathbb{E}_\vartheta[ST] - \mathbb{E}_\vartheta[S] b'(\vartheta) = \mathbb{E}_\vartheta[S(T - b'(\vartheta))] = \text{Cov}_\vartheta(S, T). \end{aligned}$$

Mit $S = T$ folgt

$$\text{Var}_\vartheta[T] = \frac{\partial}{\partial \vartheta} \mathbb{E}_\vartheta[T] = \tau'(\vartheta).$$

Nach Bemerkung 1.7.3 gilt

$$\ell(\vartheta, x) = \vartheta T(x) - b(\vartheta) + k(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

Also folgt

$$u(\vartheta, x) = \frac{\partial}{\partial \vartheta} \ell(\vartheta, x) = T(x) - b'(\vartheta).$$

Nun erhalten wir

$$I(\vartheta) = \text{Var}_\vartheta[u(\vartheta, X)] = \text{Var}_\vartheta[T] = \tau'(\vartheta).$$

□

Wie Satz 1.7.7 zeigt, sind für eine exponentielle Familie mit $a'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$ und die Kenngröße $\tau(\vartheta) = \mathbb{E}_\vartheta[T]$ folgende Aussagen äquivalent:

- (i) $\tau'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$.
- (ii) $\text{Var}_\vartheta[T] > 0$ für alle $\vartheta \in \Theta$.
- (iii) $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$.

Wir sehen ferner, dass T in diesem Fall Cramer-Rao-optimal ist.

Satz 1.7.8 (Cauchy-Schwarzsche Ungleichung). *Ist H ein Hilbertraum, so gilt*

$$\langle x, y \rangle \leq \|x\| \cdot \|y\| \quad \text{für alle } x, y \in H.$$

Gleichheit gilt genau dann, wenn x und y linear abhängig sind.

Bemerkung 1.7.9. *Wir werden die Cauchy-Schwarzsche Ungleichung auf $H = L^2(\Omega, \mathcal{F}, \mathbb{P})$ anwenden. Hier haben wir das Skalarprodukt*

$$\langle X, Y \rangle = \mathbb{E}[XY].$$

Die Cauchy-Schwarzsche Ungleichung besagt dann

$$\mathbb{E}[XY] \leq \sqrt{\mathbb{E}[X^2]} \sqrt{\mathbb{E}[Y^2]}.$$

Insbesondere gilt

$$\text{Cov}(X, Y) \leq \sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]}.$$

Satz 1.7.10 (Cramer-Rao, scharfe Version). *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein reguläres statistisches Modell. Weiterhin seien $\tau \in C^1(\Theta; \mathbb{R})$ eine Kenngröße mit $\tau'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$, und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann sind folgende Aussagen äquivalent:

(i) T ist Cramer-Rao-optimal.

(ii) \mathcal{M} ist eine exponentielle Familie mit kanonischer Statistik T , es gilt $a'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$ und

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

Beweis. Wir der Beweis von Satz 1.6.6 zeigt, gilt wegen der Voraussetzung $\tau'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$ auch $\text{Var}_\vartheta[T] > 0$ und $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$. Die Gleichheit in Satz 1.6.6 gilt genau dann, wenn

$$\text{Cov}_\vartheta(T, u(\vartheta, \cdot)) = \sqrt{\text{Var}_\vartheta[T]} \cdot \sqrt{\text{Var}_\vartheta[u(\vartheta, \cdot)]} \quad \text{für alle } \vartheta \in \Theta.$$

Nach der Cauchy-Schwarzschen Ungleichung (Satz 1.7.8) bedeutet dies, dass die Zufallsvariablen $T - \tau(\vartheta)$ und $u(\vartheta, \cdot)$ im Hilbertraum $L^2(\mathbb{P}_\vartheta)$ linear abhängig sind. Wegen $I(\vartheta) > 0$ gilt $u(\vartheta, \cdot) \neq 0$ in $L^2(\mathbb{P}_\vartheta)$, und wegen $\text{Var}_\vartheta[T] > 0$ gilt $T - \tau(\vartheta) \neq 0$ in $L^2(\mathbb{P}_\vartheta)$. Also ist T genau dann Cramer-Rao-optimal, wenn eine messbare Funktion $c : \Theta \rightarrow \mathbb{R} \setminus \{0\}$ existiert, so dass

$$T - \tau(\vartheta) = c(\vartheta)u(\vartheta, \cdot) \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für alle } \vartheta \in \Theta.$$

Dies bedeutet gerade

$$\frac{T}{c(\vartheta)} - \frac{\tau(\vartheta)}{c(\vartheta)} = \frac{\partial}{\partial \vartheta} \ell(\vartheta, \cdot) \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für alle } \vartheta \in \Theta.$$

Für ein gewähltes $\vartheta_0 \in \Theta$ ist dies gleichbedeutend mit

$$T(x) \int_{\vartheta_0}^{\vartheta} \frac{1}{c(s)} ds - \int_{\vartheta_0}^{\vartheta} \frac{\tau(s)}{c(s)} ds = \ell(\vartheta, x) - \ell(\vartheta_0, x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei die Log-Likelihood-Funktion gegebenenfalls auf Nullmengen abgeändert wird. Die Gleichung oben bedeutet gerade, dass

$$L(\vartheta, x) = \exp \left(T(x) \int_{\vartheta_0}^{\vartheta} \frac{1}{c(s)} ds - \int_{\vartheta_0}^{\vartheta} \frac{\tau(s)}{c(s)} ds \right) \cdot L(\vartheta_0, x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

Dann ist die Likelihood-Funktion von der Form

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei

$$a(\vartheta) = \int_{\vartheta_0}^{\vartheta} \frac{1}{c(s)} ds, \quad b(\vartheta) = \int_{\vartheta_0}^{\vartheta} \frac{\tau(s)}{c(s)} ds \quad \text{und} \quad h(x) = L(\vartheta_0, x).$$

Insbesondere gilt $a'(\vartheta) = \frac{1}{c(\vartheta)} \neq 0$ und

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

Gilt umgekehrt

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

dann gilt

$$L(\vartheta, x) = \exp\left(T(x) \int_{\vartheta_0}^{\vartheta} \frac{1}{c(s)} ds - \int_{\vartheta_0}^{\vartheta} \frac{\tau(s)}{c(s)} ds\right) \cdot L(\vartheta_0, x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei

$$c(\vartheta) = \frac{1}{a'(\vartheta)} \quad \text{und} \quad \tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)}.$$

□

Falls $T \equiv t$ für ein $t \in \mathbb{R}$, so ist $\tau(\vartheta) = t$ ein Cramer-Rao-optimaler Schätzer. Satz 1.7.10 ist in dieser Situation jedoch nicht anwendbar, da $\tau'(\vartheta) = 0$ für alle $\vartheta \in \Theta$.

Korollar 1.7.11. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_{\vartheta} : \vartheta \in \Theta))$$

eine exponentielle Familie mit kanonischer Statistik T , so dass $a'(\vartheta) \neq 0$ und $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$.

(a) *T ist ein Cramer-Rao-optimaler (und damit gleichmäßig bester) Schätzer für die Kenngröße*

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)}.$$

(b) Es gilt

$$\text{Var}_{\vartheta}[T] = \frac{\tau'(\vartheta)}{a'(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

(c) Es gilt

$$I(\vartheta) = a'(\vartheta) \cdot \tau'(\vartheta) \quad \text{für alle } \vartheta \in \Theta.$$

Beweis. Nach Satz 1.7.7 gilt $\tau(\vartheta) = \mathbb{E}_{\vartheta}[T]$ für alle $\vartheta \in \Theta$, und es folgen die Teile (b) und (c). Wegen $I(\vartheta) > 0$ für alle $\vartheta \in \Theta$ gilt $\tau'(\vartheta) \neq 0$ für alle $\vartheta \in \Theta$. Also folgt Teil (a) mit Satz 1.7.10. \square

Beispiel 1.7.12. *Beim Binomialmodell gilt*

$$\begin{aligned} L(\vartheta, x) &= \binom{n}{x} \vartheta^x (1 - \vartheta)^{n-x} \\ &= \binom{n}{x} \exp(x \ln \vartheta + (n - x) \ln(1 - \vartheta)) \\ &= \binom{n}{x} \exp\left(x \ln\left(\frac{\vartheta}{1 - \vartheta}\right) + n \ln(1 - \vartheta)\right). \end{aligned}$$

Also gilt

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei

$$\begin{aligned} a(\vartheta) &= n \ln\left(\frac{\vartheta}{1 - \vartheta}\right), \\ T(x) &= \frac{x}{n}, \\ b(\vartheta) &= -n \ln(1 - \vartheta), \\ h(x) &= \binom{n}{x}. \end{aligned}$$

Weiterhin gilt

$$\begin{aligned} a'(\vartheta) &= n \left(\frac{1}{\vartheta} + \frac{1}{1 - \vartheta} \right) = \frac{n}{\vartheta(1 - \vartheta)}, \\ b'(\vartheta) &= \frac{n}{1 - \vartheta}. \end{aligned}$$

Also ist T nach Korollar 1.7.11 ein gleichmäßig bester Schätzer für die Kenngröße

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} = \vartheta.$$

Korollar 1.7.13. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

eine exponentielle Familie mit kanonischer Statistik T .

(a) *Dann ist*

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

eine exponentielle Familie mit kanonischer Statistik

$$T_n = \frac{1}{n} \sum_{i=1}^n T(X_i).$$

(b) T_n *ist ein Cramer-Rao-optimaler (und damit gleichmäßig bester) Schätzer für die Kenngröße*

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)}.$$

Beweis.

(a) Es gilt

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta))h(x).$$

Mit Lemma 1.4.13 folgt

$$\begin{aligned} L^{\otimes n}(\vartheta, x) &= \prod_{i=1}^n \exp(a(\vartheta)T(x_i) - b(\vartheta))h(x_i) \\ &= \exp\left(a(\vartheta) \sum_{i=1}^n T(x_i) - nb(\vartheta)\right) \prod_{i=1}^n h(x_i) \\ &= \exp(a_n(\vartheta)T_n(x) - b_n(\vartheta))h_n(x), \end{aligned}$$

wobei

$$a_n(\vartheta) = na(\vartheta), \quad b_n(\vartheta) = nb(\vartheta) \quad \text{und} \quad h_n(x) = \prod_{i=1}^n h(x_i).$$

(b) Folgt nun aus Korollar 1.7.11, da

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} = \frac{b'_n(\vartheta)}{a'_n(\vartheta)} \quad \text{für alle } \vartheta \in \Theta.$$

□

Beispiel 1.7.14. *Beim Poisson-Modell gilt*

$$L(\vartheta, x) = e^{-\vartheta} \frac{\vartheta^x}{x!} = \exp(x \ln \vartheta - \vartheta) \frac{1}{x!}.$$

Also gilt

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei

$$\begin{aligned} a(\vartheta) &= \ln \vartheta, \\ T(x) &= x, \\ b(\vartheta) &= \vartheta, \\ h(x) &= \frac{1}{x!}. \end{aligned}$$

Also ist im n -fachen Produktmodell nach Korollar 1.7.13 der Schätzer

$$T_n = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

ein gleichmäßig bester Schätzer für die Kenngröße

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} = \vartheta.$$

Beispiel 1.7.15. *Beim Gaußmodell*

$$\mathbb{P}_\vartheta = N(\vartheta, \sigma^2), \quad \vartheta \in \Theta = \mathbb{R}$$

mit bekannter Varianz $\sigma^2 > 0$ gilt

$$\begin{aligned} L(\vartheta, x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\vartheta)^2}{2\sigma^2}\right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2} + \frac{x\vartheta}{\sigma^2} - \frac{\vartheta^2}{2\sigma^2}\right) \end{aligned}$$

Also gilt

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

mit

$$\begin{aligned}a(\vartheta) &= \frac{\vartheta}{\sigma^2}, \\T(x) &= x, \\b(\vartheta) &= \frac{\vartheta^2}{2\sigma^2}, \\h(x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right).\end{aligned}$$

Also ist im n -fachen Produktmodell nach Korollar 1.7.13 der Schätzer

$$T_n = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

ein gleichmäßig bester Schätzer für die Kenngröße

$$\tau(\vartheta) = \frac{b'(\vartheta)}{a'(\vartheta)} = \vartheta.$$

1.8 Suffiziente Statistiken

Definition 1.8.1. *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, und $S : \Omega \rightarrow E$ eine Statistik mit Werten in einem messbaren Raum (E, \mathcal{E}) . Dann heißt S suffizient, falls für jede messbare, beschränkte Funktion $f : \Omega \rightarrow \mathbb{R}$ eine $\sigma(S)$ -messbare Zufallsvariable $g : \Omega \rightarrow \mathbb{R}$ existiert, so dass

$$\mathbb{E}_\vartheta[f | S] = g \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für jedes } \vartheta \in \Theta.$$

Satz 1.8.2 (Faktorisierungssatz). *Es seien $Y : \Omega \rightarrow E$ eine Zufallsvariable mit Werten in einem messbaren Raum (E, \mathcal{E}) , und $X : \Omega \rightarrow \mathbb{R}$ eine $\sigma(S)$ -messbare Zufallsvariable. Dann existiert eine messbare Funktion $h : E \rightarrow \mathbb{R}$, so dass $X = h(Y)$.*

Lemma 1.8.3. *Für eine Statistik $S : \Omega \rightarrow E$ sind folgende Aussagen äquivalent:*

- (i) S ist suffizient.
- (ii) Für jede messbare, beschränkte Funktion $f : \Omega \rightarrow \mathbb{R}$ existiert eine messbare Funktion $h : E \rightarrow \mathbb{R}$, so dass

$$\mathbb{E}_\vartheta[f | S] = h(S) \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für jedes } \vartheta \in \Theta.$$

Beweis. Folgt aus dem Faktorisierungssatz (Satz 1.8.2). \square

Beispiel 1.8.4. Die Statistik $S = X : \Omega \rightarrow \Omega$ ist suffizient, da

$$\mathbb{E}_\vartheta[f | X] = f(X) \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für jedes } \vartheta \in \Theta.$$

Lemma 1.8.5. Es sei $(B_i)_{i \in I}$ eine Zerlegung von Ω . Für jede beschränkte Zufallsvariable X und $\mathcal{G} = \sigma(\{B_i : i \in I\})$ gilt

$$\mathbb{E}[X | \mathcal{G}] = \sum_{\substack{i \in I \\ \mathbb{P}(B_i) > 0}} \mathbb{E}[X | B_i] \mathbb{1}_{B_i} \quad \mathbb{P}\text{-fast sicher.}$$

Hierbei bezeichnet $\mathbb{E}[X | B_i]$ den Erwartungswert von X unter dem bedingten Wahrscheinlichkeitsmaß $\mathbb{P}^{B_i} = \mathbb{P}(\cdot | B_i)$.

Beweis. Übung. \square

Lemma 1.8.6. Es sei $S : \Omega \rightarrow E$ eine Statistik mit Werten in einem diskreten Raum E . Dann sind folgende Aussagen äquivalent:

- (i) S ist suffizient.
- (ii) Für jede messbare, beschränkte Funktion $f : \Omega \rightarrow \mathbb{R}$ existiert eine Abbildung $g : E \rightarrow \mathbb{R}$, so dass

$$\mathbb{E}_\vartheta[f | S = s] = g(s)$$

für jedes $\vartheta \in \Theta$ und jedes $s \in E$ mit $\mathbb{P}_\vartheta(S = s) > 0$.

- (iii) Es existieren Wahrscheinlichkeitsmaße $(\mu_s)_{s \in E}$ auf (Ω, \mathcal{F}) , so dass

$$\mathbb{P}_\vartheta^{\{S=s\}} = \mu_s$$

für jedes $\vartheta \in \Theta$ und jedes $s \in E$ mit $\mathbb{P}_\vartheta(S = s) > 0$.

Beweis. (i) \Leftrightarrow (ii): $\{S = s\}_{s \in E}$ ist eine Zerlegung von Ω . Mit Lemma 1.8.5 folgt

$$\mathbb{E}_\vartheta[f | S] = \sum_{\substack{s \in E \\ \mathbb{P}_\vartheta(S=s) > 0}} \mathbb{E}_\vartheta[f | S = s] \mathbb{1}_{\{S=s\}}.$$

(ii) \Leftrightarrow (iii): Für jedes $B \subset E$ gilt

$$\mathbb{P}_\vartheta^{\{S=s\}}(B) = \mathbb{E}_\vartheta[\mathbb{1}_B | S = s]$$

Also folgt die Äquivalenz mit maßtheoretischer Induktion. \square

Zur Erinnerung: Die diskrete Gleichverteilung auf einer endlichen Menge E ist die diskrete Verteilung mit stochastischem Vektor $\pi : E \rightarrow [0, 1]$ gegeben durch

$$\pi(k) = \frac{1}{n}, \quad k \in E,$$

wobei $n = |E|$. Wir bezeichnen sie mit $\text{UD}(E)$.

Beispiel 1.8.7. Wir betrachten den mehrfachen Münzwurf aus Beispiel 1.1.11. Also gilt

$$\mathbb{P}_\vartheta = \text{Ber}(\vartheta)^{\otimes n}, \quad \vartheta \in \Theta = (0, 1).$$

Es sei $S : \Omega = \{0, 1\}^n \rightarrow \{0, 1, \dots, n\} = E$ die Statistik

$$S = \sum_{i=1}^n X_i.$$

Dann gilt (Übung)

$$\mathbb{P}_\vartheta^{\{S=k\}} = \text{UD}(E_k)$$

für jedes $\vartheta \in \Theta$ und jedes $k \in E$, wobei

$$E_k = \{j \in \Omega : j_1 + \dots + j_n = k\}.$$

Also ist S nach Lemma 1.8.6 eine suffiziente Statistik.

Definition 1.8.8. Es seien $(\Omega_1, \mathcal{F}_1)$ und $(\Omega_2, \mathcal{F}_2)$ messbare Räume. Eine Abbildung $\kappa : \Omega_1 \times \mathcal{F}_2 \rightarrow [0, 1]$ heißt ein stochastischer Kern von $(\Omega_1, \mathcal{F}_1)$ nach $(\Omega_2, \mathcal{F}_2)$, falls gilt:

- (a) $\omega_1 \mapsto \kappa(\omega_1, A_2)$ ist \mathcal{F}_1 -messbar für jedes $A_2 \in \mathcal{F}_2$.
- (b) $A_2 \mapsto \kappa(\omega_1, A_2)$ ist ein Wahrscheinlichkeitsmaß auf $(\Omega_2, \mathcal{F}_2)$ für jedes $\omega_1 \in \Omega_1$.

Definition 1.8.9. Ein separabler topologischer Raum, dessen Topologie durch eine vollständige Metrik erzeugt wird, heißt ein polnischer Raum.

Lemma 1.8.10. Sofern Ω ein polnischer Raum ist, sind für eine Statistik $S : \Omega \rightarrow E$ folgende Aussagen äquivalent:

- (i) S ist suffizient.
- (ii) Es existiert ein stochastischer Kern κ von $(\Omega, \sigma(S))$ nach (Ω, \mathcal{F}) , so dass für jedes $B \in \mathcal{F}$ gilt

$$\mathbb{P}_\vartheta(B | S) = \kappa(\cdot, B) \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für alle } \vartheta \in \Theta.$$

Lemma 1.8.11. *Es seien X, Y zwei Zufallsvariablen mit $X \in \mathcal{L}^2$. Dann gilt*

$$\mathbb{E}[X | Y]^2 \leq \mathbb{E}[X^2 | Y] \quad \mathbb{P}\text{-fast sicher,}$$

und die folgenden Aussagen sind äquivalent:

(i) *Es gilt $\mathbb{E}[\mathbb{E}[X | Y]^2] = \mathbb{E}[\mathbb{E}[X^2 | Y]]$.*

(ii) *Es gilt $\mathbb{E}[X | Y]^2 = \mathbb{E}[X^2 | Y]$ \mathbb{P} -fast sicher.*

(iii) *Es gilt $X = \mathbb{E}[X | Y]$ \mathbb{P} -fast sicher.*

Beweis. Die behauptete Ungleichung folgt aus der Jensen-Ungleichung für bedingte Erwartungen

$$\varphi(\mathbb{E}[X | \mathcal{G}]) \leq \mathbb{E}[\varphi(X) | \mathcal{G}]$$

mit der konvexen Funktion $\varphi(x) = x^2$.

(i) \Rightarrow (ii): Es gilt

$$\mathbb{E}\left[\underbrace{\mathbb{E}[X^2 | Y] - \mathbb{E}[X | Y]^2}_{\geq 0}\right] = 0$$

Wegen $\mathbb{E}[X^2 | Y] - \mathbb{E}[X | Y]^2 \geq 0$ folgt

$$\mathbb{E}[X^2 | Y] - \mathbb{E}[X | Y]^2 = 0 \quad \mathbb{P}\text{-fast sicher.}$$

(ii) \Rightarrow (iii): Es gilt

$$\begin{aligned} \mathbb{E}\left[\underbrace{(X - \mathbb{E}[X | Y])^2}_{\geq 0} | Y\right] &= \mathbb{E}[X^2 - 2X\mathbb{E}[X | Y] + \mathbb{E}[X | Y]^2 | Y] \\ &= \mathbb{E}[X^2 | Y] - 2\mathbb{E}[X | Y]^2 + \mathbb{E}[X | Y]^2 = 0 \end{aligned}$$

Also folgt $X - \mathbb{E}[X | Y] = 0$ \mathbb{P} -fast sicher.

(iii) \Rightarrow (i): \checkmark

□

Satz 1.8.12 (Satz von Rao-Blackwell). *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße, $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ mit $T \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$, und $S : \Omega \rightarrow E$ eine suffiziente Statistik. Wir definieren den Schätzer $T' : \Omega \rightarrow \mathbb{R}$ durch

$$T' := \mathbb{E}[T | S].$$

(a) T' ist ein erwartungstreuer Schätzer für τ .

(b) Es gilt

$$\text{Var}_\vartheta[T'] \leq \text{Var}_\vartheta[T] \quad \text{für alle } \vartheta \in \Theta.$$

(c) Es gilt

$$\text{Var}_\vartheta[T'] = \text{Var}_\vartheta[T] \quad \text{für alle } \vartheta \in \Theta$$

genau dann, wenn

$$T = T' \quad \mathbb{P}_\vartheta\text{-fast sicher für jedes } \vartheta \in \Theta.$$

Beweis.

(a) Für jedes $\vartheta \in \Theta$ gilt

$$\mathbb{E}_\vartheta[T'] = \mathbb{E}_\vartheta[\mathbb{E}_\vartheta[T | S]] = \mathbb{E}_\vartheta[T] = \tau(\vartheta).$$

(b) Für jedes $\vartheta \in \Theta$ gilt mit der Jensen-Ungleichung (Lemma 1.8.11)

$$\begin{aligned} \text{Var}_\vartheta[T'] &= \mathbb{E}_\vartheta[(T' - \tau(\vartheta))^2] \\ &= \mathbb{E}_\vartheta[(\mathbb{E}_\vartheta[T | S] - \tau(\vartheta))^2] \\ &= \mathbb{E}_\vartheta[\mathbb{E}_\vartheta[T - \tau(\vartheta) | S]^2] \\ &\leq \mathbb{E}_\vartheta[\mathbb{E}_\vartheta[(T - \tau(\vartheta))^2 | S]] \\ &= \mathbb{E}_\vartheta[(T - \tau(\vartheta))^2] = \text{Var}_\vartheta[T]. \end{aligned}$$

(c) Es sei $\vartheta \in \Theta$ beliebig. Nach der Rechnung aus Teil (b) gilt

$$\text{Var}_\vartheta[T] = \text{Var}_\vartheta[T']$$

genau dann, wenn

$$\mathbb{E}_\vartheta[\mathbb{E}_\vartheta[T - \tau(\vartheta) | S]^2] = \mathbb{E}_\vartheta[\mathbb{E}_\vartheta[(T - \tau(\vartheta))^2 | S]].$$

Nach Lemma 1.8.11 ist dies äquivalent zu

$$T - \tau(\vartheta) = \mathbb{E}_\vartheta[T - \tau(\vartheta) | S] \quad \mathbb{P}_\vartheta\text{-fast sicher,}$$

und dies ist gleichbedeutend mit

$$T = \mathbb{E}_\vartheta[T | S] = T' \quad \mathbb{P}_\vartheta\text{-fast sicher.}$$

□

Bemerkung 1.8.13. In der Situation des Satzes von Rao-Blackwell (Satz 1.8.12) existiert nach dem Faktorisierungssatz (Satz 1.8.2) eine messbare Funktion $h : E \rightarrow \mathbb{R}$, so dass

$$T' = h(S).$$

Lemma 1.8.14. Es sei $X : \Omega \rightarrow G$ und $Y : \Omega \rightarrow E$ diskrete Zufallsvariablen, und $g : G \rightarrow \mathbb{R}$ eine Abbildung. Wir definieren

$$h : E \rightarrow \mathbb{R}, \quad h(k) := \sum_{j \in G} g(j) \mathbb{P}(X = j | Y = k)$$

Dann gilt

$$\mathbb{E}[g(X) | Y] = h(Y).$$

Beispiel 1.8.15. Wir betrachten den mehrfachen Münzwurf aus Beispiel 1.1.11. Also gilt

$$\mathbb{P}_\vartheta = \text{Ber}(\vartheta)^{\otimes n}, \quad \vartheta \in \Theta = (0, 1).$$

Dann ist $T : \Omega = \{0, 1\}^n \rightarrow \{0, 1\} = G$ definiert durch

$$T = X_1$$

ein erwartungstreuer Schätzer für die Kenngröße $\tau : \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) = \vartheta$. Nach Beispiel 1.8.7 ist $S : \Omega \rightarrow \{0, 1, \dots, n\} = E$ gegeben durch

$$S = \sum_{i=1}^n X_i$$

eine suffiziente Statistik. Wir setzen

$$T' = \mathbb{E}[T | S].$$

Dann gilt

$$T' = \frac{S}{n} = \bar{X}.$$

In der Tat, es sei $\vartheta \in \Theta$ beliebig. Dann gilt $T \sim \text{Ber}(\vartheta)$, $S \sim \text{Bi}(n, \vartheta)$ und $X_2 + \dots + X_n \sim \text{Bi}(n-1, \vartheta)$ unter \mathbb{P}_ϑ . Nun sei $k \in E$ beliebig. Dann gilt

$$\begin{aligned} \{T = 1\} \cap \{S = k\} &= \{X_1 = 1\} \cap \{X_1 + \dots + X_n = k\} \\ &= \{X_1 = 1\} \cap \{X_2 + \dots + X_n = k - 1\}, \end{aligned}$$

und daher

$$\begin{aligned}\mathbb{P}_\vartheta(T = 1 | S = k) &= \frac{\mathbb{P}_\vartheta(\{T = 1\} \cap \{S = k\})}{\mathbb{P}_\vartheta(S = k)} \\ &= \frac{\mathbb{P}_\vartheta(X_1 = 1) \cdot \mathbb{P}_\vartheta(X_2 + \dots + X_n = k - 1)}{\mathbb{P}_\vartheta(S = k)} \\ &= \frac{\vartheta \cdot \binom{n-1}{k-1} \vartheta^{k-1} (1 - \vartheta)^{n-k}}{\binom{n}{k} \vartheta^k (1 - \vartheta)^{n-k}} = \frac{\frac{(n-1)!}{(k-1)!(n-k)!}}{\frac{n!}{k!(n-k)!}} = \frac{k}{n}.\end{aligned}$$

Die Abbildung

$$h : E \rightarrow \mathbb{R}, \quad h(k) := \sum_{j \in G} g(j) \mathbb{P}(T = j | S = k)$$

mit $g(j) = j$ ist also gegeben durch

$$h(k) = \sum_{j=0,1} j \mathbb{P}(T = j | S = k) = \mathbb{P}(T = 1 | S = k) = \frac{k}{n}.$$

Mit Lemma 1.8.14 folgt also

$$T' = \frac{S}{n} = \bar{X}.$$

In der Tat gilt

$$\text{Var}_\vartheta[T'] = \frac{\vartheta(1 - \vartheta)}{n} < \vartheta(1 - \vartheta) = \text{Var}_\vartheta[T] \quad \text{für alle } \vartheta \in \Theta.$$

Satz 1.8.16 (Faktorisierungslemma von Neyman-Fischer). *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein Standardmodell und $S : \Omega \rightarrow E$ eine Statistik. Dann sind folgende Aussagen äquivalent:

(i) S ist suffizient.

(ii) Es existieren $g : \Theta \times E \rightarrow \mathbb{R}_+$ und eine messbare Funktion $h : \Omega \rightarrow \mathbb{R}_+$, so dass

$$L(\vartheta, x) = g(\vartheta, S(x)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

Beweis. Für den Fall, dass Ω und E diskret sind, und μ das Zählmaß ζ ist.

(i) \Rightarrow (ii): Wir definieren $g : \Theta \times E \rightarrow \mathbb{R}_+$ durch

$$g(\vartheta, s) := \mathbb{P}_\vartheta(S = s).$$

Nach Lemma 1.8.6 existieren Wahrscheinlichkeitsmaße $(\mu_s)_{s \in E}$ auf (Ω, \mathcal{F}) , so dass

$$\mathbb{P}_\vartheta^{\{S=s\}} = \mu_s$$

für jedes $\vartheta \in \Theta$ und jedes $s \in E$ mit $\mathbb{P}_\vartheta(S = s) > 0$. Wir definieren $h_0 : \Omega \times E \rightarrow \mathbb{R}_+$ durch

$$h_0(x, s) := \mu_s(\{x\}),$$

und $h : \Omega \rightarrow \mathbb{R}_+$ durch

$$h(x) := h_0(x, S(x)).$$

Dann gilt

$$\begin{aligned} L(\vartheta, x) &= \mathbb{P}_\vartheta(X = x) = \mathbb{P}_\vartheta(X = x, S = S(x)) \\ &= \mathbb{P}_\vartheta(X = x \mid S = S(x)) \cdot \mathbb{P}_\vartheta(S = S(x)) \\ &= \mu_{S(x)}(\{x\}) \cdot g(\vartheta, S(x)) = h_0(x, S(x)) \cdot g(\vartheta, S(x)) = h(x) \cdot g(\vartheta, S(x)). \end{aligned}$$

(ii) \Rightarrow (i): Wir definieren die Wahrscheinlichkeitsmaße $(\mu_s)_{s \in E}$ auf (Ω, \mathcal{F}) durch

$$\mu_s(\{x\}) = \frac{h(x)}{\sum_{\substack{y \in E \\ S(y)=s}} h(y)}$$

für alle $x \in \Omega$ mit $S(x) = s$. Es seien $\vartheta \in \Theta$ und $s \in E$ mit $\mathbb{P}_\vartheta(S = s) > 0$ beliebig. Dann gilt

$$\begin{aligned} \mathbb{P}_\vartheta(S = s) &= \sum_{\substack{y \in E \\ S(y)=s}} \mathbb{P}_\vartheta(X = y) = \sum_{\substack{y \in E \\ S(y)=s}} L(\vartheta, y) \\ &= \sum_{\substack{y \in E \\ S(y)=s}} g(\vartheta, S(y)) \cdot h(y) = g(s, \vartheta) \sum_{\substack{y \in E \\ S(y)=s}} h(y), \end{aligned}$$

was auch die Wohldefiniertheit von μ_s zeigt. Nun sei $x \in \Omega$ mit $S(x) = s$ beliebig. Dann gilt

$$\mathbb{P}_\vartheta(X = x, S = s) = \mathbb{P}_\vartheta(X = x) = L(\vartheta, x) = g(\vartheta, S(x)) \cdot h(x) = g(\vartheta, s) \cdot h(x).$$

Insgesamt folgt

$$\begin{aligned}\mathbb{P}_\vartheta(X = x | S = s) &= \frac{\mathbb{P}_\vartheta(X = x, S = s)}{\mathbb{P}_\vartheta(S = s)} = \frac{g(\vartheta, s) \cdot h(x)}{g(\vartheta, s) \sum_{\substack{y \in E \\ S(y)=s}} h(y)} \\ &= \frac{h(x)}{\sum_{\substack{y \in E \\ S(y)=s}} h(y)} = \mu_s(\{x\}).\end{aligned}$$

Nach Lemma 1.8.6 ist S eine suffiziente Statistik. □

Korollar 1.8.17. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

eine exponentielle Familie mit kanonischer Statistik T . Dann ist T suffizient.

Beweis. Dies folgt aus dem Faktorisierungslemma von Neyman-Fischer (Satz 1.8.16) mit

$$g : \Theta \times \mathbb{R} \rightarrow \mathbb{R}_+, \quad g(\vartheta, t) = \exp(a(\vartheta)t - b(\vartheta)).$$

□

1.9 Vollständige Statistiken

Definition 1.9.1. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell. Eine Statistik $S : \Omega \rightarrow E$ heißt vollständig, falls für jede messbare Funktion $h : E \rightarrow \mathbb{R}$ mit $h(S) \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$ aus der Bedingung

$$\mathbb{E}_\vartheta[h(S)] = 0 \quad \text{für alle } \vartheta \in \Theta$$

folgt

$$h(S) = 0 \quad \mathbb{P}_\vartheta\text{-fast sicher für alle } \vartheta \in \Theta.$$

Beispiel 1.9.2. *Wir betrachten den mehrfachen Münzwurf aus Beispiel 1.1.11. Also gilt*

$$\mathbb{P}_\vartheta = \text{Ber}(\vartheta)^{\otimes n}, \quad \vartheta \in \Theta = (0, 1).$$

Es sei $S : \Omega = \{0, 1\}^n \rightarrow \{0, 1, \dots, n\} = E$ die Statistik

$$S = \sum_{i=1}^n X_i.$$

Dann ist S vollständig. In der Tat, es sei $h : E \rightarrow \mathbb{R}$ eine beliebige Funktion. Weiterhin sei $\vartheta \in \Theta$ beliebig. Dann gilt $S \sim \text{Bi}(n, \vartheta)$ unter \mathbb{P}_ϑ , und es folgt

$$\begin{aligned} \mathbb{E}_\vartheta[h(S)] &= \sum_{k=0}^n h(k) \binom{n}{k} \vartheta^k (1 - \vartheta)^{n-k} \\ &= (1 - \vartheta)^n \sum_{k=0}^n h(k) \binom{n}{k} \left(\frac{\vartheta}{1 - \vartheta}\right)^k. \end{aligned}$$

Also folgt aus

$$\mathbb{E}_\vartheta[h(S)] = 0 \quad \text{für alle } \vartheta \in \Theta,$$

dass

$$\sum_{k=0}^n h(k) \binom{n}{k} y^k = 0 \quad \text{für alle } y \in (0, \infty),$$

und damit

$$h(k) = 0 \quad \text{für alle } k \in E.$$

Satz 1.9.3 (Satz von Lehmann-Scheffé). *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße, $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ mit $T \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$, und $S : \Omega \rightarrow E$ eine vollständige, suffiziente Statistik.

- (a) *Es gibt einen eindeutig bestimmten gleichmäßig besten Schätzer T' für die Kenngröße τ .*
- (b) *Dieser ist gegeben durch*

$$T' := \mathbb{E}[T | S].$$

- (c) *Die Definition von T' ist unabhängig von der Wahl von T ; das heißt, für jeden weiteren erwartungstreuen Schätzer $U : \Omega \rightarrow \mathbb{R}$ für τ mit $U \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$ gilt*

$$T' = \mathbb{E}[U | S].$$

(d) Es existiert eine messbare Funktion $h : E \rightarrow \mathbb{R}$, so dass

$$T' = h(S).$$

Beweis. Nach dem Satz von Rao-Blackwell (Satz 1.8.12(a), (b)) ist T' ein erwartungstreuer Schätzer für τ , und es gilt

$$\text{Var}_\vartheta[T'] \leq \text{Var}_\vartheta[T] \quad \text{für alle } \vartheta \in \Theta.$$

Nun sei U ein weiterer erwartungstreuer Schätzer wie in Teil (c). Wir setzen

$$U' := \mathbb{E}[U | S].$$

Nach dem Faktorisierungssatz (Satz 1.8.2) existieren messbare Funktionen $h_i : E \rightarrow \mathbb{R}$ für $i = 1, 2$, so dass

$$T' = h_1(S) \quad \text{und} \quad U' = h_2(S).$$

Wir definieren $h : E \rightarrow \mathbb{R}$ durch $h := h_1 - h_2$. Dann gilt $h(S) \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle ϑ , da $T', U' \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle ϑ . Weiterhin gilt für alle $\vartheta \in \Theta$

$$\begin{aligned} \mathbb{E}_\vartheta[h(S)] &= \mathbb{E}_\vartheta[h_1(S)] - \mathbb{E}_\vartheta[h_2(S)] = \mathbb{E}_\vartheta[T'] - \mathbb{E}_\vartheta[U'] \\ &= \tau(\vartheta) - \tau(\vartheta) = 0. \end{aligned}$$

Wegen der Vollständigkeit von S folgt für jedes $\vartheta \in \Theta$

$$\mathbb{P}_\vartheta(T' = U') = \mathbb{P}_\vartheta(h_1(S) = h_2(S)) = \mathbb{P}_\vartheta(h(S) = 0) = 1.$$

Also hängt die Definition von T' nicht von der Wahl von T ab, und es gilt insbesondere $T' = \mathbb{E}[U | S]$ für jeden erwartungstreuen Schätzer U für τ . Folglich gilt Nach dem Satz von Rao-Blackwell (Satz 1.8.12(b))

$$\text{Var}_\vartheta[T'] \leq \text{Var}_\vartheta[U] \quad \text{für alle } \vartheta \in \Theta$$

und jeden erwartungstreuen Schätzer U für τ . Also ist T' ein gleichmäßig bester Schätzer für die Kenngröße τ .

Für die Eindeutigkeit sei U ein weiterer gleichmäßig bester Schätzer für τ . Dann gilt

$$\text{Var}_\vartheta[T'] = \text{Var}_\vartheta[U] \quad \text{für alle } \vartheta \in \Theta.$$

Außerdem gilt $T' = \mathbb{E}[U | S]$, und nach dem Satz von Rao-Blackwell (Satz 1.8.12(c)) folgt

$$U = T' \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für jedes } \vartheta \in \Theta.$$

Dies beweist (a)–(c). Teil (d) folgt aus dem Faktorisierungssatz (Satz 1.8.2). \square

Korollar 1.9.4. *Es seien $S : \Omega \rightarrow E$ eine vollständige, suffiziente Statistik, und $h : E \rightarrow \mathbb{R}$ eine messbare Funktion. Dann ist $T : \Omega \rightarrow \mathbb{R}$ gegeben durch $T = h(S)$ der eindeutig bestimmte gleichmäßig beste Schätzer für die Kenngröße*

$$\tau : \Theta \rightarrow \mathbb{R}, \quad \tau(\vartheta) = \mathbb{E}_{\vartheta}[h(S)].$$

Beweis. Folgt aus dem Satz von Lehmann-Scheffé (Satz 1.9.3). \square

Beispiel 1.9.5. *Wir betrachten den mehrfachen Münzwurf aus Beispiel 1.1.11. Also gilt*

$$\mathbb{P}_{\vartheta} = \text{Ber}(\vartheta)^{\otimes n}, \quad \vartheta \in \Theta = (0, 1).$$

Es sei $S : \Omega = \{0, 1\}^n \rightarrow \{0, 1, \dots, n\} = E$ die Statistik

$$S = \sum_{i=1}^n X_i.$$

Wie wir in den Beispielen 1.8.7 und 1.9.2 gesehen haben, ist S eine vollständige, suffiziente Statistik. Die Statistik $T : \Omega \rightarrow \{0, 1\}$ definiert durch

$$T = X_1$$

ist ein erwartungstreuer Schätzer für die Kenngröße $\tau : \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) = \vartheta$, und nach Beispiel 1.8.15 ist

$$T' := \mathbb{E}[T | S]$$

gegeben durch

$$T' = \frac{S}{n} = \bar{X}.$$

Nach dem Satz von Lehmann-Scheffé (Satz 1.9.3) ist \bar{X} der eindeutig bestimmte gleichmäßig beste Schätzer für die Kenngröße τ .

1.10 Mehrdimensionale exponentielle Familien

Definition 1.10.1. *Ein Standardmodell*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_{\vartheta} : \vartheta \in \Theta))$$

heißt ein mehrdimensionales reguläres Modell, falls gilt:

(a) $\Theta \subset \mathbb{R}^d$ ist eine nichtleere, offene Menge.

(b) $\mathbb{P}_\vartheta \approx \mu$ für alle $\vartheta \in \Theta$.

(c) Für jeden Schätzer $S : \Omega \rightarrow \mathbb{R}$ und jedes $\vartheta \in \Theta$ mit $S \in \mathcal{L}^1(\mathbb{P}_\vartheta) < \infty$ gilt

$$\frac{\partial}{\partial \vartheta_i} \int_{\Omega} S(x) L(\vartheta, x) \mu(dx) = \int_{\Omega} S(x) \frac{\partial}{\partial \vartheta_i} L(\vartheta, x) \mu(dx) \quad \text{für alle } i = 1, \dots, d.$$

Definition 1.10.2. Ein mehrdimensionales reguläres Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

heißt eine mehrdimensionale exponentielle Familie, falls messbare Funktionen $a : \Theta \rightarrow \mathbb{R}^d$ mit $a \in C^1(\Theta; \mathbb{R}^d)$, $b : \Theta \rightarrow \mathbb{R}$, eine Statistik $T : \Omega \rightarrow \mathbb{R}^d$ und eine messbare Funktion $h : \Omega \rightarrow (0, \infty)$ existieren, so dass

$$L(\vartheta, x) = \exp(\langle a(\vartheta), T(x) \rangle_{\mathbb{R}^d} - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

In diesem Fall nennen wir T eine kanonische Statistik.

Lemma 1.10.3. Die Statistik T ist suffizient.

Beweis. Dies folgt aus dem Faktorisierungslemma von Neyman-Fischer (Satz 1.8.16) mit

$$g : \Theta \times \mathbb{R}^d \rightarrow \mathbb{R}_+, \quad g(\vartheta, t) = \exp(\langle a(\vartheta), t \rangle_{\mathbb{R}^d} - b(\vartheta)).$$

□

Lemma 1.10.4. Die Funktion $b : \Theta \rightarrow \mathbb{R}$ ist gegeben durch

$$b(\vartheta) = \ln \left(\int_{\Omega} \exp(\langle a(\vartheta), T(x) \rangle_{\mathbb{R}^d}) h(x) \mu(dx) \right).$$

Beweis. Wie der Beweis von Lemma 1.7.4. □

Bemerkung 1.10.5. Es gelte $\det J_a(\vartheta_0) \neq 0$ für ein $\vartheta_0 \in \Theta$. Hierbei bezeichnet $J_a(\vartheta_0) \in \mathbb{R}^{d \times d}$ die Jakobi-Matrix

$$J_a(\vartheta_0) = \begin{pmatrix} \frac{\partial a_1}{\partial \vartheta_1}(\vartheta_0) & \cdots & \frac{\partial a_1}{\partial \vartheta_d}(\vartheta_0) \\ \vdots & \ddots & \vdots \\ \frac{\partial a_d}{\partial \vartheta_1}(\vartheta_0) & \cdots & \frac{\partial a_d}{\partial \vartheta_d}(\vartheta_0) \end{pmatrix}.$$

Nach dem lokalen Umkehrsatz existiert eine offene Umgebung $U \subset \mathbb{R}^d$ von ϑ_0 , so dass a auf U injektiv ist, und es gilt

$$L(a^{-1}(\eta), x) = \exp(\langle \eta, T(x) \rangle_{\mathbb{R}^d} - \bar{b}(\eta)) \cdot h(x) \quad \text{für alle } \eta \in a(U),$$

wobei $\bar{b} = b \circ a^{-1}$.

Lemma 1.10.6. *Das n -fache Produktmodell*

$$\mathcal{M}^{\otimes n} = (\Omega^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n} : \vartheta \in \Theta))$$

ist eine exponentielle Familie der Form

$$L^{\otimes n}(\vartheta, x) = \exp(\langle a_n(\vartheta), T_n(x) \rangle_{\mathbb{R}^d} - b_n(\vartheta)) \cdot h_n(x)$$

mit

$$a_n(\vartheta) = n \cdot a(\vartheta), \quad b_n(\vartheta) = n \cdot b(\vartheta), \quad h_n(x) = \prod_{i=1}^n h(x_i)$$

und kanonischer Statistik

$$T_n = \frac{1}{n} \sum_{i=1}^n T(X_i).$$

Beweis. Nach Lemma 1.4.13(a) gilt

$$\begin{aligned} L^{\otimes n}(\vartheta, x) &= \prod_{i=1}^n \exp(\langle a(\vartheta), T(x_i) \rangle_{\mathbb{R}^d} - b(\vartheta)) \cdot h(x_i) \\ &= \exp\left(\left\langle a(\vartheta), \sum_{i=1}^n T(x_i) \right\rangle_{\mathbb{R}^d} - n \cdot b(\vartheta)\right) \cdot \prod_{i=1}^n h(x_i) \\ &= \exp(\langle a_n(\vartheta), T_n(x) \rangle_{\mathbb{R}^d} - b_n(\vartheta)) \cdot h_n(x). \end{aligned}$$

□

Beispiel 1.10.7. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

das Gauß-Modell aus Beispiel 1.1.3, wobei $\Theta = \mathbb{R} \times (0, \infty)$. Es gilt also

$$\mathbb{P}_\vartheta = \mathcal{N}(\mu, \sigma^2), \quad (\mu, \sigma^2) = \vartheta \in \Theta.$$

Dann gilt

$$\begin{aligned} L(\vartheta, x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \\ &= \exp\left(-\frac{1}{2} \ln(2\pi\sigma^2) - \frac{x^2}{2\sigma^2} + \frac{x\mu}{\sigma^2} - \frac{\mu^2}{2\sigma^2}\right). \end{aligned}$$

Also gilt

$$L(\vartheta, x) = \exp(\langle a(\vartheta), T(x) \rangle_{\mathbb{R}^2} - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega,$$

wobei

$$\begin{aligned} a(\vartheta) &= \left(\frac{\mu}{\sigma^2}, -\frac{1}{2\sigma^2} \right), \\ b(\vartheta) &= \frac{1}{2} \left(\frac{\mu^2}{\sigma^2} + \ln(2\pi\sigma^2) \right), \\ T(x) &= (x, x^2), \\ h(x) &= 1. \end{aligned}$$

Für alle $\vartheta \in \Theta$ gilt also

$$J_a(\vartheta) = \begin{pmatrix} \frac{1}{\sigma^2} & -\frac{\mu}{\sigma^4} \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix},$$

und daher

$$\det J_a(\vartheta) = \frac{1}{2\sigma^6} > 0.$$

Das n -fache Produktmodell hat nach Lemma 1.10.6 die kanonische Statistik

$$T_n = \left(\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n} \sum_{i=1}^n X_i^2 \right).$$

Satz 1.10.8 (Eindeutigkeitssatz für die Laplace-Transformation). *Es seien μ und ν zwei endliche Maße auf $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$, und es seien $\vartheta_0 \in \mathbb{R}^d$ und $U \subset \mathbb{R}^d$ eine offene Umgebung von ϑ_0 , so dass*

$$\int_{\mathbb{R}^d} \exp(\langle \vartheta, x \rangle_{\mathbb{R}^d}) \mu(dx) = \int_{\mathbb{R}^d} \exp(\langle \vartheta, x \rangle_{\mathbb{R}^d}) \nu(dx) < \infty \quad \text{für alle } \vartheta \in U.$$

Dann gilt $\mu = \nu$.

Lemma 1.10.9. *Es seien $(\Omega, \mathcal{F}, \mu)$ ein Maßraum, und $T : \Omega \rightarrow E$ eine messbare Abbildung mit Werten in einem messbaren Raum (E, \mathcal{E}) . Wir setzen $\nu := \mu \circ T$. Weiterhin seien $f, g : E \rightarrow \mathbb{R}$ messbare Funktionen, so dass $f = g$ ν -fast sicher. Dann gilt $f(T) = g(T)$ μ -fast sicher.*

Beweis. Es gibt eine ν -Nullmenge $N \in \mathcal{E}$, so dass $f(t) = g(t)$ für alle $t \in N^c$. Es gilt

$$\mu(T^{-1}(N)) = \nu(N) = 0.$$

Also ist $T^{-1}(N)$ eine μ -Nullmenge. Außerdem gilt

$$f(T(x)) = g(T(x)) \quad \text{für alle } x \in T^{-1}(N^c) = T^{-1}(N)^c.$$

□

Satz 1.10.10. *Es sei*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

eine mehrdimensionale exponentielle Familie, so dass eine nichtleere, offene Menge $V \subset \mathbb{R}^d$ mit $V \subset a(\Theta)$ existiert. Dann ist die kanonische Statistik T vollständig und suffizient.

Zwischenbemerkung: Es gelte $\det J_a(\vartheta_0) \neq 0$ für ein $\vartheta_0 \in \Theta$. Nach dem lokalen Umkehrsatz existiert eine offene Umgebung $U \subset \mathbb{R}^d$ von ϑ_0 , so dass $a|_U : U \rightarrow a(U)$ ein Homöomorphismus ist. Also ist $V := a(U)$ eine nichtleere, offene Menge mit $V \subset a(\Theta)$.

Beweis. Die Suffizienz folgt aus Lemma 1.10.3. Es sei $f : \mathbb{R}^d \rightarrow \mathbb{R}$ eine messbare Funktion mit $f(T) \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$, so dass

$$\mathbb{E}_\vartheta[f(T)] = 0 \quad \text{für alle } \vartheta \in \Theta.$$

Wie in Bemerkung 1.10.5 gilt

$$L(a^{-1}(\eta), x) = \exp(\langle \eta, T(x) \rangle_{\mathbb{R}^d} - \bar{b}(\eta)) \cdot h(x) \quad \text{für alle } (\eta, x) \in V \times \Omega,$$

wobei $\bar{b} = b \circ a^{-1}$. Da $a^{-1}(V)$ auch offen ist, dürfen wir also annehmen, dass

$$L(\vartheta, x) = \exp(\langle \vartheta, T(x) \rangle_{\mathbb{R}^d} - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in V \times \Omega.$$

Durch Verschiebung dürfen wir außerdem annehmen, dass $0 \in V$. Genauer gesagt, wählen wir $\vartheta_0 \in V$ und eine offene Umgebung $W \subset \mathbb{R}^d$ der Null, so dass $\vartheta_0 + W \subset V$. Dann gilt für alle $\vartheta \in W$

$$\begin{aligned} L(\vartheta_0 + \vartheta, x) &= \exp(\langle \vartheta_0 + \vartheta, T(x) \rangle_{\mathbb{R}^d} - b(\vartheta_0 + \vartheta)) \cdot h(x) \\ &= \exp(\langle \vartheta, T(x) \rangle_{\mathbb{R}^d} - \bar{b}(\vartheta)) \cdot \bar{h}(x), \end{aligned}$$

wobei

$$\begin{aligned} \bar{b}(\vartheta) &= b(\vartheta_0 + \vartheta), \\ \bar{h}(x) &= \exp(\langle \vartheta_0, T(x) \rangle_{\mathbb{R}^d}) \cdot h(x). \end{aligned}$$

Wir zerlegen $f = f^+ - f^-$ in Positiv- und Negativteil. Wir definieren die Maße κ durch $\frac{d\kappa}{d\mu} := h$ und $\nu := \kappa \circ T$. Weiterhin definieren wir die Maße ν_+ und ν_- durch

$\frac{d\nu_+}{d\nu} := f_+$ und $\frac{d\nu_-}{d\nu} := f_-$. Dann gilt für alle $\vartheta \in V$

$$\begin{aligned}\mathbb{E}_\vartheta[f_+(T)] &= \int_{\Omega} L(\vartheta, x) f_+(T(x)) \mu(dx) \\ &= \int_{\Omega} \exp(\langle \vartheta, T(x) \rangle_{\mathbb{R}^d} - b(\vartheta)) h(x) f_+(T(x)) \mu(dx) \\ &= \exp(-b(\vartheta)) \int_{\Omega} \exp(\langle \vartheta, T(x) \rangle_{\mathbb{R}^d}) f_+(T(x)) \kappa(dx) \\ &= \exp(-b(\vartheta)) \int_{\mathbb{R}^d} \exp(\langle \vartheta, t \rangle_{\mathbb{R}^d}) f_+(t) \nu(dt) \\ &= \exp(-b(\vartheta)) \int_{\mathbb{R}^d} \exp(\langle \vartheta, t \rangle_{\mathbb{R}^d}) \nu_+(dt).\end{aligned}$$

Analog gilt

$$\mathbb{E}_\vartheta[f_-(T)] = \exp(-b(\vartheta)) \int_{\mathbb{R}^d} \exp(\langle \vartheta, t \rangle_{\mathbb{R}^d}) \nu_-(dt),$$

und folglich

$$\int_{\mathbb{R}^d} \exp(\langle \vartheta, t \rangle_{\mathbb{R}^d}) \nu_+(dt) = \int_{\mathbb{R}^d} \exp(\langle \vartheta, t \rangle_{\mathbb{R}^d}) \nu_-(dt) \quad \text{für alle } \vartheta \in V.$$

Die Maße ν_+ und ν_- sind endlich, denn mit $\vartheta = 0$ folgt

$$\nu_+(\mathbb{R}^d) = \exp(b(0)) \mathbb{E}_\vartheta[f_+(T)] < \infty,$$

und analog $\nu_-(\mathbb{R}^d) < \infty$. Nach dem Eindeutigkeitssatz für die Laplace-Transformation (Satz 1.10.8) folgt $\nu_+ = \nu_-$. Also gilt $f_+ = f_-$ ν -fast sicher, und mit Lemma 1.10.9 folgt $f_+(T) = f_-(T)$ κ -fast sicher. Wegen $\kappa \approx \mu \approx \mathbb{P}_\vartheta$ folgt

$$f(T) = 0 \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für alle } \vartheta \in U.$$

□

Beispiel 1.10.11. Wir betrachten das n -fache Gaußmodell. Nach Satz 1.10.10 und Beispiel 1.10.7 ist

$$S = \left(\frac{1}{n} \sum_{i=1}^n X_i, \frac{1}{n} \sum_{i=1}^n X_i^2 \right).$$

eine vollständige, suffiziente Statistik. Wir definieren $h : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ durch

$$h(s) := \left(s_1, \frac{n}{n-1} (s_2 - s_1^2) \right).$$

Dann gilt

$$h(S) = \left(\widehat{m}_1(X), \frac{n}{n-1} (\widehat{m}_2(X) - \widehat{m}_1(X)^2) \right) = \left(\bar{X}, \frac{n}{n-1} \widehat{\sigma}^2(X) \right) = (\bar{X}, s^2(X)).$$

Nach Satz 1.4.17 gilt außerdem

$$\mathbb{E}_\vartheta[h(S)] = \vartheta \quad \text{für alle } \vartheta \in \Theta.$$

Also ist die Statistik $(\bar{X}, s^2(X))$ nach Korollar 1.9.4 der eindeutig bestimmte gleichmäßig beste Schätzer für die Kenngröße

$$\tau : \Theta \rightarrow \mathbb{R}^2, \quad \tau(\vartheta) = \vartheta.$$

1.11 Die mehrdimensionale Informationsungleichung

Definition 1.11.1. Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein mehrdimensionales reguläres statistisches Model mit $\Theta \subset \mathbb{R}^d$.

(a) Wir nennen

$$u : \Theta \times \Omega \rightarrow \mathbb{R}^d, \quad u(\vartheta, x) = \nabla_\vartheta \ell(\vartheta, x) = \frac{\nabla_\vartheta L(\vartheta, x)}{L(\vartheta, x)}$$

die Einflussfunktion (oder Score-Funktion).

(b) Wir nennen

$$I : \Theta \rightarrow \mathbb{R}^{d \times d}, \quad I(\vartheta) = \mathbb{E}_\vartheta[u(\vartheta, X)u(\vartheta, X)^\top]$$

die Informationsmatrix. Es gilt also

$$I(\vartheta)_{ij} = \mathbb{E}_\vartheta[u_i(\vartheta, X)u_j(\vartheta, X)] \quad \text{für alle } i, j = 1, \dots, d.$$

Für einen \mathbb{R}^d -wertigen Zufallsvektor $X = (X_1, \dots, X_d) \in \mathcal{L}^2$ bezeichnen wir mit $\text{Cov}(X)$ die Kovarianzmatrix gegeben durch

$$\text{Cov}(X)_{ij} = \text{Cov}(X_i, X_j), \quad i, j = 1, \dots, d.$$

Die Kovarianzmatrix ist bekanntlich symmetrisch und positiv semidefinit; letzteres bedeutet

$$\langle \text{Cov}(X)b, b \rangle_{\mathbb{R}^d} \geq 0 \quad \text{für alle } b \in \mathbb{R}^d.$$

Lemma 1.11.2. *Es sei $\vartheta \in \Theta$ beliebig.*

(a) *Es gilt $\mathbb{E}_\vartheta[u(\vartheta, X)] = 0$.*

(b) *Es gilt $I(\vartheta) = \text{Cov}_\vartheta(u(\vartheta, X))$, und $I(\vartheta)$ ist symmetrisch und positiv semidefinit.*

(c) *Für alle $\eta \in \mathbb{R}^d$ gilt*

$$\text{Var}_\vartheta[\langle \eta, u(\vartheta, X) \rangle_{\mathbb{R}^d}] = \langle I(\vartheta)\eta, \eta \rangle_{\mathbb{R}^d}.$$

Beweis.

(a) Es gilt

$$\begin{aligned} \mathbb{E}_\vartheta[u(\vartheta, X)] &= \int_{\Omega} u(\vartheta, x)L(\vartheta, x)\mu(dx) \\ &= \int_{\Omega} \nabla_\vartheta L(\vartheta, x)\mu(dx) = \nabla_\vartheta \underbrace{\int_{\Omega} L(\vartheta, x)\mu(dx)}_{=1} = 0. \end{aligned}$$

(b) Folgt aus Teil (a).

(c) ✓

□

Lemma 1.11.3. *Es sei $X \in \mathcal{L}^2$ eine Zufallsvariable. Dann gilt*

$$\sqrt{\text{Var}[X]} = \max_{Z \in \mathcal{L}} \frac{\mathbb{E}[XZ]}{\sqrt{\text{Var}[Z]}},$$

wobei

$$\mathcal{L} = \{Z \in \mathcal{L}^2 : \mathbb{E}[Z] = 0 \text{ und } \text{Var}[Z] > 0\}.$$

Beweis. Wir dürfen annehmen, dass $\text{Var}[X] > 0$. Es sei $Z \in \mathcal{L}$ beliebig. Nach der Ungleichung von Cauchy-Schwarz gilt

$$\mathbb{E}[XZ] \leq \sqrt{\text{Var}[X]}\sqrt{\text{Var}[Z]},$$

und daher

$$\sqrt{\text{Var}[X]} \geq \frac{\mathbb{E}[XZ]}{\sqrt{\text{Var}[Z]}},$$

Nun setzen wir

$$Z := \frac{X - \mathbb{E}[X]}{\sqrt{\text{Var}[X]}} \in \mathcal{Z}.$$

Dann gilt

$$\frac{\mathbb{E}[XZ]}{\sqrt{\text{Var}[Z]}} = \frac{\text{Cov}(X, Z)}{\sqrt{\text{Var}[Z]}} = \frac{\sqrt{\text{Var}[X]}}{\sqrt{\text{Var}[X]}} \cdot \frac{\text{Cov}(X, X)}{\sqrt{\text{Var}[X]}} = \sqrt{\text{Var}[X]}.$$

□

Eine Matrix $A \in \mathbb{R}^{d \times d}$ heißt bekanntlich positiv definit, falls

$$\langle Ab, b \rangle_{\mathbb{R}^d} > 0 \quad \text{für alle } b \in \mathbb{R}^d \setminus \{0\}.$$

Für eine symmetrische, positiv semidefinite Matrix $A \in \mathbb{R}^{d \times d}$ gilt $\det A \geq 0$. Es gilt $\det A > 0$ genau dann, wenn A positiv definit ist. In dem Fall ist A^{-1} ebenfalls symmetrisch und positiv definit.

Satz 1.11.4 (Mehrdimensionale Informationsungleichung von Cramer-Rao). *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein mehrdimensionales reguläres statistisches Modell mit $\Theta \subset \mathbb{R}^d$, so dass $I(\vartheta)$ für jedes $\vartheta \in \Theta$ positiv definit ist, $\tau \in C^1(\Theta; \mathbb{R})$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann gilt

$$\text{Var}_\vartheta[T] \geq \langle I(\vartheta)^{-1} \nabla \tau(\vartheta), \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d} \quad \text{für alle } \vartheta \in \Theta.$$

Beweis. Es sei $\vartheta \in \Theta$ beliebig. Wir dürfen annehmen, dass $\nabla \tau(\vartheta) \neq 0$. Für alle $j = 1, \dots, d$ gilt

$$\begin{aligned} \frac{\partial}{\partial \vartheta_j} \tau(\vartheta) &= \frac{\partial}{\partial \vartheta_j} \mathbb{E}_\vartheta[T] = \frac{\partial}{\partial \vartheta_j} \int_{\Omega} T(x) L(\vartheta, x) \mu(dx) \\ &= \int_{\Omega} T(x) \frac{\partial}{\partial \vartheta_j} L(\vartheta, x) \mu(dx) = \int_{\Omega} T(x) u_j(\vartheta, x) L(\vartheta, x) \mu(dx) \\ &= \mathbb{E}_\vartheta[T u_j(\vartheta, \cdot)]. \end{aligned}$$

Also gilt für alle $\eta \in \mathbb{R}^d$

$$\mathbb{E}_\vartheta[T \langle \eta, u(\vartheta, X) \rangle_{\mathbb{R}^d}] = \langle \eta, \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d}.$$

Es sei

$$\mathcal{Z}_\vartheta = \{Z \in \mathcal{L}^2(\mathbb{P}_\vartheta) : \mathbb{E}_\vartheta[Z] = 0 \text{ und } \text{Var}_\vartheta[Z] > 0\}.$$

Für alle $\eta \in \mathbb{R}^d \setminus \{0\}$ gilt nach Lemma 1.11.2(c), dass $Z := \langle \eta, u(\vartheta, X) \rangle_{\mathbb{R}^d} \in \mathcal{Z}_\vartheta$ mit

$$\text{Var}_\vartheta[Z] = \langle I(\vartheta)\eta, \eta \rangle_{\mathbb{R}^d} > 0.$$

Also folgt mit Lemma 1.11.3

$$\begin{aligned} \sqrt{\text{Var}_\vartheta[T]} &= \max_{Z \in \mathcal{Z}_\vartheta} \frac{\mathbb{E}_\vartheta[TZ]}{\sqrt{\text{Var}_\vartheta[Z]}} \\ &\geq \max_{\eta \in \mathbb{R}^d \setminus \{0\}} \frac{\mathbb{E}_\vartheta[T \langle \eta, u(\vartheta, X) \rangle_{\mathbb{R}^d}]}{\sqrt{\text{Var}_\vartheta[\langle \eta, u(\vartheta, X) \rangle_{\mathbb{R}^d}]} } \\ &= \max_{\eta \in \mathbb{R}^d \setminus \{0\}} \frac{\langle \nabla \tau(\vartheta), \eta \rangle_{\mathbb{R}^d}}{\sqrt{\langle I(\vartheta)\eta, \eta \rangle_{\mathbb{R}^d}}}. \end{aligned}$$

Für $\eta := I(\vartheta)^{-1} \nabla \tau(\vartheta) \in \mathbb{R}^d$ gilt $\eta \neq 0$, da $\nabla \tau(\vartheta) \neq 0$ und $I(\vartheta)^{-1} : \mathbb{R}^d \rightarrow \mathbb{R}^d$ ein Isomorphismus ist. Also folgt

$$\sqrt{\text{Var}_\vartheta[T]} \geq \frac{\langle \nabla \tau(\vartheta), I(\vartheta)^{-1} \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d}}{\sqrt{\langle \nabla \tau(\vartheta), I(\vartheta)^{-1} \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d}}} = \sqrt{\langle I(\vartheta)^{-1} \nabla \tau(\vartheta), \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d}}.$$

□

Definition 1.11.5. *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein mehrdimensionales reguläres statistisches Modell mit $\Theta \subset \mathbb{R}^d$, so dass $I(\vartheta)$ für jedes $\vartheta \in \Theta$ positiv definit ist, $\tau \in C^1(\Theta; \mathbb{R})$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer Schätzer für τ . Dann heißt T Cramer-Rao-optimal, falls

$$\text{Var}_\vartheta[T] = \langle I(\vartheta)^{-1} \nabla \tau(\vartheta), \nabla \tau(\vartheta) \rangle_{\mathbb{R}^d} \quad \text{für alle } \vartheta \in \Theta.$$

Bemerkung 1.11.6. *Ein Cramer-Rao-optimaler Schätzer ist ein gleichmäßig bester Schätzer, aber ein gleichmäßig bester Schätzer braucht nicht Cramer-Rao-optimal zu sein.*

Beispiel 1.11.7. *Wir betrachten das n -fache Gaußmodell. Dann gilt $\Theta = \mathbb{R} \times (0, \infty)$. Es sei $\vartheta = (\mu, \sigma^2) \in \Theta$ beliebig. Bei einer Beobachtung ist die Likelihood-Funktion*

$$\begin{aligned} L(\vartheta, x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \\ &= \exp\left(-\frac{1}{2} \ln(2\pi\sigma^2) - \frac{(x-\mu)^2}{2\sigma^2}\right), \end{aligned}$$

und daher erhalten wir die Log-Likelihood-Funktion

$$\ell(\vartheta, x) = -\frac{1}{2} \ln(2\pi\sigma^2) - \frac{(x - \mu)^2}{2\sigma^2}.$$

Also gilt beim n -fachen Gaußmodell

$$\ell^{\otimes n}(\vartheta, x) = -\frac{n}{2} \ln(2\pi\sigma^2) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}.$$

Es folgt

$$\frac{\partial}{\partial \mu} \ell^{\otimes n}(\vartheta, x) = \sum_{i=1}^n \frac{x_i - \mu}{\sigma^2} = \frac{1}{\sigma} \sum_{i=1}^n \frac{x_i - \mu}{\sigma}$$

und

$$\frac{\partial}{\partial \sigma^2} \ell^{\otimes n}(\vartheta, x) = -\frac{n \cdot 2\pi}{2 \cdot 2\pi\sigma^2} + \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^4} = \frac{1}{2\sigma^2} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^2 - \frac{n}{2\sigma^2}.$$

Also gilt

$$u(\vartheta, x) = \left(\frac{1}{\sigma} \sum_{i=1}^n \frac{x_i - \mu}{\sigma}, \frac{1}{2\sigma^2} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^2 - \frac{n}{2\sigma^2} \right).$$

Wir setzen

$$Y_i := \frac{X_i - \mu}{\sigma}, \quad i = 1, \dots, n.$$

Dann sind Y_1, \dots, Y_n unabhängig mit

$$Y_i \sim N(0, 1), \quad i = 1, \dots, n.$$

Daher gilt

$$\text{Var}_{\vartheta}[u_1(\vartheta, X)] = \text{Var}_{\vartheta} \left[\frac{1}{\sigma} \sum_{i=1}^n Y_i \right] = \frac{1}{\sigma^2} \sum_{i=1}^n \text{Var}_{\vartheta}[Y_i] = \frac{n}{\sigma^2}.$$

Es gilt

$$\sum_{i=1}^n Y_i^2 \sim \chi_n^2,$$

und daher

$$\text{Var} \left[\sum_{i=1}^n Y_i^2 \right] = 2n.$$

Also folgt

$$\begin{aligned} \text{Var}_{\vartheta}[u_2(\vartheta, X)] &= \text{Var}_{\vartheta} \left[\frac{1}{2\sigma^2} \sum_{i=1}^n Y_i^2 - \frac{n}{2\sigma^2} \right] \\ &= \frac{1}{4\sigma^4} \text{Var}_{\vartheta} \left[\sum_{i=1}^n Y_i^2 \right] = \frac{2n}{4\sigma^4} = \frac{n}{2\sigma^4}. \end{aligned}$$

Für $Z \sim N(0, 1)$ gilt

$$\text{Cov}(Z, Z^2) = \mathbb{E}[Z^3] = 0.$$

Also folgt

$$\begin{aligned} \text{Cov}_{\vartheta}(u_1(\vartheta, X), u_2(\vartheta, X)) &= \text{Cov} \left(\frac{1}{\sigma} \sum_{i=1}^n Y_i, \frac{1}{2\sigma^2} \sum_{i=1}^n Y_i^2 \right) \\ &= \frac{1}{2\sigma^3} \sum_{i,j=1}^n \text{Cov}(Y_i, Y_j^2) = 0. \end{aligned}$$

Wir erhalten die Informationsmatrix

$$I(\vartheta) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix}, \quad \vartheta \in \Theta.$$

Also ist $I(\vartheta)$ positiv definit mit

$$I(\vartheta)^{-1} = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}, \quad \vartheta \in \Theta.$$

Nun betrachten wir die Kenngröße $\tau : \Theta \rightarrow \mathbb{R}$ gegeben durch

$$\tau(\vartheta) = \sigma^2, \quad \vartheta = (\mu, \sigma^2) \in \Theta.$$

Dann gilt

$$\nabla \tau(\vartheta) = \begin{pmatrix} 0 \\ 1 \end{pmatrix}.$$

Also folgt

$$\begin{aligned} \langle I(\vartheta)^{-1} \nabla \tau(\vartheta), \nabla \tau(\vartheta) \rangle_{\mathbb{R}^2} &= \left\langle \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix} \cdot \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix} \right\rangle_{\mathbb{R}^2} \\ &= \left\langle \begin{pmatrix} 0 \\ \frac{2\sigma^4}{n} \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix} \right\rangle_{\mathbb{R}^2} = \frac{2\sigma^4}{n}. \end{aligned}$$

Nach Beispiel 1.10.11 ist $s^2(X)$ der eindeutig bestimmte gleichmäßig beste Schätzer für σ^2 . Nach Beispiel 1.5.7(c) gilt jedoch

$$\text{Var}_{\vartheta}[s^2(X)] = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n} = \langle I(\vartheta)^{-1} \nabla \tau(\vartheta), \nabla \tau(\vartheta) \rangle_{\mathbb{R}^2} \quad \text{für alle } \vartheta \in \Theta.$$

Also ist $s^2(X)$ nicht Cramer-Rao-optimal.

1.12 Bayes'sche Schätzer

Wir erinnern nochmal an die Definition eines stochastischen Kerns (siehe Definition 1.8.8).

Definition 1.12.1. Es seien $(\Omega_1, \mathcal{F}_1)$ und $(\Omega_2, \mathcal{F}_2)$ messbare Räume. Eine Abbildung $\kappa : \Omega_1 \times \mathcal{F}_2 \rightarrow [0, 1]$ heißt ein stochastischer Kern von $(\Omega_1, \mathcal{F}_1)$ nach $(\Omega_2, \mathcal{F}_2)$, falls gilt:

- (a) $\omega_1 \mapsto \kappa(\omega_1, A_2)$ ist \mathcal{F}_1 -messbar für jedes $A_2 \in \mathcal{F}_2$.
- (b) $A_2 \mapsto \kappa(\omega_1, A_2)$ ist ein Wahrscheinlichkeitsmaß auf $(\Omega_2, \mathcal{F}_2)$ für jedes $\omega_1 \in \Omega_1$.

Satz 1.12.2. Es seien $(\Omega_1, \mathcal{F}_1, \nu)$ ein Wahrscheinlichkeitsraum, $(\Omega_2, \mathcal{F}_2)$ ein messbarer Raum und κ ein stochastischer Kern von $(\Omega_1, \mathcal{F}_1)$ nach $(\Omega_2, \mathcal{F}_2)$. Dann existiert ein eindeutig bestimmtes Wahrscheinlichkeitsmaß $\nu \otimes \kappa$ auf $(\Omega_1 \times \Omega_2, \mathcal{F}_1 \otimes \mathcal{F}_2)$, so dass

$$(\nu \otimes \kappa)(A_1 \times A_2) = \int_{A_1} \kappa(\omega_1, A_2) \nu(d\omega_1) \quad \text{für alle } A_1 \in \mathcal{F}_1 \text{ und } A_2 \in \mathcal{F}_2.$$

Satz 1.12.3 (Satz von Fubini für stochastische Kerne). Es seien $(\Omega_1, \mathcal{F}_1)$ und $(\Omega_2, \mathcal{F}_2)$ messbare Räume, es sei ν ein Wahrscheinlichkeitsmaß auf $(\Omega_1, \mathcal{F}_1)$, und es sei κ ein stochastischer Kern von $(\Omega_1, \mathcal{F}_1)$ nach $(\Omega_2, \mathcal{F}_2)$. Weiterhin sei

$$f \in \mathcal{L}^1(\Omega_1 \times \Omega_2, \mathcal{F}_1 \otimes \mathcal{F}_2, \nu \otimes \kappa).$$

Dann gilt

$$\int_{\Omega_1 \times \Omega_2} f d(\nu \otimes \kappa) = \int_{\Omega_1} \left(\int_{\Omega_2} f(\omega_1, \omega_2) \kappa(\omega_1, d\omega_2) \right) \nu(d\omega_1).$$

Definition 1.12.4. Ein Paar $(\mathcal{M}, \mathcal{T})$ heißt ein Bayes'sches Modell, falls gilt:

- (a) $\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$ ist ein Standardmodell mit Likelihood-Funktion $L : \Theta \times \Omega \rightarrow \mathbb{R}_+$.
- (b) \mathcal{T} ist eine σ -Algebra über Θ , und die Likelihood-Funktion L ist $\mathcal{T} \otimes \mathcal{F}$ -messbar.

Bemerkung 1.12.5. Die Abbildung $\kappa : \Theta \times \mathcal{F} \rightarrow [0, 1]$ gegeben durch

$$\kappa(\vartheta, A) = \mathbb{P}_\vartheta(A)$$

ist ein stochastischer Kern von (Θ, \mathcal{T}) nach (Ω, \mathcal{F}) . In der Tat, für jedes $A \in \mathcal{F}$ ist

$$\Theta \rightarrow \mathbb{R}, \quad \vartheta \mapsto \mathbb{P}_\vartheta(A) = \int_A L(\vartheta, x) \mu(dx)$$

nach dem Satz von Fubini \mathcal{T} -messbar.

Definition 1.12.6. Es sei $(\mathcal{M}, \mathcal{T})$ ein Bayes'sches Modell. Ein Wahrscheinlichkeitsmaß ν auf (Θ, \mathcal{T}) mit $L(\cdot, x) \in \mathcal{L}^1(\Theta, \mathcal{T}, \nu)$ für jedes $x \in \Omega$ heißt eine a-priori-Verteilung für den Parameter $\vartheta \in \Theta$.

Definition 1.12.7. Es seien $(\mathcal{M}, \mathcal{T})$ ein Bayes'sches Modell, und ν eine a-priori-Verteilung für den Parameter $\vartheta \in \Theta$. Wir bezeichnen mit $\nu \otimes \mathbb{P}$ das gemäß Satz 1.12.2 eindeutig bestimmte Wahrscheinlichkeitsmaß auf $(\Theta \times \Omega, \mathcal{T} \otimes \mathcal{F})$, und nennen es die Mischung der Familie $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$ mit der Verteilung ν .

Korollar 1.12.8. Es seien $(\mathcal{M}, \mathcal{T})$ ein Bayes'sches Modell, und ν eine a-priori-Verteilung für den Parameter $\vartheta \in \Theta$. Für jede Funktion $f \in \mathcal{L}^1(\Theta \times \Omega, \mathcal{T} \otimes \mathcal{F}, \nu \otimes \mathbb{P})$ gilt

$$\int_{\Theta \times \Omega} f d(\nu \otimes \mathbb{P}) = \int_{\Theta} \left(\int_{\Omega} f(\vartheta, x) \mathbb{P}_\vartheta(dx) \right) \nu(d\vartheta) = \int_{\Theta} \mathbb{E}_\vartheta[f(\vartheta, X)] \nu(d\vartheta).$$

Beweis. Folgt aus dem Satz von Fubini für stochastische Kerne (Satz 1.12.3). \square

Definition 1.12.9. Es seien $(\mathcal{M}, \mathcal{T})$ ein Bayes'sches Modell, und ν eine a-priori-Verteilung für den Parameter $\vartheta \in \Theta$.

- (a) Wir definieren $L_\nu : \Omega \rightarrow \mathbb{R}$ durch

$$L_\nu(x) := \int_{\Theta} L(\vartheta, x) \nu(d\vartheta).$$

- (b) Wir definieren $\pi : \Theta \times \Omega \rightarrow \mathbb{R}_+$ durch

$$\pi(\vartheta, x) := \frac{L(\vartheta, x)}{L_\nu(x)}.$$

(c) Für $x \in \Omega$ heißt $\pi(\cdot, x)$ die a-posteriori-Dichte für den Parameter $\vartheta \in \Theta$ gegeben die Beobachtung x .

(d) Für $x \in \Omega$ heißt das Wahrscheinlichkeitsmaß ν_x auf (Θ, \mathcal{F}) mit

$$\frac{d\nu_x}{d\nu} = \pi(\cdot, x)$$

die a-posteriori-Verteilung für den Parameter $\vartheta \in \Theta$ gegeben die Beobachtung x .

Bemerkung 1.12.10. Es gilt

$$\int_{\Theta} \pi(\vartheta, x) \nu(d\vartheta) = 1 \quad \text{für alle } x \in \Omega.$$

Definition 1.12.11. Die Betaverteilung mit Parametern $r, s \in (0, \infty)$ ist die absolutstetige Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{x^{r-1}(1-x)^{s-1}}{B(r, s)} \mathbb{1}_{(0,1)}(x),$$

Wir bezeichnen sie mit $\text{Beta}(r, s)$. Hierbei bezeichnet

$$B : (0, \infty)^2 \rightarrow \mathbb{R}, \quad B(r, s) = \int_0^1 y^{r-1}(1-y)^{s-1} dy$$

die Betafunktion. Es gilt auch

$$B(r, s) = \frac{\Gamma(r)\Gamma(s)}{\Gamma(r+s)}.$$

Beispiel 1.12.12. Wir betrachten das Binomialmodell aus Beispiel 1.1.10. Dann ist $(\mathcal{M}, \mathcal{F})$ wie folgt gegeben:

- $\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_{\vartheta} : \vartheta \in \Theta))$ ist gegeben durch

$$\Omega = \{0, 1, \dots, n\}, \quad \mathcal{F} = \mathfrak{P}(\Omega)$$

und $\mathbb{P}_{\vartheta} = \text{Bi}(n, \vartheta)$ für $\vartheta \in \Theta = (0, 1)$.

- $\mathcal{F} = \mathcal{B}(\Theta)$.

Dann ist $(\mathcal{M}, \mathcal{F})$ ein Bayes'sches Modell. Wir wählen die a-priori-Verteilung

$$\nu = \text{UC}(\Theta).$$

Es sei $k \in \Omega$ beliebig. Wir erhalten als *a-posteriori-Verteilung* ν_k die absolutstetige Verteilung mit *a-posteriori-Dichte*

$$\pi(\vartheta, k) = \frac{\binom{n}{k} \vartheta^k (1 - \vartheta)^{n-k}}{\int_0^1 \binom{n}{k} t^k (1 - t)^{n-k} dt} = \frac{\vartheta^k (1 - \vartheta)^{n-k}}{B(k+1, n-k+1)}, \quad \vartheta \in \Theta.$$

Also gilt

$$\nu_k = \text{Beta}(k+1, n-k+1) \quad \text{für jedes } k \in \Omega.$$

Zur Erinnerung: Der mittlere quadratische Fehler eines Schätzers T ist gegeben durch

$$\mathbb{F}_\vartheta(T) = \mathbb{E}_\vartheta[(T - \tau(\vartheta))^2], \quad \vartheta \in \Theta.$$

Definition 1.12.13. Es seien $(\mathcal{M}, \mathcal{F})$ ein Bayes'sches Modell, und ν eine *a-priori-Verteilung* für den Parameter $\vartheta \in \Theta$. Weiterhin seien $\tau : \Theta \rightarrow \mathbb{R}$ eine messbare Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein Schätzer.

(a) Wir definieren den (über x und ϑ gemittelten) quadratischen Fehler

$$\mathbb{F}_\nu(T) := \int_\Theta \mathbb{F}_\vartheta(T) \nu(d\vartheta).$$

(b) Der Schätzer T heißt ein Bayes-Schätzer zur Kenngröße τ , falls

$$\mathbb{F}_\nu(T) \leq \mathbb{F}_\nu(S)$$

für jeden Schätzer $S : \Omega \rightarrow \mathbb{R}$.

Lemma 1.12.14.

(a) Es gilt

$$\mathbb{F}_\nu(T) = \int_{\Theta \times \Omega} (T(x) - \tau(\vartheta))^2 (\nu \otimes \mathbb{P})(d\vartheta, dx).$$

(b) Es gilt

$$\mathbb{F}_\nu(T) = \int_\Omega \left(\int_\Theta (T(x) - \tau(\vartheta))^2 L(\vartheta, x) \nu(d\vartheta) \right) \mu(dx).$$

Beweis.

(a) Nach dem Satz von Fubini für stochastische Kerne (Satz 1.12.3) gilt

$$\begin{aligned}\mathbb{F}_\nu(T) &= \int_{\Theta} \mathbb{F}_\vartheta(T) \nu(d\vartheta) = \int_{\Theta} \mathbb{E}_\vartheta[(T - \tau(\vartheta))^2] \nu(d\vartheta) \\ &= \int_{\Theta} \left(\int_{\Omega} (T(x) - \tau(\vartheta))^2 \mathbb{P}_\vartheta(dx) \right) \nu(d\vartheta) \\ &= \int_{\Theta \times \Omega} (T(x) - \tau(\vartheta))^2 (\nu \otimes \mathbb{P})(d\vartheta, dx).\end{aligned}$$

(b) Mit dem gewöhnlichen Satz von Fubini erhalten wir

$$\begin{aligned}\mathbb{F}_\nu(T) &= \int_{\Theta} \left(\int_{\Omega} (T(x) - \tau(\vartheta))^2 L(\vartheta, x) \mu(dx) \right) \nu(d\vartheta) \\ &= \int_{\Omega} \left(\int_{\Theta} (T(x) - \tau(\vartheta))^2 L(\vartheta, x) \nu(d\vartheta) \right) \mu(dx).\end{aligned}$$

□

Satz 1.12.15. *Es seien $(\mathcal{M}, \mathcal{F})$ ein Bayes'sches Modell, und ν eine a-priori-Verteilung für den Parameter $\vartheta \in \Theta$. Weiterhin seien $\tau : \Theta \rightarrow \mathbb{R}$ eine messbare Kenngröße mit $\tau \in \mathcal{L}^1(\nu_x)$ für alle $x \in \Omega$. Dann ist*

$$T : \Omega \rightarrow \mathbb{R}, \quad T(x) := \int_{\Theta} \tau(\vartheta) \nu_x(d\vartheta) = \int_{\Theta} \tau(\vartheta) \pi(\vartheta, x) \nu(d\vartheta)$$

ein Bayes-Schätzer zur Kenngröße τ .

Beweis. Es sei $S : \Omega \rightarrow \mathbb{R}$ ein Schätzer. Mit Lemma 1.12.14(b) und der Gleichung $\int_{\Theta} \pi(\vartheta, x) \nu(d\vartheta) = 1$ (siehe Bemerkung 1.12.10) für alle $x \in \Omega$ folgt

$$\begin{aligned}\mathbb{F}_\nu(S) - \mathbb{F}_\nu(T) &= \int_{\Omega} \left(\int_{\Theta} [(S(x) - \tau(\vartheta))^2 - (T(x) - \tau(\vartheta))^2] L(\vartheta, x) \nu(d\vartheta) \right) \mu(dx) \\ &= \int_{\Omega} \left(\int_{\Theta} [S(x)^2 - 2S(x)\tau(\vartheta) - T(x)^2 + 2T(x)\tau(\vartheta)] L(\vartheta, x) \nu(d\vartheta) \right) \mu(dx) \\ &= \int_{\Omega} L_\nu(x) \left(\int_{\Theta} [S(x)^2 - 2S(x)\tau(\vartheta) - T(x)^2 + 2T(x)\tau(\vartheta)] \pi(\vartheta, x) \nu(d\vartheta) \right) \mu(dx) \\ &= \int_{\Omega} L_\nu(x) [S(x)^2 - 2S(x)T(x) - T(x)^2 + 2T(x)^2] \mu(dx) \\ &= \int_{\Omega} L_\nu(x) (S(x) - T(x))^2 \mu(dx) \geq 0.\end{aligned}$$

□

Beispiel 1.12.16. *Beim Binomialmodell aus Beispiel 1.12.12 betrachten wir die Kenngröße $\tau : \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) = \vartheta$. Wir erhalten den Bayes-Schätzer*

$$\begin{aligned} T(k) &= \int_{\Theta} \vartheta \pi(\vartheta, k) \nu(d\vartheta) = \frac{1}{B(k+1, n-k+1)} \int_0^1 \vartheta^{k+1} (1-\vartheta)^{n-k} d\vartheta \\ &= \frac{B(k+2, n-k+1)}{B(k+1, n-k+1)} = \frac{\Gamma(k+2)\Gamma(n-k+1)}{\Gamma(n+3)} \cdot \frac{\Gamma(n+2)}{\Gamma(k+1)\Gamma(n-k+1)} \\ &= \frac{\Gamma(k+2) \cdot \Gamma(n+2)}{\Gamma(n+3) \cdot \Gamma(k+1)} = \frac{(k+1)! \cdot (n+1)!}{(n+2)! \cdot k!} = \frac{k+1}{n+2}. \end{aligned}$$

Hierbei haben wir benutzt, dass $\Gamma(n+1) = n!$ für alle $n \in \mathbb{N}_0$. Also gilt

$$T = \frac{X+1}{n+2};$$

vergleiche Beispiel 1.5.4.

Kapitel 2

Bereichsschätzer

2.1 Definitionen und Eigenschaften

Definition 2.1.1. *Es seien*

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell, und $\tau : \Theta \rightarrow E$ eine Kenngröße mit Werten in einem messbaren Raum (E, \mathcal{E}) .

(a) *Ein Abbildung $C : \Omega \rightarrow \mathcal{E}$ heißt ein Bereichsschätzer.*

(b) *Für $\alpha \in (0, 1)$ heißt ein Bereichsschätzer C eine Konfidenzmenge (oder ein Konfidenzbereich) für τ zum Niveau α , falls $\{\tau(\vartheta) \in C\} \in \mathcal{F}$ und*

$$\mathbb{P}_\vartheta(\tau(\vartheta) \in C) \geq 1 - \alpha \quad \text{für alle } \vartheta \in \Theta.$$

(c) *Gilt $(E, \mathcal{E}) = (\mathbb{R}, \mathcal{B}(\mathbb{R}))$, und ist C von der Form $C = [\underline{T}, \overline{T}]$ mit zwei Statistiken $\underline{T} \leq \overline{T}$, so nennen wir C auch ein Konfidenzintervall. In diesem Fall gilt automatisch*

$$\{\tau(\vartheta) \in C\} = \{\underline{T} \leq \tau(\vartheta) \leq \overline{T}\} = \{\underline{T} \leq \tau(\vartheta)\} \cap \{\tau(\vartheta) \leq \overline{T}\} \in \mathcal{F}$$

für jedes $\vartheta \in \Theta$.

Lemma 2.1.2. *Für beliebige Ereignisse $A_1, \dots, A_m \in \mathcal{F}$ gilt*

$$\mathbb{P}\left(\bigcap_{j=1}^m A_j\right) \geq 1 - \sum_{j=1}^m \mathbb{P}(A_j^c).$$

Beweis. Nach den De Morgan'schen Gesetzen und der σ -Subadditivität von \mathbb{P} gilt

$$\mathbb{P}\left(\bigcap_{j=1}^m A_j\right) = \mathbb{P}\left(\left(\bigcup_{j=1}^m A_j^c\right)^c\right) = 1 - \mathbb{P}\left(\bigcup_{j=1}^m A_j^c\right) \geq 1 - \sum_{j=1}^m \mathbb{P}(A_j^c).$$

□

Satz 2.1.3. *Es seien $\tau_i : \Theta \rightarrow E_i$ Kenngrößen mit Werten in einem messbaren Raum (E_i, \mathcal{E}_i) für $i = 1, \dots, m$, und es seien $\alpha \in (0, 1)$ und $\alpha_i \in (0, 1)$, $i = 1, \dots, m$, so dass $\alpha = \alpha_1 + \dots + \alpha_m$. Weiterhin seien $C_i : \Omega \rightarrow \mathcal{E}_i$ Konfidenzmengen für τ_i zum Niveau α_i für $i = 1, \dots, m$. Dann ist $C : \Omega \rightarrow \mathcal{E}_1 \otimes \dots \otimes \mathcal{E}_m$ gegeben durch $C := (C_1, \dots, C_m)$ eine Konfidenzmenge für $\tau : \Theta \rightarrow E_1 \times \dots \times E_m$ gegeben durch $\tau := (\tau_1, \dots, \tau_m)$ zum Niveau α .*

Beweis. Für jedes $\vartheta \in \Theta$ gilt

$$\{\tau(\vartheta) \in C\} = \bigcap_{j=1}^m \underbrace{\{\tau_j(\vartheta) \in C_j\}}_{\in \mathcal{F}},$$

und nach Lemma 2.1.2 gilt

$$\begin{aligned} \mathbb{P}_\vartheta(\tau(\vartheta) \in C) &= \mathbb{P}_\vartheta\left(\bigcap_{j=1}^m \{\tau_j(\vartheta) \in C_j\}\right) \\ &\geq 1 - \sum_{j=1}^m \mathbb{P}_\vartheta(\tau_j(\vartheta) \notin C_j) \geq 1 - \sum_{j=1}^m \alpha_j = 1 - \alpha. \end{aligned}$$

□

Definition 2.1.4. *Eine Abbildung $\pi : \Theta \times \Omega \rightarrow E$ heißt eine Pivot-Statistik (oder ein Pivot), falls gilt:*

- (a) Für jedes $\vartheta \in \Theta$ ist $\pi(\vartheta, \cdot) : (\Omega, \mathcal{F}) \rightarrow (E, \mathcal{E})$ messbar.
- (b) Es existiert ein Wahrscheinlichkeitsmaß η auf (E, \mathcal{E}) , so dass

$$\mathbb{P}_\vartheta \circ \pi(\vartheta, \cdot) = \eta \quad \text{für alle } \vartheta \in \Theta.$$

In diesem Fall nennen wir η die zugehörige Pivot-Verteilung.

Satz 2.1.5. *Es sei π eine Pivot-Statistik mit Pivot-Verteilung η . Es seien $\alpha \in (0, 1)$ und $B \in \mathcal{E}$, so dass*

$$\eta(B) \geq 1 - \alpha.$$

Weiterhin sei $C : \Omega \rightarrow \mathcal{E}$ eine Abbildung, so dass

$$\{\tau(\vartheta) \in C\} = \{\pi(\vartheta, \cdot) \in B\} \quad \text{für jedes } \vartheta \in \Theta.$$

Dann ist C eine Konfidenzmenge für τ zum Niveau α .

Beweis. Für jedes $\vartheta \in \Theta$ gilt

$$\{\tau(\vartheta) \in C\} = \{\pi(\vartheta, \cdot) \in B\} \in \mathcal{F}$$

und

$$\mathbb{P}_\vartheta(\tau(\vartheta) \in C) = \mathbb{P}_\vartheta(\pi(\vartheta, \cdot) \in B) = \eta(B) \geq 1 - \alpha.$$

□

2.2 Bereichsschätzer in Gaußmodellen

Definition 2.2.1. Es sei $n \in \mathbb{N}$ beliebig.

- (a) Wir nennen $\chi_n^2 = \Gamma(\frac{n}{2}, \frac{1}{2})$ eine Chi-Quadrat-Verteilung mit n Freiheitsgraden. Ihre Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ ist gegeben durch

$$f(x) = \frac{1}{2^{n/2} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} \mathbb{1}_{(0, \infty)}(x), \quad x \in \mathbb{R}.$$

- (b) Wir nennen die absolutstetige Verteilung t_n auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi} \Gamma(\frac{n}{2})} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}, \quad x \in \mathbb{R}$$

eine t-Verteilung mit n Freiheitsgraden.

Satz 2.2.2. Es sei $n \in \mathbb{N}$ beliebig.

- (a) Es seien $X_1, \dots, X_n \sim N(0, 1)$ unabhängige, standardnormalverteilte Zufallsvariablen. Dann gilt

$$\sum_{i=1}^n X_i^2 \sim \chi_n^2.$$

- (b) Es seien $X \sim N(0, 1)$ und $Y \sim \chi_n^2$ unabhängige Zufallsvariablen. Dann gilt

$$\frac{X}{\sqrt{Y/n}} \sim t_n.$$

Beweis. Übung.

□

Satz 2.2.3. *Es seien $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ unabhängige, normalverteilte Zufallsvariablen. Dann sind \bar{X} und $s^2(X)$ unabhängig mit*

$$\frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}} \sim N(0, 1), \quad \frac{n-1}{\sigma^2} s^2(X) \sim \chi_{n-1}^2 \quad \text{und} \quad \frac{\bar{X} - \mu}{\sqrt{s^2(X)/n}} \sim t_{n-1}.$$

Beweis. Nach Satz 1.4.17 sind \bar{X} und $s^2(X)$ unabhängig, und es gilt

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \quad \text{und} \quad Z := \frac{n-1}{\sigma^2} s^2(X) \sim \chi_{n-1}^2.$$

Also gilt

$$Y := \frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}} \sim N(0, 1).$$

Die Zufallsvariablen Y und Z sind ebenfalls unabhängig, und mit Satz 2.2.2(b) folgt

$$\frac{\bar{X} - \mu}{\sqrt{s^2(X)/n}} = \frac{Y}{\sqrt{Z/(n-1)}} \sim t_{n-1}.$$

□

Definition 2.2.4. *Für $a \in (0, 1)$ bezeichnen wir mit $z_a := \Phi^{-1}(a)$ das a -Quantil der Standardnormalverteilung. Hierbei bezeichnet $\Phi : \mathbb{R} \rightarrow [0, 1]$ die Verteilungsfunktion von $N(0, 1)$.*

Im Folgenden benutzen wir für $a \in \mathbb{R}$ und $\epsilon > 0$ die Schreibweise

$$a \pm \epsilon := [a - \epsilon, a + \epsilon].$$

Satz 2.2.5. *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$.*

(a) *Die Zufallsvariable*

$$\pi(\mu, \cdot) = \frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}}$$

ist eine Pivot-Statistik mit Pivot-Verteilung $\eta = N(0, 1)$.

(b) *Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch*

$$C = \bar{X} \pm z_{1-\alpha/2} \sqrt{\sigma^2/n}$$

ein Konfidenzintervall für μ zum Niveau α .

Beweis.

(a) Folgt aus Satz 2.2.3.

(b) Mit $c := z_{1-\alpha/2}$ und $B = [-c, c]$ gilt wegen der Symmetrie der Dichte

$$\begin{aligned}\eta(B) &= \eta((-\infty, c]) - \eta((-\infty, -c)) = \Phi(c) - \Phi(-c) = \Phi(c) - (1 - \Phi(c)) \\ &= 2\Phi(c) - 1 = 2\left(1 - \frac{\alpha}{2}\right) - 1 = 1 - \alpha,\end{aligned}$$

und für jedes $\mu \in \mathbb{R}$ gilt

$$\begin{aligned}\{\mu \in C\} &= \left\{\mu \in \bar{X} \pm c\sqrt{\sigma^2/n}\right\} = \left\{\bar{X} - c\sqrt{\sigma^2/n} \leq \mu \leq \bar{X} + c\sqrt{\sigma^2/n}\right\} \\ &= \left\{\bar{X} - \mu - c\sqrt{\sigma^2/n} \leq 0 \leq \bar{X} - \mu + c\sqrt{\sigma^2/n}\right\} \\ &= \{\pi(\mu, \cdot) - c \leq 0 \leq \pi(\mu, \cdot) + c\} = \{|\pi(\mu, \cdot)| \leq c\} = \{\pi(\mu, \cdot) \in B\}.\end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

□

Satz 2.2.6. *Wir betrachten das n -fache Gaußmodell mit bekanntem Erwartungswert $\mu \in \mathbb{R}$, und setzen*

$$\tilde{\sigma}^2(X) := \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2.$$

(a) *Die Zufallsvariable*

$$\pi(\sigma^2, \cdot) = \frac{n\tilde{\sigma}^2(X)}{\sigma^2}$$

ist eine Pivot-Statistik mit Pivot-Verteilung $\eta = \chi_n^2$.

(b) *Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch*

$$C = \left[\frac{n\tilde{\sigma}^2(X)}{\chi_{n,1-\alpha/2}^2}, \frac{n\tilde{\sigma}^2(X)}{\chi_{n,\alpha/2}^2} \right]$$

ein Konfidenzintervall für σ^2 zum Niveau α .

Beweis.

(a) Mit Satz 2.2.2(a) folgt

$$\pi(\sigma^2, \cdot) = \frac{n\tilde{\sigma}^2(X)}{\sigma^2} = \sum_{i=1}^n \underbrace{\left(\frac{X_i - \mu}{\sigma} \right)^2}_{\sim N(0,1)} \sim \chi_n^2.$$

(b) Es sei F die Verteilungsfunktion von η . Mit $B = [\chi_{n,\alpha/2}^2, \chi_{n,1-\alpha/2}^2]$ gilt

$$\begin{aligned} \eta(B) &= \eta((-\infty, \chi_{n-d,1-\alpha/2}^2]) - \eta((-\infty, \chi_{n-d,\alpha/2}^2)) \\ &= F(\chi_{n-d,1-\alpha/2}^2) - F(\chi_{n-d,\alpha/2}^2) = \left(1 - \frac{\alpha}{2}\right) - \frac{\alpha}{2} = 1 - \alpha, \end{aligned}$$

und für jedes $\sigma^2 > 0$ gilt

$$\begin{aligned} \{\sigma^2 \in C\} &= \left\{ \sigma^2 \in \left[\frac{n\tilde{\sigma}^2(X)}{\chi_{n,1-\alpha/2}^2}, \frac{n\tilde{\sigma}^2(X)}{\chi_{n,\alpha/2}^2} \right] \right\} = \left\{ \frac{n\tilde{\sigma}^2(X)}{\chi_{n,1-\alpha/2}^2} \leq \sigma^2 \leq \frac{n\tilde{\sigma}^2(X)}{\chi_{n,\alpha/2}^2} \right\} \\ &= \left\{ \frac{1}{\chi_{n,1-\alpha/2}^2} \leq \frac{1}{\pi(\sigma^2, \cdot)} \leq \frac{1}{\chi_{n,\alpha/2}^2} \right\} = \{ \chi_{n,\alpha/2}^2 \leq \pi(\sigma^2, \cdot) \leq \chi_{n,1-\alpha/2}^2 \} \\ &= \{ \pi(\sigma^2, \cdot) \in B \}. \end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

□

Satz 2.2.7. Wir betrachten das n -fache Gaußmodell mit $\Theta = \mathbb{R} \times (0, \infty)$.

(a) Die Zufallsvariable

$$\pi_1(\vartheta, \cdot) = \frac{\bar{X} - \mu}{\sqrt{s^2(X)/n}}, \quad \vartheta = (\mu, \sigma^2)$$

ist eine Pivot-Statistik mit Pivot-Verteilung $\eta_1 = t_{n-1}$.

(b) Die Zufallsvariable

$$\pi_2(\vartheta, \cdot) = \frac{n-1}{\sigma^2} s^2(X), \quad \vartheta = (\mu, \sigma^2)$$

ist eine Pivot-Statistik mit Pivot-Verteilung $\eta_2 = \chi_{n-1}^2$.

(c) Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C_1 : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch

$$C_1 = \bar{X} \pm t_{n-1,1-\alpha/2} \sqrt{s^2(X)/n}$$

ein Konfidenzintervall für μ zum Niveau α .

(d) Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C_2 : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch

$$C_2 = \left[\frac{n-1}{\chi_{n-1, 1-\alpha/2}^2} s^2(X), \frac{n-1}{\chi_{n-1, \alpha/2}^2} s^2(X) \right]$$

ein Konfidenzintervall für σ^2 zum Niveau α .

(e) Für jedes $\alpha \in (0, 1)$ ist das Zufallsrechteck $C : \Omega \rightarrow \mathcal{B}(\mathbb{R}^2)$ gegeben durch

$$\left(\bar{X} \pm t_{n-1, 1-\alpha/4} \sqrt{s^2(X)/n} \right) \times \left[\frac{n-1}{\chi_{n-1, 1-\alpha/4}^2} s^2(X), \frac{n-1}{\chi_{n-1, \alpha/4}^2} s^2(X) \right]$$

ist ein Konfidenzbereich für $\vartheta = (\mu, \sigma^2)$ zum Niveau α .

Beweis.

(a) Folgt aus Satz 2.2.3.

(b) Folgt aus Satz 2.2.3.

(c) Mit $c := t_{n-1, 1-\alpha/2}$ und $B = [-c, c]$ gilt wegen der Symmetrie der Dichte

$$\begin{aligned} \eta_1(B) &= \eta((-\infty, c]) - \eta((-\infty, -c)) = \Phi(c) - \Phi(-c) = \Phi(c) - (1 - \Phi(c)) \\ &= 2\Phi(c) - 1 = 2\left(1 - \frac{\alpha}{2}\right) - 1 = 1 - \alpha, \end{aligned}$$

und für alle $\vartheta = (\mu, \sigma^2) \in \mathbb{R} \times (0, \infty)$ gilt

$$\begin{aligned} \{\mu \in C_1\} &= \left\{ \mu \in \bar{X} \pm c \sqrt{s^2(X)/n} \right\} \\ &= \left\{ \bar{X} - c \sqrt{s^2(X)/n} \leq \mu \leq \bar{X} + c \sqrt{s^2(X)/n} \right\} \\ &= \left\{ \bar{X} - \mu - c \sqrt{s^2(X)/n} \leq 0 \leq \bar{X} - \mu + c \sqrt{s^2(X)/n} \right\} \\ &= \{ \pi_1(\vartheta, \cdot) - c \leq 0 \leq \pi_1(\vartheta, \cdot) + c \} \\ &= \{ |\pi_1(\vartheta, \cdot)| \leq c \} = \{ \pi_1(\vartheta, \cdot) \in B \}. \end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

(d) Es sei F die Verteilungsfunktion von η_2 . Mit $B = [\chi_{n-1, \alpha/2}^2, \chi_{n-1, 1-\alpha/2}^2]$ gilt

$$\begin{aligned} \eta_2(B) &= \eta_2((-\infty, \chi_{n-d, 1-\alpha/2}^2]) - \eta_2((-\infty, \chi_{n-d, \alpha/2}^2)) \\ &= F(\chi_{n-d, 1-\alpha/2}^2) - F(\chi_{n-d, \alpha/2}^2) = \left(1 - \frac{\alpha}{2}\right) - \frac{\alpha}{2} = 1 - \alpha, \end{aligned}$$

und für alle $\vartheta = (\mu, \sigma^2) \in \mathbb{R} \times (0, \infty)$ gilt

$$\begin{aligned}\{\sigma^2 \in C_2\} &= \left\{ \sigma^2 \in \left[\frac{n-1}{\chi_{n-1,1-\alpha/2}^2} s^2(X), \frac{n-1}{\chi_{n-1,\alpha/2}^2} s^2(X) \right] \right\} \\ &= \left\{ \frac{n-1}{\chi_{n-1,1-\alpha/2}^2} s^2(X) \leq \sigma^2 \leq \frac{n-1}{\chi_{n-1,\alpha/2}^2} s^2(X) \right\} \\ &= \left\{ \frac{1}{\chi_{n-1,1-\alpha/2}^2} \leq \frac{1}{\pi_2(\vartheta, \cdot)} \leq \frac{1}{\chi_{n-1,\alpha/2}^2} \right\} \\ &= \{ \chi_{n-1,\alpha/2}^2 \leq \pi_2(\vartheta, \cdot) \leq \chi_{n-1,1-\alpha/2}^2 \} \\ &= \{ \pi_2(\vartheta, \cdot) \in B \}.\end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

(e) Folgt aus den Teilen (c) und (d) sowie Satz 2.1.3.

□

Kapitel 3

Hypothesentests

3.1 Definitionen und grundlegende Eigenschaften

Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell. Es seien $\Theta_0, \Theta_1 \subset \Theta$ zwei Teilmengen, so dass $\Theta_0 \cap \Theta_1 = \emptyset$ und $\Theta = \Theta_0 \cup \Theta_1$.

Definition 3.1.1.

- (a) Wir nennen $H_0 = \{\vartheta \in \Theta_0\}$ die Null-Hypothese.
- (b) Wir nennen $H_1 = \{\vartheta \in \Theta_1\}$ die Alternative.
- (c) Ist $\Theta_0 = \{\vartheta_0\}$ für ein $\vartheta_0 \in \Theta$, so sprechen wir von einer einfachen Hypothese, ansonsten von einer zusammengesetzten Hypothese.
- (d) Sind $\Theta \subset \mathbb{R}$ und $\Theta_1 = \{\vartheta \in \Theta : \vartheta \neq \vartheta_0\}$ für ein $\vartheta_0 \in \Theta$, so nennen wir die Alternative zweiseitig.
- (e) Sind $\Theta \subset \mathbb{R}$ und $\Theta_1 = \{\vartheta \in \Theta : \vartheta > \vartheta_0\}$ für ein $\vartheta_0 \in \Theta$, so nennen wir die Alternative einseitig.

Definition 3.1.2. Eine Statistik $\varphi : \Omega \rightarrow \{0, 1\}$ heißt ein Test (von H_0 gegen H_1).

- Falls $\varphi(x) = 0$ für eine Beobachtung $x \in \Omega$, so wird die Null-Hypothese H_0 akzeptiert.
- Falls $\varphi(x) = 1$ für eine Beobachtung $x \in \Omega$, so wird die Null-Hypothese H_0 verworfen; das heißt, die Alternative H_1 wird akzeptiert.

Bemerkung 3.1.3. Jeder Test ist also von der Form $\varphi = \mathbb{1}_A$ für eine Menge $A \in \mathcal{F}$.

Definition 3.1.4.

- (a) Eine Entscheidung für H_1 , obwohl H_0 richtig ist, heißt ein Fehler 1. Art.
- (b) Eine Entscheidung für H_0 , obwohl H_1 richtig ist, heißt ein Fehler 2. Art.

Bemerkung 3.1.5. Es können also folgende Arten von Fehlern entstehen:

	H_0 wahr	H_1 wahr
H_0 wird akzeptiert	kein Fehler	Fehler 2. Art
H_0 wird verworfen	Fehler 1. Art	kein Fehler

Beispiel 3.1.6. Ein Unternehmen hat ein Medikament entwickelt, das angeblich in weniger als 5% der Anwendungen schädliche Nebenwirkungen hat. Wir betrachten die Null-Hypothese $H_0 = \{\vartheta \geq 0.05\}$ und die Alternative $H_1 = \{\vartheta < 0.05\}$.

	$H_0 = \{\vartheta \geq 0.05\}$	$H_1 = \{\vartheta < 0.05\}$
H_0 wird akzeptiert	kein Fehler	Fehler 2. Art: Das Medikament ist unschädlich, man hält es jedoch für schädlich.
H_0 wird verworfen	Fehler 1. Art!! Das Medikament ist schädlich, man hält es jedoch für unschädlich.	kein Fehler

Definition 3.1.7. Für einen Test φ ist die Gütefunktion $G_\varphi : \Theta \rightarrow [0, 1]$ definiert durch

$$G_\varphi(\vartheta) := \mathbb{E}_\vartheta[\varphi], \quad \vartheta \in \Theta.$$

Bemerkung 3.1.8. Bekanntlich ist jeder Test ist also von der Form $\varphi = \mathbb{1}_A$ für eine Menge $A \in \mathcal{F}$. Für jedes $\vartheta \in \Theta$ ist $G_\varphi(\vartheta) = \mathbb{P}_\vartheta(A)$ die Wahrscheinlichkeit unter \mathbb{P}_ϑ , sich für die Alternative H_1 zu entscheiden. Insbesondere gilt also:

- Falls $\vartheta \in \Theta_0$, so ist $G_\varphi(\vartheta)$ die Wahrscheinlichkeit unter \mathbb{P}_ϑ , einen Fehler 1. Art zu begehen.
- Falls $\vartheta \in \Theta_1$, so ist $1 - G_\varphi(\vartheta)$ die Wahrscheinlichkeit unter \mathbb{P}_ϑ , einen Fehler 2. Art zu begehen.

Wir werden einen Test also als gut ansehen, wenn mit primärer Priorität $G_\varphi|_{\Theta_0}$ klein (siehe Definition 3.1.9) und mit sekundärer Priorität $G_\varphi|_{\Theta_1}$ groß (siehe Definitionen 3.1.11 und 3.1.13) ist.

Definition 3.1.9. Es seien φ ein Test und $\alpha \in (0, 1)$.

(a) Der Test φ heißt zulässig zum Irrtumsniveau α , falls

$$\sup_{\vartheta \in \Theta_0} G_\varphi(\vartheta) \leq \alpha.$$

In diesem Fall sagen wir auch, dass der Test φ das Signifikanzniveau α hat.

(b) Der Test φ heißt ein Level- α -Test, falls

$$\sup_{\vartheta \in \Theta_0} G_\varphi(\vartheta) = \alpha.$$

Satz 3.1.10 (Zweiseitiger Gauß-Test für μ). Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$. Wir zerlegen $\Theta = \mathbb{R}$ in

$$\Theta_0 = \{\mu_0\} \quad \text{und} \quad \Theta_1 = \mathbb{R} \setminus \{\mu_0\}$$

für ein $\mu_0 \in \mathbb{R}$. Dann erhalten wir die Null-Hypothese $H_0 = \{\mu = \mu_0\}$ und die Alternative $H_1 = \{\mu \neq \mu_0\}$. Weiterhin sei $\alpha \in (0, 1)$ gegeben. Für $c \in \mathbb{R}$ definieren wir den Test

$$\varphi_c := \mathbb{1}_{\{|\bar{X} - \mu_0| \geq c\}}.$$

Dann gelten folgende Aussagen:

(a) Für jedes $c \geq \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}$ ist der Test φ_c zulässig zum Irrtumsniveau α .

(b) Für $c = \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}$ ist φ_c ein Level- α -Test.

Beweis. Es gilt nach Satz 2.2.3

$$\begin{aligned} G_{\varphi_c}(\mu_0) &= \mathbb{E}_{\mu_0}[\varphi_c] = \mathbb{E}_{\mu_0}[\mathbb{1}_{\{|\bar{X} - \mu_0| \geq c\}}] = \mathbb{P}_{\mu_0}(|\bar{X} - \mu_0| \geq c) \\ &= 1 - \mathbb{P}_{\mu_0}(-c < \bar{X} - \mu_0 < c) \\ &= 1 - \mathbb{P}_{\mu_0}\left(-\frac{c}{\sqrt{\sigma^2/n}} < \underbrace{\frac{\bar{X} - \mu_0}{\sqrt{\sigma^2/n}}}_{\sim N(0,1)} < \frac{c}{\sqrt{\sigma^2/n}}\right) \\ &= 1 - \left[\Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right) - \Phi\left(-\frac{c}{\sqrt{\sigma^2/n}}\right)\right] \\ &= 2\left[1 - \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right)\right]. \end{aligned}$$

(a) Also erhalten wir

$$\begin{aligned}
 G_{\varphi_c}(\mu_0) &\leq \alpha \\
 \Leftrightarrow 1 - \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right) &\leq \frac{\alpha}{2} \\
 \Leftrightarrow \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right) &\geq 1 - \frac{\alpha}{2} \\
 \Leftrightarrow \frac{c}{\sqrt{\sigma^2/n}} &\geq z_{1-\alpha/2} \\
 \Leftrightarrow c &\geq \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}.
 \end{aligned}$$

(b) Analog erhalten wir

$$G_{\varphi_c}(\mu_0) = \alpha \quad \Leftrightarrow \quad c = \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}.$$

□

Definition 3.1.11. *Es sei $\alpha \in (0, 1)$ beliebig. Es sei φ ein Test, der zulässig zum Irrtumsniveau α ist. Weiterhin sei $\beta \in (0, 1)$ beliebig. Eine Teilmenge $\Gamma_1 \subset \Theta_1$ heißt eine Indifferenzzone von φ zu den Irrtumsniveaus α und β , falls*

$$\sup_{\vartheta \in \Delta_1} (1 - G_{\varphi}(\vartheta)) \leq \beta,$$

wobei $\Delta_1 \subset \Theta_1$ gegeben ist durch $\Delta_1 := \Theta_1 \setminus \Gamma_1$.

Satz 3.1.12 (Einseitiger Gauß-Test für μ). *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$ mit einer nichtleeren, beliebigen Teilmenge $\Theta \subset \mathbb{R}$. Wir wählen $\mu_0 \in \Theta$ und zerlegen Θ in*

$$\Theta_0 = \{\mu \in \Theta : \mu \leq \mu_0\} \quad \text{und} \quad \Theta_1 = \{\mu \in \Theta : \mu > \mu_0\}.$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\mu \leq \mu_0\}$ und die Alternative $H_1 = \{\mu > \mu_0\}$. Weiterhin sei $\alpha \in (0, 1)$ gegeben. Für $c \in \mathbb{R}$ definieren wir den Test

$$\varphi_c := \mathbb{1}_{\{\bar{X} - \mu_0 \geq c\}}.$$

Dann gelten folgende Aussagen:

(a) *Die Gütefunktion $G_{\varphi_c} : \Theta \rightarrow \mathbb{R}$ ist gegeben durch*

$$G_{\varphi_c}(\mu) = 1 - \Phi\left(\frac{c + \mu_0 - \mu}{\sqrt{\sigma^2/n}}\right), \quad \mu \in \Theta.$$

- (b) Insbesondere ist die Gütefunktion $G_{\varphi_c} : \Theta \rightarrow \mathbb{R}$ monoton wachsend.
- (c) Für jedes $c \geq \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$ ist der Test φ_c zulässig zum Irrtumsniveau α .
- (d) Für $c := \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$ ist φ_c ein Level- α -Test.
- (e) Es sei $c := \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$. Für alle $\beta \in (0, 1)$ und $\nu_0 > \mu_0$ ist $(\mu_0, \nu_0) \cap \Theta_1$ genau dann eine Indifferenzzone von φ_c zu den Irrtumsniveaus α und β , wenn

$$n \geq \frac{\sigma^2(z_{1-\alpha} - z_\beta)^2}{(\nu_0 - \mu_0)^2}.$$

Beweis.

- (a) Für jedes $\mu \in \Theta_0$ gilt nach Satz 2.2.3

$$\begin{aligned} G_{\varphi_c}(\mu) &= \mathbb{E}_\mu[\varphi_c(X)] = \mathbb{E}_\mu[\mathbb{1}_{\{\bar{X} - \mu_0 \geq c\}}] = \mathbb{P}_\mu(\bar{X} \geq c + \mu_0) \\ &= \mathbb{P}_\mu\left(\underbrace{\frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}}}_{\sim N(0,1)} \geq \frac{c + \mu_0 - \mu}{\sqrt{\sigma^2/n}}\right) = 1 - \Phi\left(\frac{c + \mu_0 - \mu}{\sqrt{\sigma^2/n}}\right). \end{aligned}$$

- (b) ✓

- (c) Es folgt

$$\sup_{\mu \in \Theta_0} G_{\varphi_c}(\mu) = 1 - \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right).$$

Somit erhalten wir

$$\begin{aligned} \sup_{\mu \in \Theta_0} G_{\varphi_c}(\mu) &\leq \alpha \\ \Leftrightarrow 1 - \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right) &\leq \alpha \\ \Leftrightarrow \Phi\left(\frac{c}{\sqrt{\sigma^2/n}}\right) &\geq 1 - \alpha \\ \Leftrightarrow \frac{c}{\sqrt{\sigma^2/n}} &\geq z_{1-\alpha} \\ \Leftrightarrow c &\geq \sqrt{\sigma^2/n} \cdot z_{1-\alpha}. \end{aligned}$$

- (d) Analog erhalten wir

$$\sup_{\mu \in \Theta_0} G_{\varphi_c}(\mu) = \alpha \quad \Leftrightarrow \quad c = \sqrt{\sigma^2/n} \cdot z_{1-\alpha}.$$

(e) Es sei $\mu \geq \nu_0$ beliebig. Nach Teil (a) gilt

$$G_\varphi(\mu) = 1 - \Phi\left(\frac{c + \mu_0 - \mu}{\sqrt{\sigma^2/n}}\right) = 1 - \Phi\left(z_{1-\alpha} - \frac{\mu - \mu_0}{\sqrt{\sigma^2/n}}\right).$$

Also gilt

$$1 - G_\varphi(\mu) = \Phi\left(z_{1-\alpha} - \frac{\mu - \mu_0}{\sqrt{\sigma^2/n}}\right) \quad \text{für alle } \mu \geq \nu_0,$$

und somit

$$\sup_{\mu \geq \nu_0} (1 - G_\varphi(\mu)) = \Phi\left(z_{1-\alpha} - \frac{\nu_0 - \mu_0}{\sqrt{\sigma^2/n}}\right).$$

Daraus folgt

$$\begin{aligned} \sup_{\mu \geq \Delta} (1 - G_\varphi(\mu)) &\leq \beta \\ \Leftrightarrow \Phi\left(z_{1-\alpha} - \frac{\nu_0 - \mu_0}{\sqrt{\sigma^2/n}}\right) &\leq \beta \\ \Leftrightarrow z_{1-\alpha} - \frac{\nu_0 - \mu_0}{\sqrt{\sigma^2/n}} &\leq z_\beta \\ \Leftrightarrow z_{1-\alpha} - z_\beta &\leq \frac{\nu_0 - \mu_0}{\sqrt{\sigma^2/n}} \\ \Leftrightarrow \sqrt{n} &\geq \frac{\sigma(z_{1-\alpha} - z_\beta)}{\nu_0 - \mu_0} \\ \Leftrightarrow n &\geq \frac{\sigma^2(z_{1-\alpha} - z_\beta)^2}{(\nu_0 - \mu_0)^2}. \end{aligned}$$

□

Definition 3.1.13. Es sei $\alpha \in (0, 1)$ beliebig. Ein Test φ heißt ein gleichmäßig bester Test zum Irrtumsniveau α (von H_0 gegen H_1), falls gilt:

(a) Der Test φ ist zulässig zum Irrtumsniveau α .

(b) Es gilt

$$G_\varphi(\vartheta) \geq G_\psi(\vartheta) \quad \text{für alle } \vartheta \in \Theta_1$$

und für jeden zulässigen Test ψ (von H_0 gegen H_1) zum Irrtumsniveau α .

3.2 Das Neymann-Pearson-Lemma

Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein Standardmodell mit $\Theta = \{\vartheta_0, \vartheta_1\}$ für $\vartheta_0 \neq \vartheta_1$. Wir zerlegen Θ in $\Theta_0 = \{\vartheta_0\}$ und $\Theta_1 = \{\vartheta_1\}$. Wir betrachten das Testproblem $H_0 = \{\vartheta = \vartheta_0\}$ gegen $H_1 = \{\vartheta = \vartheta_1\}$. Wir nehmen an, dass $\mathbb{P}_{\vartheta_0} \approx \mu \approx \mathbb{P}_{\vartheta_1}$, wobei μ das dominierende Maß bezeichnet. Weiterhin sei $L : \Theta \times \Omega \rightarrow (0, \infty)$ die Likelihood-Funktion.

Definition 3.2.1.

(a) Wir definieren den Likelihood-Quotienten durch

$$L(\vartheta_0, \vartheta_1, x) := \frac{L(\vartheta_1, x)}{L(\vartheta_0, x)}.$$

(b) Für $k \in \mathbb{R}_+$ definieren den Likelihood-Quotienten-Test durch

$$\varphi_k := \mathbb{1}_{\{L(\vartheta_0, \vartheta_1, X) \geq k\}}.$$

Satz 3.2.2 (Neyman-Pearson-Lemma). *Es seien $\alpha \in (0, 1)$ und $k \in \mathbb{R}_+$, so dass der Likelihood-Quotienten-Test φ_k ein Level- α -Test ist. Dann ist φ_k ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α .*

Beweis. Es sei ψ ein beliebiger Test von H_0 gegen H_1 zum Irrtumsniveau α . Weiterhin sei $x \in \Omega$ beliebig. Wir unterscheiden zwei Fälle:

(1) Es gelte $L(\vartheta_1, x) - kL(\vartheta_0, x) \geq 0$. Dann gilt

$$L(\vartheta_0, \vartheta_1, x) - k = \frac{L(\vartheta_1, x)}{L(\vartheta_0, x)} - k = \frac{L(\vartheta_1, x) - kL(\vartheta_0, x)}{L(\vartheta_0, x)} \geq 0.$$

Also gilt $L(\vartheta_0, \vartheta_1, x) \geq k$, und daher $\varphi_k(x) = 1$. Also folgt

$$\varphi_k(x) - \psi(x) \geq 0.$$

(2) Es gelte $L(\vartheta_1, x) - kL(\vartheta_0, x) < 0$. Dann gilt

$$L(\vartheta_0, \vartheta_1, x) - k = \frac{L(\vartheta_1, x)}{L(\vartheta_0, x)} - k = \frac{L(\vartheta_1, x) - kL(\vartheta_0, x)}{L(\vartheta_0, x)} < 0.$$

Also gilt $L(\vartheta_0, \vartheta_1, x) < k$, und daher $\varphi_k(x) = 0$. Also folgt

$$\varphi_k(x) - \psi(x) \leq 0.$$

Insgesamt folgt

$$(\varphi_k(x) - \psi(x))(L(\vartheta_1, x) - kL(\vartheta_0, x)) \geq 0 \quad \text{für alle } x \in \Omega.$$

Also gilt

$$\int_{\Omega} (\varphi_k(x) - \psi(x))(L(\vartheta_1, x) - kL(\vartheta_0, x)) \mu(dx) \geq 0.$$

Hieraus folgt

$$\mathbb{E}_{\vartheta_1}[\varphi_k - \psi] - k \mathbb{E}_{\vartheta_0}[\varphi_k - \psi] \geq 0.$$

Da φ_k ein Level- α -Test ist, gilt $\mathbb{E}_{\vartheta_0}[\varphi_k] = \alpha$. Außerdem gilt $\mathbb{E}_{\vartheta_0}[\psi] \leq \alpha$, und es folgt

$$\mathbb{E}_{\vartheta_1}[\varphi_k] - \mathbb{E}_{\vartheta_1}[\psi] \geq k \mathbb{E}_{\vartheta_0}[\varphi_k] - k \mathbb{E}_{\vartheta_0}[\psi] = k(\alpha - \mathbb{E}_{\vartheta_0}[\psi]) \geq 0.$$

Also gilt

$$\mathbb{E}_{\vartheta_1}[\varphi_k] \geq \mathbb{E}_{\vartheta_1}[\psi].$$

□

Satz 3.2.3. *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$ und Parameterraum $\Theta = \{\mu_0, \mu_1\}$ für $\mu_0 < \mu_1$. Wir zerlegen Θ in*

$$\Theta_0 = \{\mu_0\} \quad \text{und} \quad \Theta_1 = \{\mu_1\}.$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\mu = \mu_0\}$ und die Alternative $H_1 = \{\mu = \mu_1\}$. Weiterhin sei $\alpha \in (0, 1)$ gegeben. Wir definieren den Test

$$\varphi_c = \mathbb{1}_{\{\bar{X} - \mu_0 \geq c\}},$$

wobei $c = \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$. Dann ist φ_c ein gleichmäßig bester Test zum Irrtumsniveau α .

Beweis. Nach Satz 3.1.12(d) ist der Test φ_c ein Level- α -Test. Weiterhin gilt

$$L(\mu_0, x) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu_0)^2\right)$$

und

$$\begin{aligned} L(\mu_1, x) &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu_1)^2\right) \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n ((X_i - \mu_0) - (\mu_1 - \mu_0))^2\right) \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n ((X_i - \mu_0)^2 - 2(\mu_1 - \mu_0)(X_i - \mu_0) + (\mu_1 - \mu_0)^2)\right) \end{aligned}$$

Also gilt

$$\begin{aligned}
 L(\mu_0, \mu_1, x) &= \frac{L(\mu_1, x)}{L(\mu_0, x)} = \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (-2(\mu_1 - \mu_0)(X_i - \mu_0) + (\mu_1 - \mu_0)^2)\right) \\
 &= \exp\left(\frac{\mu_1 - \mu_0}{\sigma^2} \sum_{i=1}^n (X_i - \mu_0) - \frac{n(\mu_1 - \mu_0)^2}{2\sigma^2}\right) \\
 &= \exp\left(\frac{n(\mu_1 - \mu_0)}{\sigma^2} (\bar{X} - \mu_0) - \frac{n(\mu_1 - \mu_0)^2}{2\sigma^2}\right) \\
 &= \exp\left(\frac{\mu_1 - \mu_0}{(\sigma^2/n)} (\bar{X} - \mu_0) - \frac{(\mu_1 - \mu_0)^2}{2(\sigma^2/n)}\right)
 \end{aligned}$$

Wir definieren die streng monoton wachsende, bijektive Funktion

$$\Phi : (0, \infty) \rightarrow \mathbb{R}, \quad \Phi(y) := \frac{\sqrt{\sigma^2/n}}{\mu_1 - \mu_0} \left(\ln y + \frac{(\mu_1 - \mu_0)^2}{2(\sigma^2/n)} \right).$$

Dann gilt

$$\begin{aligned}
 \Phi(L(\mu_0, \mu_1, x)) &= \frac{\sqrt{\sigma^2/n}}{\mu_1 - \mu_0} \left(\ln L(\mu_0, \mu_1, x) + \frac{(\mu_1 - \mu_0)^2}{2(\sigma^2/n)} \right) \\
 &= \frac{\bar{X} - \mu_0}{\sqrt{\sigma^2/n}}.
 \end{aligned}$$

Mit

$$k := \Phi^{-1}\left(\frac{c}{\sqrt{\sigma^2/n}}\right)$$

folgt

$$\{\bar{X} - \mu_0 \geq c\} = \left\{ \frac{\bar{X} - \mu_0}{\sqrt{\sigma^2/n}} \geq \frac{c}{\sqrt{\sigma^2/n}} \right\} = \{L(\mu_0, \mu_1, X) \geq k\}.$$

Nach dem Neyman-Pearson-Lemma (Satz 3.2.2) ist φ_c also ein gleichmäßig bester Test. \square

3.3 Erweiterung auf allgemeinere Bereiche

Satz 3.3.1. *Es seien $\Theta \subset \mathbb{R}$ und $\vartheta_0 \in \Theta$ beliebig. Wir zerlegen Θ in*

$$\Theta_0 = (-\infty, \vartheta_0] \cap \Theta \quad \text{und} \quad \Theta_1 = (\vartheta_0, \infty) \cap \Theta.$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\vartheta \leq \vartheta_0\}$ und die Alternative $H_1 = \{\vartheta > \vartheta_0\}$. Es seien $\alpha \in (0, 1)$ und $\varphi : \Omega \rightarrow \{0, 1\}$ eine Statistik, so dass gilt:

- (1) Die Gütefunktion $\vartheta \mapsto G_\varphi(\vartheta)$ ist monoton wachsend auf Θ_0 .
- (2) Für alle $\vartheta_1 \in \Theta_1$ ist φ ein gleichmäßig bester Test von $\{\vartheta = \vartheta_0\}$ gegen $\{\vartheta = \vartheta_1\}$ zum Irrtumsniveau α .

Dann ist φ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α .

Beweis. Wegen der Monotonie der Gütefunktion gilt

$$\sup_{\vartheta \in \Theta_0} G_\varphi(\vartheta) = G_\varphi(\vartheta_0) \leq \alpha.$$

Also ist φ ein zulässiger Test von H_0 gegen H_1 zum Irrtumsniveau α . Nun sei ψ ein zulässiger Test von H_0 gegen H_1 zum Irrtumsniveau α . Es gilt also

$$\sup_{\vartheta \in \Theta_0} G_\psi(\vartheta) \leq \alpha,$$

und damit insbesondere

$$G_\psi(\vartheta_0) \leq \alpha.$$

Also ist ψ für jedes $\vartheta_1 \in \Theta_1$ ein zulässiger Test von $\{\vartheta = \vartheta_0\}$ gegen $\{\vartheta = \vartheta_1\}$ zum Irrtumsniveau α . Es folgt

$$G_\varphi(\vartheta_1) \geq G_\psi(\vartheta_1) \quad \text{für alle } \vartheta_1 \in \Theta_1.$$

Also ist φ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α . \square

Satz 3.3.2 (Einseitiger Gauß-Test für μ). *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$ mit $\Theta = \mathbb{R}$. Wir wählen $\mu_0 \in \mathbb{R}$ und zerlegen Θ in*

$$\Theta_0 = (-\infty, \mu_0] \quad \text{und} \quad \Theta_1 = (\mu_0, \infty).$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\mu \leq \mu_0\}$ und die Alternative $H_1 = \{\mu > \mu_0\}$. Weiterhin sei $\alpha \in (0, 1)$ gegeben. Wir definieren den Test

$$\varphi_c := \mathbb{1}_{\{\bar{X} - \mu_0 \geq c\}},$$

wobei $c := \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$. Dann ist φ_c ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α .

Beweis. Nach Satz 3.1.12(b) ist die Gütefunktion G_{φ_c} monoton wachsend, und nach Satz 3.2.3 ist φ_c für jedes $\mu_1 \in \Theta_1$ ein gleichmäßig bester Test von $\{\mu = \mu_0\}$ gegen $\{\mu = \mu_1\}$ zum Irrtumsniveau α . Mit Satz 3.3.1 folgt, dass φ_c ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α ist. \square

3.4 Exponentielle Familien

Es sei \mathcal{M} eine exponentielle Familie mit Likelihood-Funktion

$$L(\vartheta, x) = \exp(a(\vartheta)T(x) - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Theta \times \Omega.$$

Definition 3.4.1. Die exponentielle Familie \mathcal{M} heißt *monoton wachsend*, falls $a : \Theta \rightarrow \mathbb{R}$ streng monoton wachsend ist.

Lemma 3.4.2. Die exponentielle Familie \mathcal{M} sei monoton wachsend. Dann existiert für alle $\vartheta_0, \vartheta_1 \in \Theta$ mit $\vartheta_0 < \vartheta_1$ eine streng monoton wachsende, bijektive Funktion $\Phi = \Phi_{\vartheta_0, \vartheta_1} : (0, \infty) \rightarrow \mathbb{R}$, so dass

$$\Phi(L(\vartheta_0, \vartheta_1, x)) = T(x) \quad \text{für alle } x \in \Omega.$$

Beweis. Wir definieren $\Phi : (0, \infty) \rightarrow \mathbb{R}$ durch

$$\Phi(y) := \frac{1}{a(\vartheta_1) - a(\vartheta_0)} \left(\ln y + (b(\vartheta_1) - b(\vartheta_0)) \right).$$

Dann ist Φ streng monoton wachsend und bijektiv, und wegen

$$L(\vartheta_0, \vartheta_1, x) = \frac{L(\vartheta_1, x)}{L(\vartheta_0, x)} = \exp((a(\vartheta_1) - a(\vartheta_0))T(x) - (b(\vartheta_1) - b(\vartheta_0))), \quad x \in \Omega$$

folgt

$$\Phi(L(\vartheta_0, \vartheta_1, x)) = T(x) \quad \text{für alle } x \in \Omega.$$

□

Satz 3.4.3. Die exponentielle Familie \mathcal{M} sei monoton wachsend. Es sei $\Theta = \{\vartheta_0, \vartheta_1\}$ mit $\vartheta_0 < \vartheta_1$. Wir zerlegen Θ in

$$\Theta_0 = \{\vartheta_0\} \quad \text{und} \quad \Theta_1 = \{\vartheta_1\}.$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\vartheta = \vartheta_0\}$ und die Alternative $H_1 = \{\vartheta = \vartheta_1\}$. Es seien $\alpha \in (0, 1)$ und $\gamma \in \mathbb{R}$, so dass

$$\varphi_\gamma := \mathbb{1}_{\{T(X) \geq \gamma\}}$$

ein Level- α -Test ist. Dann ist φ_γ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α .

Beweis. Nach Lemma 3.4.2 gilt

$$\varphi_\gamma = \mathbb{1}_{\{T(X) \geq \gamma\}} = \mathbb{1}_{\{L(\vartheta_0, \vartheta_1, X) \geq k\}},$$

wobei $k = \Phi^{-1}(\gamma)$. Nach dem Neyman-Pearson-Lemma (Satz 3.2.2) ist φ_γ ein gleichmäßig bester Test von $H_0 = \{\vartheta = \vartheta_0\}$ gegen $H_1 = \{\vartheta = \vartheta_1\}$ zum Irrtumsniveau α . \square

Lemma 3.4.4. *Die exponentielle Familie \mathcal{M} sei monoton wachsend. Dann ist für jedes $\gamma \in \mathbb{R}$ die Gütefunktion $G_{\varphi_\gamma} : \Theta \rightarrow [0, 1]$ des Tests $\varphi_\gamma = \mathbb{1}_{\{T(X) \geq \gamma\}}$ monoton wachsend.*

Beweis. Es seien $\vartheta_1, \vartheta_2 \in \Theta$ mit $\vartheta_1 < \vartheta_2$ beliebig. Weiterhin sei $x \in \Omega$ beliebig. Nach Lemma 3.4.2 gilt $T(x) \geq \gamma$ genau dann, wenn

$$\frac{L(\vartheta_1, x)}{L(\vartheta_0, x)} = L(\vartheta_0, \vartheta_1, x) \geq k,$$

wobei $k = \Phi^{-1}(\gamma)$. Also folgt für alle $x \in \Omega$ mit $T(x) \geq \gamma$, dass $\varphi_\gamma(x) = 1$ und

$$\begin{aligned} (L(\vartheta_1, x) - kL(\vartheta_0, x))(\varphi_\gamma(x) - b) &\geq 0 \quad \text{für alle } b \in [0, 1] \\ \Leftrightarrow (L(\vartheta_1, x) - kL(\vartheta_0, x))\varphi_\gamma(x) &\geq (L(\vartheta_1, x) - kL(\vartheta_0, x))b \quad \text{für alle } b \in [0, 1]. \end{aligned}$$

Daraus folgt

$$\mathbb{E}_{\vartheta_1}[\varphi] - k\mathbb{E}_{\vartheta_0}[\varphi] \geq (1 - k)b \quad \text{für alle } b \in [0, 1].$$

Mit $b := \mathbb{E}_{\vartheta_0}[\varphi] \in [0, 1]$ folgt

$$\mathbb{E}_{\vartheta_1}[\varphi] \geq \mathbb{E}_{\vartheta_0}[\varphi].$$

\square

Satz 3.4.5. *Die exponentielle Familie \mathcal{M} sei monoton wachsend. Es seien $\Theta \subset \mathbb{R}$ und $\vartheta_0 \in \Theta$ beliebig. Wir zerlegen Θ in*

$$\Theta_0 = (-\infty, \vartheta_0] \cap \Theta \quad \text{und} \quad \Theta_1 = (\vartheta_0, \infty) \cap \Theta.$$

Dann erhalten wir die Null-Hypothese $H_0 = \{\vartheta \leq \vartheta_0\}$ und die Alternative $H_1 = \{\vartheta > \vartheta_0\}$. Es seien $\alpha \in (0, 1)$ und $\gamma \in \mathbb{R}$, so dass für

$$\varphi_\gamma := \mathbb{1}_{\{T(X) \geq \gamma\}}$$

gilt $G_{\varphi_\gamma}(\vartheta_0) = \alpha$. Dann ist φ_γ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α .

Beweis. Nach Lemma 3.4.4 ist die Gütefunktion $G_{\varphi_\gamma} : \Theta \rightarrow [0, 1]$ monoton wachsend. Nach Satz 3.4.3 ist für alle $\vartheta_1 \in \Theta_1$ der Test φ_γ ein gleichmäßig bester Test von $\{\vartheta = \vartheta_0\}$ gegen $\{\vartheta = \vartheta_1\}$ zum Irrtumsniveau α . Also folgt mit Satz 3.3.1, dass φ_γ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α ist. \square

Beispiel 3.4.6. Für das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$ können wir die Aussage von Satz 3.3.2 nun leicht alternativ beweisen. In der Tat, es handelt sich um eine exponentielle Familie mit

$$a(\mu) = \frac{n\mu}{\sigma^2} \quad \text{und} \quad T(X) = \bar{X}.$$

Die Funktion a ist streng monoton wachsend. Also ist die exponentielle Familie \mathcal{M} monoton. Wir setzen $\gamma := \mu_0 + c$ mit $c := \sqrt{\sigma^2/n} \cdot z_{1-\alpha}$ und betrachten den Test

$$\varphi_\gamma = \mathbb{1}_{\{T(X) \geq \gamma\}}.$$

Nach Satz 3.1.12(d) gilt $G_{\varphi_\gamma}(\mu_0) = \alpha$. Also folgt mit Satz 3.4.5, dass φ_γ ein gleichmäßig bester Test von H_0 gegen H_1 zum Irrtumsniveau α ist.

3.5 Dualität zwischen Konfidenzmengen und Hypothesentests

In diesem Abschnitt sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein statistisches Modell.

Satz 3.5.1. Es sei $\alpha \in (0, 1)$ beliebig, und es sei $C : \Omega \rightarrow \mathcal{E}$ eine Konfidenzmenge für ϑ zum Niveau α . Weiterhin sei $\vartheta_0 \in \Theta$ beliebig. Wir zerlegen Θ in

$$\Theta_0 = \{\vartheta_0\} \quad \text{und} \quad \Theta_1 = \Theta \setminus \{\vartheta_0\}.$$

Das heißt, wird erhalten die Null-Hypothese $H_0 = \{\vartheta = \vartheta_0\}$ und die Alternative $H_1 = \{\vartheta \neq \vartheta_0\}$. Dann ist

$$\varphi : \Omega \rightarrow \{0, 1\}, \quad \varphi := \mathbb{1}_{\{\vartheta_0 \notin C\}}$$

ein Test, der zulässig zum Irrtumsniveau α ist.

Beweis. Nach Voraussetzung gilt $\{\vartheta \in C\} \in \mathcal{F}$ und

$$\mathbb{P}_\vartheta(\vartheta \in C) \geq 1 - \alpha \quad \text{für alle } \vartheta \in \Theta.$$

Also gilt insbesondere $\{\vartheta_0 \in C\} \in \mathcal{F}$, und folglich ist φ ein Test. Weiterhin gilt

$$\begin{aligned} G_\varphi(\vartheta_0) &= \mathbb{E}_{\vartheta_0}[\varphi] = \mathbb{E}_{\vartheta_0}[\mathbb{1}_{\{\vartheta_0 \notin C\}}] = \mathbb{P}_{\vartheta_0}(\vartheta_0 \notin C) \\ &= 1 - \mathbb{P}_{\vartheta_0}(\vartheta_0 \in C) \leq 1 - (1 - \alpha) = \alpha. \end{aligned}$$

□

Nun erhalten wir leicht einen alternativen Beweis von Satz 3.1.10.

Korollar 3.5.2. *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$. Wir zerlegen $\Theta = \mathbb{R}$ in*

$$\Theta_0 = \{\mu_0\} \quad \text{und} \quad \Theta_1 = \mathbb{R} \setminus \{\mu_0\}$$

für ein $\mu_0 \in \mathbb{R}$. Das heißt, wir erhalten die Null-Hypothese $H_0 = \{\mu = \mu_0\}$ und die Alternative $H_1 = \{\mu \neq \mu_0\}$. Weiterhin sei $\alpha \in (0, 1)$ gegeben. Dann ist

$$\varphi := \mathbb{1}_{\{|\bar{X} - \mu_0| > \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}\}}$$

ein Test, der zulässig zum Irrtumsniveau α ist.

Beweis. Nach Satz 2.2.5(b) ist das Zufallsintervall $C : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch

$$C = \bar{X} \pm z_{1-\alpha/2} \sqrt{\sigma^2/n}$$

ein Konfidenzintervall für μ zum Niveau α . Außerdem gilt

$$\{\mu_0 \notin C\} = \{\mu_0 \notin \bar{X} \pm z_{1-\alpha/2} \sqrt{\sigma^2/n}\} = \{|\bar{X} - \mu_0| > \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}\}.$$

Nach Satz 3.5.1 folgt, dass φ ein Test ist, der zulässig zum Irrtumsniveau α ist. □

Satz 3.5.3. *Es sei $\alpha \in (0, 1)$ beliebig, und es sei \mathcal{T} eine σ -Algebra über Θ . Weiterhin sei $(\varphi_\vartheta)_{\vartheta \in \Theta}$ eine Familie von Tests, so dass gilt:*

- Für jedes $\vartheta_0 \in \Theta$ ist φ_{ϑ_0} ein Test, der für $H_0 = \{\vartheta = \vartheta_0\}$ gegen $H_1 = \{\vartheta \neq \vartheta_0\}$ zulässig zum Irrtumsniveau α ist.
- Die Abbildung $\Theta \times \Omega \rightarrow \{0, 1\}$, $(\vartheta, x) \mapsto \varphi_\vartheta(x)$ ist $\mathcal{T} \otimes \mathcal{F}$ -messbar.

Dann ist

$$C : \Omega \rightarrow \mathcal{T}, \quad C(x) = \{\vartheta \in \Theta : \varphi_\vartheta(x) = 0\}$$

eine Konfidenzmengensammlung für ϑ zum Niveau α .

Beweis. Es sei $\vartheta \in \Theta$ beliebig. Nach Voraussetzung gilt

$$\mathbb{P}_\vartheta(\varphi_\vartheta = 1) = \mathbb{E}_\vartheta[\varphi_\vartheta] = G_{\varphi_\vartheta}(\vartheta) \leq \alpha.$$

Nach Voraussetzung gilt außerdem

$$\{\vartheta \in C\} = \{\varphi_\vartheta = 0\} \in \mathcal{F}$$

sowie

$$\mathbb{P}_\vartheta(\vartheta \in C) = \mathbb{P}_\vartheta(\varphi_\vartheta = 0) = 1 - \mathbb{P}_\vartheta(\varphi_\vartheta = 1) \geq 1 - \alpha.$$

□

Nun erhalten wir leicht einen alternativen Beweis von Satz 2.2.5.

Korollar 3.5.4. *Wir betrachten das n -fache Gaußmodell mit bekannter Varianz $\sigma^2 > 0$. Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch*

$$C = \bar{X} \pm z_{1-\alpha/2} \sqrt{\sigma^2/n}$$

ein Konfidenzintervall für μ zum Niveau α .

Beweis. Hier sind $\Theta = \mathbb{R}$ und $\mathcal{T} = \mathcal{B}(\mathbb{R})$. Nach Satz 3.1.10 ist

$$\varphi_{\mu_0} = \mathbb{1}_{\{|\bar{X} - \mu_0| > \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}\}}$$

für jedes $\mu_0 \in \Theta$ ein Test, der für $H_0 = \{\mu = \mu_0\}$ gegen $H_1 = \{\mu \neq \mu_0\}$ zulässig zum Irrtumsniveau α ist. Außerdem ist $(\mu, x) \mapsto \varphi_\mu(x)$ bezüglich $\mathcal{T} \otimes \mathcal{F}$ messbar. Weiterhin gilt

$$\{\mu \in \mathbb{R} : \varphi_\mu = 0\} = \{\mu \in \mathbb{R} : |\bar{X} - \mu| \leq \sqrt{\sigma^2/n} \cdot z_{1-\alpha/2}\} = \bar{X} \pm z_{1-\alpha/2} \sqrt{\sigma^2/n}.$$

Also ist C nach Satz 3.5.3 ein Konfidenzintervall für μ zum Niveau α . □

Kapitel 4

Nichtparametrische Modelle

4.1 Der Satz von Glivenko-Cantelli

Ein statistisches Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

heißt bekanntlich ein parametrisches Modell, falls $\Theta \subset \mathbb{R}^d$ für ein $d \in \mathbb{N}$. Andernfalls sprechen wir von einem nichtparametrischen Modell.

Beispiel 4.1.1. *Es sei Θ die Menge aller Wahrscheinlichkeitsmaße auf (Ω, \mathcal{F}) . Für jedes $\vartheta \in \Theta$ sei $\mathbb{P}_\vartheta = \vartheta$. Dann ist \mathcal{M} ein nichtparametrisches Modell.*

Beispiel 4.1.2. *Es seien Ω eine abzählbare Menge, und $\mathcal{F} = \mathfrak{P}(\Omega)$ die Potenzmenge. Weiterhin sei Θ die Menge aller stochastischen Vektoren; also aller Abbildungen $\vartheta : \Omega \rightarrow [0, 1]$, so dass*

$$\sum_{k \in \Omega} \vartheta(k) = 1.$$

Für jedes $\vartheta \in \Theta$ sei \mathbb{P}_ϑ das Wahrscheinlichkeitsmaß auf (Ω, \mathcal{F}) gegeben durch

$$\mathbb{P}_\vartheta(B) = \sum_{k \in B} \vartheta(k), \quad B \in \mathcal{F}.$$

Dann ist \mathcal{M} ein nichtparametrisches Modell.

Beispiel 4.1.3. *Es sei $(\Omega, \mathcal{F}) = (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$. Weiterhin sei Θ die Menge aller Äquivalenzklassen von Wahrscheinlichkeitsdichten; also aller messbaren Funktionen $\vartheta : \mathbb{R}^d \rightarrow \mathbb{R}_+$, so dass*

$$\int_{\mathbb{R}^d} \vartheta(x) dx = 1.$$

Für jedes $\vartheta \in \Theta$ sei \mathbb{P}_ϑ das Wahrscheinlichkeitsmaß auf (Ω, \mathcal{F}) gegeben durch

$$\mathbb{P}_\vartheta(B) = \int_B \vartheta(x) dx, \quad B \in \mathcal{F}.$$

Dann ist \mathcal{M} ein nichtparametrisches Modell.

Beispiel 4.1.4. Es sei $(\Omega, \mathcal{F}) = (\mathbb{R}, \mathcal{B}(\mathbb{R}))$. Weiterhin sei Θ die Menge aller Verteilungsfunktionen $\vartheta : \mathbb{R} \rightarrow [0, 1]$. Für jedes $\vartheta \in \Theta$ sei \mathbb{P}_ϑ das Wahrscheinlichkeitsmaß auf (Ω, \mathcal{F}) gegeben durch

$$\mathbb{P}_\vartheta((-\infty, t]) = \vartheta(t), \quad t \in \mathbb{R}_+.$$

Dann ist \mathcal{M} ein nichtparametrisches Modell.

Nun sei $(X_n)_{n \in \mathbb{N}}$ eine Folge von unabhängigen, identisch verteilten Zufallsvariablen mit Verteilungsfunktion F .

Definition 4.1.5. Für jedes $n \in \mathbb{N}$ definieren wir die empirische Verteilungsfunktion $F_n : \mathbb{R} \times \Omega \rightarrow [0, 1]$ durch

$$F_n(x) := \frac{1}{n} \sum_{j=1}^n \mathbb{1}_{\{X_j \leq x\}}, \quad x \in \mathbb{R}.$$

Satz 4.1.6.

(a) Es gilt für $n \rightarrow \infty$

$$F_n(x) \xrightarrow{f.s.} F(x) \quad \text{für alle } x \in \mathbb{R}.$$

(b) Es gilt für $n \rightarrow \infty$

$$\mathbb{P} \circ (\sqrt{n}(F_n(x) - F(x))) \xrightarrow{w} \mathbb{N}(0, \sigma^2(x)) \quad \text{für alle } x \in \mathbb{R},$$

wobei $\sigma^2(x) = F(x)(1 - F(x))$.

Beweis. Es sei $x \in \mathbb{R}$ fest. Wir definieren die Folge $(Y_n(x))_{n \in \mathbb{N}}$ durch

$$Y_n(x) := \mathbb{1}_{\{X_n \leq x\}}.$$

Dann sind die Zufallsvariablen $(Y_n(x))_{n \in \mathbb{N}} \subset \mathcal{L}^2$ unabhängig und identisch verteilt mit

$$\mathbb{E}[Y_n(x)] = \mathbb{P}(X_n \leq x) = F(x),$$

$$\text{Var}[Y_n(x)] = \mathbb{E}[Y_n(x)^2] - \mathbb{E}[Y_n(x)]^2 = F(x) - F(x)^2 = F(x)(1 - F(x)).$$

Außerdem erhalten wir die Darstellung

$$F_n(x) = \frac{1}{n} \sum_{j=1}^n Y_j(x) \quad \text{für jedes } n \in \mathbb{N}.$$

(a) Nach dem Gesetz der großen Zahlen (Satz 1.2.6) folgt für $n \rightarrow \infty$

$$F_n(x) \xrightarrow{f.s.} F(x).$$

(b) Wir setzen

$$S_n(x) := \sum_{j=1}^n Y_j(x) \quad \text{für jedes } n \in \mathbb{N}.$$

Dann gilt für jedes $n \in \mathbb{N}$

$$\sqrt{n}(F_n(x) - F(x)) = \sqrt{n} \left(\frac{1}{n} \sum_{j=1}^n Y_j(x) - F(x) \right) = \frac{S_n(x) - nF(x)}{\sqrt{n}}.$$

Nach dem zentralen Grenzwertsatz (Satz 1.2.9) folgt für $n \rightarrow \infty$

$$\mathbb{P} \circ (\sqrt{n}(F_n(x) - F(x))) \xrightarrow{w} N(0, \sigma^2(x)).$$

□

Definition 4.1.7. *Es sei $F : \mathbb{R} \rightarrow [0, 1]$ eine Verteilungsfunktion. Die Quantilfunktion $F^{-1} : (0, 1) \rightarrow \mathbb{R}$ ist gegeben durch*

$$F^{-1}(y) := \inf\{x \in \mathbb{R} : F(x) \geq y\}.$$

Bemerkung 4.1.8. *Nur wenn F stetig und streng monoton wachsend ist, dann ist F^{-1} die Umkehrfunktion von F im üblichen Sinne.*

Bemerkung 4.1.9. *Die Quantilfunktion F^{-1} ist stets monoton wachsend und linksstetig.*

Lemma 4.1.10. *Es sei $F : \mathbb{R} \rightarrow [0, 1]$ eine Verteilungsfunktion. Für alle $x \in \mathbb{R}$ und $y \in (0, 1)$ sind folgende Aussagen äquivalent:*

(i) *Es gilt $y \leq F(x)$.*

(ii) *Es gilt $F^{-1}(y) \leq x$.*

Beweis. (i) \Rightarrow (ii): Folgt aus Definition 4.1.7.

(ii) \Rightarrow (i): Es gelte $F(x) < y$. Wegen der Rechtsstetigkeit von F existiert ein $\epsilon > 0$, so dass $F(x + \epsilon) < y$. Mit Definition 4.1.7 folgt $x + \epsilon \leq F^{-1}(y)$, und folglich $x < F^{-1}(y)$. □

Lemma 4.1.11. *Es sei $F : \mathbb{R} \rightarrow [0, 1]$ eine Verteilungsfunktion. Dann gilt*

$$F(F^{-1}(y) -) \leq y \leq F(F^{-1}(y)) \quad \text{für alle } y \in (0, 1).$$

Beweis. Wir definieren die streng monoton wachsende Folge $(x_n)_{n \in \mathbb{N}} \subset \mathbb{R}$ durch

$$x_n := F^{-1}(y) - \frac{1}{n} \quad \text{für alle } n \in \mathbb{N}.$$

Dann gilt $x_n \uparrow F^{-1}(y)$, und nach Definition 4.1.7 gilt

$$F(x_n) < y \quad \text{für alle } n \in \mathbb{N}.$$

Da F linksseitige Grenzwerte besitzt, folgt

$$F(F^{-1}(y) -) = \lim_{n \rightarrow \infty} F(x_n) \leq y.$$

Es sei $x := F^{-1}(y)$. Dann gilt $F^{-1}(y) \leq x$, und daher nach Lemma 4.1.10

$$F(F^{-1}(y)) = F(x) \geq y.$$

□

Satz 4.1.12 (Satz von Glivenko-Cantelli, Hauptsatz der Mathematischen Statistik). *Es sei $(X_n)_{n \in \mathbb{N}}$ eine Folge von unabhängigen, identisch verteilten Zufallsvariablen mit Verteilungsfunktion F . Dann gilt*

$$\sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \xrightarrow{f.s.} 0 \quad \text{für } n \rightarrow \infty,$$

wobei die $(F_n)_{n \in \mathbb{N}}$ die empirischen Verteilungsfunktionen sind.

Beweis. Es sei $x \in \mathbb{R}$ beliebig. Dann gilt nach Satz 4.1.6(a) für $n \rightarrow \infty$

$$F_n(x) \xrightarrow{f.s.} F(x).$$

Wir definieren die Folge $(Z_n(x))_{n \in \mathbb{N}}$ durch

$$Z_n(x) := \mathbb{1}_{\{X_n < x\}}.$$

Dann sind die Zufallsvariablen $(Z_n(x))_{n \in \mathbb{N}} \subset \mathcal{L}^2$ unabhängig und identisch verteilt mit

$$\mathbb{E}[Z_n(x)] = \mathbb{P}(X_n < x) = F(x-).$$

Außerdem erhalten wir die Darstellung

$$F_n(x-) = \frac{1}{n} \sum_{j=1}^n Z_j(x) \quad \text{für jedes } n \in \mathbb{N}.$$

Nach dem Gesetz der großen Zahlen (Satz 1.2.6) folgt für $n \rightarrow \infty$

$$F_n(x-) \xrightarrow{f.s.} F(x-).$$

Also existiert ein $N \in \mathcal{F}$ mit $\mathbb{P}(N) = 0$, so dass für $n \rightarrow \infty$

$$F_n(x, \omega) \rightarrow F(x) \quad \text{und} \quad F_n(x-, \omega) \rightarrow F(x-)$$

für alle $x \in F^{-1}((0, 1) \cap \mathbb{Q})$ und alle $\omega \in N^c$.

Es sei $\omega \in N^c$ beliebig. Weiterhin sei $\epsilon > 0$ beliebig. Dann existiert ein $k \in \mathbb{N}$ mit $\frac{1}{k} < \frac{\epsilon}{2}$. Wir definieren $(x_i)_{i=0, \dots, k} \subset [-\infty, \infty]$ durch

$$\begin{aligned} x_0 &:= -\infty, \\ x_i &:= F^{-1}\left(\frac{i}{k}\right), \quad i = 1, \dots, k-1, \\ x_k &:= \infty. \end{aligned}$$

Dann existiert ein $n_0 \in \mathbb{N}$, so dass für alle $n \geq n_0$ und alle $i = 0, \dots, k$ gilt

$$|F_n(x_i, \omega) - F(x_i)| \leq \frac{\epsilon}{2} \quad \text{und} \quad |F_n(x_{i-}, \omega) - F(x_{i-})| \leq \frac{\epsilon}{2},$$

wobei wir etwa die Konvention $F(\infty-) = 1$ verwenden. Nun sei $x \in \mathbb{R}$ beliebig. Dann existiert ein $i \in \{1, \dots, k\}$, so dass $x \in [x_{i-1}, x_i)$. Weiterhin sei $n \geq n_0$ beliebig. Wegen der Monotonie von F und F_n folgt mit Lemma 4.1.11

$$\begin{aligned} F_n(x, \omega) - F(x) &\leq F_n(x_i-, \omega) - F(x_{i-1}) \\ &\leq |F_n(x_{i-}, \omega) - F(x_{i-})| + F(x_{i-}) - F(x_{i-1}) \\ &\leq \frac{\epsilon}{2} + \left(\frac{i}{k} - \frac{i-1}{k}\right) = \frac{\epsilon}{2} + \frac{1}{k} \leq \epsilon \end{aligned}$$

und

$$\begin{aligned} F(x) - F_n(x, \omega) &\leq F(x_{i-}) - F_n(x_{i-1}, \omega) \\ &\leq F(x_{i-}) - F(x_{i-1}) + |F(x_{i-1}) - F_n(x_{i-1}, \omega)| \\ &\leq \left(\frac{i}{k} - \frac{i-1}{k}\right) + \frac{\epsilon}{2} = \frac{1}{k} + \frac{\epsilon}{2} \leq \epsilon. \end{aligned}$$

Also gilt für alle $n \geq n_0$

$$\sup_{x \in \mathbb{R}} |F_n(x, \omega) - F(x)| \leq \epsilon.$$

□

Die empirische Verteilungsfunktion war gegeben durch

$$F_n : \mathbb{R} \times \Omega \rightarrow [0, 1], \quad F_n(x, \omega) = \frac{1}{n} \sum_{j=1}^n \mathbb{1}_{\{X_j(\omega) \leq x\}}.$$

Bezeichnet Θ die Menge aller Verteilungsfunktionen, so können wir die empirische Verteilungsfunktion als Abbildung

$$F_n : \Omega \rightarrow \Theta$$

ansehen; und zwar ist $F_n(\omega)$ für festes $\omega \in \Omega$ dann die Verteilungsfunktion

$$x \mapsto \frac{1}{n} \sum_{j=1}^n \mathbb{1}_{\{X_j(\omega) \leq x\}}.$$

Wir betrachten nun das statistische Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

aus Beispiel 4.1.4. Wie in Abschnitt 1.2 betrachten wir die Folge $(\mathcal{M}_n)_{n \in \mathbb{N}}$ gegeben durch

$$\mathcal{M}_n = (\Omega^{\mathbb{N}}, \mathcal{F}^{\otimes \mathbb{N}}, (\mathbb{P}_\vartheta : \vartheta \in \Theta)).$$

Es sei $\tau : \Theta \rightarrow \Theta$ die Kenngröße $\tau(F) = F$. Wir betrachten die Folge von Schätzern $(T_n)_{n \in \mathbb{N}}$ gegeben durch

$$T_n : \Omega^{\mathbb{N}} \rightarrow \Theta, \quad T_n(x) = \frac{1}{n} \sum_{j=1}^n \mathbb{1}_{\{X_j \leq x\}} \quad \text{für } x \in \mathbb{R}.$$

Korollar 4.1.13. *Es gilt für $n \rightarrow \infty$*

$$\sup_{x \in \mathbb{R}} |T_n(x) - F(x)| \xrightarrow{f.s.} 0 \text{ bezüglich } \mathbb{P}_F \quad \text{für alle } F \in \Theta.$$

Beweis. Folgt aus dem Satz von Glivenko-Cantelli (Satz 4.1.12). □

Bemerkung 4.1.14. *In diesem Sinne ist die Folge von Schätzern $(T_n)_{n \in \mathbb{N}}$ stark konsistent für τ .*

4.2 Der Kolmogorov-Smirnov-Anpassungstest

Definition 4.2.1. Es sei μ ein Wahrscheinlichkeitsmaß auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Verteilungsfunktion F .

(a) Für $a \in (0, 1)$ nennen wir $\mu_a := F^{-1}(a)$ das a -Quantil von μ , wobei $F^{-1} : (0, 1) \rightarrow \mathbb{R}$ die Quantilfunktion aus Definition 4.1.7 bezeichnet.

(b) Für $\alpha \in (0, 1)$ nennen wir $\mu_{1-\alpha}$ auch das α -Fraktile von μ .

Lemma 4.2.2. Es sei μ ein Wahrscheinlichkeitsmaß auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Verteilungsfunktion F . Weiterhin sei $X \sim \mu$ eine Zufallsvariable. Dann gilt für jedes $\alpha \in (0, 1)$

$$\mathbb{P}(X > \mu_{1-\alpha}) \leq \alpha.$$

Beweis. Nach Lemma 4.1.11 gilt

$$\begin{aligned} \mathbb{P}(X > \mu_{1-\alpha}) &= \mathbb{P}(X > F^{-1}(1 - \alpha)) \\ &= 1 - F(F^{-1}(1 - \alpha)) \leq 1 - (1 - \alpha) = \alpha. \end{aligned}$$

□

Definition 4.2.3. Eine Funktion $F : \mathbb{R} \rightarrow \mathbb{R}$ heißt càdlàg, falls sie rechtsstetig ist und linksseitige Grenzwerte besitzt.

Definition 4.2.4. Es sei $F : \mathbb{R} \rightarrow \mathbb{R}$ eine càdlàg-Funktion.

(a) Für jedes $x \in \mathbb{R}$ definieren wir den linksseitigen Grenzwert

$$F(x-) := \lim_{y \uparrow x} F(y).$$

(b) Für jedes $x \in \mathbb{R}$ definieren wir den Sprung

$$\Delta F(x) := F(x) - F(x-).$$

(c) Wir nennen $\{\Delta F \neq 0\}$ die Menge aller Sprungstellen von F .

(d) Wir nennen $\{\Delta F = 0\}$ die Menge aller Stetigkeitsstellen von F .

Lemma 4.2.5. Es seien I eine Indexmenge und $(A_i)_{i \in I} \subset \mathcal{F}$ paarweise disjunkte Ereignisse mit $\mathbb{P}(A_i) > 0$ für alle $i \in I$. Dann ist I höchstens abzählbar.

Beweis. Es genügt, zu zeigen, dass für jedes $n \in \mathbb{N}$ die Indexmenge

$$I_n := \left\{ i \in I : \mathbb{P}(A_i) \geq \frac{1}{n} \right\}$$

höchstens n Elemente hat. Andernfalls existiert eine Teilmenge $J_n \subset I_n$ mit $n + 1$ Elementen, und wir erhalten den Widerspruch

$$1 < \frac{n+1}{n} \leq \sum_{j \in J_n} \mathbb{P}(A_j) = \mathbb{P}\left(\bigcup_{j \in J_n} A_j\right) \leq 1.$$

□

Satz 4.2.6. *Es sei $F : \mathbb{R} \rightarrow [0, 1]$ eine Verteilungsfunktion.*

- (a) F ist càdlàg.
- (b) Die Menge $\{\Delta F \neq 0\}$ ist höchstens abzählbar.
- (c) Zu jedem $x \in \mathbb{R}$ existiert eine Folge $(x_k)_{k \in \mathbb{N}} \subset \{\Delta F = 0\}$ von Stetigkeitspunkten von F , so dass $x_k \downarrow x$.

Beweis.

- (a) Da F monoton wachsend ist, existieren die linksseitigen Grenzwerte. Es sei μ das zu F gehörige Wahrscheinlichkeitsmaß auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Verteilungsfunktion F . Es sei $x \in \mathbb{R}$ beliebig, und es sei $(x_n)_{n \in \mathbb{N}} \subset \mathbb{R}$ eine Folge mit $x_n \downarrow x$. Wegen $(-\infty, x_n] \downarrow (-\infty, x]$ folgt

$$F(x_n) = \mu((-\infty, x_n]) \downarrow \mu((-\infty, x]) = F(x) \quad \text{für } n \rightarrow \infty.$$

- (b) Es sei μ das zu F gehörige Wahrscheinlichkeitsmaß auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Verteilungsfunktion F . Dann gilt

$$\{\Delta F \neq 0\} = \{x \in \mathbb{R} : \mu(\{x\}) > 0\}.$$

Da die Mengen $(\{x\})_{x \in \mathbb{R}}$ paarweise disjunkt sind, ist $\{\Delta F \neq 0\}$ nach Lemma 4.2.5 höchstens abzählbar.

- (c) Es sei $x \in \mathbb{R}$ beliebig. Es genügt, zu zeigen, dass zu jedem $\epsilon > 0$ ein Stetigkeitspunkt $y \in [x, x + \epsilon)$ existiert. Dies ist der Fall, da die Menge der Sprungstellen von F nach Teil (b) ist höchstens abzählbar ist.

□

Lemma 4.2.7.

- (a) Es sei X eine Zufallsvariable mit stetiger Verteilungsfunktion F_X . Wir setzen $U := F_X(X)$. Dann gilt $U \sim \text{UC}(0, 1)$.
- (b) Es seien $F : \mathbb{R} \rightarrow [0, 1]$ eine stetige Verteilungsfunktion und $U \sim \text{UC}(0, 1)$ eine gleichverteilte Zufallsvariable. Dann hat die Zufallsvariable $X := F^{-1}(U)$ die Verteilungsfunktion F .

Beweis.

- (a) Es sei $u \in (0, 1)$ beliebig. Da F_X stetig ist mit $F_X(\mathbb{R}) \subset (0, 1)$, existiert nach dem Zwischenwertsatz der Topologie ein $x \in \mathbb{R}$ mit $F_X(x) = u$. Wegen

$$\{F_X(X) < F_X(x)\} \subset \{X \leq x\}$$

gilt

$$F_U(u-) = \mathbb{P}(U < u) = \mathbb{P}(F_X(X) < F_X(x)) \leq \mathbb{P}(X \leq x) = F_X(x) = u,$$

und wegen

$$\{X \leq x\} \subset \{F_X(X) \leq F_X(x)\}$$

gilt

$$u = F_X(x) = \mathbb{P}(X \leq x) \leq \mathbb{P}(F_X(X) \leq F_X(x)) = \mathbb{P}(U \leq u) = F_U(u).$$

Insgesamt folgt

$$F_U(u-) \leq u \leq F_U(u) \quad \text{für alle } u \in (0, 1).$$

Also gilt für jeden Stetigkeitspunkt $u \in (0, 1)$ von F_U , dass

$$F_U(u) = u.$$

Nun sei $u \in (0, 1)$ beliebig. Nach Satz 4.2.6(c) existiert eine Folge $(u_k)_{k \in \mathbb{N}} \subset (0, 1)$ von Stetigkeitspunkten von F_U mit $u_k \downarrow u$. Wegen der Rechtsstetigkeit von F_U folgt

$$F_U(u) = F_U\left(\lim_{k \rightarrow \infty} u_k\right) = \lim_{k \rightarrow \infty} F_U(u_k) = \lim_{k \rightarrow \infty} u_k = u.$$

Insgesamt folgt

$$F_U(u) = u\mathbb{1}_{(0,1)}(u) + \mathbb{1}_{[1,\infty)}(u), \quad u \in \mathbb{R}.$$

(b) Es gilt $F_U(u) = u$ für alle $u \in [0, 1]$. Nach Lemma 4.1.10 gilt also für jedes $x \in \mathbb{R}$

$$F_X(x) = \mathbb{P}(X \leq x) = \mathbb{P}(F^{-1}(U) \leq x) = \mathbb{P}(U \leq F(x)) = F_U(F(x)) = F(x).$$

□

Bemerkung 4.2.8.

(a) Es sei X eine Zufallsvariable mit stetiger Verteilungsfunktion F , und es sei $T : \mathbb{R} \rightarrow \mathbb{R}$ eine stetige Transformation. Dann gilt für alle $t \in \mathbb{R}$

$$\mathbb{P}(T(X) = t) = \mathbb{P}(X \in T^{-1}(\{t\})).$$

Also braucht die Verteilungsfunktion von $T(X)$ nicht stetig zu sein; es sei denn T ist injektiv.

(b) Eine Verteilung mit stetiger Verteilungsfunktion F braucht nicht absolutstetig zu sein. Ein Gegenbeispiel ist die Cantor-Verteilung.

Definition 4.2.9. Es seien $U_1, \dots, U_n \sim \text{UC}(0, 1)$ unabhängige, gleichverteilte Zufallsvariablen. Es sei

$$\widehat{F}_n(u) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i \leq u\}}$$

die empirische Verteilungsfunktion. Dann nennen wir die Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ gegeben durch $\mathbb{P} \circ T_n$ mit

$$T_n = \sup_{u \in [0, 1]} |\widehat{F}_n(u) - u|$$

die diskrete Kolmogorov-Verteilung mit n Freiheitsgraden, und bezeichnen diese mit K_n .

Bemerkung 4.2.10. Nach dem Satz von Glivenko-Cantelli (Satz 4.1.12) gilt $T_n \xrightarrow{f.s.} 0$ für $n \rightarrow \infty$.

Definition 4.2.11. Wir nennen die Verteilung auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit der Verteilungsfunktion $F : \mathbb{R} \rightarrow [0, 1]$ gegeben durch

$$F(x) = \left(1 - 2 \sum_{k=1}^{\infty} (-1)^{k+1} \exp(-2k^2 x^2) \right) \mathbb{1}_{(0, \infty)}(x), \quad x \in \mathbb{R}$$

die Kolmogorov-Verteilung, und bezeichnen sie mit K .

Satz 4.2.12 (Satz von Kolmogorov-Smirnov). *Es gilt für $n \rightarrow \infty$*

$$\mathbb{P} \circ (\sqrt{n}T_n) \xrightarrow{w} K.$$

Beweis. Siehe [L6w, Satz 7.7]. □

Nun betrachten wir folgendes nichtparametrische statistische Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta)).$$

Hierbei ist $(\Omega, \mathcal{F}) = (\mathbb{R}, \mathcal{B}(\mathbb{R}))$. Weiterhin ist Θ die Menge aller stetigen Verteilungsfunktionen $F : \mathbb{R} \rightarrow [0, 1]$. Für jedes $F \in \Theta$ ist \mathbb{P}_F das Wahrscheinlichkeitsmaß auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ mit Verteilungsfunktion F ; also

$$\mathbb{P}_F((-\infty, t]) = F(t), \quad t \in \mathbb{R}_+.$$

Wir betrachten im Folgenden das Produktmodell $\mathcal{M}^{\otimes n}$ für ein $n \in \mathbb{N}$.

Definition 4.2.13. *Wir definieren $D_n : \Theta \times \Omega^n \rightarrow \mathbb{R}$ durch*

$$D_n(F, \omega) := \sup_{x \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{X_i(\omega) \leq x\}} - F(x) \right|,$$

oder in Kurzform

$$D_n(F) := \sup_{x \in \mathbb{R}} |F_n(x) - F(x)|.$$

Bemerkung 4.2.14. *Nach dem Satz von Glivenko-Cantelli (Satz 4.1.12) gilt für $n \rightarrow \infty$*

$$D_n(F) \xrightarrow{f.s.} 0 \quad \text{bezüglich } \mathbb{P}_F \quad \text{für jedes } F \in \Theta.$$

Lemma 4.2.15. *Es gilt $\mathbb{P}_F \circ D_n(F) = K_n$ für alle $F \in \Theta$. Mit anderen Worten $D_n(F)$ ist eine Pivot-Statistik mit Pivot-Verteilung K_n .*

Beweis. Es sei $F \in \Theta$ beliebig. Wir setzen $U_i := F(X_i)$ für $i = 1, \dots, n$. Da X_1, \dots, X_n unabhängig unter \mathbb{P}_F sind, sind auch U_1, \dots, U_n unabhängig unter \mathbb{P}_F . Nach Lemma 4.2.7(a) gilt $U_i \sim \text{UC}(0, 1)$ für alle $i = 1, \dots, n$. Wir setzen $\tilde{X}_i := F^{-1}(U_i)$ für $i = 1, \dots, n$. Da U_1, \dots, U_n unabhängig unter \mathbb{P}_F sind, sind auch $\tilde{X}_1, \dots, \tilde{X}_n$ unabhängig unter \mathbb{P}_F . Nach Lemma 4.2.7(b) gilt $\tilde{X}_i \sim F$ für alle $i = 1, \dots, n$. Nun sei $x \in \mathbb{R}$ beliebig. Mit Lemma 4.1.10 folgt

$$\begin{aligned} F_n(x) &= \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{X_i \leq x\}} \stackrel{d}{=} \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{\tilde{X}_i \leq x\}} = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{F^{-1}(U_i) \leq x\}} \\ &= \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{U_i \leq F(x)\}} = \hat{F}_n(F(x)). \end{aligned}$$

Hierbei bedeutet $Y \stackrel{d}{=} Z$ für zwei Zufallsvariablen Y und Z , dass $\mathbb{P}_F \circ Y = \mathbb{P}_F \circ Z$. Es folgt

$$\begin{aligned} D_n(F) &= \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \stackrel{d}{=} \sup_{x \in \mathbb{R}} |\widehat{F}_n(F(x)) - F(x)| \\ &= \sup_{u \in [0,1]} |\widehat{F}_n(u) - u| = T_n. \end{aligned}$$

□

Im Folgenden bezeichnen wir mit $X_{(1)} \leq \dots \leq X_{(n)}$ die Ordnungsstatistiken der Stichprobe (X_1, \dots, X_n) .

Lemma 4.2.16. *Für jedes $F \in \Theta$ gilt*

$$D_n(F) = \max_{i=1, \dots, n} \max \left\{ \left| F(X_{(i)}) - \frac{i-1}{n} \right|, \left| \frac{i}{n} - F(X_{(i)}) \right| \right\}.$$

Beweis. Die empirische Verteilungsfunktion ist gegeben durch

$$F_n(x) = \sum_{i=1}^{n-1} \frac{i}{n} \mathbb{1}_{[X_{(i)}, X_{(i+1)})} + \mathbb{1}_{[X_{(n)}, \infty)}, \quad x \in \mathbb{R}.$$

Da F stetig und monoton wachsend ist, folgt

$$\begin{aligned} D_n(F) &= \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| = \max_{i=1, \dots, n} \left\{ |F(X_{(i)}) - F_n(X_{(i)-})|, |F_n(X_{(i)}) - F(X_{(i)})| \right\} \\ &= \max_{i=1, \dots, n} \max \left\{ \left| F(X_{(i)}) - \frac{i-1}{n} \right|, \left| \frac{i}{n} - F(X_{(i)}) \right| \right\}. \end{aligned}$$

□

Korollar 4.2.17. *Für jedes $F \in \Theta$ gilt*

$$D_n(F) \stackrel{d}{=} \max_{i=1, \dots, n} \max \left\{ \left| U_{(i)} - \frac{i-1}{n} \right|, \left| \frac{i}{n} - U_{(i)} \right| \right\},$$

wobei $U_{(1)} \leq \dots \leq U_{(n)}$ die Ordnungsstatistiken von unabhängigen, gleichverteilten Zufallsvariablen $U_1, \dots, U_n \sim \text{UC}(0, 1)$ sind.

Wir fixieren nun eine stetige Verteilungsfunktion F_0 und setzen $D_n = D_n(F_0)$.

Satz 4.2.18 (Kolmogorov-Smirnov-Anpassungstest). *Wir zerlegen Θ in*

$$\Theta_0 = \{F_0\} \quad \text{und} \quad \Theta_1 = \Theta \setminus \{F_0\}.$$

Wir betrachten also die Null-Hypothese $H_0 = \{F = F_0\}$ und die Alternative $H_1 = \{F \neq F_0\}$. Es sei $\alpha \in (0, 1)$ beliebig. Dann ist

$$\varphi := \mathbb{1}_{\{D_n > K_{n, 1-\alpha}\}}$$

ein zulässiger Test zum Irrtumsniveau α .

Beweis. Nach Lemma 4.2.2 gilt

$$G_\varphi(F_0) = \mathbb{E}_{F_0}[\varphi] = \mathbb{E}_{F_0}[\mathbb{1}_{\{D_n > K_{n,1-\alpha}\}}] = \mathbb{P}_{F_0}(D_n > K_{n,1-\alpha}) \leq \alpha.$$

□

Bemerkung 4.2.19. *Alternativ können wir den Test*

$$\psi := \mathbb{1}_{\{\sqrt{n}D_n > K_{1-\alpha}\}}$$

betrachten. Dies ist die asymptotische Variante des Kolmogorov-Smirnov-Anpassungstests. Nach dem Satz von Kolmogorov-Smirnov (Satz 4.2.12) gilt für große $n \in \mathbb{N}$

$$G_\psi(F_0) = \mathbb{E}_{F_0}[\psi] = \mathbb{E}_{F_0}[\mathbb{1}_{\{\sqrt{n}D_n > K_{1-\alpha}\}}] = \mathbb{P}_{F_0}(\sqrt{n}D_n > K_{1-\alpha}) \approx \mathbb{P}_{F_0}(D > K_{1-\alpha}) \leq \alpha,$$

wobei $\mathbb{P}_{F_0} \circ D = K$. In diesem Sinne ist φ asymptotisch zulässig zum Irrtumsniveau α .

Bemerkung 4.2.20. *Es seien $n \in \mathbb{N}$ und eine konkrete Stichprobe (X_1, \dots, X_n) gegeben. Weiterhin sei eine vermutete Verteilung F_0 gegeben; beispielsweise $F_0 = N(\mu, \sigma^2)$ mit Parametern $\mu \in \mathbb{R}$ und $\sigma^2 > 0$, etwa*

$$\mu = \bar{X} \quad \text{und} \quad \sigma^2 = s^2(X).$$

Gemäß Lemma 4.2.16 berechnen wir D_n als

$$D_n = \max_{i=1, \dots, n} \max \left\{ \left| F_0(X_{(i)}) - \frac{i-1}{n} \right|, \left| \frac{i}{n} - F_0(X_{(i)}) \right| \right\}.$$

Dann stehen uns zwei Möglichkeiten zur Verfügung:

- *Wir verwerfen H_0 , falls $D_n > K_{n,1-\alpha}$; und akzeptieren H_0 andernfalls. Ist n nicht zu groß, so sind die Fraktile $K_{n,1-\alpha}$ bekannt. Bei großen n ist es sehr schwierig, die Fraktile zu ermitteln.*
- *Wir verwerfen H_0 , falls $\sqrt{n}D_n > K_{1-\alpha}$; und akzeptieren H_0 andernfalls. Dieses Verfahren bietet sich für große n an.*

Beispiel 4.2.21. *Wir betrachten den Kurs eines Wertpapiers (S_0, S_1, \dots, S_n) für ein $n \in \mathbb{N}$, und definieren (X_1, \dots, X_n) durch $X_i := \ln(S_i/S_{i-1})$ für $i = 1, \dots, n$. Dann ist die Nullhypothese $H_0 = \{F = N(\mu, \sigma^2)\}$ typischerweise zu verwerfen.*

4.3 Mehrdimensionale Normalverteilungen

Weitere Details zu diesem Thema können beispielsweise in [JP04, Chapter 16] oder [Tap13, Kapitel 12] nachgelesen werden.

Definition 4.3.1. Für jedes $\mu \in \mathbb{R}$ setzen wir $N(\mu, 0) := \delta_\mu$, und sprechen von einer entarteten Normalverteilung.

Definition 4.3.2. Ein \mathbb{R}^d -wertiger Zufallsvektor X heißt ein Gauß'scher Zufallsvektor, falls für jedes lineare Funktional $\ell : \mathbb{R}^d \rightarrow \mathbb{R}$ die Zufallsvariable $\ell(X)$ (möglicherweise entartet) normalverteilt ist.

Bemerkung 4.3.3. Jedes lineare Funktional $\ell : \mathbb{R}^d \rightarrow \mathbb{R}$ ist von der Form $\ell(x) = \langle a, x \rangle_{\mathbb{R}^d}$ für ein $a \in \mathbb{R}^d$.

Satz 4.3.4. Es seien X und Y Gauß'sche Zufallsvektoren mit $\mathbb{E}[X] = \mathbb{E}[Y]$ und $\text{Cov}(X) = \text{Cov}(Y)$. Dann gilt $\mathbb{P} \circ X = \mathbb{P} \circ Y$.

Definition 4.3.5. Es sei X ein Gauß'scher Zufallsvektor. Wir setzen $\mu := \mathbb{E}[X] \in \mathbb{R}^d$ und $\Sigma^2 := \text{Cov}(X) \in \mathbb{R}^{d \times d}$, und nennen die Verteilung $N(\mu, \Sigma^2) := \mathbb{P} \circ X$ auf $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$ die mehrdimensionale Normalverteilung mit Parametern μ und Σ^2 .

Bemerkung 4.3.6. Die Kovarianzmatrix Σ^2 ist stets symmetrisch und positiv semidefinit.

Satz 4.3.7. Es seien $\mu \in \mathbb{R}^d$ und $\Sigma^2 \in \mathbb{R}^{d \times d}$ eine symmetrische, positiv semidefinite Matrix. Dann existiert die mehrdimensionale Normalverteilung $N(\mu, \Sigma^2)$ auf $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$.

Satz 4.3.8. Es sei $X \sim N(\mu, \Sigma^2)$ ein \mathbb{R}^d -wertiger Gauß'scher Zufallsvektor. Dann sind folgende Aussagen äquivalent:

- (i) X ist absolutstetig.
- (ii) Σ^2 ist positiv definit.

Satz 4.3.9. Für einen \mathbb{R}^d -wertigen Gauß'schen Zufallsvektor $X \sim N(\mu, \Sigma^2)$ sind folgende Aussagen äquivalent:

- (i) X_1, \dots, X_n sind unabhängig.
- (ii) Σ^2 ist eine Diagonalmatrix.

Satz 4.3.10. Es sei $X \sim N(\mu, \Sigma^2)$ ein \mathbb{R}^d -wertiger Gauß'scher Zufallsvektor. Weiterhin seien $A \in \mathbb{R}^{d \times e}$ eine Matrix und $b \in \mathbb{R}^e$ ein Vektor. Dann ist $Y := AX + b$ ein \mathbb{R}^e -wertiger Gauß'scher Zufallsvektor mit

$$Y \sim N(A\mu + b, A\Sigma^2 A^\top).$$

Korollar 4.3.11. *Es seien $X_1, \dots, X_d \sim N(0, \sigma^2)$ unabhängige, normalverteilte Zufallsvariablen. Weiterhin sei $A \in \mathbb{R}^{d \times d}$ eine orthogonale Matrix. Wir setzen $Y := AX$. Dann sind Y_1, \dots, Y_d unabhängig mit $Y_i \sim N(0, \sigma^2)$ für $i = 1, \dots, d$.*

Satz 4.3.12 (Mehrdimensionaler zentraler Grenzwertsatz). *Es sei $(X_j)_{j \in \mathbb{N}} \subset \mathcal{L}^2$ eine Folge unabhängiger, identisch verteilter \mathbb{R}^d -wertiger Zufallsvektoren mit Erwartungswert $\mu \in \mathbb{R}^d$ und Kovarianzmatrix $\Sigma^2 \in \mathbb{R}^{d \times d}$. Wir setzen*

$$S_n := \sum_{j=1}^n X_j \quad \text{und} \quad Y_n := \frac{S_n - n\mu}{\sqrt{n}} \quad \text{für } n \in \mathbb{N}.$$

Dann gilt $\mathbb{P} \circ Y_n \xrightarrow{w} N(0, \Sigma^2)$.

4.4 Multinomialverteilungen

Es sei $E = \{1, \dots, d\}$ für ein $d \in \mathbb{N}$.

Definition 4.4.1. *Es sei $\pi : E \rightarrow [0, 1]$ ein stochastischer Vektor. Die Verteilung auf $(\mathbb{N}_0^d, \mathfrak{P}(\mathbb{N}_0^d))$ mit stochastischem Vektor $p : \mathbb{N}_0^d \rightarrow [0, 1]$ gegeben durch*

$$p(e_k) = \pi_k, \quad k = 1, \dots, d$$

nennen wir die verallgemeinerte Bernoulli-Verteilung mit Parameter π , und bezeichnen sie mit $\text{VBer}(\pi)$.

Bemerkung 4.4.2. *Für alle $p \in [0, 1]$ gilt*

$$\text{Ber}(p)(1) = \text{VBer}((p, 1-p))(1, 0) \quad \text{und} \quad \text{Ber}(p)(0) = \text{VBer}((p, 1-p))(0, 1).$$

Definition 4.4.3.

(a) *Für $k \in \mathbb{N}_0^d$ setzen wir*

$$|k| := k_1 + \dots + k_d.$$

(b) *Für $n \in \mathbb{N}$ und $k \in \mathbb{N}_0^d$ mit $|k| = n$ setzen wir*

$$\binom{n}{k} := \frac{n!}{k_1! \cdot \dots \cdot k_d!}.$$

(c) *Für $\pi \in \mathbb{R}^d$ und $k \in \mathbb{N}_0^d$ setzen wir*

$$\pi^k := \pi_1^{k_1} \cdot \dots \cdot \pi_d^{k_d}.$$

Definition 4.4.4. Es seien $n \in \mathbb{N}$ und $\pi : E \rightarrow [0, 1]$ ein stochastischer Vektor. Dann nennen wir die Verteilung auf $(\mathbb{N}_0^d, \mathfrak{P}(\mathbb{N}_0^d))$ mit stochastischem Vektor $p : \mathbb{N}_0^d \rightarrow [0, 1]$ gegeben durch

$$p(k) = \binom{n}{k} \pi^k \mathbb{1}_{\{|k|=n\}}$$

die Multinomialverteilung mit Parametern n und π , und bezeichnen sie mit $\text{Mult}(n, \pi)$.

Bemerkung 4.4.5. Für alle $p \in [0, 1]$ gilt

$$\text{Bi}(n, p)(k) = \text{Mult}(n, (p, 1 - p))(k, n - k), \quad k = 0, \dots, n.$$

Bemerkung 4.4.6. Für jeden stochastischer Vektor $\pi : E \rightarrow [0, 1]$ gilt

$$\text{VBer}(\pi) = \text{Mult}(1, \pi).$$

Satz 4.4.7. Es seien $X_1, \dots, X_n \sim \text{VBer}(\pi)$ unabhängige, identisch verteilte Zufallsvariablen. Dann gilt

$$X_1 + \dots + X_n \sim \text{Mult}(n, \pi).$$

Satz 4.4.8 (Verallgemeinerter Satz von Moivre-Laplace). Es sei $(X_j)_{j \in \mathbb{N}}$ eine Folge unabhängiger, identisch verteilter \mathbb{R}^d -wertiger Zufallsvariablen mit $X_1 \sim \text{VBer}(\pi)$. Wir setzen

$$S_n := \sum_{j=1}^n X_j \quad \text{und} \quad Y_n := \frac{S_n - n\pi}{\sqrt{n}} \quad \text{für } n \in \mathbb{N}.$$

Dann gilt $\mathbb{P} \circ Y_n \xrightarrow{w} \mathcal{N}(0, \Sigma^2)$, wobei die Kovarianzmatrix $\Sigma^2 \in \mathbb{R}^{d \times d}$ gegeben ist durch $\Sigma^2 = \text{diag}(\pi) - \pi\pi^\top$; das heißt

$$\Sigma_{ij}^2 = \begin{cases} \pi_i(1 - \pi_i), & \text{falls } i = j, \\ -\pi_i\pi_j, & \text{falls } i \neq j. \end{cases}$$

Beweis. Wir setzen $X := X_1$. Dann gilt $X^i \sim \text{Ber}(\pi_i)$ für alle $i = 1, \dots, d$. Folglich gilt für alle $i = 1, \dots, d$

$$\mathbb{E}[X^i] = \pi_i \quad \text{und} \quad \text{Var}[X^i] = \pi_i(1 - \pi_i).$$

Nun seien $i, j \in \{1, \dots, d\}$ mit $i \neq j$ beliebig. Wegen $|X| = 1$ gilt $X^i X^j = 0$, und es folgt

$$\text{Cov}(X^i, X^j) = \mathbb{E}[X^i X^j] - \mathbb{E}[X^i]\mathbb{E}[X^j] = -\pi_i\pi_j.$$

Nun folgt die Aussage mit dem mehrdimensionalen zentralen Grenzwertsatz (Satz 4.3.12). \square

Nun sei $\pi : E \rightarrow (0, 1)$ eine stochastischer Vektor. Weiterhin seien $(X_k)_{k \in \mathbb{N}}$ unabhängige, identisch verteilte E -wertige Zufallsvariablen mit $X_1 \sim \pi$. Wir definieren die Folge $(H_n)_{n \in \mathbb{N}}$ wie folgt. Für $n \in \mathbb{N}$ sei $H_n = (H_n^1, \dots, H_n^d) : \Omega \rightarrow \mathbb{N}_0^d$ der Zufallsvektor mit den Häufigkeiten

$$H_n^i = \sum_{k=1}^n \mathbb{1}_{\{X_k=i\}}, \quad i \in E.$$

Lemma 4.4.9. *Es gilt $H_n \sim \text{Mult}(n, \pi)$ für jedes $n \in \mathbb{N}$.*

Satz 4.4.10 (Satz von Pearson). *Wir definieren die Folge $(T_n)_{n \in \mathbb{N}}$ durch*

$$T_n := \sum_{i=1}^d \frac{1}{n\pi_i} (H_n^i - n\pi_i)^2.$$

Dann gilt für $n \rightarrow \infty$

$$\mathbb{P} \circ T_n \xrightarrow{w} \chi_{d-1}^2.$$

Beweis. Wir definieren die Folge $(Y_n)_{n \in \mathbb{N}}$ von \mathbb{R}^d -wertigen Zufallsvariablen durch

$$Y_n := \frac{H_n - n\pi}{\sqrt{n}} \quad \text{für } n \in \mathbb{N}.$$

Nach Lemma 4.4.9 und Satz 4.4.7 gilt $H_n \sim \text{Mult}(n, \pi) = \text{VBer}(\pi)^{\otimes n}$. Also gilt nach dem Verallgemeinerten Satz von Moivre-Laplace (Satz 4.4.8) $\mathbb{P} \circ Y_n \xrightarrow{w} \text{N}(0, \Sigma^2)$, wobei $\Sigma^2 = \text{diag}(\pi) - \pi\pi^\top$. Nun definieren wir die stetige Transformation

$$h : \mathbb{R}^d \rightarrow \mathbb{R}, \quad h(x) := \sum_{i=1}^d \frac{x_i^2}{\pi_i}.$$

Dann gilt $T_n = h(Y_n)$ für alle $n \in \mathbb{N}$, und folglich $T_n \xrightarrow{\mathcal{D}} h(Z)$ mit $Z \sim \text{N}(0, \Sigma^2)$. Wir setzen

$$D := \text{diag}(\pi^{-1/2}) := \text{diag}(\pi_1^{-1/2}, \dots, \pi_d^{-1/2}) \in \mathbb{R}^{d \times d}$$

und $\tilde{Z} := DZ$. Nach Satz 4.3.10 ist \tilde{Z} ein Gauß'scher Zufallsvektor mit

$$\begin{aligned} \text{Cov}(\tilde{Z}) &= D\Sigma^2 D^\top = \text{diag}(\pi^{-1/2})(\text{diag}(\pi) - \pi\pi^\top)\text{diag}(\pi^{-1/2}) \\ &= \text{Id} - (\pi^{1/2})^\top \pi^{1/2}. \end{aligned}$$

Also gilt

$$\tilde{Z} \sim \text{N}(0, \text{Id} - (\pi^{1/2})^\top \pi^{1/2}).$$

Für den Vektor $v := (\pi^{1/2})^\top$ gilt $\|v\|_{\mathbb{R}^d} = 1$, wobei

$$\|v\|_{\mathbb{R}^d} = \langle v, v \rangle_{\mathbb{R}^d} = \sqrt{v_1 + \dots + v_d}$$

die euklidische Norm bezeichnet. Also existiert eine orthogonale Matrix $A \in \mathbb{R}^{d \times d}$ mit $A_{i1} = v_i$ für alle $i = 1, \dots, d$. Wir setzen $\bar{Z} := A^\top \tilde{Z}$. Nach Satz 4.3.10 ist \tilde{Z} ein Gauß'scher Zufallsvektor. Es gilt $v^\top A = e_1$, und folglich

$$\begin{aligned} \text{Cov}(\bar{Z}) &= A^\top \text{Cov}(\tilde{Z}) A = A^\top (\text{Id} - (\pi^{1/2})^\top \pi^{1/2}) A \\ &= A^\top A - A^\top v v^\top A = \text{Id} - e_1^\top e_1 \\ &= \text{Id} - \text{diag}(e_1) = \text{diag}(0, 1, \dots, 1). \end{aligned}$$

Also gilt

$$\bar{Z} \sim \text{N}(0, \text{diag}(0, 1, \dots, 1)).$$

Nach Satz 4.3.9 sind $\bar{Z}_2, \dots, \bar{Z}_d \sim \text{N}(0, 1)$ unabhängig. Da $AA^\top = \text{Id}$, folgt mit Lemma 1.4.16

$$\begin{aligned} h(Z) &= \sum_{i=1}^d \frac{Z_i^2}{\pi_i} = Z^\top \text{diag}(\pi^{-1}) Z = Z^\top D^2 Z = (DZ)^\top DZ \\ &= \tilde{Z}^\top \tilde{Z} = \tilde{Z}^\top A A^\top \tilde{Z} = (A^\top \tilde{Z})^\top A^\top \tilde{Z} = \bar{Z}^\top \bar{Z} = \sum_{j=2}^d \bar{Z}_j^2 \sim \chi_{d-1}^2. \end{aligned}$$

□

4.5 Der χ^2 -Anpassungstest

Beispiel 4.5.1. *Bei insgesamt 189 Würfeln mit einem Würfel zweifelhafter Qualität erschienen die Augenzahlen 1 bis 6 jeweils 30, 37, 26, 29, 29 und 38 mal. Geben diese Daten Anlass, die Hypothese, dass der Würfel fair ist, zu verwerfen?*

Es sei $E = \{1, \dots, d\}$. Wir betrachten das statistische Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $(\Omega, \mathcal{F}) = (E, \mathfrak{P}(E))$, und Θ bestehend aus der Menge aller stochastischen Vektoren $\pi : E \rightarrow (0, 1)$. Für jedes $\pi \in \Theta$ ist \mathbb{P}_π das Wahrscheinlichkeitsmaß mit stochastischem Vektor π . Wir gehen zum Produktmodell $\mathcal{M}^{\otimes n}$ für ein $n \in \mathbb{N}$ über, und fixieren einen stochastischen Vektor $\pi_0 : E \rightarrow (0, 1)$. Wir zerlegen Θ in

$$\Theta_0 = \{\pi_0\} \quad \text{und} \quad \Theta_1 = \Theta \setminus \{\pi_0\}.$$

Wir betrachten also die Null-Hypothese $H_0 = \{\pi = \pi_0\}$ und die Alternative $H_1 = \{\pi \neq \pi_0\}$. Es sei $H_n = (H_n^1, \dots, H_n^d) : \Omega^n \rightarrow \mathbb{N}_0^d$ der Zufallsvektor mit den Häufigkeiten

$$H_n^i = \sum_{k=1}^n \mathbb{1}_{\{X_k=i\}}, \quad i \in E.$$

Satz 4.5.2 (Multinomial-Anpassungstest). *Es sei $\alpha \in (0, 1)$ beliebig. Weiterhin sei $B \subset \mathbb{N}_0^d$, so dass*

$$\text{Mult}(n, \pi_0)(B) \geq 1 - \alpha.$$

Dann ist

$$\varphi := \mathbb{1}_{\{H_n \notin B\}}$$

ein zulässiger Test zum Irrtumsniveau α .

Beweis. Nach Lemma 4.4.9 gilt $\mathbb{P}_{\pi_0} \circ H_n = \text{Mult}(n, \pi_0)$, und daher

$$G_\varphi(\pi_0) = \mathbb{E}_{\pi_0}[\varphi] = \mathbb{E}_{\pi_0}[\mathbb{1}_{\{H_n \notin B\}}] = \mathbb{P}_{\pi_0}(H_n \notin B) = \text{Mult}(n, \pi_0)(B^c) \leq \alpha.$$

□

Nun betrachten wir die Statistik

$$T_n := \sum_{i=1}^d \frac{1}{n\pi_0^i} (H_n^i - n\pi_0^i)^2.$$

Definition 4.5.3. Für $\alpha \in (0, 1)$ nennen wir

$$\varphi = \mathbb{1}_{\{T_n > \chi_{d-1, 1-\alpha}^2\}}$$

den χ^2 -Anpassungstest zum Irrtumsniveau α .

Bemerkung 4.5.4. Der χ^2 -Anpassungstest ist ein asymptotischer Test. Für große $n \in \mathbb{N}$ gilt nach dem Satz von Pearson (Satz 4.4.10) und Lemma 4.2.2

$$\begin{aligned} G_\varphi(\pi_0) &= \mathbb{E}_{\pi_0}[\varphi] = \mathbb{E}_{\pi_0}[\mathbb{1}_{\{T_n > \chi_{d-1, 1-\alpha}^2\}}] = \mathbb{P}_{\pi_0}(T_n > \chi_{d-1, 1-\alpha}^2) \\ &\approx \mathbb{P}_{\pi_0}(T > \chi_{d-1, 1-\alpha}^2) \leq \alpha, \end{aligned}$$

wobei $\mathbb{P}_{\pi_0} \circ T = \chi_{d-1}^2$. In diesem Sinne ist φ asymptotisch zulässig zum Irrtumsniveau α .

Beispiel 4.5.5. In Beispiel 4.5.1 sind $d = 6$ und $n = 189$. Weiterhin ist $\pi_0 = \text{UD}(E)$ mit $E = \{1, \dots, 6\}$. Wir wählen das Irrtumsniveau $\alpha = 0.05$. Es gilt

$$T_{189} = 3.730 < 11.1 = \chi_{5, 0.95}^2,$$

so dass wir die Null-Hypothese H_0 annehmen. Es besteht also kein Anlass, die Hypothese, dass der Würfel fair ist, zu verwerfen.

4.6 Der χ^2 -Test auf Unabhängigkeit

Es seien $E = \{1, \dots, d\}$ und $F = \{1, \dots, e\}$ für $d, e \in \mathbb{N}$. Es sei $(X_k)_{k \in \mathbb{N}}$ eine Folge unabhängiger, identisch verteilter $E \times F$ -wertiger Zufallsvariablen. Für $n \in \mathbb{N}$ seien $H^n : \Omega \rightarrow \mathbb{N}_0^{d \times e}$, $K^n : \Omega \rightarrow \mathbb{N}_0^d$ und $L^n : \Omega \rightarrow \mathbb{N}_0^e$ gegeben durch

$$\begin{aligned} H_n^{ij} &= \sum_{k=1}^n \mathbb{1}_{\{X_k=(i,j)\}}, \\ K_n^i &= \sum_{k=1}^n \mathbb{1}_{\{Y_k=i\}}, \\ L_n^j &= \sum_{k=1}^n \mathbb{1}_{\{Z_k=j\}}, \end{aligned}$$

wobei $X_k = (Y_k, Z_k)$. Weiterhin setzen wir

$$D_n = \sum_{i=1}^d \sum_{j=1}^e \frac{(H_n^{ij} - \frac{K_n^i L_n^j}{n})^2}{\frac{K_n^i L_n^j}{n}}.$$

Satz 4.6.1 (Verallgemeinerter Satz von Pearson). *Falls Y_1 und Z_1 unabhängig sind, dann gilt für $n \rightarrow \infty$*

$$\mathbb{P} \circ D_n \xrightarrow{w} \chi_{(d-1)(e-1)}^2.$$

Beweis. Siehe [Geo04, Satz 11.18]. □

Nun betrachten wir das statistische Modell

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $(\Omega, \mathcal{F}) = (E \times F, \mathfrak{P}(E \times F))$ und Θ der Menge aller stochastischen Vektoren auf $E \times F$. Für jedes $\pi \in \Theta$ ist \mathbb{P}_π das Wahrscheinlichkeitsmaß mit stochastischem Vektor π .

Definition 4.6.2. *Es sei $\pi \in \Theta$ beliebig.*

(a) $\pi_1 : E \rightarrow [0, 1]$ ist der stochastische Vektor gegeben durch

$$\pi_1^i = \sum_{j=1}^e \pi^{ij}, \quad i \in E.$$

(b) $\pi_2 : F \rightarrow [0, 1]$ ist der stochastische Vektor gegeben durch

$$\pi_2^j = \sum_{i=1}^d \pi^{ij}, \quad j \in F.$$

Definition 4.6.3. Für zwei stochastische Vektoren $\pi_1 : E \rightarrow [0, 1]$ und $\pi_2 : F \rightarrow [0, 1]$ ist $\pi_1 \otimes \pi_2 \in \Theta$ der stochastische Vektor gegeben durch

$$(\pi_1 \otimes \pi_2)^{ij} = \pi_1^i \pi_2^j, \quad (i, j) \in E \times F.$$

Wir setzen

$$\Theta_0 = \{\pi \in \Theta : \pi = \pi_1 \otimes \pi_2\} \quad \text{und} \quad \Theta_1 = \Theta \setminus \Theta_0.$$

Wir betrachten also die Null-Hypothese $H_0 = \{\pi = \pi_1 \otimes \pi_2\}$ und die Alternative $H_1 = \{\pi \neq \pi_1 \otimes \pi_2\}$. Für jedes $\pi \in \Theta$ sind folgende Aussagen äquivalent:

- (i) Die Stichprobe $X = ((Y_1, Z_1), \dots, (Y_n, Z_n))$ enthält unter \mathbb{P}_π unabhängige Komponenten Y_i und Z_i .
- (ii) Es gilt $\pi \in \Theta_0$.

Definition 4.6.4. Wir nennen

$$\varphi = \mathbb{1}_{\{D_n > \chi_{(d-1)(e-1), 1-\alpha}^2\}}$$

den χ^2 -Test auf Unabhängigkeit zum Irrtumsniveau α .

Bemerkung 4.6.5. Der χ^2 -Test auf Unabhängigkeit ist ein asymptotischer Test. Für große $n \in \mathbb{N}$ gilt nach dem verallgemeinerten Satz von Pearson (Satz 4.6.1) und Lemma 4.2.2 für alle $\pi \in \Theta_0$

$$\begin{aligned} G_\varphi(\pi) &= \mathbb{E}_\pi[\varphi] = \mathbb{E}_\pi[\mathbb{1}_{\{D_n > \chi_{(d-1)(e-1), 1-\alpha}^2\}}] = \mathbb{P}_\pi(D_n > \chi_{(d-1)(e-1), 1-\alpha}^2) \\ &\approx \mathbb{P}_\pi(D > \chi_{(d-1)(e-1), 1-\alpha}^2) \leq \alpha, \end{aligned}$$

wobei $\mathbb{P}_\pi \circ D = \chi_{(d-1)(e-1)}^2$. In diesem Sinne ist φ asymptotisch zulässig zum Irrtumsniveau α .

Kapitel 5

Lineare Modelle

5.1 Einfache lineare Regression

Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

das statistische Modell gegeben durch:

- $(\Omega, \mathcal{F}) = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ für ein $n \in \mathbb{N}$.
- $\Theta = \Theta_0 \times (0, \infty)$ mit $\Theta_0 = \mathbb{R}^2$ und

$$\mathbb{P}_\vartheta = \bigotimes_{i=1}^n N(\beta_0 + \beta_1 y_i, \sigma^2), \quad \vartheta = (\beta, \sigma^2) \in \Theta$$

mit einem Vektor $y \in \mathbb{R}^n$, so dass $y \notin \text{lin}\{\mathbb{1}\}$, wobei $\mathbb{1} = (1, \dots, 1)$. Wir können die Einträge von y als Kontrollvariablen interpretieren.

Wir vermuten also, dass zwischen der Stichprobe X und den Kontrollvariablen y ein linearer Zusammenhang besteht. Genauer

$$X_i = \beta_0 + \beta_1 y_i + \sigma \epsilon_i, \quad i = 1, \dots, n$$

wobei $\epsilon_1, \dots, \epsilon_n \sim N(0, 1)$ unabhängige, standardnormalverteilte Zufallsvariablen sind. Wir können dies kompakter schreiben als

$$X = \beta_0 \mathbb{1} + \beta_1 y + \sigma \epsilon.$$

Im Folgenden betrachten wir auf \mathbb{R}^n das euklidische Skalarprodukt

$$\langle x, y \rangle = \sum_{i=1}^n x_i y_i$$

und die euklidische Norm

$$\|x\| = \sqrt{\langle x, x \rangle} = \sqrt{\sum_{i=1}^n x_i^2}.$$

Definition 5.1.1. Ein Schätzer $\hat{\beta} : \Omega \rightarrow \Theta_0$ heißt ein Kleinste-Quadrate-Schätzer (KQS) für β , falls

$$\|X - (\hat{\beta}_0 \mathbb{1} + \hat{\beta}_1 y)\| = \min_{\beta \in \Theta_0} \|X - (\beta_0 \mathbb{1} + \beta_1 y)\|.$$

Satz 5.1.2. Es existiert ein eindeutig bestimmter KQS $\hat{\beta}$ für β ; dieser ist gegeben durch

$$\begin{aligned} \hat{\beta}_1 &= \frac{\langle y - \bar{y} \mathbb{1}, X - \bar{X} \mathbb{1} \rangle}{\|y - \bar{y} \mathbb{1}\|^2} = \frac{\sum_{i=1}^n (y_i - \bar{y})(X_i - \bar{X})}{\sum_{i=1}^n (y_i - \bar{y})^2}, \\ \hat{\beta}_0 &= \bar{X} - \hat{\beta}_1 \bar{y}. \end{aligned}$$

Beweis. Für eine beliebige Stichprobe $X \in \mathbb{R}^n$ definieren wir $f : \Theta_0 = \mathbb{R}^2 \rightarrow \mathbb{R}_+$ durch

$$f(\beta) = \|X - (\beta_0 \mathbb{1} + \beta_1 y)\|^2.$$

Dann gilt

$$\nabla f(\beta) = -2(\langle X - (\beta_0 \mathbb{1} + \beta_1 y), \mathbb{1} \rangle, \langle X - (\beta_0 \mathbb{1} + \beta_1 y), y \rangle), \quad \beta = (\beta_0, \beta_1) \in \mathbb{R}^2.$$

Es sei $\beta \in \mathbb{R}^2$ mit $\nabla f(\beta) = 0$. Dann gilt

$$\begin{aligned} \langle X - \beta_0 \mathbb{1} - \beta_1 y, \mathbb{1} \rangle &= 0 \\ \Leftrightarrow \langle X, \mathbb{1} \rangle - n\beta_0 - \beta_1 \langle y, \mathbb{1} \rangle &= 0 \\ \Leftrightarrow n\bar{X} - n\beta_0 - n\beta_1 \bar{y} &= 0 \\ \Leftrightarrow \beta_0 &= \bar{X} - \beta_1 \bar{y}. \end{aligned}$$

Weiterhin gilt

$$\begin{aligned} \langle X - \beta_0 \mathbb{1} - \beta_1 y, y \rangle &= 0 \\ \Leftrightarrow \langle X, y \rangle - \beta_0 \langle \mathbb{1}, y \rangle - \beta_1 \langle y, y \rangle &= 0 \\ \Leftrightarrow \langle X, y \rangle - n\beta_0 \bar{y} - \beta_1 \|y\|^2 &= 0. \end{aligned}$$

Durch Einsetzen erhalten wir

$$\begin{aligned} \langle X, y \rangle - n(\bar{X} - \beta_1 \bar{y})\bar{y} - \beta_1 \|y\|^2 &= 0 \\ \Leftrightarrow \langle X, y \rangle - n\bar{X}\bar{y} + n\beta_1 \bar{y}^2 - \beta_1 \|y\|^2 &= 0 \\ \Leftrightarrow \beta_1 (\|y\|^2 - \|\bar{y} \mathbb{1}\|^2) &= \langle X, y \rangle - \langle \bar{X} \mathbb{1}, \bar{y} \mathbb{1} \rangle. \end{aligned}$$

Nun gilt nach Lemma 1.1.8

$$\|x - \bar{x}\mathbb{1}\|^2 = \|x\|^2 - \|\bar{x}\mathbb{1}\|^2.$$

Durch Polarisierung folgt allgemeiner

$$\langle x - \bar{x}\mathbb{1}, y - \bar{y}\mathbb{1} \rangle = \langle x, y \rangle - \langle \bar{x}\mathbb{1}, \bar{y}\mathbb{1} \rangle.$$

Damit erhalten wir die gewünschte Formel. \square

Bemerkung 5.1.3. *Es gilt*

$$s^2(X) = \frac{1}{n-1} \|X - \bar{X}\mathbb{1}\|^2.$$

Wir benutzen auch die Notation $s_X^2 = s^2(X)$. Allgemeiner können wir die korrigierte Stichprobenkovarianz

$$s_{XY} = \frac{1}{n-1} \langle X - \bar{X}\mathbb{1}, Y - \bar{Y}\mathbb{1} \rangle$$

eingeführen. Dann erhalten wir die Darstellung

$$\hat{\beta}_1 = \frac{s_{yX}}{s_y^2}.$$

5.2 Lineare Modelle mit koordinatengebundener Darstellung

Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

das statistische Modell gegeben durch:

- $(\Omega, \mathcal{F}) = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ für ein $n \in \mathbb{N}$.
- $\Theta = \Theta_0 \times (0, \infty)$ mit $\Theta_0 = \mathbb{R}^d$ für ein $d \in \mathbb{N}$ mit $d \leq n$ und

$$\mathbb{P}_\vartheta = N(A\beta, \sigma^2 \text{Id}), \quad \vartheta = (\beta, \sigma^2) \in \Theta$$

mit einer Matrix $A \in \mathbb{R}^{n \times d}$, so dass $\text{rg}(A) = d$.

Wir vermuten für die Stichprobe X also den linearen Zusammenhang

$$X = A\beta + \sigma\epsilon$$

wobei $\epsilon_1, \dots, \epsilon_n \sim N(0, 1)$ unabhängige, standardnormalverteilte Zufallsvariablen sind.

Definition 5.2.1. Wir nennen \mathcal{M} ein lineares Modell mit koordinatengebundener Darstellung.

Beispiel 5.2.2. Es sei $A = (\mathbb{1}) \in \mathbb{R}^{n \times 1}$. Dann gilt $\text{rg}(A) = 1$. Wir haben in dem Fall das bekannte Gauß'sche Produktmodell

$$\mathbb{P}_\vartheta = \text{N}(\beta\mathbb{1}, \sigma^2\text{Id}) = \text{N}(\beta, \sigma^2)^{\otimes n}, \quad \vartheta = (\beta, \sigma^2) \in \Theta$$

vorliegen. Wir sprechen bei diesem Modell auch vom Einstichprobenproblem.

Beispiel 5.2.3 (Einfache lineare Regression). Es sei $y \in \mathbb{R}^n$ mit $y \notin \text{lin}\{\mathbb{1}\}$ für ein $n \geq 2$. Wir setzen

$$A = \begin{pmatrix} \mathbb{1} & y \end{pmatrix} \in \mathbb{R}^{n \times 2}.$$

Dann gilt $\text{rg}(A) = 2$. Dies ist die einfache lineare Regression, die wir in Abschnitt 5.1 kennengelernt haben.

Bemerkung 5.2.4. Für die spezielle Parameterwahl $\vartheta = (\beta, \sigma^2)$ mit $\beta = (\mu, 0)$ für ein $\mu \in \mathbb{R}$ gilt $\mathbb{P}_\vartheta = \text{N}(\mu, \sigma^2)^{\otimes n}$ wie beim Einstichprobenproblem.

Beispiel 5.2.5 (Polynomiale Regression). Es seien $d \in \mathbb{N}$ mit $d \leq n$ und $y \in \mathbb{R}^n$, welches d paarweise verschiedene Elemente besitzt. Wir setzen

$$A = \begin{pmatrix} \mathbb{1} & y & y^2 & \dots & y^{d-1} \end{pmatrix} \in \mathbb{R}^{n \times d},$$

wobei y^2, \dots, y^{d-1} komponentenweise gemeint sind. Nach dem Resultat über die Vandermonde-Matrizen gilt $\text{rg}(A) = d$. In diesem Modell vermuten wir zwischen der Stichprobe X und den Kontrollvariablen y einen polynomiellen Zusammenhang

$$X_i = \beta_0 + \beta_1 y_i + \dots + \beta_{d-1} y_i^{d-1} + \sigma \epsilon_i, \quad i = 1, \dots, n.$$

Beispiel 5.2.6 (Mehrfache lineare Regression). Es seien $d \in \mathbb{N}$ mit $d \leq n$ und $y_1, \dots, y_{d-1} \in \mathbb{R}^n$ linear unabhängige Vektoren mit $\mathbb{1} \notin \text{lin}\{y_1, \dots, y_{d-1}\}$. Wir setzen

$$A = \begin{pmatrix} \mathbb{1} & y_1 & \dots & y_{d-1} \end{pmatrix} \in \mathbb{R}^{n \times d}.$$

Dann gilt $\text{rg}(A) = d$. In diesem Modell vermuten wir zwischen der Stichprobe X und den Kontrollvariablen y_1, \dots, y_{d-1} einen linearen Zusammenhang

$$X_i = \beta_0 + \beta_1 y_{1,i} + \dots + \beta_{d-1} y_{d-1,i} + \sigma \epsilon_i, \quad i = 1, \dots, n.$$

Beispiel 5.2.7 (Mehrstichprobenproblem). Es seien $d \in \mathbb{N}$ und $n_1, \dots, n_d \in \mathbb{N}$, so dass $n = n_1 + \dots + n_d$. Wir setzen

$$A = \begin{pmatrix} \mathbb{1}_{n_1} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \mathbb{1}_{n_d} \end{pmatrix} \in \mathbb{R}^{n \times d}.$$

Dann gilt $\text{rg}(A) = d$. In diesem Modell liegen bei der Stichprobe verschiedene Gruppen $X = (X_1, \dots, X_d)$ mit $X_i \in \mathbb{R}^{n_i}$ für $i = 1, \dots, d$ vor. Wir vermuten für jede Gruppe einen Zusammenhang

$$X_i = \beta_i \mathbb{1} + \sigma^2 \epsilon_i.$$

Es gilt

$$\mathbb{P}_\vartheta = \bigotimes_{i=1}^d \mathbb{N}(\beta_i, \sigma^2)^{\otimes n_i}, \quad \vartheta = (\beta, \sigma^2) \in \Theta.$$

Für $i = 1, \dots, d$ wird der Erwartungswert $\beta_i \in \mathbb{R}$ das i -te Gruppenmittel genannt.

Definition 5.2.8. Ein Schätzer $\hat{\beta} : \Omega \rightarrow \Theta_0$ heißt ein Kleinste-Quadrate-Schätzer (KQS) für β , falls

$$\|X - A\hat{\beta}\| = \min_{\beta \in \Theta_0} \|X - A\beta\|.$$

Definition 5.2.9. Es sei $\varphi : \mathbb{R}^d \rightarrow \mathbb{R}^n$ die lineare Abbildung gegeben durch $\varphi(x) = Ax$ für alle $x \in \mathbb{R}^d$.

Bemerkung 5.2.10. Wegen $\text{rg}(A) = d$ ist φ injektiv.

Definition 5.2.11. Wir setzen $W := \varphi(\mathbb{R}^d)$.

Bemerkung 5.2.12. Es gilt $\dim W = d$, und $\varphi : \mathbb{R}^d \rightarrow W$ ist ein Isomorphismus.

Lemma 5.2.13. Die Matrix $A^\top A \in \mathbb{R}^{d \times d}$ ist symmetrisch und positiv definit, und damit insbesondere invertierbar.

Beweis. Die Symmetrie ist klar. Für jedes $b \in \mathbb{R}^d \setminus \{0\}$ gilt

$$\langle A^\top A b, b \rangle = \langle A b, A b \rangle = \|A b\|^2 > 0,$$

da φ injektiv ist. □

Definition 5.2.14. Die Moore-Penrose-Inverse von $A \in \mathbb{R}^{n \times d}$ ist definiert durch

$$A^\dagger := (A^\top A)^{-1} A^\top \in \mathbb{R}^{d \times n}.$$

Lemma 5.2.15. *Es gilt $A^\dagger A = \text{Id} \in \mathbb{R}^{d \times d}$.*

Beweis. In der Tat, es gilt

$$A^\dagger A = (A^\top A)^{-1} A^\top A = \text{Id}.$$

□

Lemma 5.2.16. *Es existiert eine eindeutig bestimmte lineare Abbildung $\Pi_W : \mathbb{R}^n \rightarrow W$, so dass*

$$\|x - \Pi_W x\| = \min_{y \in W} \|x - y\|.$$

Definition 5.2.17. *Wir nennen $\Pi_W : \mathbb{R}^n \rightarrow W$ die Orthogonalprojektion auf W .*

Lemma 5.2.18. *Für einen linearen Operator $\psi : \mathbb{R}^n \rightarrow W$ sind folgende Aussagen äquivalent:*

- (i) *Es gilt $\psi = \Pi_W$.*
- (ii) *Es gilt $\langle x - \psi(x), y \rangle = 0$ für alle $x \in \mathbb{R}^n$ und $y \in W$.*
- (iii) *Es gilt $A^\top(x - \psi(x)) = 0$ für alle $x \in \mathbb{R}^n$.*

Lemma 5.2.19. *Es gilt $\Pi_W x = AA^\dagger x$ für alle $x \in \mathbb{R}^n$.*

Beweis. Es gilt $AA^\dagger x \in W$ für alle $x \in \mathbb{R}^n$, da $W = \varphi(\mathbb{R}^d)$. Außerdem gilt

$$A^\top(x - AA^\dagger x) = A^\top(x - A(A^\top A)^{-1} A^\top x) = A^\top x - A^\top x = 0.$$

Also folgt die Behauptung mit Lemma 5.2.18. □

Lemma 5.2.20. *Für jedes $x \in \mathbb{R}^n$ hat die lineare Gleichung*

$$Ab = \Pi_W x, \quad b \in \mathbb{R}^d$$

die eindeutig bestimmte Lösung $b = A^\dagger x$.

Beweis. Nach Lemmas 5.2.19 und 5.2.15 gilt für jedes $b \in \mathbb{R}^d$

$$\begin{aligned} Ab &= \Pi_W x \\ \Leftrightarrow Ab &= AA^\dagger x \\ \Leftrightarrow A^\dagger Ab &= A^\dagger AA^\dagger x \\ \Leftrightarrow b &= A^\dagger x. \end{aligned}$$

□

Satz 5.2.21.

(a) Es gibt einen eindeutig bestimmten KQS $\hat{\beta}$ für β ; dieser ist gegeben durch

$$\hat{\beta} = A^\dagger X.$$

(b) Außerdem gilt die Darstellung $\hat{\beta} = A^\dagger \Pi_W X$.

Beweis.

(a) Nach Lemma 5.2.16 gilt

$$\|X - A\hat{\beta}\| = \min_{\beta \in \mathbb{R}^d} \|X - A\beta\|$$

genau dann, wenn

$$A\hat{\beta} = \Pi_W X.$$

Dies ist nach Lemma 5.2.20 äquivalent zu

$$\hat{\beta} = A^\dagger X.$$

(b) Nach Lemmas 5.2.19 und 5.2.15 gilt

$$A^\dagger \Pi_W X = A^\dagger A A^\dagger X = A^\dagger X.$$

□

5.3 Lineare Modelle mit koordinatenfreier Darstellung

Es sei

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

das statistische Modell gegeben durch:

- $(\Omega, \mathcal{F}) = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ für ein $n \in \mathbb{N}$.
- $\Theta = \Theta_0 \times (0, \infty)$ mit $\Theta_0 = W$ für einen Unterraum $W \subset \mathbb{R}^n$ mit $\dim(W) = d \leq n$ und

$$\mathbb{P}_\vartheta = N(\zeta, \sigma^2 \text{Id}), \quad \vartheta = (\zeta, \sigma^2) \in \Theta.$$

Für die Stichprobe X gilt also

$$X = \zeta + \sigma\epsilon$$

wobei $\epsilon_1, \dots, \epsilon_n \sim N(0, 1)$ unabhängige, standardnormalverteilte Zufallsvariablen sind.

Definition 5.3.1. Wir nennen \mathcal{M} ein lineares Modell mit koordinatenfreier Darstellung.

Bemerkung 5.3.2. Es sei

$$\mathcal{N} = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n), (\mathbb{Q}_\gamma : \gamma \in \Gamma))$$

ein lineares Modell mit koordinatengebundener Darstellung. Es gilt also $\Gamma = \mathbb{R}^d \times (0, \infty)$ und

$$\mathbb{Q}_\gamma = N(A\beta, \sigma^2 \text{Id}), \quad \gamma = (\beta, \sigma^2) \in \Gamma.$$

Wir setzen $W = A\mathbb{R}^d$. Dann ist

$$\mathcal{M} = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n), (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

mit $\Theta = W \times (0, \infty)$ und

$$\mathbb{P}_\vartheta = \mathbb{Q}_{(A^\dagger \zeta, \sigma^2)} = N(\zeta, \sigma^2 \text{Id}), \quad \vartheta = (\zeta, \sigma^2) \in \Theta$$

ein lineares Modell mit koordinatenfreier Darstellung. Für den KQS $\hat{\beta}$ in \mathcal{N} hat der Schätzer $\hat{\zeta} = A\hat{\beta}$ in \mathcal{M} die Darstellung $\hat{\zeta} = \Pi_W X$. Letzteres folgt aus Satz 5.2.21(b).

Bemerkung 5.3.3. Es sei

$$\mathcal{M} = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n), (\mathbb{P}_\vartheta : \vartheta \in \Theta))$$

ein lineares Modell mit koordinatenfreier Darstellung. Es gilt also $\Theta = W \times (0, \infty)$ und

$$\mathbb{P}_\vartheta = N(\zeta, \sigma^2 \text{Id}), \quad \vartheta = (\zeta, \sigma^2) \in \Theta.$$

Es sei $A \in \mathbb{R}^{n \times d}$ eine Matrix, so dass $W = A\mathbb{R}^d$. Dann ist

$$\mathcal{N} = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n), (\mathbb{Q}_\gamma : \gamma \in \Gamma))$$

mit $\Gamma = \mathbb{R}^d \times (0, \infty)$ und

$$\mathbb{Q}_\gamma = \mathbb{P}_{(A\beta, \sigma^2)} = N(A\beta, \sigma^2 \text{Id}), \quad \gamma = (\beta, \sigma^2) \in \Gamma$$

ein lineares Modell mit koordinatengebundener Darstellung. Für den Schätzer $\hat{\zeta} = \Pi_W X$ in \mathcal{M} ist der Schätzer $\hat{\beta} = A^\dagger \hat{\zeta}$ in \mathcal{N} der KQS für β . Dieser charakterisiert als die eindeutig bestimmte Lösung von $A\hat{\beta} = \hat{\zeta}$. Dies folgt aus Satz 5.2.21(b).

Beispiel 5.3.4. Beim Gauß'schen Produktmodell (Beispiel 5.2.2) gilt $W = \text{lin}\{\mathbb{1}\}$.

Beispiel 5.3.5. Bei der einfachen linearen Regression (Beispiel 5.2.3) gilt

$$W = \text{lin}\{\mathbb{1}, y\}.$$

Beispiel 5.3.6. Bei der polynomialen Regression (Beispiel 5.2.5) gilt

$$W = \text{lin}\{\mathbb{1}, y, y^2, \dots, y^{d-1}\}.$$

Beispiel 5.3.7. Bei der mehrfachen linearen Regression (Beispiel 5.2.6) gilt

$$W = \text{lin}\{\mathbb{1}, y_1, \dots, y_{d-1}\}.$$

Beispiel 5.3.8. Beim Mehrstichprobenproblem (Beispiel 5.2.7) gilt

$$W = \text{lin} \left\{ \begin{pmatrix} \mathbb{1}_{n_1} \\ 0 \\ \vdots \\ 0 \end{pmatrix}, \dots, \begin{pmatrix} 0 \\ \vdots \\ 0 \\ \mathbb{1}_{n_d} \end{pmatrix} \right\}.$$

Beispiel 5.3.9. Wir betrachten die einfache lineare Regression

$$A = \begin{pmatrix} \mathbb{1} & y \end{pmatrix} \in \mathbb{R}^{n \times 2}.$$

Die Menge $\{v_1, v_2\}$ mit

$$v_1 = \frac{\mathbb{1}}{\sqrt{n}} \quad \text{und} \quad v_2 = \frac{y - \bar{y}\mathbb{1}}{\sqrt{(n-1)s_y}}$$

ist eine Orthonormalbasis von $W = \text{lin}\{\mathbb{1}, y\}$. Wegen der Gleichung

$$\langle y - \bar{y}\mathbb{1}, X\mathbb{1} \rangle = \langle y - \bar{y}\mathbb{1}, X - \bar{X}\mathbb{1} \rangle$$

folgt

$$\begin{aligned} \Pi_W X &= \langle X, v_1 \rangle v_1 + \langle X, v_2 \rangle v_2 = \frac{\langle X, \mathbb{1} \rangle}{n} \mathbb{1} + \frac{1}{(n-1)s_y^2} \langle X, y - \bar{y}\mathbb{1} \rangle (y - \bar{y}\mathbb{1}) \\ &= \bar{X}\mathbb{1} + \frac{\langle y - \bar{y}\mathbb{1}, X - \bar{X}\mathbb{1} \rangle}{(n-1)s_y^2} (y - \bar{y}\mathbb{1}) = \bar{X}\mathbb{1} + \frac{s_{yX}}{s_y^2} (y - \bar{y}\mathbb{1}) \\ &= \left(\bar{X} - \frac{s_{yX}}{s_y^2} \bar{y} \right) \mathbb{1} + \frac{s_{yX}}{s_y^2} y. \end{aligned}$$

Die Gleichung

$$A\hat{\beta} = \hat{\zeta}$$

aus Bemerkung 5.3.3 lautet hier also

$$\hat{\beta}_0 \mathbb{1} + \hat{\beta}_1 y = \left(\bar{X} - \frac{s_{yX}}{s_y^2} \bar{y} \right) \mathbb{1} + \frac{s_{yX}}{s_y^2} y.$$

Also erhalten wir den KQS $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1)$ für β als

$$\hat{\beta}_1 = \frac{s_{yX}}{s_y^2}$$

und

$$\hat{\beta}_0 = \bar{X} - \hat{\beta}_1 \bar{y}.$$

Beispiel 5.3.10. Wir betrachten das Mehrstichprobenproblem

$$A = \begin{pmatrix} \mathbb{1}_{n_1} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \mathbb{1}_{n_d} \end{pmatrix} = (f_1 \ \dots \ f_d) \in \mathbb{R}^{n \times d}.$$

Die Menge $\{v_1, \dots, v_d\}$ mit

$$v_i = \frac{f_i}{\sqrt{n_i}}$$

ist eine Orthonormalbasis von $W = \text{lin}\{f_1, \dots, f_d\}$. Es folgt

$$\Pi_W X = \sum_{i=1}^d \langle X, v_i \rangle v_i = \sum_{i=1}^d \frac{1}{n_i} \langle X, f_i \rangle f_i = \sum_{i=1}^d \bar{X}_i f_i,$$

wobei die Stichprobe $X = (X_1, \dots, X_d)$ die Gruppen $X_i \in \mathbb{R}^{n_i}$ für $i = 1, \dots, d$ enthält.

Die Gleichung

$$A\hat{\beta} = \hat{\zeta}$$

aus Bemerkung 5.3.3 lautet hier also

$$\sum_{i=1}^d \hat{\beta}_i f_i = \sum_{i=1}^d \bar{X}_i f_i.$$

Also erhalten wir den KQS

$$\hat{\beta} = (\bar{X}_1, \dots, \bar{X}_d).$$

5.4 Punktschätzer

Wir betrachten ein lineares Modell \mathcal{M} mit koordinatenfreier Darstellung. Wir nehmen an, dass $d < n$, wobei $d = \dim(W)$.

Definition 5.4.1. *Wir setzen*

$$\hat{\zeta} := \Pi_W X \quad \text{und} \quad \hat{s}^2 := \frac{1}{n-d} \|X - \hat{\zeta}\|^2.$$

Lemma 5.4.2. *Es gilt $\langle b, v \rangle = \langle \Pi_W b, v \rangle$ für alle $b \in \mathbb{R}^n$ und $v \in W$.*

Beweis. Es gilt

$$\langle b, v \rangle = \langle \Pi_W b, v \rangle + \underbrace{\langle \Pi_{W^\perp} b, v \rangle}_{=0} = \langle \Pi_W b, v \rangle.$$

□

Wir fixieren ein $\vartheta = (\zeta, \sigma^2) \in \Theta$, und betrachten das Wahrscheinlichkeitsmaß \mathbb{P}_ϑ . Weiterhin fixieren wir eine Orthonormalbasis $\{v_1, \dots, v_n\}$ von \mathbb{R}^n , so dass $\{v_1, \dots, v_d\}$ eine Orthonormalbasis von W ist.

Definition 5.4.3.

- (a) *Wir setzen $\tilde{X}_i := \langle X, v_i \rangle$ für $i = 1, \dots, n$.*
- (b) *Wir setzen $Y_i := \langle X - \zeta, v_i \rangle$ für $i = 1, \dots, n$.*
- (c) *Wir setzen $Z_i := \frac{Y_i}{\sigma}$ für $i = 1, \dots, n$.*

Lemma 5.4.4.

- (a) *Die Zufallsvariablen $\tilde{X}_1, \dots, \tilde{X}_n$ sind unabhängig mit $\tilde{X}_i \sim N(\langle \zeta, v_i \rangle, \sigma^2)$ für alle $i = 1, \dots, n$.*
- (b) *Die Zufallsvariablen Y_1, \dots, Y_n sind unabhängig mit $Y_i \sim N(0, \sigma^2)$ für alle $i = 1, \dots, n$.*
- (c) *Die Zufallsvariablen Z_1, \dots, Z_n sind unabhängig mit $Z_i \sim N(0, 1)$ für alle $i = 1, \dots, n$.*

Beweis.

- (a) Folgt aus Korollar 4.3.11, da $\tilde{X} = AX$ mit der orthogonalen Matrix

$$A = \begin{pmatrix} v_1 \\ \vdots \\ v_n \end{pmatrix} \in \mathbb{R}^{n \times n}.$$

(b) Folgt aus Korollar 4.3.11, da $Y = A(X - \zeta)$ mit der orthogonalen Matrix

$$A = \begin{pmatrix} v_1 \\ \vdots \\ v_n \end{pmatrix} \in \mathbb{R}^{n \times n}.$$

(c) ✓

□

Lemma 5.4.5. *Es gelten die Darstellungen*

$$\hat{\zeta} = \sum_{i=1}^d \tilde{X}_i v_i = \zeta + \sum_{i=1}^d Y_i v_i \quad \text{und} \quad \hat{s}^2 = \frac{1}{n-d} \sum_{i=d+1}^n \tilde{X}_i^2 = \frac{1}{n-d} \sum_{i=d+1}^n Y_i^2.$$

Beweis. Es gilt

$$\hat{\zeta} = \Pi_W X = \sum_{i=1}^d \langle X, v_i \rangle v_i = \sum_{i=1}^d \tilde{X}_i v_i,$$

und wegen $\zeta \in W$ gilt

$$\hat{\zeta} = \sum_{i=1}^d \langle \zeta, v_i \rangle v_i + \sum_{i=1}^d \langle X - \zeta, v_i \rangle v_i = \zeta + \sum_{i=1}^d Y_i v_i.$$

Weiterhin gilt

$$X - \hat{\zeta} = \sum_{i=d+1}^n \tilde{X}_i v_i.$$

Wegen $\zeta \in W$ gilt $\langle \zeta, v_i \rangle = 0$ für alle $i = d+1, \dots, n$, und damit $\tilde{X}_i = Y_i$ für alle $i = d+1, \dots, n$. Es folgt

$$\hat{s}^2 = \frac{1}{n-d} \|X - \hat{\zeta}\|^2 = \frac{1}{n-d} \sum_{i=d+1}^n \tilde{X}_i^2 = \frac{1}{n-d} \sum_{i=d+1}^n Y_i^2.$$

□

Lemma 5.4.6. *Es gilt $\mathbb{E}[\hat{\zeta}] = \zeta$.*

Beweis. Nach Lemma 5.4.5 gilt

$$\mathbb{E}[\hat{\zeta}] = \mathbb{E}\left[\zeta + \sum_{i=1}^d Y_i v_i\right] = \zeta + \sum_{i=1}^d \mathbb{E}[Y_i] v_i = \zeta.$$

□

Lemma 5.4.7. Für alle $b, c \in \mathbb{R}^n$ gilt

$$\text{Cov}(\langle b, \hat{\zeta} \rangle, \langle c, \hat{\zeta} \rangle) = \langle \Pi_W b, \Pi_W c \rangle \sigma^2.$$

Beweis. Nach Lemmas 5.4.5 und 5.4.2 gilt

$$\begin{aligned} \text{Cov}(\langle b, \hat{\zeta} \rangle, \langle c, \hat{\zeta} \rangle) &= \text{Cov}\left(\left\langle b, \sum_{i=1}^d Y_i v_i \right\rangle, \left\langle c, \sum_{j=1}^d Y_j v_j \right\rangle\right) \\ &= \sum_{i=1}^d \sum_{j=1}^d \langle b, v_i \rangle \langle c, v_j \rangle \text{Cov}(Y_i, Y_j) = \sum_{i=1}^d \langle b, v_i \rangle \langle v_i, c \rangle \text{Var}[Y_i] \\ &= \sum_{i=1}^d \langle b, v_i \rangle \langle v_i, c \rangle \sigma^2 = \sum_{i=1}^d \langle \Pi_W b, v_i \rangle \langle v_i, \Pi_W c \rangle \sigma^2 = \langle \Pi_W b, \Pi_W c \rangle \sigma^2. \end{aligned}$$

□

Lemma 5.4.8. Es gilt

$$\hat{\zeta} \sim \text{N}\left(\zeta, (\langle \Pi_W e_i, \Pi_W e_j \rangle \sigma^2)_{i,j=1,\dots,n}\right).$$

Beweis. Folgt aus Lemmas 5.4.6 und 5.4.7. □

Lemma 5.4.9. Für alle $b \in \mathbb{R}^n$ gilt

$$\langle b, \hat{\zeta} \rangle \sim \text{N}(\langle b, \zeta \rangle, \|\Pi_W b\|^2 \sigma^2).$$

Beweis. Folgt aus Lemmas 5.4.6 und 5.4.7. □

Satz 5.4.10.

(a) Die Zufallsvariablen $\hat{\zeta}$ und \hat{s}^2 sind unabhängig.

(b) Für jedes $b \in \mathbb{R}^n \setminus W^\perp$ gilt

$$\frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\sigma \|\Pi_W b\|} \sim \text{N}(0, 1).$$

(c) Es gilt

$$\frac{n-d}{\sigma^2} \hat{s}^2 \sim \chi_{n-d}^2.$$

(d) Für jedes $b \in \mathbb{R}^n \setminus W^\perp$ gilt

$$\frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\hat{s} \|\Pi_W b\|} \sim t_{n-d}.$$

Beweis.

(a) Folgt aus Lemmas 5.4.4 und 5.4.5.

(b) Folgt aus Lemma 5.4.9.

(c) Mit Lemma 5.4.5 und Satz 2.2.2(a) gilt

$$\frac{n-d}{\sigma^2} \hat{s}^2 = \frac{1}{\sigma^2} \sum_{i=d+1}^n Y_i^2 = \sum_{i=d+1}^n Z_i^2 \sim \chi_{n-d}^2.$$

(d) Wir setzen

$$U := \frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\sigma \|\Pi_W b\|} \quad \text{und} \quad V := \frac{n-d}{\sigma^2} \hat{s}^2$$

Nach den Teilen (a)–(c) sind U und V unabhängig mit $U \sim N(0, 1)$ und $V \sim \chi_{n-d}^2$. Also folgt mit Satz 2.2.2(b)

$$\frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\hat{s} \|\Pi_W b\|} = \frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\sigma \|\Pi_W b\|} \cdot \sqrt{\frac{\sigma^2}{\hat{s}^2}} = \frac{U}{\sqrt{V/(n-d)}} \sim t_{n-d}.$$

□

Lemma 5.4.11. Für $W = \text{lin}\{\mathbb{1}\}$ gilt $\hat{\zeta} = \bar{X}\mathbb{1}$ und $\hat{s}^2 = s^2$.

Beweis. Wir setzen $v_1 = \frac{\mathbb{1}}{\sqrt{n}} \in W$. Dann gilt $\|v_1\| = 1$, und folglich

$$\hat{\zeta} = \Pi_W X = \langle X, v_1 \rangle v_1 = \left\langle X, \frac{\mathbb{1}}{\sqrt{n}} \right\rangle \frac{\mathbb{1}}{\sqrt{n}} = \frac{1}{n} \langle X, \mathbb{1} \rangle \mathbb{1} = \bar{X}\mathbb{1}.$$

Weiterhin gilt

$$\begin{aligned} s^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} \|X - \bar{X}\mathbb{1}\|^2 \\ &= \frac{1}{n-1} \|X - \hat{\zeta}\|^2 = \hat{s}^2. \end{aligned}$$

□

Bemerkung 5.4.12. Wir betrachten den Fall $W = \text{lin}\{\mathbb{1}\}$. Dann gilt $\hat{\zeta} = \bar{X}\mathbb{1}$ und $\zeta = \mu\mathbb{1}$ mit $\mu \in \mathbb{R}$. Wir setzen $b := \frac{\mathbb{1}}{n}$. Dann gilt $b \in W$ mit

$$\|b\| = \left\| \frac{\mathbb{1}}{n} \right\| = \frac{1}{n} \|\mathbb{1}\| = \frac{1}{n} \sqrt{1^2 + \dots + 1^2} = \frac{\sqrt{n}}{n} = \frac{1}{\sqrt{n}},$$

und für alle $\gamma \in \mathbb{R}$ gilt

$$\langle b, \gamma\mathbb{1} \rangle = \left\langle \frac{\mathbb{1}}{n}, \gamma\mathbb{1} \right\rangle = \frac{\gamma}{n} \langle \mathbb{1}, \mathbb{1} \rangle = \gamma.$$

Also verallgemeinert Satz 5.4.10 den Satz 2.2.3.

Lemma 5.4.13. Es gilt $\mathbb{E}[\hat{s}^2] = \sigma^2$.

Beweis. Wir setzen

$$V := \frac{n-d}{\sigma^2} \hat{s}^2.$$

Nach Satz 5.4.10(c) gilt $V \sim \chi_{n-d}^2$, und daher $\mathbb{E}[V] = n-d$. Also folgt

$$\mathbb{E}[\hat{s}^2] = \frac{\sigma^2}{n-d} \mathbb{E}[V] = \sigma^2.$$

□

Definition 5.4.14. Zwei statistische Modelle

$$\mathcal{M} = (\Omega, \mathcal{F}, (\mathbb{P}_\vartheta : \vartheta \in \Theta)) \quad \text{und} \quad \mathcal{N} = (\Omega, \mathcal{F}, (\mathbb{Q}_\gamma : \gamma \in \Gamma))$$

heißen äquivalent, falls

$$\{\mathbb{P}_\vartheta : \vartheta \in \Theta\} = \{\mathbb{Q}_\gamma : \gamma \in \Gamma\}.$$

Lemma 5.4.15. Es seien \mathcal{M} und \mathcal{N} zwei äquivalente statistische Modelle, und es sei $S : \Omega \rightarrow E$ eine Statistik mit Werten in einem messbaren Raum (E, \mathcal{E}) . Dann sind folgende Aussagen äquivalent:

- (i) S ist suffizient bezüglich \mathcal{M} .
- (ii) S ist suffizient bezüglich \mathcal{N} .

Beweis. (i) \Rightarrow (ii): Es sei $f : \Omega \rightarrow \mathbb{R}$ eine messbare, beschränkte Funktion. Nach Voraussetzung existiert eine $\sigma(S)$ -messbare Zufallsvariable $g : \Omega \rightarrow \mathbb{R}$, so dass

$$\mathbb{E}_{\mathbb{P}_\vartheta}[f | S] = g \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für jedes } \vartheta \in \Theta.$$

Für jedes $\gamma \in \Gamma$ existiert ein $\vartheta \in \Theta$, so dass $\mathbb{Q}_\gamma = \mathbb{P}_\vartheta$. Also folgt

$$\mathbb{E}_{\mathbb{Q}_\gamma}[f | S] = g \quad \mathbb{Q}_\gamma\text{-fast sicher} \quad \text{für jedes } \gamma \in \Gamma.$$

(ii) \Rightarrow (i): verläuft analog.

□

Lemma 5.4.16. *Es seien \mathcal{M} und \mathcal{N} zwei äquivalente statistische Modelle, und es sei $S : \Omega \rightarrow E$ eine Statistik mit Werten in einem messbaren Raum (E, \mathcal{E}) . Dann sind folgende Aussagen äquivalent:*

- (i) S ist vollständig bezüglich \mathcal{M} .
- (ii) S ist vollständig bezüglich \mathcal{N} .

Beweis. (i) \Rightarrow (ii): Es sei $h : E \rightarrow \mathbb{R}$ eine messbare Funktion mit $h(S) \in \mathcal{L}^2(\mathbb{Q}_\gamma)$ für alle $\gamma \in \Gamma$, so dass

$$\mathbb{E}_{\mathbb{Q}_\gamma}[h(S)] = 0 \quad \text{für alle } \gamma \in \Gamma.$$

Für jedes $\vartheta \in \Theta$ existiert ein $\gamma \in \Gamma$, so dass $\mathbb{P}_\vartheta = \mathbb{Q}_\gamma$. Also folgt $h(S) \in \mathcal{L}^2(\mathbb{P}_\vartheta)$ für alle $\vartheta \in \Theta$, sowie

$$\mathbb{E}_{\mathbb{P}_\vartheta}[h(S)] = 0 \quad \text{für alle } \vartheta \in \Theta.$$

Nach Voraussetzung folgt

$$h(S) = 0 \quad \mathbb{P}_\vartheta\text{-fast sicher} \quad \text{für alle } \vartheta \in \Theta.$$

Für jedes $\gamma \in \Gamma$ existiert ein $\vartheta \in \Theta$, so dass $\mathbb{Q}_\gamma = \mathbb{P}_\vartheta$. Also folgt

$$h(S) = 0 \quad \mathbb{Q}_\gamma\text{-fast sicher} \quad \text{für alle } \gamma \in \Gamma.$$

(ii) \Rightarrow (i): verläuft analog. □

Satz 5.4.17. *Die Statistik*

$$S = \left(\tilde{X}_1, \dots, \tilde{X}_d, \sum_{i=1}^n \tilde{X}_i^2 \right)$$

ist vollständig und suffizient.

Beweis. Da die Statistik S von der transformierten Stichprobe \tilde{X} abhängt, dürfen wir nach Lemma 5.4.4 das statistische Modell mit

$$\mathbb{P}_\vartheta = \bigotimes_{i=1}^n N(\langle \zeta, v_i \rangle, \sigma^2), \quad \vartheta = (\zeta, \sigma^2) \in W \times (0, \infty) = \Theta$$

betrachten. Gemäß Lemmas 5.4.15 und 5.4.16 dürfen wir das statistische Modell mit

$$\mathbb{Q}_\vartheta = \bigotimes_{i=1}^d N(\eta_i, \sigma^2) \times \bigotimes_{i=d+1}^n N(0, \sigma^2), \quad \vartheta = (\eta, \sigma^2) \in \mathbb{R}^d \times (0, \infty) =: \Gamma$$

betrachten. Die Likelihood-Funktion ist gegeben durch

$$\begin{aligned} L(\vartheta, x) &= \prod_{i=1}^d \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\eta_i)^2}{2\sigma^2}\right) \cdot \prod_{i=d+1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \\ &= \exp\left(-\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{1}{\sigma^2} \sum_{i=1}^d x_i \eta_i - \frac{1}{2\sigma^2} \sum_{i=1}^d \eta_i^2\right). \end{aligned}$$

Also ist \mathcal{M} eine mehrdimensionale exponentielle Familie der Form

$$L(\vartheta, x) = \exp(\langle a(\vartheta), T(x) \rangle_{\mathbb{R}^{d+1}} - b(\vartheta)) \cdot h(x) \quad \text{für alle } (\vartheta, x) \in \Gamma \times \Omega,$$

wobei

$$\begin{aligned} a(\vartheta) &= \left(\frac{\eta_1}{\sigma^2}, \dots, \frac{\eta_d}{\sigma^2}, -\frac{1}{2\sigma^2}\right) = \left(\frac{\eta}{\sigma^2}, -\frac{1}{2\sigma^2}\right), \\ b(\vartheta) &= \frac{n}{2} \ln(2\pi\sigma^2) + \frac{1}{2\sigma^2} \sum_{i=1}^d \eta_i^2 = \frac{n}{2} \ln(2\pi\sigma^2) + \frac{1}{2\sigma^2} \|\eta\|_{\mathbb{R}^d}^2, \\ T(x) &= \left(x_1, \dots, x_d, \sum_{i=1}^n x_i^2\right) = \left((x_i)_{i=1, \dots, d}, \|x\|_{\mathbb{R}^n}^2\right), \\ h(x) &= 1. \end{aligned}$$

Für jedes $\vartheta \in \Gamma$ gilt

$$J_a(\vartheta) = \begin{pmatrix} \frac{\text{Id}}{\sigma^2} & -\frac{\eta}{\sigma^4} \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix} \in \mathbb{R}^{(d+1) \times (d+1)},$$

und daher

$$\det J_a(\vartheta) = \frac{1}{2\sigma^{2d+4}} > 0.$$

Nun folgt mit Satz 1.10.10, dass S vollständig und suffizient ist. \square

Satz 5.4.18.

(a) Für jedes $b \in \mathbb{R}^n$ ist $\langle b, \hat{\zeta} \rangle$ der eindeutig bestimmte gleichmäßig beste Schätzer für $\langle b, \zeta \rangle$.

(b) $\hat{\sigma}^2$ ist der eindeutig bestimmte gleichmäßig beste Schätzer für σ^2 .

Beweis. Nach Satz 5.4.17 ist die Statistik

$$S = \left(\tilde{X}_1, \dots, \tilde{X}_d, \sum_{i=1}^n \tilde{X}_i^2\right)$$

vollständig und suffizient.

(a) Wir definieren

$$h : \mathbb{R}^{d+1} \rightarrow \mathbb{R}, \quad h(x) = \left\langle b, \sum_{i=1}^d x_i v_i \right\rangle.$$

Nach Lemma 5.4.5 gilt

$$\langle b, \hat{\zeta} \rangle = \left\langle b, \sum_{i=1}^d \tilde{X}_i v_i \right\rangle = h(S).$$

Nach Lemma 5.4.9 gilt außerdem für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$

$$\mathbb{E}_\vartheta[h(S)] = \mathbb{E}_\vartheta[\langle b, \hat{\zeta} \rangle] = \langle b, \zeta \rangle.$$

Also folgt mit Korollar 1.9.4, dass $\langle b, \hat{\zeta} \rangle$ der eindeutig bestimmte gleichmäßig beste Schätzer für $\langle b, \zeta \rangle$ ist.

(b) Wir definieren

$$h : \mathbb{R}^{d+1} \rightarrow \mathbb{R}, \quad h(x) = \frac{1}{n-d} \left(x_{d+1} - \sum_{i=1}^d x_i^2 \right).$$

Nach Lemma 5.4.5 gilt

$$\hat{s}^2 = \frac{1}{n-d} \sum_{i=d+1}^n \tilde{X}_i^2 = h(S).$$

Nach Lemma 5.4.13 gilt außerdem für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$

$$\mathbb{E}_\vartheta[h(S)] = \sigma^2.$$

Also folgt mit Korollar 1.9.4, dass \hat{s}^2 der eindeutig bestimmte gleichmäßig beste Schätzer für σ^2 ist.

□

Definition 5.4.19. Ein Schätzer $T : \Omega \rightarrow \mathbb{R}$ heißt linear, falls $T = \langle b, X \rangle$ für ein $b \in \mathbb{R}^n$.

Definition 5.4.20. Es seien $\tau : \Theta \rightarrow \mathbb{R}$ eine Kenngröße und $T : \Omega \rightarrow \mathbb{R}$ ein erwartungstreuer, linearer Schätzer für τ . Dann heißt T ein gleichmäßig bester linearer Schätzer (oder BLUE für "best linear unbiased estimator"), wenn

$$\text{Var}_\vartheta[T] \leq \text{Var}_\vartheta[S]$$

für alle $\vartheta \in \Theta$ und für jeden erwartungstreuen, linearen Schätzer $S : \Omega \rightarrow \mathbb{R}$ für τ .

Satz 5.4.21 (Satz von Gauß-Markov). *Für jedes $b \in \mathbb{R}^n$ ist $\langle b, \hat{\zeta} \rangle$ der eindeutig bestimmte gleichmäßig beste lineare Schätzer für $\langle b, \zeta \rangle$, und es gilt*

$$\text{Var}_\vartheta[\langle b, \hat{\zeta} \rangle] = \|\Pi_W b\|^2 \sigma^2 \quad \text{für alle } \vartheta = (\zeta, \sigma^2) \in \Theta.$$

Beweis. Wir setzen $T := \langle b, \hat{\zeta} \rangle$. Dann gilt

$$T = \langle b, \Pi_W X \rangle = \langle \Pi_W b, X \rangle.$$

Also ist T ein linearer Schätzer, der nach Lemma 5.4.9 erwartungstreu für $\langle b, \zeta \rangle$ ist. Nun sei $c \in \mathbb{R}^n$, so dass der Schätzer $S = \langle c, X \rangle$ erwartungstreu für $\langle b, \zeta \rangle$ ist. Dann gilt für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$

$$\langle b, \zeta \rangle = \mathbb{E}_\vartheta[S] = \mathbb{E}_\vartheta[\langle c, X \rangle] = \langle c, \zeta \rangle.$$

Also gilt

$$\langle b - c, \zeta \rangle = 0 \quad \text{für alle } \zeta \in W.$$

Es folgt $b - c \in W^\perp$, und damit $\Pi_W b = \Pi_W c$. Nun sei $\vartheta = (\zeta, \sigma^2) \in \Theta$ beliebig. Mit Lemma 5.4.9 folgt

$$\text{Var}_\vartheta[T] = \text{Var}_\vartheta[\langle b, \hat{\zeta} \rangle] = \|\Pi_W b\|^2 \sigma^2 = \|\Pi_W c\|^2 \sigma^2.$$

Außerdem gilt

$$\text{Var}_\vartheta[S] = \text{Var}_\vartheta[\langle c, X \rangle] = \text{Var}_\vartheta\left[\sum_{i=1}^n c_i X_i\right] = \sum_{i=1}^n c_i^2 \sigma^2 = \|c\|^2 \sigma^2.$$

Wegen

$$\|c\|^2 = \|\Pi_W c\|^2 + \|\Pi_{W^\perp} c\|^2$$

gilt also

$$\text{Var}_\vartheta[T] \leq \text{Var}_\vartheta[S] \quad \text{für alle } \vartheta \in \Theta,$$

und folglich ist T ein gleichmäßig bester linearer Schätzer für $\langle b, \zeta \rangle$. Zum Beweis der Eindeutigkeit nehmen wir an, dass

$$\text{Var}_\vartheta[T] = \text{Var}_\vartheta[S] \quad \text{für alle } \vartheta \in \Theta.$$

Dann folgt $\|\Pi_{W^\perp} c\| = 0$, und daher $c \in W$. Nun folgt aber $c = \Pi_W c = \Pi_W b$, und damit $T = S$. \square

Bemerkung 5.4.22. *Selbstverständlich läßt sich der Satz von Gauß-Markov (Satz 5.4.21) einfacher mit Hilfe von Satz 5.4.18 beweisen.*

5.5 Bereichsschätzer

Wir betrachten ein lineares Modell \mathcal{M} mit koordinatenfreier Darstellung. Wir nehmen an, dass $d < n$, wobei $d = \dim(W)$.

Satz 5.5.1.

(a) Für jedes $b \in \mathbb{R}^n \setminus W$ ist die Zufallsvariable

$$\pi(\vartheta, \cdot) = \frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle}{\hat{s} \|\Pi_W b\|}, \quad \vartheta = (\zeta, \sigma^2)$$

eine Pivot-Statistik mit Pivot-Verteilung $\eta = t_{n-d}$.

(b) Für jedes $b \in \mathbb{R}^n \setminus W$ und jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C_b : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch

$$C_b = \langle b, \hat{\zeta} \rangle \pm t_{n-d, 1-\alpha/2} \hat{s} \|\Pi_W b\|$$

ein Konfidenzintervall für $\langle b, \zeta \rangle$ zum Niveau α .

(c) Für jedes $\alpha \in (0, 1)$ ist die zufällige Kugel $C : \Omega \rightarrow \mathcal{B}(W)$ gegeben durch

$$C = \hat{\zeta} + B_W(\sqrt{d} t_{n-d, 1-\alpha/(2d)} \hat{s})$$

mit

$$B_W(\epsilon) := \{x \in W : \|x\| \leq \epsilon\}$$

ein Konfidenzbereich für ζ zum Niveau α .

Beweis.

(a) Folgt aus Satz 5.4.10(d).

(b) Es sei F die Verteilungsfunktion von η . Mit $c := t_{n-d, 1-\alpha/2}$ und $B = [-c, c]$ gilt wegen der Symmetrie der Dichte

$$\begin{aligned} \eta(B) &= \eta((-\infty, c]) - \eta((-\infty, -c)) = F(c) - F(-c) = F(c) - (1 - F(c)) \\ &= 2F(c) - 1 = 2\left(1 - \frac{\alpha}{2}\right) - 1 = 1 - \alpha, \end{aligned}$$

und für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$ gilt

$$\begin{aligned} \{\langle b, \zeta \rangle \in C_b\} &= \left\{ \langle b, \zeta \rangle \in \langle b, \hat{\zeta} \rangle \pm t_{n-d, 1-\alpha/2} \hat{s} \|\Pi_W b\| \right\} \\ &= \left\{ \langle b, \hat{\zeta} \rangle - c \hat{s} \|\Pi_W b\| \leq \langle b, \zeta \rangle \leq \langle b, \hat{\zeta} \rangle + c \hat{s} \|\Pi_W b\| \right\} \\ &= \left\{ \langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle - c \hat{s} \|\Pi_W b\| \leq 0 \leq \langle b, \hat{\zeta} \rangle - \langle b, \zeta \rangle + c \hat{s} \|\Pi_W b\| \right\} \\ &= \{\pi(\vartheta, \cdot) - c \leq 0 \leq \pi(\vartheta, \cdot) + c\} \\ &= \{|\pi(\vartheta, \cdot)| \leq c\} = \{\pi(\vartheta, \cdot) \in B\}. \end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

- (c) Es sei $c := t_{n-d, 1-\alpha/2}$. Es sei $\{v_1, \dots, v_d\}$ eine Orthonormalbasis von W . Nach Teil (b) und Satz 2.1.3 ist das Zufallsrechteck $\tilde{C} : \Omega \rightarrow \mathcal{B}(\mathbb{R}^d)$ gegeben durch

$$\tilde{C} := \left(\langle v_1, \hat{\zeta} \rangle \pm c \hat{s} \right) \times \dots \times \left(\langle v_d, \hat{\zeta} \rangle \pm c \hat{s} \right)$$

ist ein Konfidenzbereich für $\langle v, \zeta \rangle := (\langle v_1, \zeta \rangle, \dots, \langle v_d, \zeta \rangle)$ zum Niveau α . Für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$ folgt

$$\begin{aligned} \mathbb{P}_\vartheta(\zeta \in C) &= \mathbb{P}_\vartheta(\|\hat{\zeta} - \zeta\| \leq \sqrt{d} c \hat{s}) = \mathbb{P}_\vartheta(\|\hat{\zeta} - \zeta\|^2 \leq d c^2 \hat{s}^2) \\ &= \mathbb{P}_\vartheta\left(\sum_{i=1}^d |\langle v_i, \hat{\zeta} - \zeta \rangle|^2 \leq d c^2 \hat{s}^2\right) \geq \mathbb{P}_\vartheta\left(\bigcap_{i=1}^d \{|\langle v_i, \hat{\zeta} - \zeta \rangle|^2 \leq c^2 \hat{s}^2\}\right) \\ &= \mathbb{P}_\vartheta\left(\bigcap_{i=1}^d \{|\langle v_i, \hat{\zeta} - \zeta \rangle| \leq c \hat{s}\}\right) = \mathbb{P}_\vartheta(\langle v, \zeta \rangle \in \tilde{C}) \geq 1 - \alpha. \end{aligned}$$

□

Satz 5.5.2.

- (a) Die Zufallsvariable

$$\pi(\vartheta, \cdot) = \frac{n-d}{\sigma^2} \hat{s}^2, \quad \vartheta = (\zeta, \sigma^2)$$

ist eine Pivot-Statistik mit Pivot-Verteilung $\eta = \chi_{n-d}^2$.

- (b) Für jedes $\alpha \in (0, 1)$ ist das Zufallsintervall $C : \Omega \rightarrow \mathcal{B}(\mathbb{R})$ gegeben durch

$$C = \left[\frac{n-d}{\chi_{n-d, 1-\alpha/2}^2} \hat{s}^2, \frac{n-d}{\chi_{n-d, \alpha/2}^2} \hat{s}^2 \right]$$

ein Konfidenzintervall für σ^2 zum Niveau α .

Beweis.

(a) Folgt aus Satz 5.4.10(c).

(b) Es sei F die Verteilungsfunktion von η . Mit $B = [\chi_{n-d,\alpha/2}^2, \chi_{n-d,1-\alpha/2}^2]$ gilt

$$\begin{aligned}\eta(B) &= \eta((-\infty, \chi_{n-d,1-\alpha/2}^2]) - \eta((-\infty, \chi_{n-d,\alpha/2}^2)) \\ &= F(\chi_{n-d,1-\alpha/2}^2) - F(\chi_{n-d,\alpha/2}^2) = \left(1 - \frac{\alpha}{2}\right) - \frac{\alpha}{2} = 1 - \alpha,\end{aligned}$$

und für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$ gilt

$$\begin{aligned}\{\sigma^2 \in C\} &= \left\{ \sigma^2 \in \left[\frac{n-d}{\chi_{n-d,1-\alpha/2}^2} \hat{s}^2, \frac{n-d}{\chi_{n-d,\alpha/2}^2} \hat{s}^2 \right] \right\} \\ &= \left\{ \frac{n-d}{\chi_{n-d,1-\alpha/2}^2} \hat{s}^2 \leq \sigma^2 \leq \frac{n-d}{\chi_{n-d,\alpha/2}^2} \hat{s}^2 \right\} \\ &= \left\{ \frac{1}{\chi_{n-d,1-\alpha/2}^2} \leq \frac{1}{\pi(\vartheta, \cdot)} \leq \frac{1}{\chi_{n-d,\alpha/2}^2} \right\} \\ &= \{ \chi_{n-d,\alpha/2}^2 \leq \pi(\vartheta, \cdot) \leq \chi_{n-d,1-\alpha/2}^2 \} \\ &= \{ \pi(\vartheta, \cdot) \in B \}.\end{aligned}$$

Also folgt dieser Teil mit Satz 2.1.5.

□

Korollar 5.5.3. Für jedes $\alpha \in (0, 1)$ ist der Bereichsschätzer $C : \Omega \rightarrow \mathcal{B}(\Theta)$ gegeben durch

$$C = \left(\hat{\zeta} + B_W(\sqrt{d} t_{n-d,1-\alpha/(4d)} \hat{s}) \right) \times \left[\frac{n-d}{\chi_{n-d,1-\alpha/4}^2} \hat{s}^2, \frac{n-d}{\chi_{n-d,\alpha/4}^2} \hat{s}^2 \right]$$

ein Konfidenzbereich für (ζ, σ^2) zum Niveau α .

Beweis. Folgt aus den Sätzen 2.1.3 und 5.5.1, 5.5.2.

□

5.6 Hypothesentests

Wir betrachten ein lineares Modell \mathcal{M} mit koordinatenfreier Darstellung. Wir nehmen an, dass $d < n$, wobei $d = \dim(W)$.

Satz 5.6.1 (*t*-Test für den Erwartungswert). *Es sei $\zeta_0 \in W$ beliebig. Wir zerlegen Θ in*

$$\Theta_0 = \{\zeta_0\} \times (0, \infty) \quad \text{und} \quad \Theta_1 = (W \setminus \{\zeta_0\}) \times (0, \infty).$$

Wir betrachten also die Null-Hypothese $H_0 = \{\zeta = \zeta_0\}$ und die Alternative $H_1 = \{\zeta \neq \zeta_0\}$. Für jedes $\alpha \in (0, 1)$ ist $\varphi = \mathbb{1}_B$ mit

$$B := \{\|\hat{\zeta} - \zeta_0\| > \sqrt{d} t_{n-d, 1-\alpha/(2d)} \hat{s}\}$$

ein zulässiger Test zum Irrtumsniveau α .

Beweis. Wir setzen $c := t_{n-d, 1-\alpha/(2d)}$. Es sei $b \in \mathbb{R}^n \setminus W^\perp$ beliebig. Weiterhin sei $\vartheta = (\zeta_0, \sigma^2) \in \Theta_0$ beliebig. Nach Satz 5.4.10(d) gilt

$$\frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta_0 \rangle}{\hat{s} \|\Pi_W b\|} \sim t_{n-d} \quad \text{unter } \mathbb{P}_\vartheta.$$

Es folgt

$$\mathbb{P}_\vartheta(|\langle b, \hat{\zeta} - \zeta_0 \rangle| > c \hat{s} \|\Pi_W b\|) = \mathbb{P}_\vartheta\left(\left|\frac{\langle b, \hat{\zeta} \rangle - \langle b, \zeta_0 \rangle}{\hat{s} \|\Pi_W b\|}\right| > c\right) \leq \frac{\alpha}{d}.$$

Nun sei $\{v_1, \dots, v_d\}$ eine Orthonormalbasis von W . Dann folgt

$$\begin{aligned} G_\varphi(\vartheta) &= \mathbb{E}_\vartheta[\varphi] = \mathbb{E}_\vartheta[\mathbb{1}_B] = \mathbb{P}_\vartheta(B) = \mathbb{P}_\vartheta(\|\hat{\zeta} - \zeta_0\| > \sqrt{dc} \hat{s}) \\ &= \mathbb{P}_\vartheta(\|\hat{\zeta} - \zeta_0\|^2 > dc^2 \hat{s}^2) = \mathbb{P}_\vartheta\left(\sum_{i=1}^d |\langle v_i, \hat{\zeta} - \zeta_0 \rangle|^2 > dc^2 \hat{s}^2\right) \\ &\leq \mathbb{P}_\vartheta\left(\bigcup_{i=1}^d \{|\langle v_i, \hat{\zeta} - \zeta_0 \rangle|^2 > c^2 \hat{s}^2\}\right) \leq \sum_{i=1}^d \mathbb{P}_\vartheta(|\langle v_i, \hat{\zeta} - \zeta_0 \rangle| > c \hat{s}) \leq d \cdot \frac{\alpha}{d} = \alpha. \end{aligned}$$

□

Bemerkung 5.6.2. *Satz 5.6.1 folgt auch aus Satz 3.5.1 und Satz 5.5.1(c).*

Bemerkung 5.6.3. *Satz 5.5.1(c) folgt auch aus Satz 3.5.3 und Satz 5.6.1.*

Satz 5.6.4 (χ^2 -Test für die Varianz). *Es sei $\sigma_0^2 \in (0, \infty)$ beliebig. Wir zerlegen Θ in*

$$\Theta_0 = W \times (0, \sigma_0^2] \quad \text{und} \quad \Theta_1 = W \times (\sigma_0^2, \infty).$$

Wir betrachten also die Null-Hypothese $H_0 = \{\sigma^2 \leq \sigma_0^2\}$ und die Alternative $H_1 = \{\sigma^2 > \sigma_0^2\}$. Für jedes $\alpha \in (0, 1)$ ist $\varphi = \mathbb{1}_B$ mit

$$B := \{(n-d)\hat{s}^2 > \sigma_0^2 \chi_{n-d, 1-\alpha}^2\}$$

ein zulässiger Test zum Irrtumsniveau α .

Beweis. Wir setzen $c := \chi_{n-d, 1-\alpha}^2$. Weiterhin sei $\vartheta = (\zeta, \sigma^2) \in \Theta_0$ beliebig. Es gilt also $\sigma^2 \leq \sigma_0^2$. Nach Satz 5.4.10(c) gilt

$$\frac{n-d}{\sigma^2} \hat{s}^2 \sim \chi_{n-d}^2 \quad \text{unter } \mathbb{P}_\vartheta,$$

und es folgt

$$\begin{aligned} G_\varphi(\vartheta) &= \mathbb{E}_\vartheta[\varphi] = \mathbb{E}_\vartheta[\mathbb{1}_B] = \mathbb{P}_\vartheta(B) \\ &= \mathbb{P}_\vartheta((n-d)\hat{s}^2 > \sigma_0^2 c) \leq \mathbb{P}_\vartheta((n-d)\hat{s}^2 > \sigma^2 c) = \mathbb{P}_\vartheta\left(\frac{n-d}{\sigma^2} \hat{s}^2 > c\right) = \alpha. \end{aligned}$$

□

Nun sei $W_0 \subset W$ ein weiterer Unterraum mit $e < d$, wobei $e = \dim(W_0)$. Wir zerlegen $\Theta = W \times (0, \infty)$ in

$$\Theta_0 = W_0 \times (0, \infty) \quad \text{und} \quad \Theta_1 = (W \setminus W_0) \times (0, \infty).$$

Wir haben also die Null-Hypothese $H_0 = \{\zeta \in W_0\}$ und die Alternative $H_1 = \{\zeta \notin W_0\}$.

Beispiel 5.6.5. *Bei der einfachen linearen Regression (Beispiel 5.2.3) mit*

$$W = \text{lin}\{\mathbb{1}, y\}$$

setzen wir

$$W_0 = \text{lin}\{\mathbb{1}\}.$$

Wir testen also, ob tatsächlich eine nichttriviale lineare Abhängigkeit tatsächlich vorliegt. Genauer sind hier:

- H_0 : Gauß'sches Produktmodell. *Es liegt also keine Abhängigkeit zwischen der Stichprobe X und den Kontrollvariablen y vor.*
- H_1 : Lineares Regressionsmodell, das kein Produktmodell ist. *Es liegt also eine Abhängigkeit zwischen der Stichprobe X und den Kontrollvariablen y vor; und zwar eine lineare.*

Beispiel 5.6.6. *Bei der polynomialen Regression (Beispiel 5.2.5) mit*

$$W = \text{lin}\{\mathbb{1}, y, y^2, \dots, y^{d-1}\}$$

setzen wir

$$W_0 = \text{lin}\{\mathbb{1}, y, y^2, \dots, y^{e-1}\}$$

für ein $e < d$. Wir testen also, ob der Grad des Polynoms reduziert werden kann. Im Fall $e = 2$ ist $W_0 = \text{lin}\{\mathbb{1}, y\}$, und wir erhalten:

- H_0 : Lineares Regressionsmodell.
- H_1 : Polynomiales Regressionsmodell, das nicht linear ist.

Beispiel 5.6.7. Bei der mehrfachen linearen Regression (Beispiel 5.2.6) mit

$$W = \text{lin}\{\mathbb{1}, y_1, \dots, y_{d-1}\}$$

setzen wir

$$W_0 = \text{lin}(\{\mathbb{1}\} \cup \{y_i : i \in I\})$$

mit einer echten Teilmenge $I \subsetneq \{1, \dots, d-1\}$. Wir testen also, ob die Anzahl der linearen Einflüsse verkleinert werden kann. Wichtige Spezialfälle sind $W_0 = \text{lin}\{\mathbb{1}, y_i\}$ für ein $i = 1, \dots, d-1$ sowie $W_0 = \text{lin}\{\mathbb{1}\}$.

Beispiel 5.6.8. Beim Mehrstichprobenproblem (Beispiel 5.2.7) mit

$$W = \text{lin}\{f_1, \dots, f_d\},$$

wobei die f_1, \dots, f_d wie in Beispiel 5.3.10 die „verallgemeinerten Einheitsvektoren“ bezeichnen, setzen wir

$$W_0 = \text{lin}\{\mathbb{1}\}.$$

Wir testen also, ob alle Gruppenmittel übereinstimmen. Genauer sind hier:

- H_0 : Alle Gruppenmittel stimmen überein.
- H_1 : Es gibt (mindestens zwei) Gruppen, deren Gruppenmittel nicht übereinstimmt.

Definition 5.6.9. Es seien $X_1, \dots, X_n \sim N(\mu_i, 1)$ unabhängige Zufallsvariablen. Die Verteilung von

$$U := \sum_{i=1}^n X_i^2 = \|X\|^2$$

heißt die nichtzentrale χ^2 -Verteilung mit n Freiheitsgraden und Nichtzentralitätsparameter

$$\delta^2 := \sum_{i=1}^n \mu_i^2 = \|\mu\|^2 \in \mathbb{R}_+.$$

Wir bezeichnen sie mit $\chi_n^2(\delta^2)$.

Bemerkung 5.6.10. Es gilt $\chi_n^2 = \chi_n^2(0)$.

Definition 5.6.11. Es seien $U \sim \chi_n^2(\delta^2)$ und $V \sim \chi_m^2$ unabhängige Zufallsvariablen. Die Verteilung von

$$Z := \frac{mU}{nV}$$

heißt die nichtzentrale Fischer-Verteilung mit (n, m) Freiheitsgraden und Nichtzentralitätsparameter δ^2 . Wir bezeichnen sie mit $F_{n,m}(\delta^2)$.

Definition 5.6.12. Wir nennen $F_{n,m} := F_{n,m}(0)$ die die Fischer-Verteilung mit (n, m) Freiheitsgraden.

Satz 5.6.13. Die Fischer-Verteilung $F_{n,m}$ ist absolutstetig mit Dichte $f : \mathbb{R} \rightarrow \mathbb{R}_+$ gegeben durch

$$f(x) = \frac{n^{n/2} m^{m/2}}{B(n/2, m/2)} \frac{x^{\frac{n}{2}-1}}{(m + nx)^{(n+m)/2}} \mathbb{1}_{(0, \infty)}(x),$$

wobei

$$B(r, s) = \frac{\Gamma(r)\Gamma(s)}{\Gamma(r+s)}$$

die Betafunktion bezeichnet.

Wir fixieren ein $\vartheta = (\zeta, \sigma^2) \in \Theta$.

Definition 5.6.14.

- (a) Wir setzen $\zeta_0 := \Pi_{W_0}\zeta$ und $\hat{\zeta}_0 := \Pi_{W_0}X$.
 (b) Wir setzen

$$\hat{\sigma}_0^2 := \frac{1}{d-e} \|\hat{\zeta} - \hat{\zeta}_0\|^2.$$

- (c) Wir definieren die Quotienten-Statistik

$$V_n := \frac{\hat{\sigma}_0^2}{\hat{\sigma}^2} = \frac{n-d}{d-e} \frac{\|\hat{\zeta} - \hat{\zeta}_0\|^2}{\|X - \hat{\zeta}\|^2}.$$

Definition 5.6.15. Für zwei Unterräume $U \subset V \subset \mathbb{R}^n$ mit $\dim(U) = e$ und $\dim(V) = d$ setzen wir

$$\hat{\sigma}_{V,U}^2 := \frac{1}{d-e} \|\Pi_V X - \Pi_U X\|^2.$$

Bemerkung 5.6.16. Es gilt $\hat{s}^2 = \hat{s}_{\mathbb{R}^n, W}^2$ und $\hat{s}_0^2 = \hat{s}_{W, W_0}^2$, und daher

$$V_n = \frac{\hat{s}_{W, W_0}^2}{\hat{s}_{\mathbb{R}^n, W}^2}.$$

Satz 5.6.17 (Pythagoras). Es gilt die Zerlegung

$$\begin{aligned} (n - e)\hat{s}_{\mathbb{R}^n, W_0}^2 &= (n - d)\hat{s}_{\mathbb{R}^n, W}^2 + (d - e)\hat{s}_{W, W_0}^2 \\ &= (n - d)\hat{s}^2 + (d - e)\hat{s}_0^2. \end{aligned}$$

Beweis. Es gilt

$$\begin{aligned} (n - e)\hat{s}_{\mathbb{R}^n, W_0}^2 &= \|X - \Pi_{W_0} X \mathbb{1}\|^2 = \|X - \Pi_W X\|^2 + \|\Pi_W X - \Pi_{W_0} X \mathbb{1}\|^2 \\ &= (n - d)\hat{s}_{\mathbb{R}^n, W}^2 + (d - e)\hat{s}_{W_0, W}^2. \end{aligned}$$

□

Wir setzen

$$\delta^2 := \frac{\|\zeta - \zeta_0\|^2}{\sigma^2}.$$

Satz 5.6.18. Die Schätzer \hat{s}^2 und \hat{s}_0^2 sind unabhängig mit

$$\frac{n - d}{\sigma^2} \hat{s}^2 \sim \chi_{n-d}^2 \quad \text{und} \quad \frac{d - e}{\sigma^2} \hat{s}_0^2 \sim \chi_{d-e}^2(\delta^2).$$

Folglich gilt $V_n \sim F_{d-e, n-d}(\delta^2)$.

Beweis. Nach Satz 5.4.10(c) gilt

$$\frac{n - d}{\sigma^2} \hat{s}^2 \sim \chi_{n-d}^2.$$

Es sei $\{v_1, \dots, v_n\}$ eine Orthonormalbasis von \mathbb{R}^n , so dass $\{v_1, \dots, v_e\}$ eine Orthonormalbasis von W_0 ist, und $\{v_1, \dots, v_d\}$ eine Orthonormalbasis von W ist. Wir setzen $Y_i := \langle X, v_i \rangle$ und $Z_i := \frac{Y_i}{\sigma}$ für $i = 1, \dots, n$. Dann sind die Zufallsvariablen Z_1, \dots, Z_n unabhängig mit $Z_i \sim N(\mu_i, 1)$ für alle $i = 1, \dots, n$, wobei

$$\mu_i := \frac{\langle \zeta, v_i \rangle}{\sigma}, \quad i = 1, \dots, n.$$

Es gilt

$$\delta^2 = \frac{\|\zeta - \zeta_0\|^2}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=e+1}^d |\langle \zeta, v_i \rangle|^2 = \sum_{i=e+1}^d \mu_i^2 = \|(\mu_{e+1}, \dots, \mu_d)\|^2,$$

und daher folgt

$$\frac{d-e}{\sigma^2} \hat{s}_0^2 = \frac{1}{\sigma^2} \|\hat{\zeta} - \hat{\zeta}_0\|^2 = \frac{1}{\sigma^2} \sum_{i=e+1}^d Y_i^2 = \sum_{i=e+1}^d Z_i^2 \sim \chi_{d-e}^2(\delta^2).$$

Nach Lemma 5.4.5 gilt außerdem

$$\frac{n-d}{\sigma^2} \hat{s}^2 = \sum_{i=d+1}^n Z_i^2 \sim \chi_{n-d}^2,$$

so dass die Unabhängigkeit von \hat{s}^2 und \hat{s}_0^2 folgt. □

Satz 5.6.19. Für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$ gilt

$$\mathbb{E}_{\vartheta}[\hat{s}_{\mathbb{R}^n, W_0}^2] = \sigma^2 + \frac{\|\zeta - \zeta_0\|^2}{n-e}.$$

Beweis. Nach Satz 5.6.17 gilt

$$\hat{s}_{\mathbb{R}^n, W_0}^2 = \frac{n-d}{n-e} \hat{s}^2 + \frac{d-e}{n-e} \hat{s}_0^2.$$

Für $X \sim \chi_n(\delta^2)$ gilt $\mathbb{E}[X] = n + \delta^2$. Also folgt mit Satz 5.6.18

$$\begin{aligned} \mathbb{E}_{\vartheta}[\hat{s}_{\mathbb{R}^n, W_0}^2] &= \frac{n-d}{n-e} \sigma^2 + \frac{\sigma^2}{n-e} \mathbb{E}_{\vartheta} \left[\frac{d-e}{\sigma^2} \hat{s}_0^2 \right] \\ &= \frac{n-d}{n-e} \sigma^2 + \frac{\sigma^2}{n-e} (d-e + \delta^2) \\ &= \sigma^2 + \frac{\|\zeta - \zeta_0\|^2}{n-e}. \end{aligned}$$

□

Korollar 5.6.20. Für jedes $\vartheta = (\zeta, \sigma^2) \in \Theta$ sind folgenden Aussagen äquivalent:

- (i) Es gilt $\mathbb{E}_{\vartheta}[\hat{s}_{\mathbb{R}^n, W_0}^2] = \sigma^2$.
- (ii) Es gilt $\vartheta \in \Theta_0$, das heißt $\zeta \in W_0$.
- (iii) Es gilt $\delta^2 = 0$.

Beweis. Folgt aus Satz 5.6.19. □

Korollar 5.6.21. Für alle $\vartheta \in \Theta_0$ gilt $V_n \sim F_{d-e, n-d}$ unter \mathbb{P}_{ϑ} .

Beweis. Folgt aus Satz 5.6.18 und Korollar 5.6.20. \square

Satz 5.6.22 (*F-Test der linearen Hypothese*). Für jedes $\alpha \in (0, 1)$ ist

$$\varphi := \mathbb{1}_{\{V_n \geq F_{d-e, n-d, 1-\alpha}\}} = \mathbb{1}_{\{\hat{s}_0^2 \geq F_{d-e, n-d, 1-\alpha} \hat{s}^2\}}$$

ein Level- α -Test.

Beweis. Für jedes $\vartheta \in \Theta_0$ gilt nach Korollar 5.6.21

$$G_\varphi(\vartheta) = \mathbb{E}_\vartheta[\varphi] = \mathbb{P}_\vartheta(V_n \geq F_{d-e, n-d, 1-\alpha}) = \alpha.$$

\square

Bemerkung 5.6.23. Große Werte von $\hat{s}_0^2 = \hat{s}_{W, W_0}^2$ führen zur Ablehnung der Nullhypothese, die besagt, dass ζ in W_0 liegt.

5.7 Varianzanalyse

Wir betrachten das Mehrstichprobenproblem. Bei der koordinatengebundenen Darstellung haben wir die Matrix

$$A = \begin{pmatrix} \mathbb{1}_{n_1} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \mathbb{1}_{n_d} \end{pmatrix} = (f_1 \ \dots \ f_d) \in \mathbb{R}^{n \times d},$$

und bei der koordinatenfreien Darstellung haben wir den Unterraum

$$W = \text{lin}\{f_1, \dots, f_d\} \subset \mathbb{R}^n.$$

In diesem Modell liegen bei der Stichprobe verschiedene Gruppen $X = (X_1, \dots, X_d)$ mit $X_i \in \mathbb{R}^{n_i}$ für $i = 1, \dots, d$ vor, wobei $n_1 + \dots + n_d = n$.

Satz 5.7.1.

(a) Der Schätzer $\hat{\zeta}$ ist gegeben durch

$$\hat{\zeta} = \sum_{i=1}^d \bar{X}_i f_i.$$

(b) Der KQS $\hat{\beta}$ ist gegeben durch

$$\hat{\beta} = (\bar{X}_1, \dots, \bar{X}_d).$$

Beweis. Siehe Beispiel 5.3.10. □

Es sei $W_0 = \text{lin}\{\mathbb{1}\}$. Wir möchten also testen, ob die Gruppenmittel übereinstimmen.

Bemerkung 5.7.2. *Es gilt $\Pi_{W_0}X = \bar{X}\mathbb{1}$; siehe Lemma 5.4.11. Folglich gilt*

$$\Pi_{\text{lin}\{f_i\}}X_i = \bar{X}_i f_i \quad \text{für alle } i = 1, \dots, d.$$

Definition 5.7.3. *Wir nennen \hat{s}^2 die Stichprobenvarianz innerhalb der Gruppen.*

Definition 5.7.4. *Für $i = 1, \dots, d$ nennen wir*

$$s_{X_i}^2 = \frac{1}{n_i - 1} \|X_i - \bar{X}_i f_i\|^2$$

die Stichprobenvarianz der i -ten Gruppe.

Satz 5.7.5. *Es gilt die Zerlegung*

$$(n - d)\hat{s}^2 = \sum_{i=1}^d (n_i - 1)s_{X_i}^2.$$

Beweis. Wir setzen $W_i := \text{lin}\{f_i\}$ für $i = 1, \dots, d$. Dann gilt

$$W = W_1 \oplus \dots \oplus W_d.$$

Außerdem seien V_1, \dots, V_d die eindeutig bestimmten Unterräume des \mathbb{R}^n , die von Einheitsvektoren erzeugt werden, so dass $f_i \in V_i$ für alle $i = 1, \dots, d$. Dann gilt

$$\mathbb{R}^n = V_1 \oplus \dots \oplus V_d,$$

und es folgt mit Bemerkung 5.7.2

$$\begin{aligned} (n - d)\hat{s}^2 &= \|X - \Pi_W X\|^2 = \left\| \sum_{i=1}^d (\Pi_{V_i} X - \Pi_{W_i} X) \right\|^2 \\ &= \sum_{i=1}^d \|\Pi_{V_i} X - \Pi_{W_i} X\|^2 = \sum_{i=1}^d (n_i - 1)\hat{s}_{V_i, W_i}^2 = \sum_{i=1}^d (n_i - 1)s_{X_i}^2. \end{aligned}$$

□

Definition 5.7.6. *Wir nennen*

$$s_X^2 = \frac{1}{n - 1} \|X - \bar{X}\mathbb{1}\|^2$$

die totale empirische Varianz (oder Gesamtvarianz).

Definition 5.7.7. *Wir nennen*

$$\hat{s}_0^2 = \hat{s}_{W, W_0}^2 = \frac{1}{d-1} \sum_{i=1}^d \|\bar{X}_i f_i - \bar{X} f_i\|^2$$

die Stichprobenvarianz zwischen den Gruppen.

Satz 5.7.8. *Es gilt die Zerlegung*

$$(n-1)s_X^2 = (n-d)\hat{s}^2 + (d-1)\hat{s}_0^2.$$

Beweis. Folgt aus Satz 5.6.17. □

Satz 5.7.9. *Es gilt für alle $\vartheta = (\zeta, \sigma^2) \in \Theta$*

$$\mathbb{E}_\vartheta[s_X^2] = \sigma^2 + \frac{\|\zeta - \zeta_0\|^2}{n-1}.$$

Beweis. Folgt aus Satz 5.6.19. □

Korollar 5.7.10. *Für jedes $\vartheta = (\zeta, \sigma^2) \in \Theta$ sind folgenden Aussagen äquivalent:*

- (i) *Es gilt $\mathbb{E}_\vartheta[s_X^2] = \sigma^2$.*
- (ii) *Es gilt $\vartheta \in \Theta_0$, das heißt $\zeta \in W_0$.*
- (iii) *Es gilt $\delta^2 = 0$.*

Beweis. Folgt aus Korollar 5.6.20. □

Korollar 5.7.11. *Für jedes $\alpha \in (0, 1)$ ist*

$$\varphi := \mathbb{1}_{\{\hat{s}_0^2 \geq F_{d-e, n-d, 1-\alpha} \hat{s}^2\}}$$

ein Level- α -Test.

Beweis. Folgt aus Satz 5.6.22. □

Bemerkung 5.7.12. *Je größer die Stichprobenvarianz \hat{s}_0^2 zwischen den Gruppen, desto eher wird H_0 abgelehnt.*

Literaturverzeichnis

- [Bib16] BIBINGER, M.: *Mathematische Statistik*. 2016. – Vorlesungsskript aus dem SS 2016, Philipps-Universität Marburg
- [CS11] CZADO, C. ; SCHMIDT, T.: *Mathematische Statistik*. Springer-Verlag, Berlin, 2011
- [Geo04] GEORGII, H. O.: *Stochastik: Einführung in die Wahrscheinlichkeitstheorie und Statistik*. Walter de Gruyter & Co., Berlin, 2004
- [Grü10] GRÜBEL, R.: *Stochastik*. 2010. – Vorlesungsskript, Leibniz Universität Hannover
- [JP04] JACOD, J. ; PROTTER, P.: *Probability Essentials*. Berlin : Springer-Verlag, 2004 (Universitext)
- [Kre05] KRENGEL, U.: *Einführung in die Wahrscheinlichkeitstheorie und Statistik*. Vieweg-Verlag, Wiesbaden, 2005
- [Löw] LÖWE, M.: *Mathematische Statistik I*. – Vorlesungsskript, Universität Münster
- [Pru00] PRUSCHA, H.: *Vorlesungen über Mathematische Statistik*. Teubner-Verlag, Stuttgart, 2000
- [Ren12] RENESSE, M.: *Mathematische Statistik*. 2012. – Vorlesungsskript aus dem SS 2012, Universität Leipzig, aufgezeichnet von Tobias Weihrauch
- [Rüs14] RÜSCHENDORF, L.: *Mathematische Statistik*. Springer-Verlag, Berlin, 2014
- [Sha03] SHAO, J.: *Mathematical Statistics*. Springer-Verlag, New York, 2003
- [Tap13] TAPPE, S.: *Einführung in die Wahrscheinlichkeitstheorie*. Springer-Verlag, Berlin, 2013