

*Mathematische Statistik*  
Gliederung zur Vorlesung  
im Wintersemester 2006/07

Markus Reiß  
Universität Heidelberg  
reiss@statlab.uni-heidelberg.de

VORLÄUFIGE FASSUNG: 9. Februar 2007

## Inhaltsverzeichnis

<b>1</b>	<b>Einführende Beispiele</b>	<b>1</b>
<b>2</b>	<b>Entscheidungstheorie</b>	<b>1</b>
2.1	Formalisierung eines statistischen Problems . . . . .	1
2.2	Minimax- und Bayes-Ansatz . . . . .	1
2.3	Das Stein-Phänomen . . . . .	3
2.4	Ergänzungen . . . . .	4
<b>3</b>	<b>Dominierte Experimente und Suffizienz</b>	<b>5</b>
3.1	Dominierte Experimente . . . . .	5
3.2	Exponentialfamilien . . . . .	5
3.3	Suffizienz . . . . .	6
<b>4</b>	<b>Testtheorie</b>	<b>7</b>
4.1	Neyman-Pearson-Theorie . . . . .	7
4.2	Bedingte Tests . . . . .	9
4.3	Tests im Normalverteilungsmodell . . . . .	10
<b>5</b>	<b>Schätztheorie</b>	<b>11</b>
5.1	Momentenschätzer . . . . .	11
5.2	Maximum-Likelihood- und M-Schätzer . . . . .	12
5.3	Effizienz . . . . .	13
5.4	Nichtparametrische Dichteschätzung . . . . .	14

# 1 Einführende Beispiele

- Modellierung
- Modelldiagnostik (QQ-Plot, Boxplot, empirische Korrelation)
- Median, Mittelwert, Ausreißer
- Konfidenzintervall
- Hypothesentest
- Klassifikation
- Vorhersage

# 2 Entscheidungstheorie

## 2.1 Formalisierung eines statistischen Problems

**2.1 Definition.** Ein Messraum  $(\mathcal{X}, \mathcal{F})$  versehen mit einer Familie  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  von Wahrscheinlichkeitsmaßen,  $\Theta \neq \emptyset$  beliebige Parametermenge, heißt statistisches Experiment. Jede  $(\mathcal{F}, \mathcal{S})$ -messbare Funktion  $Y : \mathcal{X} \rightarrow S$  heißt Beobachtung oder Statistik mit Werten in  $(S, \mathcal{S})$  und induziert das statistische Experiment  $(S, \mathcal{S}, (\mathbb{P}_\vartheta^Y)_{\vartheta \in \Theta})$ . Sind die Beobachtungen  $Y_1, \dots, Y_n$  für jedes  $\mathbb{P}_\vartheta$  unabhängig und identisch verteilt, so nennt man  $Y_1, \dots, Y_n$  eine mathematische Stichprobe.

**2.2 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein statistisches Experiment. Eine Entscheidungsregel ist eine messbare Abbildung  $\rho : \mathcal{X} \rightarrow A$ , wobei der Messraum  $(A, \mathcal{A})$  der sogenannte Aktionsraum ist. Jede Funktion  $l : \Theta \times A \rightarrow [0, \infty) =: \mathbb{R}^+$ , die messbar im zweiten Argument ist, heißt Verlustfunktion. Das Risiko einer Entscheidungsregel  $\rho$  bei Vorliegen des Parameters  $\vartheta \in \Theta$  ist

$$R(\vartheta, \rho) := \mathbb{E}_\vartheta[l(\vartheta, \rho)] = \int_{\mathcal{X}} l(\vartheta, \rho(x)) \mathbb{P}_\vartheta(dx).$$

**2.3 Definition.** Die Entscheidungsregel  $\rho$  heißt besser als eine Entscheidungsregel  $\rho'$ , falls  $R(\vartheta, \rho) \leq R(\vartheta, \rho')$  für alle  $\vartheta \in \Theta$  gilt und falls ein  $\vartheta_0 \in \Theta$  mit  $R(\vartheta_0, \rho) < R(\vartheta_0, \rho')$  existiert. Eine Entscheidungsregel heißt zulässig, wenn es keine bessere Entscheidungsregel gibt.

## 2.2 Minimax- und Bayes-Ansatz

**2.4 Definition.** Eine Entscheidungsregel  $\rho$  heißt minimax, falls

$$\sup_{\vartheta \in \Theta} R(\vartheta, \rho) = \inf_{\rho'} \sup_{\vartheta \in \Theta} R(\vartheta, \rho'),$$

wobei sich das Infimum über alle Entscheidungsregeln  $\rho'$  erstreckt.

**2.5 Definition.** Der Parameterraum  $\Theta$  trage die  $\sigma$ -Algebra  $\mathcal{F}_\Theta$ , die Verlustfunktion  $l$  sei produktmessbar und  $\vartheta \mapsto \mathbb{P}_\vartheta(B)$  sei messbar für alle  $B \in \mathcal{F}$ . Die a priori-Verteilung  $\pi$  des Parameters  $\vartheta$  ist gegeben durch ein Wahrscheinlichkeitsmaß auf  $(\Theta, \mathcal{F}_\Theta)$ . Das zu  $\pi$  assoziierte Bayesrisiko einer Entscheidungsregel  $\rho$  ist

$$R_\pi(\rho) := \mathbb{E}_\pi[R(\vartheta, \rho)] = \int_\Theta R(\vartheta, \rho) \pi(d\vartheta) = \int_\Theta \int_{\mathcal{X}} l(\vartheta, \rho(x)) \mathbb{P}_\vartheta(dx) \pi(d\vartheta).$$

$\rho$  heißt Bayesregel oder Bayes-optimal (bezüglich  $\pi$ ), falls

$$R_\pi(\rho) = \inf_{\rho'} R_\pi(\rho')$$

gilt, wobei sich das Infimum über alle Entscheidungsregeln  $\rho'$  erstreckt.

**2.6 Satz.** Es liege die Situation aus der vorangegangenen Definition vor.

(a) Für jede Entscheidungsregel  $\rho$  gilt

$$\sup_{\vartheta \in \Theta} R(\vartheta, \rho) = \sup_{\pi} R_\pi(\rho),$$

wobei sich das zweite Supremum über alle a priori-Verteilungen  $\pi$  erstreckt. Insbesondere ist das Risiko einer Bayesregel stets kleiner oder gleich dem Minimaxrisiko.

(b) Für eine Minimaxregel  $\rho$  gilt  $\sup_{\pi} R_\pi(\rho) = \inf_{\rho'} \sup_{\pi} R_\pi(\rho')$ .

**2.7 Definition.** Definiere  $\Omega := \mathcal{X} \times \Theta$  und  $\tilde{\mathbb{P}}$  auf  $(\Omega, \mathcal{F} \otimes \mathcal{F}_\Theta)$  gemäß  $\tilde{\mathbb{P}}(dx, d\vartheta) = P_\vartheta(dx)\pi(d\vartheta)$  (gemeinsame Verteilung von Beobachtung und Parameter). Bezeichne mit  $X$  und  $\bar{\vartheta}$  die Koordinatenprojektionen von  $\Omega$  auf  $\mathcal{X}$  bzw.  $\Theta$ .

**2.8 Satz.** Eine Regel  $\rho$  ist Bayes-optimal, falls für  $\tilde{\mathbb{P}}$ -f.a.  $x \in \mathcal{X}$  gilt

$$\rho(x) = \operatorname{argmin}_{a \in A} \mathbb{E}_{\tilde{\mathbb{P}}}[l(\bar{\vartheta}, a) \mid X = x].$$

**2.9 Korollar.** Für  $\Theta \subseteq \mathbb{R}$ ,  $A = \mathbb{R}$  und quadratisches Risiko (d.h.  $l(\vartheta, a) = (a - \vartheta)^2$ ) ist die bedingte Erwartung  $\hat{\vartheta}_\pi := \mathbb{E}_{\tilde{\mathbb{P}}}[\bar{\vartheta} \mid X = x]$  Bayes-optimaler Schätzer von  $\vartheta$  bezüglich der a priori-Verteilung  $\pi$ .

**2.10 Definition.** Es sei  $X$  eine  $(S, \mathcal{S})$ -wertige Zufallsvariable auf  $(\Omega, \mathcal{F}, \mathbb{P})$ . Eine Abbildung  $K : S \times \mathcal{F} \rightarrow [0, 1]$  heißt reguläre bedingte Wahrscheinlichkeit oder Markovkern bezüglich  $X$ , falls

(a)  $A \mapsto K(x, A)$  ist Wahrscheinlichkeitsmaß für alle  $x \in S$ ;

(b)  $x \mapsto K(x, A)$  ist messbar für alle  $A \in \mathcal{F}$ ;

(c)  $K(X, A) = \mathbb{P}(A \mid X) := \mathbb{E}[\mathbf{1}_A \mid X]$   $\mathbb{P}$ -f.s. für alle  $A \in \mathcal{F}$ .

**2.11 Satz.** Es sei  $(\Omega, d)$  ein vollständiger, separabler Raum mit Metrik  $d$  und Borel- $\sigma$ -Algebra  $\mathcal{F}$  (polnischer Raum). Für jede Zufallsvariable  $X$  auf  $(\Omega, \mathcal{F}, \mathbb{P})$  existiert eine reguläre bedingte Wahrscheinlichkeit  $K$  bezüglich  $X$ .  $K$  ist  $\mathbb{P}$ -f.s. eindeutig bestimmt, d.h. für eine zweite solche reguläre bedingte Wahrscheinlichkeit  $K'$  gilt

$$\mathbb{P}(\forall A \in \mathcal{F} : K(X, A) = K'(X, A)) = 1.$$

**2.12 Definition.** Die Verteilung von  $\bar{\vartheta}$  unter der regulären bedingten Wahrscheinlichkeit  $\tilde{\mathbb{P}}(\bullet | X = x)$  von  $\tilde{\mathbb{P}}$  heißt a posteriori-Verteilung des Parameters gegeben die Beobachtung  $X = x$ .

**2.13 Satz.** Für jede Entscheidungsregel  $\rho$  gilt:

- (a) Ist  $\rho$  minimax und eindeutig in dem Sinn, dass jede andere Minimax-Regel die gleiche Risikofunktion besitzt, so ist  $\rho$  zulässig.
- (b) Ist  $\rho$  zulässig mit konstanter Risikofunktion, so ist  $\rho$  minimax.
- (c) Ist  $\rho$  eine Bayesregel (bzgl.  $\pi$ ) und eindeutig in dem Sinn, dass jede andere Bayesregel (bzgl.  $\pi$ ) die gleiche Risikofunktion besitzt, so ist  $\rho$  zulässig.
- (d) Die Parametermenge  $\Theta$  bilde einen metrischen Raum mit Borel- $\sigma$ -Algebra  $\mathcal{F}_\Theta$ . Ist  $\rho$  eine Bayesregel (bzgl.  $\pi$ ), so ist  $\rho$  zulässig, falls (i)  $R_\pi(\rho) < \infty$ ; (ii) für jede nichtleere offene Menge  $U$  in  $\Theta$  gilt  $\pi(U) > 0$ ; (iii) für jede Regel  $\rho'$  ist  $\vartheta \mapsto R(\vartheta, \rho')$  stetig.

**2.14 Korollar.** Es sei  $X_1, \dots, X_n$  eine  $N(\mu, 1)$ -verteilte mathematische Stichprobe mit  $\mu \in \mathbb{R}$  unbekannt. Bezüglich quadratischem Risiko ist das arithmetische Mittel  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  zulässig und minimax als Schätzer von  $\mu$ .

**2.15 Definition.** Eine Verteilung  $\pi$  auf  $(\Theta, \mathcal{F}_\Theta)$  heißt ungünstigste a priori-Verteilung zu einer gegebenen Verlustfunktion, falls

$$\inf_{\rho} R_\pi(\rho) = \sup_{\pi'} \inf_{\rho} R_{\pi'}(\rho).$$

**2.16 Lemma.** Gilt  $R_\pi(\rho_\pi) = \sup_{\vartheta \in \Theta} R(\vartheta, \rho_\pi)$  für eine a priori-Verteilung  $\pi$  und ihre zugehörige Bayesregel  $\rho_\pi$ , so folgt die Sattelpunkteigenschaft

$$\forall \pi' \forall \rho' : R_{\pi'}(\rho_\pi) \leq R_\pi(\rho_\pi) \leq R_\pi(\rho').$$

Weiterhin ist  $\rho_\pi$  minimax und  $\pi$  ungünstigste a priori-Verteilung.

### 2.3 Das Stein-Phänomen

**2.17 Lemma.** Es sei  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  eine Funktion, die Lebesgue-f.ü. absolut stetig in jeder Koordinate ist. Dann gilt für  $Y \sim N(\mu, \sigma^2 E_d)$  mit  $\mu \in \mathbb{R}^d$ ,  $\sigma > 0$ ,  $E_d = \text{diag}(1, \dots, 1) \in \mathbb{R}^{d \times d}$  und für alle  $i = 1, \dots, d$

$$\mathbb{E}[(\mu_i - Y_i)f(Y)] = -\sigma^2 \mathbb{E}\left[\frac{\partial f}{\partial x_i}(Y)\right],$$

sofern  $\mathbb{E}\left[\left|\frac{\partial f}{\partial x_i}(Y)\right|\right] < \infty$ .

**2.18 Satz.** Es sei  $d \geq 3$  und  $Y_1, \dots, Y_n$  eine  $N(\mu, E_d)$ -verteilte mathematische Stichprobe mit  $\mu \in \mathbb{R}^d$  unbekannt. Dann gilt für den James-Stein-Schätzer

$$\hat{\mu}_{JS} := \left(1 - \frac{d-2}{n|\bar{Y}|^2}\right) \bar{Y}$$

mit  $\bar{Y} := \frac{1}{n} \sum_{i=1}^n Y_i$ , dass

$$\mathbb{E}_\mu[|\hat{\mu}_{JS} - \mu|^2] = \frac{d}{n} - \mathbb{E}_\mu \left[ \frac{(d-2)^2}{n^2 |\bar{Y}|^2} \right] < \frac{d}{n} = \mathbb{E}_\mu[|\bar{Y} - \mu|^2].$$

Insbesondere ist  $\bar{Y}$  bei quadratischem Risiko kein zulässiger Schätzer von  $\mu$  im Fall  $d \geq 3$ !

**2.19 Satz.** Es sei  $d \geq 3$  und  $Y_1, \dots, Y_n$  eine  $N(\mu, E_d)$ -verteilte mathematische Stichprobe mit  $\mu \in \mathbb{R}^d$  unbekannt. Dann ist der James-Stein-Schätzer mit positivem Gewicht

$$\hat{\mu}_{JS+} := \left(1 - \frac{d-2}{n|\bar{Y}|^2}\right)_+ \bar{Y}, \quad x_+ := \max(x, 0)$$

bei quadratischem Risiko besser als der James-Stein-Schätzer  $\hat{\mu}_{JS}$ .

## 2.4 Ergänzungen

**2.20 Definition.** Zu vorgegebener Verlustfunktion  $l$  heißt eine Entscheidungsregel  $\rho$  unverzerrt, falls

$$\forall \vartheta, \vartheta' \in \Theta : \mathbb{E}_\vartheta[l(\vartheta', \rho)] \geq \mathbb{E}_\vartheta[l(\vartheta, \rho)] =: R(\vartheta, \rho).$$

**2.21 Lemma.** Es seien  $g : \Theta \rightarrow A \subseteq \mathbb{R}$  und  $l(\vartheta, \rho) = (\rho - g(\vartheta))^2$  der quadratische Verlust. Dann ist eine Entscheidungsregel (ein Schätzer von  $g(\vartheta)$ )  $\hat{g} : \mathcal{X} \rightarrow A$  mit  $\mathbb{E}_\vartheta[\hat{g}^2] < \infty$  und  $\mathbb{E}_\vartheta[\hat{g}] \in g(\Theta)$  für alle  $\vartheta \in \Theta$  genau dann unverzerrt, wenn sie erwartungstreu ist, d.h.  $\mathbb{E}_\vartheta[\hat{g}] = g(\vartheta)$  für alle  $\vartheta \in \Theta$  gilt.

**2.22 Lemma.** Es sei  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ ,  $A = [0, 1]$ . Für den Verlust  $l(\vartheta, a) = l_0 a \mathbf{1}_{\Theta_0}(\vartheta) + l_1 (1-a) \mathbf{1}_{\Theta_1}(\vartheta)$  ist eine Entscheidungsregel  $\rho$  (ein randomisierter Test von  $H_0 : \vartheta \in \Theta_0$  gegen  $H_1 : \vartheta \in \Theta_1$ ) genau dann unverzerrt, wenn sie zum Niveau  $\alpha := \frac{l_1}{l_0+l_1}$  unverfälscht ist, d.h.

$$\forall \vartheta \in \Theta_0 : \mathbb{E}_\vartheta[\rho] \leq \alpha, \quad \forall \vartheta \in \Theta_1 : \mathbb{E}_\vartheta[\rho] \geq \alpha.$$

**2.23 Definition.** Ein Entscheidungskern oder randomisierte Entscheidungsregel  $\rho : \mathcal{X} \times \mathcal{A} \rightarrow [0, 1]$  ist eine reguläre bedingte Wahrscheinlichkeit auf dem Aktionsraum  $(A, \mathcal{A})$  mit der Interpretation, dass bei Vorliegen der Beobachtung  $x$  gemäß  $\rho(x, \bullet)$  eine Entscheidung zufällig ausgewählt wird. Das zugehörige Risiko ist

$$R(\vartheta, \rho) := \mathbb{E}_\vartheta \left[ \int_A l(\vartheta, a) \rho(da) \right] = \int_{\mathcal{X}} \int_A l(\vartheta, a) \rho(x, da) \mathbb{P}_\vartheta(dx).$$

**2.24 Lemma.** Es sei  $A \subseteq \mathbb{R}^d$  konvex sowie  $l(\vartheta, a)$  eine im zweiten Argument konvexe Verlustfunktion. Dann gibt es zu jeder randomisierten Entscheidungsregel eine deterministische Entscheidungsregel, deren Risiko nicht größer ist.

### 3 Dominierte Experimente und Suffizienz

#### 3.1 Dominierte Experimente

**3.1 Definition.** Ein statistisches Experiment  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  heißt dominiert (von  $\mu$ ), falls es ein  $\sigma$ -endliches Maß  $\mu$  auf  $\mathcal{F}$  gibt, so dass  $\mathbb{P}_\vartheta$  absolutstetig bezüglich  $\mu$  ist ( $\mathbb{P}_\vartheta \ll \mu$ ) für alle  $\vartheta \in \Theta$ . Die durch  $\vartheta$  parametrisierte Radon-Nikodym-Dichte

$$L(\vartheta, x) := \frac{d\mathbb{P}_\vartheta}{d\mu}(x), \quad \vartheta \in \Theta, x \in \mathcal{X},$$

heißt auch Likelihoodfunktion, wobei diese meist als durch  $x$  parametrisierte Funktion in  $\vartheta$  aufgefasst wird.

**3.2 Satz.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein dominiertes Experiment. Dann gibt es ein Wahrscheinlichkeitsmaß  $\mathbb{Q}$  der Form  $\mathbb{Q} = \sum_{i=1}^{\infty} c_i \mathbb{P}_{\vartheta_i}$  mit  $c_i \geq 0$ ,  $\sum_i c_i = 1$ ,  $\vartheta_i \in \Theta$ , so dass  $\mathbb{P}_\vartheta \ll \mathbb{Q}$  für alle  $\vartheta \in \Theta$  gilt.

**3.3 Satz.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein dominiertes Experiment mit produktmessbarer Likelihoodfunktion  $L(\vartheta, x)$ . Zu vorgegebener a priori-Verteilung  $\pi$  hat die a posteriori-Verteilung von  $\vartheta$  gegeben  $X = x$  folgende Dichte bezüglich  $\pi$ :

$$Z_x^\pi(\vartheta) = \frac{L(\vartheta, x)}{\int_{\Theta} L(\vartheta', x) \pi(d\vartheta')} \mathbf{1}_{\{\int L(\vartheta', x) \pi(d\vartheta') > 0\}}, \quad \vartheta \in \Theta \quad (\text{Bayesformel}).$$

#### 3.2 Exponentialfamilien

**3.4 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein von  $\mu$  dominiertes Experiment. Dann heißt  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  Exponentialfamilie (in  $\eta(\vartheta)$  und  $T$ ), wenn  $k \in \mathbb{N}$ ,  $\eta : \Theta \rightarrow \mathbb{R}^k$ ,  $C : \Theta \rightarrow \mathbb{R}^+$ ,  $T : \mathcal{X} \rightarrow \mathbb{R}^k$  messbar und  $h : \mathcal{X} \rightarrow \mathbb{R}^+$  messbar existieren, so dass

$$\frac{d\mathbb{P}_\vartheta}{d\mu}(x) = C(\vartheta) h(x) \exp(\langle \eta(\vartheta), T(x) \rangle_{\mathbb{R}^k}), \quad x \in \mathcal{X}, \vartheta \in \Theta.$$

$T$  wird natürliche suffiziente Statistik von  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  genannt. Sind  $\eta_1, \dots, \eta_k$  linear unabhängige Funktionen und gilt für alle  $\vartheta \in \Theta$  die Implikation

$$\lambda_0 + \lambda_1 T_1 + \dots + \lambda_k T_k = 0 \quad \mathbb{P}_\vartheta \text{-f.s.} \Rightarrow \lambda_0 = \lambda_1 = \dots = \lambda_k = 0$$

( $1, T_1, \dots, T_k$  sind  $\mathbb{P}_\vartheta$ -f.s. linear unabhängig), so heißt die Exponentialfamilie k-parametrisch.

**3.5 Definition.** Bildet  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  eine Exponentialfamilie (mit obiger Notation), so heißt

$$\mathcal{Z} := \left\{ u \in \mathbb{R}^k \mid \int_{\mathcal{X}} e^{\langle u, T(x) \rangle} h(x) \mu(dx) \in (0, \infty) \right\}$$

ihr natürlicher Parameterraum. Die entsprechend mit  $u \in \mathcal{Z}$  parametrisierte Familie wird natürliche Exponentialfamilie in  $T$  genannt.

**3.6 Lemma.** Bildet  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  eine ( $k$ -parametrische) Exponentialfamilie in  $\eta(\vartheta)$  und  $T(x)$ , so bilden auch die Produktmaße  $(\mathbb{P}_\vartheta^{\otimes n})_{\vartheta \in \Theta}$  eine ( $k$ -parametrische) Exponentialfamilie in  $\eta(\vartheta)$  und  $\sum_{i=1}^n T(x_i)$  mit

$$\frac{d\mathbb{P}_\vartheta^{\otimes n}}{d\mu^{\otimes n}}(x) = C(\vartheta)^n \left( \prod_{i=1}^n h(x_i) \right) \exp(\langle \eta(\vartheta), \sum_{i=1}^n T(x_i) \rangle_{\mathbb{R}^k}), \quad x \in \mathcal{X}^n, \vartheta \in \Theta.$$

**3.7 Satz.** Es sei  $(\mathbb{P}_\vartheta)_{\vartheta \in \mathcal{X}}$  eine Exponentialfamilie mit natürlichem Parameterraum  $\mathcal{X} \subseteq \mathbb{R}^k$  und Darstellung

$$\frac{d\mathbb{P}_\vartheta}{d\mu}(x) = C(\vartheta)h(x) \exp(\langle \vartheta, T(x) \rangle) = h(x) \exp(\langle \vartheta, T(x) \rangle - A(\vartheta)),$$

wobei  $A(\vartheta) = \log \left( \int h(x) \exp(\langle \vartheta, T(x) \rangle) \mu(dx) \right)$ . Ist  $\tilde{\vartheta}$  ein innerer Punkt von  $\mathcal{X}$ , so ist die erzeugende Funktion  $\psi_{\tilde{\vartheta}}(s) = \mathbb{E}_{\tilde{\vartheta}}[e^{\langle T, s \rangle}]$  in einer Umgebung der Null wohldefiniert und beliebig oft differenzierbar. Es gilt  $\psi_{\tilde{\vartheta}}(s) = \exp(A(\tilde{\vartheta} + s) - A(\tilde{\vartheta}))$  für alle  $s$  mit  $\tilde{\vartheta} + s \in \mathcal{X}$ .

Für  $i, j = 1, \dots, k$  folgt  $\mathbb{E}_{\tilde{\vartheta}}[T_i] = \frac{dA}{d\vartheta_i}(\tilde{\vartheta})$  und  $\text{Cov}_{\tilde{\vartheta}}(T_i, T_j) = \frac{d^2A}{d\vartheta_i d\vartheta_j}(\tilde{\vartheta})$ .

### 3.3 Suffizienz

**3.8 Definition.** Eine  $(S, \mathcal{S})$ -wertige Statistik  $T$  auf  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  heißt suffizient (für  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$ ), falls für jedes  $\vartheta \in \Theta$  die reguläre bedingte Wahrscheinlichkeit von  $\mathbb{P}_\vartheta$  gegeben  $T$  (existiert und) nicht von  $\vartheta$  abhängt, d.h.

$$\exists k \forall \vartheta \in \Theta, B \in \mathcal{F} : k(T, B) = \mathbb{P}_\vartheta(B | T) := \mathbb{E}_\vartheta[\mathbf{1}_B | T] \quad \mathbb{P}_\vartheta\text{-f.s.}$$

Statt  $k(t, B)$  schreiben wir  $\mathbb{P}_\bullet(B | T = t)$  bzw.  $\mathbb{E}_\bullet[\mathbf{1}_B | T = t]$ .

**3.9 Satz** (Faktorisierungskriterium von Neyman). Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein von  $\mu$  dominiertes Experiment mit Likelihoodfunktion  $L$  sowie  $T$  eine  $(S, \mathcal{S})$ -wertige Statistik. Dann ist  $T$  genau dann suffizient, wenn eine messbare Funktion  $h : \mathcal{X} \rightarrow \mathbb{R}^+$  existiert, so dass für alle  $\vartheta \in \Theta$  eine messbare Funktion  $g_\vartheta : S \rightarrow \mathbb{R}^+$  existiert mit

$$L(\vartheta, x) = g_\vartheta(T(x))h(x) \quad \text{für } \mu\text{-f.a. } x \in \mathcal{X}.$$

**3.10 Korollar.** Die natürliche suffiziente Statistik einer Exponentialfamilie ist in der Tat suffizient.

**3.11 Satz** (Rao-Blackwell). Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein statistisches Experiment,  $A \subseteq \mathbb{R}^k$  konvex und  $l(\vartheta, a)$  eine im zweiten Argument konvexe Verlustfunktion. Ist  $T$  eine für  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  suffiziente Statistik, so gilt für jede Entscheidungsregel  $\rho$  die Risikoabschätzung

$$\forall \vartheta \in \Theta : R(\vartheta, \tilde{\rho}) \leq R(\vartheta, \rho) \quad \text{mit } \tilde{\rho} := \mathbb{E}_\bullet[\rho | T].$$

**3.12 Satz.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein statistisches Experiment und  $T$  eine suffiziente Statistik. Dann gibt es zu jedem randomisierten Test  $\varphi$  einen randomisierten Test  $\tilde{\varphi}$ , der nur von  $T$  abhängt und dieselbe Gütefunktion besitzt, nämlich  $\tilde{\varphi} = \mathbb{E}_\bullet[\varphi | T]$ .

## 4 Testtheorie

### 4.1 Neyman-Pearson-Theorie

**4.1 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein statistisches Experiment mit Zerlegung  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ . Jede messbare Funktion  $\varphi : \mathcal{X} \rightarrow [0, 1]$  heißt (randomisierter) Test.  $\varphi$  besitzt Niveau  $\alpha \in [0, 1]$ , falls  $\mathbb{E}_\vartheta[\varphi] \leq \alpha$  für alle  $\vartheta \in \Theta_0$  gilt. Die Abbildung  $\vartheta \mapsto \mathbb{E}_\vartheta[\varphi]$  heißt Gütefunktion von  $\varphi$ . Ein Test  $\varphi$  der Hypothese  $H_0 : \vartheta \in \Theta_0$  gegen die Alternative  $H_1 : \vartheta \in \Theta_1$  ist ein gleichmäßig bester Test zum Niveau  $\alpha$ , falls  $\varphi$  Niveau  $\alpha$  besitzt sowie für alle anderen Tests  $\varphi'$  vom Niveau  $\alpha$  gilt

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

$\varphi$  heißt gleichmäßig bester unverfälschter Test zum Niveau  $\alpha$ , falls  $\varphi$  unverfälscht zum Niveau  $\alpha$  ist sowie für alle anderen unverfälschten Tests  $\varphi'$  zum Niveau  $\alpha$  obige Ungleichung gilt.

**4.2 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein (binäres) statistisches Experiment mit  $\Theta = \{0, 1\}$ . Bezeichnet  $p_i$ ,  $i = 1, 2$ , die Dichte von  $\mathbb{P}_i$  bezüglich  $\mathbb{P}_0 + \mathbb{P}_1$ , so heißt ein Test der Form

$$\varphi(x) = \begin{cases} 1, & \text{falls } p_1(x) > kp_0(x) \\ 0, & \text{falls } p_1(x) < kp_0(x) \\ \gamma(x), & \text{falls } p_1(x) = kp_0(x) \end{cases}$$

mit  $k \in \mathbb{R}^+$  und  $\gamma(x) \in [0, 1]$  Neyman-Pearson-Test.

**4.3 Satz** (Neyman-Pearson-Lemma).

- (a) Jeder Neyman-Pearson-Test  $\varphi$  ist ein (gleichmäßig) bester Test für  $H_0 : \vartheta = 0$  gegen  $H_1 : \vartheta = 1$  zum Niveau  $\mathbb{E}_0[\varphi]$ .
- (b) Für jedes vorgegebene  $\alpha \in (0, 1)$  gibt es einen Neyman-Pearson-Test zum Niveau  $\alpha$  mit  $\gamma(x) = \gamma \in [0, 1]$  konstant.

**4.4 Definition.** Es seien  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein dominiertes Experiment mit  $\Theta \subseteq \mathbb{R}$  und Likelihoodfunktion  $L(\vartheta, x)$  sowie  $T$  eine reellwertige Statistik. Dann hat die Familie  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  monotonen Dichtequotienten (oder monotonen Likelihoodquotienten) in  $T$ , falls

- (a)  $\vartheta \neq \vartheta' \Rightarrow \mathbb{P}_\vartheta \neq \mathbb{P}_{\vartheta'}$ ;
- (b) Für alle  $\vartheta < \vartheta'$  gibt es eine monoton wachsende Funktion  $h(\bullet, \vartheta, \vartheta') : \mathbb{R} \rightarrow \mathbb{R}^+ \cup \{+\infty\}$  mit (Konvention  $a/0 := +\infty$  für  $a > 0$ )

$$\frac{L(\vartheta, x)}{L(\vartheta', x)} = h(T(x), \vartheta, \vartheta') \quad \text{für } (\mathbb{P}_\vartheta + \mathbb{P}_{\vartheta'})\text{-f.a. } x \in \mathcal{X}.$$

**4.5 Satz.** Ist  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  mit  $\Theta \subseteq \mathbb{R}$  eine einparametrische Exponentialfamilie in  $\eta(\vartheta)$  und  $T$ , so hat sie monotonen Dichtequotienten, sofern  $\eta$  streng monoton wächst.



**4.6 Satz.** Die Familie  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$ ,  $\Theta \subseteq \mathbb{R}$ , besitze monotonen Dichtequotienten in  $T$ . Für  $\alpha \in (0, 1)$  und  $\vartheta_0 \in \Theta$  gilt dann:

- (a) Unter allen Tests  $\varphi$  für das einseitige Testproblem  $H_0 : \vartheta \leq \vartheta_0$  gegen  $H_1 : \vartheta > \vartheta_0$  mit der Eigenschaft  $\mathbb{E}_{\vartheta_0}[\varphi] = \alpha$  gibt es einen Test  $\varphi^*$ , der die Fehlerwahrscheinlichkeiten erster und zweiter Art gleichmäßig minimiert, nämlich

$$\varphi^*(x) = \begin{cases} 1, & \text{falls } T(x) > k, \\ 0, & \text{falls } T(x) < k, \\ \gamma, & \text{falls } T(x) = k, \end{cases}$$

wobei  $k \in \mathbb{R}$ ,  $\gamma \in [0, 1]$  gemäß  $\mathbb{E}_{\vartheta_0}[\varphi^*] = \alpha$  bestimmt werden.

- (b) Dieser Test  $\varphi^*$  ist gleichmäßig bester Test zum Niveau  $\alpha$  für  $H_0 : \vartheta \leq \vartheta_0$  gegen  $H_1 : \vartheta > \vartheta_0$ .
- (c) Für alle  $\vartheta < \vartheta'$  gilt  $\mathbb{E}_\vartheta[\varphi^*] \leq \mathbb{E}_{\vartheta'}[\varphi^*]$ , wobei in den Fällen  $\mathbb{E}_\vartheta[\varphi^*] \in (0, 1)$  und  $\mathbb{E}_{\vartheta'}[\varphi^*] \in (0, 1)$  sogar die strikte Ungleichung gilt.

**4.7 Satz** (Verallgemeinertes NP-Lemma). Es seien  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  eine Exponentialfamilie in  $\eta(\vartheta)$  und  $T, L$  die zugehörige Likelihoodfunktion sowie  $\vartheta_0, \vartheta_1 \in \Theta$  zwei Parameter. Erfüllt ein Test für  $H_0 : \vartheta = \vartheta_0$  gegen  $H_1 : \vartheta = \vartheta_1$  der Form

$$\varphi(x) = \begin{cases} 1, & \text{falls } L(\vartheta_1, x) > kL(\vartheta_0, x) + lT(x)L(\vartheta_0, x) \\ 0, & \text{falls } L(\vartheta_1, x) < kL(\vartheta_0, x) + lT(x)L(\vartheta_0, x) \\ \gamma, & \text{falls } L(\vartheta_1, x) = kL(\vartheta_0, x) + lT(x)L(\vartheta_0, x) \end{cases}$$

mit  $k, l \in \mathbb{R}^+$  und  $\gamma \in [0, 1]$  die Nebenbedingungen

$$\mathbb{E}_{\vartheta_0}[\varphi] = \alpha \quad \text{und} \quad \mathbb{E}_{\vartheta_0}[T\varphi] = \alpha \mathbb{E}_{\vartheta_0}[T],$$

so maximiert er die Güte  $\mathbb{E}_{\vartheta_1}[\varphi]$  in der Menge aller Tests, die diese Nebenbedingungen erfüllen.

**4.8 Satz.**  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  sei eine einparametrische Exponentialfamilie in  $\eta(\vartheta)$  und  $T$ .  $\Theta \subseteq \mathbb{R}$  sei offen,  $\vartheta_0 \in \Theta$  und  $\eta \in C^1(\Theta)$  sei streng monoton (wachsend oder fallend) mit  $\eta'(\vartheta_0) \neq 0$ . Für  $\alpha \in (0, 1)$ ,  $c_1 < c_2$  und  $\gamma_1, \gamma_2 \in [0, 1]$  erfülle der Test

$$\varphi^*(x) = \begin{cases} 1, & \text{falls } T(x) < c_1 \text{ oder } T(x) > c_2 \\ 0, & \text{falls } T(x) \in (c_1, c_2) \\ \gamma_i, & \text{falls } T(x) = c_i, i = 1, 2 \end{cases}$$

die Nebenbedingungen

$$\mathbb{E}_{\vartheta_0}[\varphi^*] = \alpha \quad \text{und} \quad \mathbb{E}_{\vartheta_0}[T\varphi^*] = \alpha \mathbb{E}_{\vartheta_0}[T].$$

Dann ist  $\varphi^*$  gleichmäßig bester unverfälschter Test zum Niveau  $\alpha$  für  $H_0 : \vartheta = \vartheta_0$  gegen  $H_1 : \vartheta \neq \vartheta_0$ .

## 4.2 Bedingte Tests

**4.9 Definition.** Eine  $(S, \mathcal{S})$ -wertige Statistik  $T$  auf  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  heißt vollständig (bezüglich  $\Theta$ ), falls für alle messbaren Funktionen  $f : S \rightarrow \mathbb{R}$  gilt

$$\forall \vartheta \in \Theta : \mathbb{E}_\vartheta[f(T)] = 0 \text{ (und existiert)} \Rightarrow \forall \vartheta \in \Theta : \mathbb{P}_\vartheta(f(T) = 0) = 1.$$

**4.10 Definition.** Es sei  $\Theta' \subseteq \Theta$ . Dann heißt ein Test  $\varphi$   $\alpha$ -ähnlich auf  $\Theta'$ , wenn  $\mathbb{E}_\vartheta[\varphi] = \alpha$  für alle  $\vartheta \in \Theta'$  gilt.

**4.11 Satz.** Ist  $T$  eine bezüglich  $\Theta'$  vollständige und suffiziente Statistik und ist  $\varphi$  ein auf  $\Theta'$   $\alpha$ -ähnlicher Test, so gilt  $\mathbb{E}_\bullet[\varphi | T] = \alpha$   $\mathbb{P}_\vartheta$ -f.s. für alle  $\vartheta \in \Theta'$ .

**4.12 Satz.** Es sei  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  eine  $k$ -parametrische natürliche Exponentialfamilie in  $T$ . Enthält  $\Theta' \subseteq \Theta$  eine offene Menge im  $\mathbb{R}^k$ , so ist  $T$  suffizient und vollständig bezüglich  $\Theta'$ .

**4.13 Satz.** Gegeben sei die natürliche Exponentialfamilie

$$\frac{d\mathbb{P}_\vartheta}{d\mu}(x) = C(\vartheta)h(x) \exp\left(\vartheta^0 U(x) + \sum_{i=1}^k \vartheta^i T_i(x)\right), \quad x \in \mathcal{X}, \vartheta \in \Theta,$$

sowie  $\alpha \in (0, 1)$  und ein Punkt  $\vartheta_0$  im Innern von  $\Theta$ . Dann ist

$$\varphi^*(x) = \begin{cases} 1, & \text{falls } U(x) < K(T(x)) \\ 0, & \text{falls } U(x) > K(T(x)) \\ \gamma(T(x)), & \text{falls } U(x) = K(T(x)) \end{cases}$$

mit  $K(t) \in \mathbb{R}$ ,  $\gamma(t) \in [0, 1]$  derart, dass  $\mathbb{E}_{\vartheta_0}[\varphi^* | T] = \mathbb{E}_{\vartheta_0^0}[\varphi^* | T] = \alpha$   $\mathbb{P}_{\vartheta_0}$ -f.s., ein gleichmäßig bester unverfälschter Test zum Niveau  $\alpha$  von  $H_0 : \vartheta^0 \leq \vartheta_0^0$  gegen  $H_1 : \vartheta^0 > \vartheta_0^0$  (d.h.  $\Theta_0 = \{\vartheta \in \Theta \mid \vartheta^0 \leq \vartheta_0^0\}$ ,  $\Theta_1 = \{\vartheta \in \Theta \mid \vartheta^0 > \vartheta_0^0\}$ ).

**4.14 Satz.** Es liege die Situation des vorigen Satzes vor. Dann ist

$$\varphi^*(x) = \begin{cases} 1, & \text{falls } U(x) < K_1(T(x)) \text{ oder } U(x) > K_2(T(x)) \\ 0, & \text{falls } U(x) \in (K_1(T(x)), K_2(T(x))) \\ \gamma_i(T(x)), & \text{falls } U(x) = K_i(T(x)), i = 1, 2, \end{cases}$$

mit  $K_i(t) \in \mathbb{R}$ ,  $\gamma_i(t) \in [0, 1]$  derart, dass

$$\mathbb{E}_{\vartheta_0^0}[\varphi^* | T] = \alpha \text{ und } \mathbb{E}_{\vartheta_0^0}[U\varphi^* | T] = \alpha \mathbb{E}_{\vartheta_0^0}[U | T] \quad \mathbb{P}_{\vartheta_0^0}\text{-f.s.}$$

ein gleichmäßig bester unverfälschter Test zum Niveau  $\alpha$  von  $H_0 : \vartheta^0 = \vartheta_0^0$  gegen  $H_1 : \vartheta^0 \neq \vartheta_0^0$ .

### 4.3 Tests im Normalverteilungsmodell

**4.15 Satz.** *Es sei  $X_1, \dots, X_n$  eine  $N(\mu, \sigma^2)$ -verteilte mathematische Stichprobe mit  $\mu \in \mathbb{R}$  und  $\sigma > 0$  unbekannt. Für  $\sigma_0 > 0$  ist ein gleichmäßig bester unverfälschter Test von  $H_0 : \sigma \leq \sigma_0$  gegen  $H_1 : \sigma > \sigma_0$  zum Niveau  $\alpha \in (0, 1)$  gegeben durch*

$$\varphi^*(X_1, \dots, X_n) = \begin{cases} 1, & \text{falls } \frac{1}{\sigma_0^2} \sum_{i=1}^n (X_i - \bar{X})^2 > K_\alpha \\ 0, & \text{falls } \frac{1}{\sigma_0^2} \sum_{i=1}^n (X_i - \bar{X})^2 \leq K_\alpha \end{cases}$$

mit dem  $\alpha$ -Fraktile  $K_\alpha$  der  $\chi^2(n-1)$ -Verteilung:

$$\int_{K_\alpha}^{\infty} \frac{2^{-(n-1)/2}}{\Gamma((n-1)/2)} z^{(n-1)/2-1} e^{-z/2} dz = \alpha.$$

**4.16 Lemma.** *Sind  $Z_1, \dots, Z_n$  unabhängig  $N(0, \sigma^2)$ -verteilt sowie  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  messbar mit  $f(cx) = f(x)$  für alle  $c > 0$ ,  $x \in \mathbb{R}^n$ , so ist  $f(Z_1, \dots, Z_n)$  unabhängig von  $\sum_{i=1}^n Z_i^2$ . Insbesondere sind jeweils  $\frac{\bar{Z}}{\sqrt{\sum_i (Z_i - \bar{Z})^2}}$  und  $\frac{\bar{Z}}{\sqrt{\sum_i Z_i^2}}$  unabhängig von  $\sum_{i=1}^n Z_i^2$ .*

**4.17 Satz.** *Es sei  $X_1, \dots, X_n$  eine  $N(\mu, \sigma^2)$ -verteilte mathematische Stichprobe mit  $\mu \in \mathbb{R}$  und  $\sigma > 0$  unbekannt. Ein gleichmäßig bester unverfälschter Test von  $H_0 : \mu = \mu_0$  gegen  $H_1 : \mu \neq \mu_0$  zum Niveau  $\alpha \in (0, 1)$  ist gegeben durch den zweiseitigen t-Test*

$$\varphi^*(X) = \mathbf{1}_{\{|t(X)| > K_{\alpha/2}\}}, \quad t(X) := \frac{\sqrt{n}(\bar{X} - \mu_0)}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}},$$

mit dem  $\alpha/2$ -Fraktile  $K_{\alpha/2}$  der  $t(n-1)$ -Verteilung :

$$\int_{K_{\alpha/2}}^{\infty} \frac{\Gamma(n/2)}{\sqrt{\pi(n-1)}\Gamma((n-1)/2)} \left(1 + \frac{z^2}{n-1}\right)^{-n/2} dz = \alpha/2.$$

**4.18 Satz.** *Es werden zwei unabhängige mathematische Stichproben  $X_1, \dots, X_m \sim N(\mu, \sigma^2)$  und  $Y_1, \dots, Y_n \sim N(\nu, \sigma^2)$  beobachtet mit  $\mu, \nu \in \mathbb{R}$  und  $\sigma > 0$  unbekannt. Ein gleichmäßig bester unverfälschter Test von  $H_0 : \mu = \nu$  gegen  $H_1 : \mu \neq \nu$  zum Niveau  $\alpha \in (0, 1)$  ist gegeben durch*

$$\varphi^*(X, Y) = \mathbf{1}_{\{|t(X, Y)| > K_{\alpha/2}\}},$$

mit

$$t(X, Y) := \frac{(\frac{1}{m} + \frac{1}{n})^{-1/2}(\bar{Y} - \bar{X})}{\sqrt{(\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2)/(m+n-2)}}$$

und dem  $\alpha/2$ -Fraktile  $K_{\alpha/2}$  der  $t(m+n-2)$ -Verteilung.

**4.19 Satz.** *Es werden zwei unabhängige mathematische Stichproben  $X_1, \dots, X_m \sim N(\mu, \sigma^2)$  und  $Y_1, \dots, Y_n \sim N(\nu, \tau^2)$  beobachtet mit  $\mu, \nu \in \mathbb{R}$  und  $\sigma, \tau > 0$  unbekannt. Für  $c_0 > 0$  ist ein gleichmäßig bester unverfälschter*

Test von  $H_0 : \tau^2 \leq c_0 \sigma^2$  gegen  $H_1 : \tau^2 > c_0 \sigma^2$  zum Niveau  $\alpha \in (0, 1)$  gegeben durch

$$\varphi^*(X, Y) = \mathbf{1}_{\{c_0^{-1} V(X, Y) > K_\alpha\}},$$

$$\text{mit } V(X, Y) := \frac{\sum_{j=1}^n (Y_j - \bar{Y})^2 / (n-1)}{\sum_{i=1}^m (X_i - \bar{X})^2 / (m-1)}$$

und dem  $\alpha$ -Fraktile  $K_\alpha$  der  $F(n-1, m-1)$ -Verteilung:

$$\int_{K_\alpha}^{\infty} \frac{\Gamma((m+n-2)/2) \binom{n-1}{m-1}^{(n-1)/2}}{\Gamma((m-1)/2) \Gamma((n-1)/2)} \frac{z^{(n-3)/2}}{(1 + \frac{n-1}{m-1} z)^{(m+n-2)/2}} dz = \alpha.$$

## 5 Schätztheorie

### 5.1 Momentenschätzer

**5.1 Definition.** Es seien  $(\mathcal{X}^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n})_{\vartheta \in \Theta})$  ein statistisches (Produkt-)Experiment mit  $\mathcal{X} \subseteq \mathbb{R}$ ,  $\mathcal{F} \subseteq \mathfrak{B}_{\mathbb{R}}$  und  $g(\vartheta)$  mit  $g : \Theta \rightarrow \mathbb{R}^p$  ein abgeleiteter Parameter. Ferner sei  $\psi = (\psi_1, \dots, \psi_q) : \mathbb{R} \rightarrow \mathbb{R}^q$  derart, dass

$$\varphi(\vartheta) := \mathbb{E}_\vartheta[\psi] = (\mathbb{E}_\vartheta[\psi_j])_{j=1, \dots, q}$$

existiert. Gibt es nun eine Borel-messbare Funktion  $G : \varphi(\Theta) \rightarrow g(\Theta)$  mit  $G \circ \varphi = g$  und liegt  $\frac{1}{n} \sum_{i=1}^n \psi(x_i)$  in  $\varphi(\Theta)$  für alle  $x_1, \dots, x_n \in \mathcal{X}$ , so heißt  $G(\frac{1}{n} \sum_{i=1}^n \psi(x_i))$  Momentenschätzer für  $g(\vartheta)$  mit Momentenfunktionen  $\psi_1, \dots, \psi_q$ .

**5.2 Lemma.** Existiert für hinreichend großes  $n$  der Momentenschätzer  $\hat{g}_n = G(\frac{1}{n} \sum_{i=1}^n \psi(x_i))$  und ist  $G$  stetig, so ist  $\hat{g}_n$  (stark) konsistent, d.h.  $\lim_{n \rightarrow \infty} \hat{g}_n = g(\vartheta)$   $\mathbb{P}_\vartheta$ -f.s.

**5.3 Satz** ( $\Delta$ -Methode). Es seien  $(X_n)$  eine Folge von Zufallsvektoren im  $\mathbb{R}^k$ ,  $\sigma_n > 0$ ,  $\sigma_n \rightarrow 0$ ,  $\vartheta_0 \in \mathbb{R}^k$  sowie  $\Sigma \in \mathbb{R}^{k \times k}$  positiv definit und es gelte

$$\sigma_n^{-1}(X_n - \vartheta_0) \xrightarrow{d} N(0, \Sigma).$$

Ist  $f : \mathbb{R}^k \rightarrow \mathbb{R}$  in einer Umgebung von  $\vartheta_0$  stetig differenzierbar mit  $(\nabla f(\vartheta_0))^\top \Sigma \nabla f(\vartheta_0) > 0$ , so folgt

$$\sigma_n^{-1}(f(X_n) - f(\vartheta_0)) \xrightarrow{d} N(0, (\nabla f(\vartheta_0))^\top \Sigma \nabla f(\vartheta_0)).$$

**5.4 Satz.** Es seien  $\vartheta_0 \in \Theta$ ,  $g : \Theta \rightarrow \mathbb{R}$  und für hinreichend großes  $n$  existiere der Momentenschätzer  $\hat{g}_n = G(\frac{1}{n} \sum_{i=1}^n \psi(x_i))$  mit Momentenfunktionen  $\psi_j \in L^2(\mathbb{P}_{\vartheta_0})$ ,  $j = 1, \dots, q$ . Setze  $\Sigma(\vartheta_0) := (\text{Cov}_{\vartheta_0}(\psi_i, \psi_j))_{i,j=1, \dots, q}$ . Sofern  $G$  in einer Umgebung von  $\varphi(\vartheta_0)$  stetig differenzierbar ist mit  $\sigma^2 := (\nabla G(\varphi(\vartheta_0)))^\top \Sigma(\vartheta_0) \nabla G(\varphi(\vartheta_0)) > 0$ , ist  $\hat{g}_n$  unter  $\mathbb{P}_{\vartheta_0}^{\otimes n}$  asymptotisch normalverteilt mit Rate  $n^{-1/2}$  und asymptotischer Varianz  $\sigma^2$ :

$$\sqrt{n}(\hat{g}_n - g(\vartheta_0)) \xrightarrow{d} N(0, \sigma^2).$$

## 5.2 Maximum-Likelihood- und M-Schätzer

**5.5 Definition.** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  ein von  $\mu$  dominiertes Experiment mit Likelihoodfunktion  $L(\vartheta, x)$ . Eine Statistik  $\hat{\vartheta} : \mathcal{X} \rightarrow \Theta$  ( $\Theta$  trage eine  $\sigma$ -Algebra  $\mathcal{F}_\Theta$ ) heißt Maximum-Likelihood-Schätzer (MLE) von  $\vartheta$ , falls  $L(\hat{\vartheta}(x), x) = \sup_{\vartheta \in \Theta} L(\vartheta, x)$  für  $\mathbb{P}_\vartheta$ -fast alle  $x \in \mathcal{X}$  und alle  $\vartheta \in \Theta$  gilt.

Mit  $\ell(\vartheta, x) := \log L(\vartheta, x)$  wird die Loglikelihood-Funktion bezeichnet.

**5.6 Lemma.** Für eine natürliche Exponentialfamilie  $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$  in  $T(x)$  ist der MLE  $\hat{\vartheta}$  implizit gegeben durch die Momentengleichung  $\mathbb{E}_{\hat{\vartheta}}[T] = T(x)$ , vorausgesetzt der MLE existiert und liegt im Innern  $\text{int}(\Theta)$  von  $\Theta$ .

**5.7 Definition.** Es sei  $(\mathcal{X}_n, \mathcal{F}_n, (\mathbb{P}_\vartheta^n)_{\vartheta \in \Theta})_{n \geq 1}$  eine Folge statistischer Experimente. Eine Funktion  $K : \Theta \times \Theta \rightarrow \mathbb{R} \cup \{+\infty\}$  heißt Kontrastfunktion, falls  $\vartheta \mapsto K(\vartheta_0, \vartheta)$  ein eindeutiges Minimum bei  $\vartheta_0$  hat für alle  $\vartheta_0 \in \Theta$ . Eine Folge  $K_n : \Theta \times \mathcal{X}_n \rightarrow \mathbb{R} \cup \{+\infty\}$  heißt zugehöriger Kontrastprozess (oder bloß Kontrast), falls folgende Bedingungen gelten:

(a)  $K_n(\vartheta, \bullet)$  ist  $\mathcal{F}_n$ -messbar für alle  $\vartheta \in \Theta$ ;

(b)  $\forall \vartheta, \vartheta_0 \in \Theta : K_n(\vartheta) \xrightarrow{\mathbb{P}_{\vartheta_0}^n} K(\vartheta_0, \vartheta)$  für  $n \rightarrow \infty$ .

Ein zugehöriger M-Schätzer (oder Minimum-Kontrast-Schätzer) ist gegeben durch  $\hat{\vartheta}_n(x_n) := \text{argmin}_{\vartheta \in \Theta} K_n(\vartheta, x_n)$  (sofern existent; nicht notwendigerweise eindeutig).

**5.8 Satz.** Es sei  $(K_n)_{n \geq 1}$  ein Kontrastprozess zur Kontrastfunktion  $K$ . Dann ist der zugehörige M-Schätzer  $\hat{\vartheta}_n$  konsistent für  $\vartheta_0 \in \Theta$  unter folgenden Bedingungen:

(A1)  $\Theta$  ist ein kompakter Raum;

(A2)  $\vartheta \mapsto K(\vartheta_0, \vartheta)$  ist stetig und  $\vartheta \mapsto K_n(\vartheta)$  ist  $\mathbb{P}_{\vartheta_0}^n$ -f.s. stetig;

(A3)  $\sup_{\vartheta \in \Theta} |K_n(\vartheta) - K(\vartheta_0, \vartheta)| \xrightarrow{\mathbb{P}_{\vartheta_0}^n} 0$ .

**5.9 Satz.** Es mögen die Annahmen (A1)-(A3) sowie  $\Theta \subseteq \mathbb{R}^k$  und  $\vartheta_0 \in \text{int}(\Theta)$  gelten. Der Kontrastprozess  $K_n$  sei zweimal stetig differenzierbar in einer Umgebung von  $\vartheta_0$  ( $\mathbb{P}_{\vartheta_0}^n$ -f.s.), so dass mit

$$U_n(\vartheta) := \nabla_\vartheta K_n(\vartheta) \text{ (Score)}, \quad V_n(\vartheta) := \nabla_\vartheta^2 K_n(\vartheta)$$

folgende Konvergenzen unter  $\mathbb{P}_{\vartheta_0}^n$  gelten:

(a)  $\sqrt{n}U_n(\vartheta_0) \xrightarrow{d} N(0, I(\vartheta_0))$  mit  $I(\vartheta_0) \in \mathbb{R}^{k \times k}$  positiv definit.

(b) Aus  $\vartheta_n \xrightarrow{\mathbb{P}_{\vartheta_0}^n} \vartheta_0$  folgt  $V_n(\vartheta_n) \xrightarrow{\mathbb{P}_{\vartheta_0}^n} V(\vartheta_0)$  mit  $V(\vartheta_0) \in \mathbb{R}^{k \times k}$  regulär.

Dann ist der M-Schätzer  $\hat{\vartheta}_n$  asymptotisch normalverteilt. Genauer gilt unter  $\mathbb{P}_{\vartheta_0}^n$ :

$$\sqrt{n}(\hat{\vartheta}_n - \vartheta_0) \xrightarrow{d} N(0, V(\vartheta_0)^{-1}I(\vartheta_0)V(\vartheta_0)^{-1}).$$

**5.10 Satz.** Ist  $\Theta \subseteq \mathbb{R}^k$  kompakt,  $(X_n(\vartheta), \vartheta \in \Theta)_{n \geq 1}$  eine Folge stetiger Prozesse mit  $X_n(\vartheta) \xrightarrow{\mathbb{P}} X(\vartheta)$  für alle  $\vartheta \in \Theta$  und stetigem Grenzprozess  $(X(\vartheta), \vartheta \in \Theta)$ , so gilt  $\max_{\vartheta \in \Theta} |X_n(\vartheta) - X(\vartheta)| \xrightarrow{\mathbb{P}} 0$  genau dann, wenn  $(X_n)$  straff ist, also wenn

$$\forall \varepsilon, \eta > 0 \exists \delta > 0 : \limsup_{n \rightarrow \infty} \mathbb{P} \left( \sup_{|\vartheta_1 - \vartheta_2| < \delta} |X_n(\vartheta_1) - X_n(\vartheta_2)| \geq \varepsilon \right) \leq \eta.$$

**5.11 Satz.** Es seien  $(\mathcal{X}^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_{\vartheta}^{\otimes n})_{\vartheta \in \Theta})_{n \geq 1}$  eine Folge dominierter Produktexperimente mit eindimensionaler Loglikelihoodfunktion  $\ell(\vartheta, x) = \log\left(\frac{d\mathbb{P}_{\vartheta}}{d\mu}(x)\right)$ . Es gelte:

- (a)  $\Theta \subseteq \mathbb{R}^k$  ist kompakt und  $\vartheta_0$  liegt im Innern  $\text{int}(\Theta)$  von  $\Theta$ .
- (b)  $\vartheta \mapsto \ell(\vartheta, x) = \log(L(\vartheta, x))$  ist zweimal stetig differenzierbar in einer Umgebung  $U$  von  $\vartheta_0$  für alle  $x \in \mathcal{X}$ .
- (c) Für  $i = 0, 1, 2$  gibt es  $H_i \in L^1(\mathbb{P}_{\vartheta_0})$  mit  $\sup_{\vartheta \in \Theta} |\ell(\vartheta, x)| \leq H_0(x)$  und  $\sup_{\vartheta \in U} |\nabla_{\vartheta}^i \ell(\vartheta, x)| \leq H_i(x)$  für  $i = 1, 2, x \in \mathcal{X}$ .
- (d) Die Fisher-Informationsmatrix  $I(\vartheta_0) = \mathbb{E}_{\vartheta_0}[(\nabla_{\vartheta} \ell(\vartheta_0))(\nabla_{\vartheta} \ell(\vartheta_0))^{\top}]$  ist positiv definit.

Dann gilt für den MLE  $\hat{\vartheta}_n$  unter  $\mathbb{P}_{\vartheta_0}^{\otimes n}$

$$\sqrt{n}(\hat{\vartheta}_n - \vartheta_0) \xrightarrow{d} N(0, I(\vartheta_0)^{-1}).$$

Ferner gilt die Formel  $I(\vartheta_0) = -\mathbb{E}_{\vartheta_0}[\nabla_{\vartheta}^2 \ell(\vartheta_0)]$ .

### 5.3 Effizienz

**5.12 Definition.** Für  $n \geq 1$  seien  $\hat{\vartheta}_{n,1}$  und  $\hat{\vartheta}_{n,2}$  Schätzer von  $\vartheta$  definiert auf  $(\mathcal{X}^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_{\vartheta}^{\otimes n})_{\vartheta \in \Theta})$  mit  $\Theta \subseteq \mathbb{R}^k$  sowie

$$V_{n,i}(\vartheta)^{-1/2}(\hat{\vartheta}_{n,i} - \vartheta) \xrightarrow{d} N(0, E_k) \quad \text{für alle } \vartheta \in \Theta, i = 1, 2$$

mit geeigneten symmetrisch, positiv-definiten Matrizen  $V_{n,i}(\vartheta)$ ,  $E_k$  Einheitsmatrix. Dann heißt  $(\hat{\vartheta}_{n,1})_{n \geq 1}$  asymptotisch effizienter als  $(\hat{\vartheta}_{n,2})_{n \geq 1}$ , falls  $V_{n,1}(\vartheta) \leq V_{n,2}(\vartheta)$  (d.h.  $V_{n,2}(\vartheta) - V_{n,1}(\vartheta)$  positiv semi-definit) für alle  $\vartheta \in \Theta, n \geq 1$  gilt.

**5.13 Satz (Cramér-Rao).** Es sei  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_{\vartheta})_{\vartheta \in \Theta})$  mit  $\Theta \subseteq \mathbb{R}^k$  ein von  $\mu$  dominiertes Experiment mit Likelihoodfunktion  $L(\vartheta, x)$ . Ferner sei  $g : \Theta \rightarrow \mathbb{R}$  differenzierbar,  $\hat{g}$  ein erwartungstreuer Schätzer von  $g(\vartheta)$  sowie

$$\nabla_{\vartheta} \int_{\mathcal{X}} h(x) L(\vartheta, x) \mu(dx) = \int_{\mathcal{X}} h(x) \nabla_{\vartheta} L(\vartheta, x) \mu(dx), \quad \vartheta \in \Theta,$$

für  $h(x) = 1$  und  $h(x) = \hat{g}(x)$ . Ist die Fisher-Informationsmatrix  $I(\vartheta)$  positiv definit, so gilt folgende untere Schranke für das quadratische Risiko von  $\hat{g}$ :

$$\mathbb{E}_{\vartheta}[(\hat{g} - g(\vartheta))^2] = \text{Var}_{\vartheta}(\hat{g}) \geq (\nabla_{\vartheta} g(\vartheta))^{\top} I(\vartheta)^{-1} \nabla_{\vartheta} g(\vartheta), \quad \vartheta \in \Theta.$$

## 5.4 Nichtparametrische Dichteschätzung

**5.14 Definition.** Eine Funktion  $K : \mathbb{R} \rightarrow \mathbb{R}$  heißt Kern (oder Kernfunktion), falls  $\int_{-\infty}^{\infty} K(x) dx = 1$  und  $K \in L^2(\mathbb{R})$ . Gilt

$$\int_{-\infty}^{\infty} K(x)x^p dx = 0, \quad 1 \leq p \leq P,$$

sowie  $\int |K(x)x^{P+1}| dx < \infty$ , so besitzt der Kern  $K$  die Ordnung  $P$ . Für  $h > 0$  setze  $K_h(x) := h^{-1}K(h^{-1}x)$ . Hierbei wird  $h$  als Bandweite bezeichnet.

**5.15 Definition.** Für reellwertige Beobachtungen  $X_1, \dots, X_n$  bezeichnet

$$\hat{f}_{h,n}(x) = \frac{1}{n} \sum_{i=1}^n K_h(x - X_i), \quad x \in \mathbb{R}$$

den Kerndichteschätzer zu gegebenem Kern  $K$  mit Bandweite  $h > 0$ .

**5.16 Satz.** Es sei  $X_1, \dots, X_n$  eine mathematische Stichprobe gemäß einer Dichte  $f$ . Gilt  $f \in C^s(\mathbb{R})$  und besitzt der Kern  $K$  die Ordnung  $P \geq s - 1$ , so gilt für das quadratische Risiko der Kerndichteschätzung

$$\forall x_0 \in \mathbb{R} : \mathbb{E}_f[(\hat{f}_{h,n}(x_0) - f(x_0))^2] \leq C(K, s) \|f^{(s)}\|_{\infty} h^s + \|K\|_{L^2}^2 \|f\|_{\infty} (nh)^{-1},$$

wobei  $C(K, s) > 0$  nur von  $K$  und  $s$  abhängt.

**5.17 Korollar.** Setze für  $s \geq 1$ ,  $R > 0$

$$\mathcal{D}(s, R) := \{f : \mathbb{R} \rightarrow \mathbb{R}^+ \mid f \in C^s(\mathbb{R}), \int f(x) dx = 1, \max(\|f\|_{\infty}, \|f^{(s)}\|_{\infty}) \leq R\}.$$

Dann erfüllt der Kerndichteschätzer mit einem Kern der Ordnung  $P \geq s - 1$  und der Bandweite  $h(n) = Cn^{-s/(2s+1)}$ ,  $C > 0$  beliebig, asymptotisch:

$$\forall x_0 \in \mathbb{R} : \limsup_{n \rightarrow \infty} n^{2s/(2s+1)} \sup_{f \in \mathcal{D}(s, R)} \mathbb{E}_f[(\hat{f}_{n, h(n)}(x_0) - f(x_0))^2] < \infty.$$

Insbesondere ergeben sich die Konvergenzraten  $n^{-2/3}$  ( $s=1$ ),  $n^{-4/5}$  ( $s=2$ ) sowie als Grenzwert für  $s \rightarrow \infty$  die parametrische Rate  $n^{-1}$  für das quadratische Risiko.