

# Inhalt

1. Einführung in statistische Modelle und Inferenzkonzepte
  - Statistische Modelle
  - Konzepte der statistischen Inferenz
2. Klassische Schätz- und Testtheorie
  - Klassische Schätztheorie
  - Klassische Testtheorie
  - Bereichsschätzung und Konfidenzintervalle
  - Multiple Testen
3. Likelihood-Inferenz
  - Parametrische Likelihood-Inferenz
  - Maximum-Likelihood-Schätzung
  - Testen linearer Hypothesen und Konfidenzintervalle
  - Fehlspezifikation, Quasi-Likelihood und Schätzgleichungen

## 2 Klassische Schätz- und Testtheorie

### Grundmodell:

Die Stichprobe  $X = (X_1, \dots, X_n)$  besitzt die Verteilung  $\mathbb{P} \in \mathcal{P} = \{\mathbb{P}_\theta : \theta \in \Theta\}$ ,  $\Theta \subseteq \mathbb{R}^k$ , wobei

- ▶  $\theta$ :  $k$ -dimensionaler Parameter
- ▶  $\Theta$ : Parameterraum
- ▶  $k < n$ , oft  $k \ll n$ , mit  $\dim(\theta) = k$  fest für asymptotische ( $n \rightarrow \infty$ )-Betrachtungen.
- ▶ In der Regel vorausgesetzt: Es existiert Dichte

$$f(x|\theta) = f(x_1, \dots, x_n|\theta) \text{ zu } \mathbb{P}_\theta,$$

so dass man analog schreiben kann:

$$\mathcal{P} = \{f(x|\theta) : \theta \in \Theta\}.$$

## 2 Klassische Schätz- und Testtheorie

- ▶ Klassische Schätz- und Testtheorie für finite (d.h. für festen Stichprobenumfang  $n$ ) i.i.d.-Stichprobe von besonderer Relevanz; es gilt:

$$f(x|\theta) = f(x_1|\theta) \cdot \dots \cdot f(x_n|\theta).$$

- ▶ Viele Begriffe, insbesondere der Schätztheorie, jedoch von genereller Bedeutung.
- ▶ Literatur: Lehmann & Casella (1998), Lehmann & Romano (2005), Rüger (1999, 2002) Band I+II

## 2 Klassische Schätz- und Testtheorie

### Definition 2.1 (Statistik)

*Eine Statistik ist eine messbare Funktion*

$$T : \begin{cases} \mathcal{X} & \longrightarrow \mathbb{R}^l \\ x & \longmapsto T(x). \end{cases}$$

*Normalerweise ist  $l < n$ , da mit der Statistik  $T$  eine Dimensionsreduktion erzielt werden soll.*

### Beispiel 2.1

- $T(x)$  Schätzfunktion
- $T(x)$  Teststatistik

## 2.1 Klassische Schätztheorie

Gesucht: Punkt- oder Bereichsschätzung für  $\theta$  oder einen transformierten Parametervektor  $\tau(\theta)$ .

### Beispiel 2.2

$X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$  mit  $\theta = (\mu, \sigma^2)^\top$ . Hier könnte  $\tau(\theta) = \mu$  sein (d.h.  $\sigma^2$  ist Nuisance-Parameter) oder  $\tau(\theta) = 1/\sigma^2$  (d.h. die Präzision ist von Interesse).

## 2.1 Klassische Schätztheorie

### Definition 2.2 (Punktschätzung, Schätzer, Schätzfunktion)

Sei

$$T : \begin{cases} \mathcal{X} & \longrightarrow & \Theta \subseteq \mathbb{R}^k \\ x & \longmapsto & T(x) \end{cases}$$

eine messbare Abbildung.

Man bezeichnet mit  $T(x)$  den Schätzwert oder die Punktschätzung (zu konkreter Realisation  $x$ ) und mit  $T(X)$  den Punktschätzer von  $\theta$ , der eine Zufallsvariable ist (auch gebräuchlich:  $\hat{\theta}(x)$  oder kurz  $\hat{\theta}$ , d.h. notationell wird nicht zwischen Schätzwert und Schätzfunktion unterschieden).

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

Der Begriff der Suffizienz ist von grundlegender Bedeutung in der klassischen parametrischen Inferenz; darüber hinaus ist die Bedeutung (stark) abgeschwächt, vgl. auch Statistik IV.

#### Definition 2.3

*Eine Statistik  $T$  heißt suffizient für  $\theta$  (oder auch für  $\mathcal{P}$ )  $\stackrel{\text{def}}{\Leftrightarrow}$  die bedingte Verteilung bzw. Dichte von  $X$  gegeben  $T(x) = t$  ist für alle Werte von  $T(x) = t$  von  $\theta$  unabhängig, d.h.*

$$f_{X|T}(x|T(x) = t, \theta) = f_{X|T}(x|T(x) = t)$$

*hängt nicht von  $\theta$  ab.*

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

Idee: Zusätzliche Information in  $X$ , die nicht in  $T$  enthalten ist, ist durch  $f_{X|T}$  gegeben. Falls  $f_{X|T}$  von  $\theta$  unabhängig ist, dann enthält die Stichprobe  $x$  nicht mehr Information über  $\theta$  als  $T(x)$ .

Im Folgenden nehmen wir die Existenz einer Dichte für  $X$  an. Das Kriterium im folgenden Satz ist äquivalent und konstruktiv:

#### Satz 2.4 (Faktorisierungssatz, Neyman-Kriterium)

*Eine Statistik  $T$  ist suffizient für  $\theta$  genau dann wenn*

$$f(x|\theta) = h(x)g(T(x)|\theta)$$

*für fast alle  $x$ .*

D.h. die Dichte lässt sich in zwei Teile faktorisieren, von denen ein Teil von  $x$ , aber nicht von  $\theta$ , und der andere nur von  $\theta$  und  $T(x)$  abhängt.



## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

*Beweis.*

„ $\Rightarrow$ “: Falls  $T$  suffizient ist, gilt:

$$f_{X|T}(x|T(x) = t, \theta) = f_{X|T}(x|T(x) = t) = \frac{f_{X,T}(x, t|\theta)}{f_{T|\theta}(t|\theta)}.$$

Weiterhin ist

$$f_{X,T}(x, t|\theta) = \begin{cases} f_{X|\theta}(x|\theta) & \text{für } T(x) = t \\ 0 & \text{sonst,} \end{cases}$$

d.h. insgesamt

$$\underbrace{f_{X|T}(x|t)}_{h(x)} \cdot \underbrace{f_{T|\theta}(t|\theta)}_{g(T(x)|\theta)} = f_{X|\theta}(x|\theta).$$

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

*Beweis fortgeführt*

„ $\Leftarrow$ “: Man erhält die Dichte von  $T$ , ausgewertet an  $t$ , indem man im obigen Faktorisierungskriterium über die  $x$ , für die  $T(x) = t$  gilt, summiert (bzw. integriert). Im diskreten Fall also:

$$f_{T|\theta}(t|\theta) = \sum_{x: T(x)=t} h(x)g(T(x)|\theta) = g(t|\theta) \sum_{x: T(x)=t} h(x).$$

Damit ist die bedingte Dichte von  $X$  gegeben  $T = t$ ,

$$\frac{f_{X|\theta}(x|\theta)}{f_{T|\theta}(t|\theta)} = \frac{h(x)g(T(x)|\theta)}{\sum_{x: T(x)=t} h(x)g(t|\theta)} = \frac{h(x)}{\sum_{x: T(x)=t} h(x)},$$

unabhängig von  $\theta$ . Im stetigen Fall werden Summen durch Integrale ersetzt; im Detail werden Messbarkeitsbedingungen verwendet.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.3 (Bernoulli-Experiment)

Seien  $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \text{Bin}(1, \pi)$  und  $Z = \sum_{i=1}^n X_i$  die Anzahl der Erfolge.

Dann ist  $Z$  suffizient für  $\pi$ , denn

$$\begin{aligned} f_{X|Z}(x|z, \pi) &= \mathbb{P}_\pi(X = x | Z = z) \\ &= \frac{\prod_{i=1}^n \pi^{x_i} (1 - \pi)^{1-x_i}}{\binom{n}{z} \pi^z (1 - \pi)^{n-z}}, \quad \text{wobei } \sum_{i=1}^n x_i = z \\ &= \binom{n}{z}^{-1} \end{aligned}$$

ist unabhängig von  $\pi$ .

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

**Beispiel 2.3 (Bernoulli-Experiment)** fortgeführt

Gemäß Faktorisierungssatz ist

$$f(x|\pi) = \underbrace{\frac{1}{\binom{n}{z}}}_{=h(x)} \underbrace{\binom{n}{z} \pi^z (1-\pi)^{n-z}}_{=g(z|\pi)} = \underbrace{1}_{=h^*(x)} \underbrace{\pi^z (1-\pi)^{n-z}}_{=g^*(z|\pi)}.$$

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.4 (Normalverteilung)

Sei  $X = (X_1, \dots, X_n)$  mit  $X_i \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$  und  $\theta = (\mu, \sigma^2)^\top$ .

$$\begin{aligned} f_{X|\theta}(x|\theta) &= \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right) \\ &= \underbrace{(2\pi)^{-n/2}}_{h(x)} \underbrace{(\sigma^2)^{-n/2} \exp \left( -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2 \right) \right)}_{g((\sum_{i=1}^n x_i, \sum_{i=1}^n x_i^2)|\theta)}, \end{aligned}$$

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

**Beispiel 2.4 (Normalverteilung)** fortgeführt

d.h.  $T(X) = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)$  ist suffizient für  $\theta = (\mu, \sigma^2)^\top$ .

Aber: Die bijektive Transformation  $\tilde{T}(X) = (\bar{X}, S^2)$  ist auch suffizient für  $\theta$ , wobei  $S^2$  die Stichprobenvarianz bezeichnet.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.5 (Exponentialverteilung)

Sei  $X = (X_1, \dots, X_n) \stackrel{\text{i.i.d.}}{\sim} \text{Exp}(\lambda)$ , dann

$$f(x|\lambda) = \prod_{i=1}^n f(x_i|\lambda) = \underbrace{1}_{h(x)} \cdot \underbrace{\lambda^n \exp\left(-\lambda \sum_{i=1}^n x_i\right)}_{g(T(x)|\lambda)}$$

mit  $T(x) = \sum_{i=1}^n x_i$ . Nach der ursprünglichen Definition ist

$$\frac{f_{X,T|\lambda}(x, t|\lambda)}{f_{T|\lambda}(t|\lambda)} = \frac{\lambda^n \exp(-\lambda \sum_{i=1}^n x_i)}{\frac{\lambda^n}{\Gamma(n)} (\sum_{i=1}^n x_i)^{n-1} \exp(-\lambda \sum_{i=1}^n x_i)} = \frac{\Gamma(n)}{(\sum_{i=1}^n x_i)^{n-1}},$$

unabhängig von  $\lambda$ . Dabei wird benutzt, dass die Summe von  $n$  unabhängigen und identisch exponentialverteilten Zufallsvariablen mit Parameter  $\lambda$  gammaverteilt ist mit Parametern  $n$  und  $\lambda$ .

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.6 (Ordnungsstatistik)

Sei  $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f(x|\theta)$  (wobei  $f$  stetige Dichte ist) und  $T(X) = X_{(\cdot)} = (X_{(1)}, \dots, X_{(n)})$  die Ordnungsstatistik.

Dann gilt

$$f_{X|T, \theta}(x|T = x_{(\cdot)}, \theta) = \frac{1}{n!}.$$

Die Gleichheit folgt aus der Stetigkeit, denn  $x_i \neq x_j \forall i \neq j$  (mit Wahrscheinlichkeit 1).  $X_{(\cdot)}$  ist suffizient für  $\theta$ . Wir haben also bei i.i.d.-Beobachtungen keinen Informationsverlust durch Ordnen der Daten.



## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### **Bemerkung.**

- ▶ Offensichtlich ist  $T(X) = X$ , d.h. die Stichprobe selbst, suffizient.
- ▶ Ebenso ist jede eindeutige Transformation von  $X$  oder von einer suffizienten Statistik  $T(X)$  suffizient.
- ▶ Ist  $T$  suffizient, dann auch  $(T, T^*)$ , wobei  $T^*$  eine beliebige weitere Statistik darstellt.

Dies zeigt: Die Dimension einer suffizienten Statistik sollte soweit wie möglich reduziert werden.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Definition 2.5 (Minimalsuffizienz)

*Eine Statistik  $T$  heißt minimalsuffizient für  $\theta \stackrel{\text{def}}{\Leftrightarrow} T$  ist suffizient, und zu jeder anderen suffizienten Statistik  $V$  existiert eine Funktion  $H$  mit*

$$T(X) = H(V(X)) \quad \mathcal{P} - \text{fast überall.}$$

Frage: Existieren minimalsuffiziente Statistiken? Wenn ja, sind sie eindeutig?

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.7 (Normalverteilung)

Seien  $X_1, \dots, X_n \stackrel{iid}{\sim} N(\mu, \sigma^2)$ .

1.  $T(X) = \bar{X}$  ist minimal suffizient für  $\mu$  bei bekanntem  $\sigma^2$ .
2.  $T(X) = \sum_{i=1}^n (X_i - \mu)^2$  ist minimal suffizient für  $\sigma^2$  bei bekanntem  $\mu$ .
3.  $T(X) = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)$  ist minimal suffizient für  $\mu$  und  $\sigma^2$ .
4.  $T(X) = |X|$  ist minimal suffizienz für  $\sigma^2$  wenn  $X \sim N(0, \sigma^2)$  ( $n = 1, \mu = 0$ ).  $X$  ist ebenfalls suffizient, aber nicht minimal suffizient (trotz gleicher Dimension).

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Lemma 2.6

*Sind  $T$  und  $S$  minimalsuffiziente Statistiken, dann existieren injektive Funktionen  $g_1, g_2$ , so dass  $T = g_1(S)$  und  $S = g_2(T)$ .*

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Satz 2.7 (Charakterisierung von Minimalsuffizienz durch Likelihood-Quotienten)

*Definiere den Likelihood-Quotienten*

$$\Lambda_x(\theta_1, \theta_2) = \frac{f(x|\theta_1)}{f(x|\theta_2)}.$$

*Eine notwendige und hinreichende Bedingung für die Minimalsuffizienz einer Statistik  $T$  für  $\theta$  ist, dass für alle  $\theta_1$  und  $\theta_2$  mit  $\theta_1 \neq \theta_2$  gilt:*

$$T(x) = T(x') \Leftrightarrow \Lambda_x(\theta_1, \theta_2) = \Lambda_{x'}(\theta_1, \theta_2).$$

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.8 (Suffizienz in Exponentialfamilien)

Die Dichte einer  $k$ -parametrischen Exponentialfamilie hat die Form

$$\begin{aligned} f(x|\theta) &= h(x) \cdot c(\theta) \cdot \exp(\gamma_1(\theta) T_1(x) + \dots + \gamma_k(\theta) T_k(x)) \\ &= h(x) \cdot \exp(b(\theta) + \gamma(\theta)^\top \mathbf{T}(x)), \end{aligned}$$

d.h.  $\mathbf{T}(X) = (T_1(X), \dots, T_k(X))^\top$  ist suffizient für  $\theta$  nach Faktorisierungssatz. Falls  $\Theta$  ein offenes Rechteck in  $\mathbb{R}^k$  enthält, ist  $\mathbf{T}$  auch minimal suffizient.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

Es folgt nun die Charakterisierung der Minimalsuffizienz nach Lehmann-Scheffé. Dazu wird der Begriff der Vollständigkeit benötigt.

#### Definition 2.8

*Eine Statistik  $T$  ist vollständig  $\stackrel{\text{def}}{\Leftrightarrow}$  für jede reelle (messbare) Funktion  $g$  gilt:*

$$\mathbb{E}_\theta[g(T)] = 0 \quad \forall \theta \Rightarrow \mathbb{P}_\theta(g(T) = 0) = 1 \quad \forall \theta.$$

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel Vollständigkeit

Sei  $X = (X_1, \dots, X_n) \sim Po(\lambda)$  und  $T = \sum_{i=1}^n X_i$ . Nach Beispiel 2.8 ist  $T$  suffizient.

Sei  $h$  messbar. Da  $T = \sum_i X_i \sim Po(n\lambda)$ , gilt für

$$E_\lambda[h(T)] = \sum_{t=0}^{\infty} h(t) \frac{(n\lambda)^t}{t!} \exp(-n\lambda) = \exp(-n\lambda) \sum_{t=0}^{\infty} h(t) \underbrace{\frac{n^t}{t!}}_{c_t} \lambda^t = 0$$

$$\Rightarrow \sum_{t=0}^{\infty} c_t \lambda^t = \sum_{t=0}^{\infty} 0 \lambda^t$$

(zwei konvergierende Potenzreihen). Daraus folgt  $c_t = 0$  für alle  $t$  und wegen  $\frac{n^t}{t!} \neq 0$  also  $h(t) = 0$  für alle  $t$ . Damit ist  $T$  vollständig (und mit dem folgenden Satz auch minimal suffizient).



## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

Aus der Definition wird nicht unmittelbar klar, warum „Vollständigkeit“ eine wünschenswerte Eigenschaft eines Schätzers sein sollte. Einen möglichen Grund liefert der folgende Satz.

#### Satz 2.9 (Lehmann-Scheffé)

*Angenommen,  $X$  besitzt eine Dichte  $f(x|\theta)$  und  $T(X)$  ist suffizient und vollständig für  $\theta$ . Dann ist  $T(X)$  minimalsuffizient für  $\theta$ .*

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

**Beweis** des Satzes von Lehmann-Scheffé:

Vorausgesetzt wird, dass eine minimal suffiziente Statistik existiert - bewiesen wurde dies von Lehmann und Scheffé (1950). Ist dies der Fall, so ist diese bis auf bijektive Transformationen eindeutig.

Bezeichne  $S = g_1(T)$  eine solche minimal suffiziente Statistik für eine Funktion  $g_1$ . Definiere  $g_2(S) = \mathbb{E}[T|S]$ . Da  $S$  suffizient für  $\theta$  ist, hängt  $g_2(S)$  nicht von  $\theta$  ab. Betrachte nun

$$g(T) = T - g_2(S) = T - g_2(g_1(T)).$$

Anwendung des Satzes von der iterierten Erwartung liefert:

$$\mathbb{E}_\theta[g(T)] = \mathbb{E}_\theta[T] - \mathbb{E}_\theta[\mathbb{E}[T|S]] = 0.$$

Da  $T$  vollständig ist, ist  $g(T) = 0$  bzw.  $g_2(S) = T$  mit Wahrscheinlichkeit 1, d.h.  $T$  ist eine Funktion von  $S$ . Wähle  $x$  und  $x'$ , so dass  $g_2(S(x)) = g_2(S(x'))$ , dann ist  $T(x) = T(x')$  und  $S(x) = g_1(T(x)) = g_1(T(x')) = S(x')$ , d.h.  $g_1$  und  $g_2$  sind injektiv, so dass  $T$  und  $S$  äquivalent. Somit ist auch  $T$  minimal suffizient.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### **Bemerkung (Ancillarity einer Statistik)**

Eine Statistik  $V(X)$  heißt *ancillary* („Hilfsstatistik“, „ankillar“) für  $\mathcal{P}$ , wenn ihre Verteilung nicht von  $\theta$  abhängt (also bekannt ist). Häufiger Sachverhalt:  $T = (U, V)$  ist suffizient für  $\theta$ ,  $V$  ancillary,  $U$  nicht suffizient.

## 2.1 Klassische Schätztheorie

### 2.1.1 Suffizienz

#### Beispiel 2.9 (Ancillary Statistik)

$X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U\left[\theta - \frac{1}{2}, \theta + \frac{1}{2}\right]$ .

Man kann dann zeigen (Davison, 2004, Ex. 12.3), dass mit

$$U = \frac{1}{2}(X_{(1)} + X_{(n)})$$

$$V = X_{(n)} - X_{(1)}$$

$T = (U, V)$  suffizient, aber nicht vollständig für  $\theta$  ist. Ferner ist  $U$  alleine nicht suffizient und  $V$  ancillary.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

- ▶ Fehler eines Schätzers  $\hat{\theta} = \hat{\theta}(X)$  ist  $\hat{\theta} - \theta$ .
- ▶ Messung des Fehlers durch Verlustfunktion, zum Beispiel

$$L(\hat{\theta}, \theta) = |\hat{\theta} - \theta| \quad \text{Abstand } (\theta \text{ skalar}),$$

$$L(\hat{\theta}, \theta) = \|\hat{\theta} - \theta\|^2 \quad \text{quadratischer Fehler,}$$

$$L(\hat{\theta}, \theta) = \frac{\|\hat{\theta} - \theta\|^2}{\|\theta\|^2} \quad \text{relativer quadratischer Fehler,}$$

$$L(\hat{\theta}, \theta) = (\hat{\theta} - \theta)^\top \mathbf{D}(\hat{\theta} - \theta) \quad \text{gewichteter quadratischer Fehler} \\ \text{(} \mathbf{D} \text{ positiv definit).}$$

- ▶ Risikofunktion  $R(\hat{\theta}, \theta) = \mathbb{E}_\theta[L(\hat{\theta}, \theta)]$ .
- ▶ Hier wird (hauptsächlich) quadratischer Verlust betrachtet.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

#### Definition 2.10 (Erwartungstreue, Bias, Varianz eines Schätzers)

- ▶  $\hat{\theta}$  heißt erwartungstreu  $\stackrel{\text{def}}{\Leftrightarrow} \mathbb{E}_{\theta}[\hat{\theta}] = \theta$ .
- ▶  $\text{Bias}_{\theta}(\hat{\theta}) = \mathbb{E}_{\theta}[\hat{\theta}] - \theta$ .
- ▶  $\text{Var}_{\theta}(\hat{\theta}) = \mathbb{E}_{\theta}[(\hat{\theta} - \mathbb{E}_{\theta}[\hat{\theta}])^2]$ ,  $\theta$  skalar.

#### Definition 2.11 (MSE)

*Der mittlere quadratische Fehler (mean squared error) ist definiert als*

$$\text{MSE}_{\theta}(\hat{\theta}) = \mathbb{E}_{\theta}[(\hat{\theta} - \theta)^2] = \text{Var}_{\theta}(\hat{\theta}) + (\text{Bias}_{\theta}(\hat{\theta}))^2.$$

*Der Gesamtfehler lässt sich also aufteilen in einen zufälligen Fehler (Varianz) und einen systematischen (quadrierter Bias).*

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

Vergleicht man zwei Schätzer bezüglich ihres MSE, kann für einen Teilbereich von  $\Theta$  der MSE des einen, für andere Teilbereiche der MSE des zweiten Schätzers kleiner sein:

**Beispiel 2.10**  $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} B(1, \pi)$ .

1. MSE von  $\hat{\pi} = \bar{X}$ :

$$\mathbb{E}_{\pi}[(\bar{X} - \pi)^2] = \text{Var}_{\pi}(\bar{X}) = \frac{\pi(1 - \pi)}{n}.$$

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.10** fortgeführt

2. MSE des Bayes-Schätzers (Posteriori-Erwartungswert) bei einer Priori  $p(\pi) \sim \text{Be}(\alpha, \beta)$ :

$$\hat{\pi}_B = \frac{Y + \alpha}{\alpha + \beta + n}, \quad Y = \sum_{i=1}^n X_i,$$

$$\begin{aligned} \text{MSE}(\hat{\pi}_B) &= \text{Var}_\pi \left( \frac{Y + \alpha}{\alpha + \beta + n} \right) + \left( \mathbb{E}_\pi \left[ \frac{Y + \alpha}{\alpha + \beta + n} - \pi \right] \right)^2 \\ &= \frac{n\pi(1 - \pi)}{(\alpha + \beta + n)^2} + \left( \frac{n\pi + \alpha}{\alpha + \beta + n} - \pi \right)^2. \end{aligned}$$

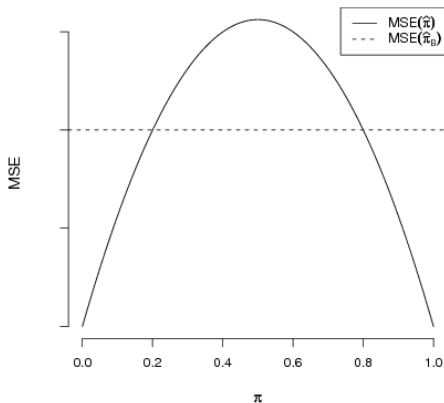


## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

Für  $\alpha = \beta = \sqrt{n}/2$  ergibt sich

$$\text{MSE}_{\pi}(\hat{\pi}_B) = \mathbb{E}_{\pi}[(\hat{\pi}_B - \pi)^2] = \frac{1}{4} \frac{n}{(n + \sqrt{n})^2} = \text{const bezüglich } \pi.$$



## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

Fazit: In der Regel wird man keinen „MSE-optimalen“ Schätzer  $\hat{\theta}^{\text{opt}}$  finden in dem Sinne, dass  $\text{MSE}_{\theta}(\hat{\theta}^{\text{opt}}) \leq \text{MSE}_{\theta}(\hat{\theta})$  für alle  $\theta$  und alle konkurrierenden  $\hat{\theta}$ . Bei Einschränkung auf erwartungstreue Schätzer ist dies öfter möglich. Deshalb die Forderung:

#### Definition 2.12 (zulässiger („admissible“) Schätzer)

*Ein Schätzer  $\hat{\theta}$  heißt zulässig  $\stackrel{\text{def}}{\Leftrightarrow}$  es gibt keinen Schätzer  $\tilde{\theta}$  mit  $\text{MSE}_{\theta}(\tilde{\theta}) \leq \text{MSE}_{\theta}(\hat{\theta})$  für alle  $\theta$  und  $\text{MSE}_{\theta}(\tilde{\theta}) < \text{MSE}_{\theta}(\hat{\theta})$  für mindestens ein  $\theta$ , d.h. es gibt keinen Schätzer  $\tilde{\theta}$ , der  $\hat{\theta}$  gleichmäßig/strikt „dominiert“.*

# 2.1 Klassische Schätztheorie

## 2.1.2 Erwartungstreue, Varianz und MSE

**Definition 2.13** (Verallgemeinerungen des MSE auf  $\theta \in \mathbb{R}^p, p > 1$ )

*Üblich sind die folgenden zwei Alternativen:*

1. *MSE (skalar):*

$$\begin{aligned} \text{MSE}_\theta^{(1)}(\hat{\theta}) &= \mathbb{E}_\theta[\|\hat{\theta} - \theta\|^2] \\ &= \sum_{j=1}^p \mathbb{E}_\theta[(\hat{\theta}_j - \theta_j)^2] \\ &= \sum_{j=1}^p \text{MSE}_\theta(\hat{\theta}_j) \end{aligned}$$

2. *MSE-Matrix:*

$$\begin{aligned} \text{MSE}_\theta^{(2)}(\hat{\theta}) &= \mathbb{E}_\theta[(\hat{\theta} - \theta)(\hat{\theta} - \theta)^\top] \\ &= \text{Cov}_\theta(\hat{\theta}) + (\mathbb{E}_\theta[\hat{\theta}] - \theta)(\mathbb{E}_\theta[\hat{\theta}] - \theta)^\top \end{aligned}$$

*Diese Variante wird häufig bei linearen Modellen betrachtet.*

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Bemerkung.** Das  $j$ -te Diagonalelement der MSE-Matrix ist  $\text{MSE}_\theta(\hat{\theta}_j)$ . Vergleich von MSE-Matrizen gemäß „Löwner“-Ordnung:

$$\text{MSE}_\theta(\tilde{\theta}) \stackrel{(\leq)}{<} \text{MSE}_\theta(\hat{\theta})$$

bedeutet, dass die Differenz  $\text{MSE}_\theta(\hat{\theta}) - \text{MSE}_\theta(\tilde{\theta})$  positiv (semi-)definit ist.

Man definiert allgemein für symmetrische  $(p \times p)$ -Matrizen  $\mathbf{A}, \mathbf{B}$ :

$$\mathbf{A} \leq \mathbf{B} \stackrel{\text{def}}{\Leftrightarrow} \mathbf{B} - \mathbf{A} \text{ ist positiv semidefinit,}$$

$$\mathbf{A} < \mathbf{B} \stackrel{\text{def}}{\Leftrightarrow} \mathbf{B} - \mathbf{A} \text{ ist positiv definit.}$$

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.11** (Gauß-Experiment) Seien  $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ .

- ▶  $\sigma^2$  bekannt,  $\mu$  unbekannt: MSE-Vergleich von  $\bar{X}$  und  $T = a\bar{X} + b$ .
- ▶  $\sigma^2$  unbekannt,  $\mu$  bekannt:
  - ▶ Eine Möglichkeit:

$$S_\mu^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2, \mathbb{E}_{\sigma^2}(S_\mu^2) = \sigma^2$$

- ▶ Weitere Möglichkeit:

$$V_\mu^2 = \frac{1}{n+2} \sum_{i=1}^n (X_i - \mu)^2, \mathbb{E}_{\sigma^2}(V_\mu^2) = \frac{n}{n+2} \sigma^2$$

Es stellt sich heraus, dass  $\text{MSE}_{\sigma^2}(V_\mu^2) < \text{MSE}_{\sigma^2}(S_\mu^2)$  ist.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.11** (Gauß-Experiment) fortgeführt

- ▶  $\mu$  und  $\sigma^2$  unbekannt:
  - ▶ Eine Möglichkeit:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

$$\mathbb{E}_{\sigma^2}(S^2) = \sigma^2, \quad \text{MSE}_{\sigma^2}(S^2) = \text{Var}_{\sigma^2}(S^2) = \frac{2}{n-1} \sigma^4.$$

- ▶ Weitere Möglichkeit:

$$V^2 = \frac{1}{n+1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

$$\mathbb{E}_{\sigma^2}(V^2) = \frac{n-1}{n+1} \sigma^2, \quad \text{MSE}_{\sigma^2}(V^2) = \frac{2}{n+1} \sigma^4,$$

d.h.  $V^2$  dominiert  $S^2$ .

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.11** (Gauß-Experiment) fortgeführt

- ▶  $\mu$  und  $\sigma^2$  (weiterhin) unbekannt:
  - ▶ Der sogenannte *Stein-Schätzer*

$$T = \min \left\{ V^2, \frac{1}{n+2} \sum_{i=1}^n X_i^2 \right\}$$

dominiert  $V^2$  (und damit  $S^2$ ).

Plausibilitätsbetrachtung: Ist  $\mu = 0$ , so ist  $\sum_{i=1}^n X_i^2 / (n+2)$  besserer Schätzer als  $V^2$ . Ist  $\mu \neq 0$ , so ist  $V^2$  ein besserer Schätzer als  $\sum_{i=1}^n X_i^2 / (n+2)$ . Beim Stein-Schätzer wird fallweise mit hoher Wahrscheinlichkeit der jeweils bessere Schätzer benutzt.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.12** (Steins Paradoxon)

Seien  $(X_1, \dots, X_m)^\top \sim N_m(\boldsymbol{\mu}, \sigma^2 \mathbf{I}_m)$  multivariat normalverteilt mit  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_m)^\top$  und  $\sigma^2$  bekannt. Es sollen simultan die Erwartungswerte  $\mu_1, \dots, \mu_m$  geschätzt werden. Man beachte dabei, dass die einzelnen Komponenten als unabhängig angenommen werden. Die Stichprobe hat die Form

$$X_{11}, \dots, X_{1n_1}, \dots, X_{m1}, \dots, X_{mn_m}$$

(i.i.d. Stichproben aus „Gruppen“  $1, \dots, m$ ). Übliche Schätzer:

$$T_j = \bar{X}_j, \quad j = 1, \dots, m, \quad \mathbf{T} = (T_1, \dots, T_m)^\top = (\bar{X}_1, \dots, \bar{X}_m)^\top.$$

Der (skalare) MSE ist:

$$\mathbb{E}_\mu[\|\mathbf{T} - \boldsymbol{\mu}\|^2] = \sum_{j=1}^m \mathbb{E}_\mu[(\bar{X}_j - \mu_j)^2] = \sum_{j=1}^m \frac{\sigma_j^2}{n_j}.$$



## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Beispiel 2.12** (Steins Paradoxon) fortgeführt  
Paradoxerweise gilt:

1. Für  $m \leq 2$  ist  $\mathbf{T}$  zulässig.
2. Für  $m \geq 3$  ist  $\mathbf{T}$  *nicht* zulässig und wird dominiert durch den Stein-Schätzer

$$\mathbf{T}^* = \left( 1 - \frac{(m-2)\sigma^2}{\sum_{j=1}^m n_j \bar{X}_j^2} \right) \mathbf{T}.$$

Es lässt sich zeigen:  $T^*$  ist selbst unzulässig. Der Stein-Schätzer ist ein sogenannter *Shrinkage-Schätzer*.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

#### Beispiel 2.13 (Lineares Modell)

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim (N)(\mathbf{0}, \sigma^2\mathbf{I})$$

KQ-Schätzer:  $\hat{\boldsymbol{\beta}}_{\text{KQ}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$

Ridge-Schätzer:  $\hat{\boldsymbol{\beta}}_{\text{Ridge}} = (\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{D})^{-1} \mathbf{X}^\top \mathbf{y},$

wobei  $\mathbf{D}$  eine Diagonalmatrix mit positiven Diagonalelementen ist.  
Für einen MSE-Vergleich siehe Übung.

## 2.1 Klassische Schätztheorie

### 2.1.2 Erwartungstreue, Varianz und MSE

**Fazit:** Bereits im einfachen Beispiel der Schätzung von  $\pi$  in  $B(1, \pi)$  (siehe Beispiel 2.10) zeigt sich, dass es im Allgemeinen keine MSE-optimalen Schätzer gibt.

Auswege:

1. Einschränkung auf Teilklasse von Schätzern, zum Beispiel erwartungstreue (und lineare) Schätzer, äquivalente Schätzer, ...
2. MSE-Kriterium verändern:
  - ▶ Ersetze  $\text{MSE}_\theta(\hat{\theta})$  durch Minimierung von  $\max_{\theta \in \Theta} \text{MSE}_\theta(\hat{\theta})$  (Minimax-Kriterium)
  - ▶ oder ersetze  $\text{MSE}_\theta(\hat{\theta})$  durch  $\mathbb{E}_{p(\theta)}[\text{MSE}_\theta(\hat{\theta})]$  bei einer Priori-Verteilung  $p(\theta)$  (Bayes-Schätzer).

Hier: Strategie 1 mit erwartungstreuen Schätzern, vgl. 2.1.4.

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

#### Definition 2.14 (Fisher-reguläre Verteilungsfamilien)

Eine Familie von Verteilungen  $\mathcal{P}_\theta$  mit Dichte  $f(x|\theta) = f(x_1, \dots, x_n|\theta)$ ,  $\theta \in \Theta$ , heißt Fisher-regulär, wenn Folgendes gilt:

1. Der Träger  $\{x \in \mathcal{X} : f(x|\theta) > 0\}$  ist unabhängig von  $\theta$  (dies ist zum Beispiel bei  $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} U[0; \theta]$  oder bei der Pareto-Verteilung verletzt).
2.  $\Theta$  ist offen in  $\mathbb{R}^p$  (verletzt zum Beispiel bei  $\sigma^2 \geq 0$ ).
3. Die ersten und zweiten Ableitungen von  $f(x|\theta)$  bzgl.  $\theta$  existieren und sind für jedes  $\theta$  endliche Funktionen von  $x$ .
4. Vertauschbarkeit: Sowohl für  $f(x|\theta)$  als auch für  $\log(f(x|\theta))$  kann erstes und zweites Differenzieren nach  $\theta$  und Integration über  $x$  vertauscht werden.

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

#### Definition 2.15 (Log-Likelihood, Scorefunktion und Information)

$\ell(\theta; \mathbf{x}) = \log f(\mathbf{x}|\theta)$  (Log-Likelihood von  $\theta$  bzgl. der Stichprobe  $\mathbf{x}$ )

$$s(\theta; \mathbf{x}) = \frac{\partial}{\partial \theta} \ell(\theta; \mathbf{x}) = \left( \frac{\partial}{\partial \theta_1} \ell(\theta; \mathbf{x}), \dots, \frac{\partial}{\partial \theta_p} \ell(\theta; \mathbf{x}) \right)^\top$$

(Score-Funktion)

$$J(\theta; \mathbf{x}) = -\frac{\partial^2 \ell(\theta; \mathbf{x})}{\partial \theta \partial \theta^\top}$$

(beobachtete Informationsmatrix der  
Stichprobe mit Elementen  $(J(\theta; \mathbf{x}))_{ij} = -\frac{\partial^2 \log f(\mathbf{x}|\theta)}{\partial \theta_i \partial \theta_j}$ )

$$I(\theta) = \mathbb{E}_\theta[J(\theta; \mathbf{X})] \quad (\text{erwartete oder Fisher-Informationsmatrix})$$

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

#### Satz 2.16

Ist  $\mathcal{P}_\theta$  Fisher-regulär, so gilt:

1.  $\mathbb{E}_\theta [s(\theta; X)] = 0$
2.  $\mathbb{E}_\theta \left[ -\frac{\partial^2 \ell(\theta; X)}{\partial \theta \partial \theta^\top} \right] = I(\theta) = \text{Cov}_\theta(s(\theta; X))$

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

#### Beweis

Zu 1.:

$$\begin{aligned}\mathbb{E}_\theta[s(\theta; X)] &= \int s(\theta; x) f(x|\theta) dx \\ &= \int \frac{\partial}{\partial \theta} \log(f(x|\theta)) f(x|\theta) dx \\ &= \int \frac{\frac{\partial}{\partial \theta} f(x|\theta)}{f(x|\theta)} f(x|\theta) dx \\ &= \frac{\partial}{\partial \theta} \int f(x|\theta) dx = 0\end{aligned}$$

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

Zu 2.:

$$\begin{aligned}\mathbb{E}_\theta \left[ -\frac{\partial^2 \ell(\theta; \mathbf{X})}{\partial \theta \partial \theta^\top} \right] &= -\mathbb{E}_\theta \left[ \frac{\partial}{\partial \theta} \left( \frac{\frac{\partial}{\partial \theta^\top} f(\mathbf{X}|\theta)}{f(\mathbf{X}|\theta)} \right) \right] \\ &= -\mathbb{E}_\theta \left[ \frac{f(\mathbf{X}|\theta) \frac{\partial^2}{\partial \theta \partial \theta^\top} f(\mathbf{X}|\theta) - \left( \frac{\partial}{\partial \theta} f(\mathbf{X}|\theta) \right) \left( \frac{\partial}{\partial \theta^\top} f(\mathbf{X}|\theta) \right)}{f(\mathbf{X}|\theta)^2} \right]\end{aligned}$$

unter Verwendung der Quotientenregel der Differentiation. Dies ist

$$\begin{aligned}&= -\mathbb{E}_\theta \left[ \frac{\frac{\partial^2}{\partial \theta \partial \theta^\top} f(\mathbf{X}|\theta)}{f(\mathbf{X}|\theta)} \right] + \mathbb{E}_\theta \left[ \frac{\frac{\partial}{\partial \theta} f(\mathbf{X}|\theta)}{f(\mathbf{X}|\theta)} \cdot \frac{\frac{\partial f(\mathbf{X}|\theta)}{\partial \theta^\top}}{f(\mathbf{X}|\theta)} \right] \\ &= -\int \frac{\partial^2}{\partial \theta \partial \theta^\top} f(x|\theta) dx + \mathbb{E}_\theta [s(\theta; \mathbf{X}) s(\theta; \mathbf{X})^\top]\end{aligned}$$



## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

Zu 2. (fortgeführt):

Der erste Summand ist unter Vertauschung von Differentiation und Integration gleich null. Für den zweiten Teil ergibt sich mit Teil 1.

$$\mathbb{E}[s(\theta; X)s(\theta; X)^\top] = \text{Cov}_\theta(s(\theta; X)).$$



## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

Weitere Eigenschaften:

- Sind  $X_1, \dots, X_n$  unabhängig und gemäß  $X_i \sim f_i(x|\theta)$ ,  $i = 1, \dots, n$ , verteilt, so gilt:

$$\ell(\theta) = \sum_{i=1}^n \ell_i(\theta) \quad , \quad \ell_i(\theta) = \log f_i(x_i|\theta)$$

$$s(\theta) = \sum_{i=1}^n s_i(\theta) \quad , \quad s_i(\theta) = \frac{\partial}{\partial \theta} \log f_i(x_i|\theta)$$

$$J(\theta) = -\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta^\top} = \sum_{i=1}^n -\frac{\partial^2 \log f_i(x_i|\theta)}{\partial \theta \partial \theta^\top}$$

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

Weitere Eigenschaften (fortgeführt):

- ▶ Für  $X_1, \dots, X_n$  i.i.d. wie  $X_1 \sim f_1(x|\theta)$  folgt

$$I(\theta) = \mathbb{E}_\theta[J(\theta)] = n \cdot i(\theta),$$

wobei

$$i(\theta) = \mathbb{E}_\theta \left[ -\frac{\partial^2 \ell_1(\theta; X)}{\partial \theta \partial \theta^\top} \right] = \text{Cov}_\theta \left( \frac{\partial \log f_1(X|\theta)}{\partial \theta} \right)$$

die erwartete Information einer Einzelbeobachtung ist, d.h. die erwartete Informationsmatrix der Stichprobe  $X_1, \dots, X_n$  ist die  $n$ -fache erwartete Information einer (typischen) Stichprobenvariable  $X_1$ .

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

Weitere Eigenschaften (fortgeführt):

- ▶ Für eine Statistik  $T = T(X)$ ,  $X = (X_1, \dots, X_n)^\top$  mit  $T \sim f_T(t|\theta)$  kann man die Begriffe Score-Funktion und Fisher-Information völlig analog definieren. Insbesondere ist

$$I_T(\theta) = \mathbb{E}_\theta \left[ -\frac{\partial^2 \log f_T(t|\theta)}{\partial \theta \partial \theta^\top} \right].$$

## 2.1 Klassische Schätztheorie

### 2.1.3 Fisher-Information und Suffizienz

#### Satz 2.17 (Suffizienz und Fisher-Information)

Sei  $I(\theta)$  die Fisher-Information für  $X$ . Dann gilt unter Fisher-Regularität für jede Statistik  $T$ :

1.  $I_T(\theta) \leq I(\theta)$ .
2.  $I_T(\theta) = I(\theta) \Leftrightarrow T$  ist suffizient für  $\theta$ .

Also: Bei einer suffizienten Statistik  $T$  wird keine (erwartete) Information „verschenkt“.