

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

- ▶ θ : k -dimensionaler Parameter
- ▶ Θ : 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

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

so dass man analog schreiben kann:

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

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:

$$f(\mathbf{x}|\boldsymbol{\theta}) = f(x_1|\boldsymbol{\theta}) \cdot \dots \cdot f(x_n|\boldsymbol{\theta}).$$

- ▶ 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

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

Normalerweise ist $l < n$, da mit der Statistik \mathbf{T} eine Dimensionsreduktion erzielt werden soll.

Beispiel 2.1

- ▶ \mathbf{T} Schätzfunktion
- ▶ T Teststatistik

2.1 Klassische Schätztheorie

Gesucht: Punkt- oder Bereichsschätzung für θ 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. σ^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

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

eine messbare Abbildung, die Schätzfunktion.

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

2.1 Klassische Schätztheorie

Überblick

2.1.1 Suffizienz

2.1.2 Erwartungstreue, Varianz und MSE

2.1.3 Fisher-Information und Suffizienz

2.1.4 Erwartungstreue Schätzer

2.1.5 Asymptotische Eigenschaften und Kriterien

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 \mathbf{T} heißt *suffizient* für θ (oder auch für \mathcal{P}) $\stackrel{\text{def}}{\Leftrightarrow}$ die bedingte Verteilung bzw. Dichte von \mathbf{X} gegeben $\mathbf{T}(\mathbf{X}) = \mathbf{t}$ hängt für alle Werte von $\mathbf{T}(\mathbf{X}) = \mathbf{t}$ nicht von θ ab, d.h.

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

hängt nicht von θ ab.

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

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

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

Satz 2.4 (Faktorisierungssatz, Neyman-Kriterium)

Eine Statistik \mathbf{T} ist suffizient für θ genau dann wenn

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

für fast alle \mathbf{x} .

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

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beweis.

„ \Rightarrow “: Falls \mathbf{T} suffizient ist, gilt:

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

Weiterhin ist

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

d.h. insgesamt $f_{X|T}(\mathbf{x}|\mathbf{T}(\mathbf{X}) = \mathbf{t}) \cdot f_T(\mathbf{t}|\theta) = f_X(\mathbf{x}|\theta) \cdot \mathbf{1}_{\mathbf{T}(\mathbf{x})=\mathbf{t}}$
und damit

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

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beweis fortgeführt

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

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

Die bedingte Dichte von \mathbf{X} gegeben $\mathbf{T}(\mathbf{X}) = \mathbf{T}(\mathbf{x}) = \mathbf{t}$,

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

hängt damit nicht von $\boldsymbol{\theta}$ ab. Im stetigen Fall werden Summen durch Integrale ersetzt (und es sind Messbarkeitsbedingungen zu beachten).

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 π , denn

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

hängt nicht von π ab.

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel 2.3 (Bernoulli-Experiment) fortgeführt

Gemäß Faktorisierungssatz ist

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

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel 2.4 (Normalverteilung)

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

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

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

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

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel 2.5 (Exponentialverteilung)

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

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

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

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

und hängt nicht von λ ab. Dabei wird benutzt, dass die Summe von n unabhängigen und identisch exponentialverteilten Zufallsvariablen mit Parameter λ gammaverteilt ist mit Parametern n und λ .

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 Dichte einer stetigen Verteilung ist) und $\mathbf{T}(\mathbf{X}) = \mathbf{X}_{(\cdot)} = (X_{(1)}, \dots, X_{(n)})$ die Ordnungsstatistik.

Dann gilt

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

Die Gleichheit folgt aus der Stetigkeit, denn $x_i \neq x_j \forall i \neq j$ (mit Wahrscheinlichkeit 1). $\mathbf{X}_{(\cdot)}$ ist suffizient für θ . 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 $\mathbf{T}(\mathbf{X}) = \mathbf{X}$, d.h. die Stichprobe selbst, suffizient.
- ▶ Ebenso ist jede eindeutige Transformation von \mathbf{X} oder von einer suffizienten Statistik $\mathbf{T}(\mathbf{X})$ suffizient.
- ▶ Ist \mathbf{T} suffizient, dann auch $(\mathbf{T}, \mathbf{T}^*)$, wobei \mathbf{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 \mathbf{T} heißt *minimalsuffizient* für $\theta \Leftrightarrow \mathbf{T}$ ist *suffizient*, und zu jeder anderen *suffizienten* Statistik \mathbf{V} existiert eine Funktion \mathbf{H} mit

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

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. $T(\mathbf{X}) = \bar{X}$ ist minimal suffizient für μ bei bekanntem σ^2 .
2. $T(\mathbf{X}) = \sum_{i=1}^n (X_i - \mu)^2$ ist minimal suffizient für σ^2 bei bekanntem μ .
3. $\mathbf{T}(\mathbf{X}) = (\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2)$ ist minimal suffizient für μ und σ^2 .
4. $T(X) = |X|$ ist minimal suffizient für σ^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 \mathbf{T} und \mathbf{S} minimalsuffiziente Statistiken, dann existieren injektive Funktionen \mathbf{g}_1 , \mathbf{g}_2 , so dass $\mathbf{T} = \mathbf{g}_1(\mathbf{S})$ und $\mathbf{S} = \mathbf{g}_2(\mathbf{T})$.

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Satz 2.7 (Charakterisierung von Minimalsuffizienz durch Likelihood-Quotienten)

Definiere den Likelihood-Quotienten

$$\Lambda_{\mathbf{x}}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = \frac{f(\mathbf{x}|\boldsymbol{\theta}_1)}{f(\mathbf{x}|\boldsymbol{\theta}_2)}.$$

Eine notwendige und hinreichende Bedingung für die Minimalsuffizienz einer Statistik \mathbf{T} für $\boldsymbol{\theta}$ ist, dass gilt:

$$\mathbf{T}(\mathbf{x}) = \mathbf{T}(\mathbf{x}') \Leftrightarrow \Lambda_{\mathbf{x}}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = \Lambda_{\mathbf{x}'}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) \quad \forall \boldsymbol{\theta}_1, \boldsymbol{\theta}_2.$$

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel 2.8 (Suffizienz in Exponentialfamilien)

Die Dichte einer r -parametrischen Exponentialfamilie hat die Form

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

d.h. $\mathbf{T}(\mathbf{X}) = (T_1(\mathbf{X}), \dots, T_r(\mathbf{X}))^\top$ ist suffizient für $\boldsymbol{\theta}$ nach dem Faktorisierungssatz. Mit Satz 2.7 folgt, dass $\mathbf{T}(\mathbf{X})$ auch minimal suffizient ist, falls $\boldsymbol{\gamma}(\Theta)$ ein offenes Rechteck in \mathbb{R}^r enthält.

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

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

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel Vollständigkeit

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

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

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

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

(zwei konvergierende Potenzreihen). Daraus folgt $c_t = 0$ für alle t und wegen $\frac{n^t}{t!} \neq 0$ also $g(t) = 0$ 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, \mathbf{X} besitzt eine Dichte $f(\mathbf{x}|\theta)$ und $\mathbf{T}(\mathbf{X})$ ist suffizient und vollständig für θ . Dann ist $\mathbf{T}(\mathbf{X})$ minimalsuffizient für θ .

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 $\mathbf{S} = \mathbf{g}_1(\mathbf{T})$ eine solche minimal suffiziente Statistik für eine Funktion \mathbf{g}_1 . Definiere $\mathbf{g}_2(\mathbf{S}) = \mathbb{E}[\mathbf{T}|\mathbf{S}]$. Da \mathbf{S} suffizient für θ ist, hängt $\mathbf{g}_2(\mathbf{S})$ nicht von θ ab. Betrachte nun

$$\mathbf{g}(\mathbf{T}) = \mathbf{T} - \mathbf{g}_2(\mathbf{S}) = \mathbf{T} - \mathbf{g}_2(\mathbf{g}_1(\mathbf{T})).$$

Anwendung des Satzes von der iterierten Erwartung liefert:

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

Da \mathbf{T} vollständig ist, ist $\mathbf{g}(\mathbf{T}) = \mathbf{0}$ bzw. $\mathbf{g}_2(\mathbf{S}) = \mathbf{T}$ mit Wahrscheinlichkeit 1, d.h. \mathbf{T} ist eine Funktion von \mathbf{S} . Da \mathbf{S} eine Funktion jeder suffizienten Statistik ist, gilt dies damit auch für \mathbf{T} und \mathbf{T} ist also minimal suffizient. (\mathbf{S} und \mathbf{T} sind äquivalent.) \square

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Bemerkung (Ancillarity einer Statistik)

Eine Statistik $\mathbf{V}(\mathbf{X})$ heißt *ancillary* („Hilfsstatistik“, „ankillar“) für \mathcal{P} , wenn ihre Verteilung nicht von θ abhängt (also bekannt ist).

Häufiger Sachverhalt: $\mathbf{T} = (\mathbf{U}, \mathbf{V})$ ist suffizient für θ , \mathbf{V} ancillary, \mathbf{U} nicht suffizient.

2.1 Klassische Schätztheorie

2.1.1 Suffizienz

Beispiel 2.9 (Ancillary Statistik)

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

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

$$\begin{aligned}U &= \frac{1}{2}(X_{(1)} + X_{(n)}) \\V &= X_{(n)} - X_{(1)}\end{aligned}$$

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

2.1 Klassische Schätztheorie

2.1.2 Erwartungstreue, Varianz und MSE

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

$$\begin{aligned}L(\hat{\theta}, \theta) &= |\hat{\theta} - \theta| && \text{Abstand } (\theta \text{ skalar}), \\L(\hat{\theta}, \theta) &= \|\hat{\theta} - \theta\|^2 && \text{quadratischer Fehler,} \\L(\hat{\theta}, \theta) &= \frac{\|\hat{\theta} - \theta\|^2}{\|\theta\|^2} && \text{relativer quadratischer Fehler,} \\L(\hat{\theta}, \theta) &= (\hat{\theta} - \theta)^\top \mathbf{D}(\hat{\theta} - \theta) && \text{gewichteter quadratischer Fehler} \\ &&& (\mathbf{D} \text{ positiv definit}).\end{aligned}$$

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

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 Θ der MSE des einen, für andere Teilbereiche der MSE des zweiten Schätzers kleiner sein:

Beispiel 2.10 (siehe Übung 2, Aufgabe 3)

$X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \text{Bin}(1, \pi)$.

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 $p(\pi) \sim \text{Be}(a, b)$:

$$\hat{\pi}_B = \frac{n\bar{X} + a}{a + b + n},$$


$$\text{MSE}(\hat{\pi}_B) = \frac{n\pi(1 - \pi) + (a - (a + b)\pi)^2}{(a + b + n)^2}.$$

Für $a = b = \sqrt{n}/2$ ergibt sich

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

2.1 Klassische Schätztheorie

2.1.2 Erwartungstreue, Varianz und MSE



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 θ 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 θ und $\text{MSE}_{\theta}(\tilde{\theta}) < \text{MSE}_{\theta}(\hat{\theta})$ für mindestens ein θ , 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 $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k) \in \mathbb{R}^k, k > 1$)

Üblich sind die folgenden zwei Alternativen:

1. *MSE (skalar):*

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

2. *MSE-Matrix:*

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

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 $(m \times m)$ -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 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$.

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

- ▶ μ und σ^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

- ▶ μ und σ^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 σ^2 bekannt. Es sollen simultan die Erwartungswerte μ_1, \dots, μ_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:

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

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 (James-)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: \mathbf{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)

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

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

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

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 π 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, äquivariante 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} mit Dichte $f(\mathbf{x}|\theta) = f(x_1, \dots, x_n|\theta)$, $\theta \in \Theta$, heißt Fisher-regulär, wenn Folgendes gilt:

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

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Definition 2.15 (Log-Likelihood, Scorefunktion und Information)

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

$\mathbf{s}(\boldsymbol{\theta}|\mathbf{x}) = \frac{\partial}{\partial \boldsymbol{\theta}} \ell(\boldsymbol{\theta}|\mathbf{x}) = \left(\frac{\partial}{\partial \theta_1} \ell(\boldsymbol{\theta}|\mathbf{x}), \dots, \frac{\partial}{\partial \theta_k} \ell(\boldsymbol{\theta}|\mathbf{x}) \right)^\top$
(Score-Funktion)

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

$\mathcal{I}(\boldsymbol{\theta}) = \mathbb{E}_\theta[\mathbf{J}(\boldsymbol{\theta}|\mathbf{X})]$ (erwartete oder Fisher-Informationsmatrix)

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Satz 2.16

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

1. $\mathbb{E}_\theta [\mathbf{s}(\boldsymbol{\theta}|\mathbf{X})] = \mathbf{0}$
2. $\text{Cov}_\theta[\mathbf{s}(\boldsymbol{\theta}|\mathbf{X})] = \mathcal{I}(\boldsymbol{\theta})$.

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Beweis

Zu 1.:

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

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Zu 2.:

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

unter Verwendung der Quotientenregel der Differentiation. Dies ist

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

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.

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



2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Weitere Eigenschaften:

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

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

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

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

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Weitere Eigenschaften (fortgeführt):

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

$$\mathcal{I}(\boldsymbol{\theta}) = \mathbb{E}_{\boldsymbol{\theta}}[\mathbf{J}(\boldsymbol{\theta}|\mathbf{X})] = n \cdot \mathbf{i}(\boldsymbol{\theta}),$$

wobei

$$\mathbf{i}(\boldsymbol{\theta}) = \mathbb{E}_{\boldsymbol{\theta}} \left[-\frac{\partial^2 \ell_1(\boldsymbol{\theta}|X_1)}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right] = \text{Cov}_{\boldsymbol{\theta}} \left(\frac{\partial \log f_1(X_1|\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right)$$

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

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

2.1 Klassische Schätztheorie

2.1.3 Fisher-Information und Suffizienz

Satz 2.17 (Suffizienz und Fisher-Information)

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

1. $\mathcal{I}_{\mathbf{T}}(\theta) \leq \mathcal{I}(\theta)$.
2. $\mathcal{I}_{\mathbf{T}}(\theta) = \mathcal{I}(\theta) \Leftrightarrow \mathbf{T}$ ist suffizient für θ .

Also: Bei einer suffizienten Statistik \mathbf{T} wird keine (erwartete) Information „verschenkt“.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

- ▶ „Schöne“ Resultate für finites n , aber für vergleichsweise einfache statistische Modelle.
- ▶ Problem: Für komplexere Modelle existieren keine „vernünftigen“ erwartungstreuen Schätzer.
- ▶ Aber: Etliche Resultate lassen sich übertragen auf asymptotische Betrachtungen für $n \rightarrow \infty$.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Informationsungleichungen

1. $\theta \in \mathbb{R}$ (skalar). Neben θ werden auch transformierte Parameter $\tau(\theta)$ betrachtet. Wenn Ableitungen benötigt werden, nehmen wir stillschweigend an, dass sie existieren.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Satz 2.18

Sei $f(\mathbf{x}|\theta)$ Fisher-regulär.

1. Ist $\hat{\theta}$ erwartungstreu für θ , so gilt:

$$\text{Var}_{\theta}(\hat{\theta}) \geq \frac{1}{\mathcal{I}(\theta)} \quad (\text{Cramer-Rao-Ungleichung}).$$

2. Ist $T = T(\mathbf{X})$ erwartungstreu für $\tau(\theta)$, so gilt:

$$\text{Var}_{\theta}(T) \geq \frac{(\tau'(\theta))^2}{\mathcal{I}(\theta)}.$$

$\frac{(\tau'(\theta))^2}{\mathcal{I}(\theta)}$ heißt Cramer-Rao-Schranke.

3. Besitzt $\hat{\theta}$ den Bias $B(\theta) = \mathbb{E}_{\theta}[\hat{\theta}] - \theta$, so gilt

$$\text{MSE}_{\theta}(\hat{\theta}) \geq B^2(\theta) + \frac{(1 + B'(\theta))^2}{\mathcal{I}(\theta)}.$$

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beweis.

Gezeigt wird 2. Daraus folgt 1. für $\tau(\theta) = \theta$ und 3. für $\tau(\theta) = \theta + B(\theta)$.

Differentiation von

$$\tau(\theta) = \mathbb{E}_\theta[T] = \int T(\mathbf{x})f(\mathbf{x}|\theta) d\mathbf{x}$$

bezüglich θ , und Verwendung der Fisher-Regularität liefert:

$$\begin{aligned}\tau'(\theta) &= \int T(\mathbf{x}) \frac{d}{d\theta} f(\mathbf{x}|\theta) d\mathbf{x} \\ &= \int T(\mathbf{x}) s(\theta|\mathbf{x}) f(\mathbf{x}|\theta) d\mathbf{x} \\ &= \text{Cov}_\theta(T(\mathbf{X}), s(\theta|\mathbf{X})).\end{aligned}$$

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beweis fortgeführt.

Unter Verwendung der Cauchy-Schwarz-Ungleichung

$$|\text{Cov}(U, V)| \leq \sqrt{\text{Var}(U)}\sqrt{\text{Var}(V)}$$

folgt

$$\begin{aligned}(\tau'(\theta))^2 &\leq \text{Var}_\theta(T(\mathbf{X}))\text{Var}_\theta(s(\theta|\mathbf{X})) \\ &= \text{Var}_\theta(T(\mathbf{X}))\mathcal{I}(\theta).\end{aligned}$$

Also:

$$\text{Var}_\theta(T(\mathbf{X})) \geq \frac{(\tau'(\theta))^2}{\mathcal{I}(\theta)}.$$



2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Bemerkung.

Die Gleichheit wird genau dann angenommen, wenn eine einparametrische Exponentialfamilie

$f(\mathbf{x}|\theta) = h(\mathbf{x}) \exp(b(\theta) + \gamma(\theta)T(\mathbf{x}))$ vorliegt. In diesem Fall ist $T(\mathbf{x})$ ein effizienter Schätzer für seinen Erwartungswert $\tau(\theta) = -b'(\theta)/\gamma'(\theta)$. Also: eher eine kleine Modellklasse.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

II. **Informationsungleichungen** für θ bzw. $\tau(\theta)$ mehrdimensional.

Satz 2.19

Sei $f(\mathbf{x}|\theta)$ Fisher-regulär.

1. Ist $\hat{\theta}$ erwartungstreu für $\theta = (\theta_1, \dots, \theta_k)$, so gilt:

$$\text{Cov}_{\theta}(\hat{\theta}) \geq \mathcal{I}^{-1}(\theta),$$

wobei sich „ \geq “ auf die Löwner-Ordnung bezieht (vgl. F. 117).

Daraus folgt insbesondere $\text{Var}_{\theta}(\hat{\theta}_j) \geq f_{jj}$, $j = 1, \dots, k$, wobei f_{jj} das j -te Diagonalelement von $\mathcal{I}^{-1}(\theta)$ bezeichnet.

2. Ist \mathbf{T} erwartungstreu für $\tau(\theta)$, so gilt

$$\text{Cov}_{\theta}(\mathbf{T}) \geq \mathbf{H}(\theta)\mathcal{I}^{-1}(\theta)\mathbf{H}(\theta)^{\top}$$

mit der Funktionalmatrix $(\mathbf{H}(\theta))_{ij} = \frac{\partial}{\partial \theta_j} \tau_i(\theta)$. Die Matrix $\mathbf{H}(\theta)\mathcal{I}^{-1}(\theta)\mathbf{H}(\theta)^{\top}$ ist die Cramer-Rao-Schranke.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Bemerkung. Obige Bemerkung für skalares θ gilt analog für

$$f(\mathbf{x}|\boldsymbol{\theta}) = h(\mathbf{x}) \exp(b(\boldsymbol{\theta}) + \boldsymbol{\gamma}^\top(\boldsymbol{\theta})\mathbf{T}(\mathbf{x})),$$

d.h. für mehrparametrische Exponentialfamilien.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beispiel 2.14 (Cramer-Rao-Schranke bei $X \sim N(\mu, \sigma^2)$)

X_1, \dots, X_n i.i.d. wie $X \sim N(\mu, \sigma^2)$, $\theta = (\mu, \sigma^2)$. Dann gilt für die Informationsmatrix

$$\mathcal{I}(\theta) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix} \quad \text{bzw.} \quad \mathcal{I}^{-1}(\theta) = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}.$$

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beste erwartungstreue Schätzer

Erwartungstreue Schätzer minimaler Varianz innerhalb einer vorgegebenen Klasse nennt man *effizient*. Die Informationsungleichungen motivieren:

Definition 2.20 (Gleichmäßig bester erwartungstreuer (UMVU) Schätzer)

1. θ skalar:

Der Schätzer $\hat{\theta}_{\text{eff}}$ für θ heißt *gleichmäßig bester erwartungstreuer oder UMVU („uniformly minimum variance unbiased“)-Schätzer* $\stackrel{\text{def}}{\Leftrightarrow}$ $\hat{\theta}_{\text{eff}}$ ist erwartungstreu, und es gilt $\text{Var}_{\theta}(\hat{\theta}_{\text{eff}}) \leq \text{Var}_{\theta}(\hat{\theta})$ für alle θ und jeden erwartungstreuen Schätzer $\hat{\theta}$.

2. θ mehrdimensional:

Ersetze $\text{Var}_{\theta}(\hat{\theta}_{\text{eff}}) \leq \text{Var}_{\theta}(\hat{\theta})$ durch $\text{Cov}_{\theta}(\hat{\theta}_{\text{eff}}) \leq \text{Cov}_{\theta}(\hat{\theta})$.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Satz 2.21 (Effizienz und Informationsungleichungen)

Sei $f(\mathbf{x}|\boldsymbol{\theta})$ Fisher-regulär und $\hat{\boldsymbol{\theta}}$ erwartungstreu für $\boldsymbol{\theta}$. Falls $\text{Cov}_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) = \mathcal{I}^{-1}(\boldsymbol{\theta})$ für alle $\boldsymbol{\theta}$, so ist $\hat{\boldsymbol{\theta}}$ ein UMVU-Schätzer.

Beweis. Die Aussage folgt direkt aus der Informationsungleichung und obiger Definition. \square

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beispiel 2.15 (Gauß-Experiment)

Seien $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ mit μ, σ^2 unbekannt.

Aus Beispiel 2.14 wissen wir, dass $\mathcal{I}(\mu) = n/\sigma^2$ und somit $\mathcal{I}^{-1}(\mu) = \sigma^2/n = \text{Var}(\bar{X})$. Dann ist \bar{X} UMVU für μ .

Aber

$$\text{Var}(S^2) = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n} = \mathcal{I}^{-1}(\sigma^2).$$

Die Cramer-Rao-Schranke wird also nicht erreicht, somit kann nicht gefolgert werden, dass S^2 UMVU für σ^2 ist.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beispiel 2.16 (Lineares Modell)

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n) \quad \text{bzw.} \quad \mathbf{y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$$

$$\hat{\boldsymbol{\beta}}_{\text{KQ}} = \hat{\boldsymbol{\beta}}_{\text{ML}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y} \text{ ist effizient für } \boldsymbol{\beta},$$

$$\hat{\sigma}^2 = \frac{1}{n-p} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \text{ ist UMVU-Schätzer für } \sigma^2.$$

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Bemerkung. Zu unterscheiden sind folgende Situationen:

1. Es existiert ein UMVU-Schätzer, dessen Varianz gleich der Cramer-Rao-Schranke ist.
2. Es existiert ein UMVU-Schätzer, dessen Varianz größer als die Cramer-Rao-Schranke ist (findet man mit dem Satz von Lehmann-Scheffé, siehe Satz 2.23).
3. Der häufigste Fall: Es existiert (für finiten Stichprobenumfang) kein UMVU-Schätzer.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Fazit: Finite Theorie erwartungstreuer Schätzer ist von eingeschränkter Anwendungsrelevanz.

Aber: Es existiert eine analoge asymptotische Theorie mit breiter Anwendungsrelevanz, die sich an finiter Theorie orientiert (siehe Abschnitt 2.1.5).

Zur Konstruktion von UMVU-Schätzern sind folgende zwei Aussagen nützlich:

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Satz 2.22 (Rao-Blackwell)

Sei $\mathbf{T} = \mathbf{T}(\mathbf{X})$ suffizient für θ bzw. \mathcal{P} und $\hat{\theta}$ erwartungstreu für θ .
Für den Schätzer

$$\hat{\theta}_{RB} = \mathbb{E}_{\theta}[\hat{\theta} | \mathbf{T}] \quad (\text{„Rao-Blackwellization“})$$

gilt:

1. $\hat{\theta}_{RB}$ ist erwartungstreu für θ .
2. $\text{Cov}_{\theta}(\hat{\theta}_{RB}) \leq \text{Cov}_{\theta}(\hat{\theta})$.
3. In 2. gilt die Gleichheit, wenn $\hat{\theta}$ nur von \mathbf{T} abhängt, d.h. $\hat{\theta}_{RB} = \hat{\theta}$ mit Wahrscheinlichkeit 1.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Satz 2.23 (Lehmann-Scheffé)

Ist $\mathbf{T} = \mathbf{T}(\mathbf{X})$ suffizient und vollständig (also minimal suffizient) und $\hat{\theta} = \hat{\theta}(\mathbf{x})$ ein erwartungstreuer Schätzer, so ist

$$\hat{\theta}^* = \mathbb{E}_{\theta}[\hat{\theta} | \mathbf{T}]$$

der mit Wahrscheinlichkeit 1 eindeutig bestimmte UMVU-Schätzer für θ .

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beispiele Satz von Lehmann-Scheffé

- ▶ Normalverteilung: Seien $X_1, \dots, X_n \stackrel{iid}{\sim} N(\mu, \sigma^2)$. $\theta = (\mu, \sigma^2)$. $\mathbf{T} = (\sum X_i, \sum X_i^2)$ ist suffizient und vollständig. Äquivalent ist $\tilde{\mathbf{T}} = (\bar{X}, S^2)$ suffizient und vollständig. Damit gilt:
 - ▶ \bar{X} als Schätzer für μ ist UMVU.
 - ▶ S^2 als Schätzer für σ^2 ist UMVU, auch wenn die Cramer-Rao-Schranke nicht angenommen wird.
 - ▶ $\frac{\bar{X}}{S^2}$ als Schätzer für $\mathbb{E}(\frac{\bar{X}}{S^2})$ is UMVU.
- ▶ In Beispiel 2.16 (lineares Modell) ist $\hat{\sigma}^2$ erwartungstreu für σ^2 . Außerdem lässt sich ebenfalls zeigen, dass $\hat{\sigma}^2$ eine Funktion einer vollständigen suffizienten Statistik ist. Damit ist $\hat{\sigma}^2$ UMVU-Schätzer für σ^2 .

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Wichtige Schätzer (Momentenschätzer, Shrinkage-Schätzer, ML- und Quasi-ML-Schätzer etc.) sind im Allgemeinen nicht erwartungstreu, besitzen aber günstige asymptotische ($n \rightarrow \infty$) Eigenschaften.

Im Folgenden sei

$$\hat{\theta}_n = \hat{\theta}(X_1, \dots, X_n)$$

Schätzer für θ .

Definition 2.24 (Asymptotische Erwartungstreue)

$\hat{\theta}_n$ heißt asymptotisch erwartungstreu $\stackrel{\text{def}}{\Leftrightarrow}$

$$\lim_{n \rightarrow \infty} \mathbb{E}_{\theta}[\hat{\theta}_n] = \theta \quad \text{für alle } \theta.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Definition 2.25 (Konsistenz)

1. $\hat{\theta}_n$ ist (schwach) konsistent für θ (in Zeichen: $\hat{\theta}_n \xrightarrow{\mathbb{P}} \theta$ (für alle θ)) $\stackrel{\text{def}}{\Leftrightarrow}$

$$\lim_{n \rightarrow \infty} \mathbb{P}_{\theta}(\|\hat{\theta}_n - \theta\| \leq \varepsilon) = 1 \quad \text{für alle } \varepsilon > 0 \text{ und alle } \theta.$$

2. $\hat{\theta}_n$ heißt MSE-konsistent für θ $\stackrel{\text{def}}{\Leftrightarrow}$

$$\lim_{n \rightarrow \infty} \text{MSE}_{\theta}(\hat{\theta}_n) = 0 \quad \text{für alle } \theta.$$

3. $\hat{\theta}_n$ ist stark konsistent für θ $\stackrel{\text{def}}{\Leftrightarrow}$

$$\mathbb{P}_{\theta} \left(\lim_{n \rightarrow \infty} \hat{\theta}_n = \theta \right) = 1 \quad \text{für alle } \theta.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Bemerkung.

1. Aus der (verallgemeinerten) Tschebyscheff-Ungleichung folgt

$$\hat{\theta}_n \text{ MSE-konsistent} \Rightarrow \hat{\theta}_n \text{ schwach konsistent.}$$

2. Wegen $\text{MSE}_\theta(\hat{\theta}_n) = \text{Var}_\theta(\hat{\theta}_n) + (\text{Bias}_\theta(\hat{\theta}_n))^2$ folgt:

$$\hat{\theta}_n \text{ ist MSE-konsistent}$$

$$\Leftrightarrow \text{Var}_\theta(\hat{\theta}_n) \rightarrow 0 \text{ und } \text{Bias}_\theta(\hat{\theta}_n) \rightarrow 0 \text{ f\u00fcr alle } \theta$$

(bzw. komponentenweise f\u00fcr Vektoren θ).

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Bemerkung fortgeführt.

3. Ist $\hat{\theta}_n$ konsistent für θ und g eine stetige Abbildung, so ist auch $g(\hat{\theta}_n)$ konsistent für $g(\theta)$ (Continuous Mapping Theorem/Stetigkeitssatz).
4. Konsistenznachweise bestehen in der Regel in der Anwendung (schwacher) Gesetze großer Zahlen (für i.i.d. Variablen; i.n.i.d. Variablen; abhängige Variablen, z.B. Martingale, Markov-Prozesse, ...).

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.17

1. $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ ist wegen $\mathbb{E}(\bar{X}_n) = \mu$ und $\text{Var}(\bar{X}_n) = \frac{\sigma^2}{n} \rightarrow 0$ für $n \rightarrow \infty$ (MSE-)konsistent.
2. $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ und $\tilde{S}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ sind (MSE-)konsistent für σ^2 .
3. Mit $g(x) = \sqrt{x}$ folgt, dass

$$S_n = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2} \quad \text{und} \quad \tilde{S}_n = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2}$$

konsistent sind für σ .

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.17 fortgeführt

4. S_n^2/\bar{X}_n ist konsistent für σ^2/μ für $\mu > 0$, da mit $\boldsymbol{\theta} = (\mu, \sigma)$ und $g(\boldsymbol{\theta}) = \sigma^2/\mu$ wieder der Stetigkeitssatz benutzt werden kann.
5. $\hat{\pi}_n$ ist konsistent für π (im Bernoulli-Experiment).
6. $\hat{\boldsymbol{\beta}}_{KQ}, \hat{\boldsymbol{\beta}}_{Ridge}$ sind konsistent für $\boldsymbol{\beta}$ im linearen Modell unter gewissen schwachen Annahmen an \mathbf{X} , siehe Beispiel 2.19.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Asymptotische Normalität

Viele Schätzer (KQ-, Momenten-, ML-, Quasi-ML-, Bayes-Schätzer) sind unter Regularitätsannahmen asymptotisch normalverteilt. Informell ausgedrückt heißt das: Für große n ist $\hat{\theta}_n$ nicht nur approximativ erwartungstreu, sondern zusätzlich approximativ normalverteilt, kurz

$$\hat{\theta}_n \stackrel{a}{\sim} N_k(\theta, \mathbf{V}(\theta))$$

mit (approximativer) Kovarianzmatrix

$$\text{Cov}_\theta(\hat{\theta}_n) \stackrel{a}{\sim} \mathbf{V}(\theta),$$

die durch

$$\widehat{\text{Cov}}_\theta(\hat{\theta}_n) := \mathbf{V}(\hat{\theta}_n)$$

geschätzt wird.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

In der Diagonalen von $\mathbf{V}(\hat{\boldsymbol{\theta}}_n)$ stehen dann die (geschätzten) Varianzen

$$\widehat{\text{Var}}(\hat{\theta}_j) = v_{jj}(\hat{\boldsymbol{\theta}}_n)$$

der Komponenten $\hat{\theta}_j, j = 1, \dots, k$, von $\hat{\boldsymbol{\theta}}_n$.

⇒ "Üblicher" Output statistischer Software ist

$$\underbrace{\hat{\theta}_j}_{\text{Schätzer}} \quad \underbrace{\sqrt{v_{jj}(\hat{\boldsymbol{\theta}}_n)}}_{\text{Standardfehler}} \quad \underbrace{t}_{\text{t-Statistik}} \quad \underbrace{p}_{\text{p-Wert}}$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.18.

Seien $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} F(x|\theta)$ mit $\mathbb{E}(X_i) = \mu$ und $\text{Var}(X_i) = \sigma^2$.
Aber F sei *nicht* gleich Φ (Normalverteilung), sondern z.B. die Verteilungsfunktion von $B(\pi) = \text{Bin}(1, \pi)$ oder $Po(\lambda)$. Für \bar{X}_n gilt

$$\mathbb{E}(\bar{X}_n) = \mu \text{ und } \text{Var}(\bar{X}_n) = \frac{\sigma^2}{n}.$$

Aufgrund des zentralen Grenzwertsatzes folgt

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

zum Beispiel

$$\bar{X}_n \stackrel{a}{\sim} N\left(\pi, \frac{\pi(1-\pi)}{n}\right) \text{ bei } B(\pi).$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.18 fortgeführt.

Genauere Formulierung:

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \sigma^2) \quad \text{für } n \rightarrow \infty,$$

im Beispiel also

$$\sqrt{n}(\bar{X}_n - \pi) \xrightarrow{d} N(0, \pi(1 - \pi)) \quad \text{für } n \rightarrow \infty$$

bzw.

$$\left. \begin{array}{l} \frac{\bar{X}_n - \mu}{\sigma} \sqrt{n} \xrightarrow{d} N(0, 1), \\ \frac{\bar{X}_n - \pi}{\sqrt{\pi(1 - \pi)}} \sqrt{n} \xrightarrow{d} N(0, 1). \end{array} \right\} \text{zentraler Grenzwertsatz}$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Die \sqrt{n} -Normierung ist vor allem bei i.i.d. Stichprobenvariablen geeignet.

Für nicht identisch verteilte Stichprobenvariablen wie zum Beispiel $y_1|\mathbf{x}_1, \dots, y_n|\mathbf{x}_n$ in Regressionssituationen benötigt man bei \sqrt{n} -Normierung Voraussetzungen, die (teilweise) unnötig restriktiv sind.

Besser ist dann eine „Matrix-Normierung“ mit Hilfe einer „Wurzel“ $\mathcal{I}^{\frac{1}{2}}(\boldsymbol{\theta})$ der Informationsmatrix.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Einschub: Wurzel einer positiv definiten Matrix

- ▶ $\mathbf{A} \in \mathbb{R}^{m \times m}$ ist positiv definit, wenn \mathbf{A} symmetrisch ist und $\mathbf{x}^\top \mathbf{A} \mathbf{x} > 0$ für alle $\mathbf{x} \neq \mathbf{0}$ gilt.
- ▶ Dann heißt eine Matrix $\mathbf{A}^{\frac{1}{2}}$ (*linke*) Wurzel von \mathbf{A} $\stackrel{\text{def}}{\Leftrightarrow}$

$$\mathbf{A}^{\frac{1}{2}} \underbrace{(\mathbf{A}^{\frac{1}{2}})^\top}_{=\mathbf{A}^{\frac{1}{2}\top}, \text{ rechte Wurzel}} = \mathbf{A}.$$

Allerdings ist $\mathbf{A}^{\frac{1}{2}}$ nicht eindeutig, da für eine beliebige orthogonale Matrix \mathbf{Q} auch $\mathbf{A}^{\frac{1}{2}}\mathbf{Q}$ eine linke Wurzel ist:

$$\mathbf{A}^{\frac{1}{2}}\mathbf{Q}(\mathbf{A}^{\frac{1}{2}}\mathbf{Q})^\top = \mathbf{A}^{\frac{1}{2}} \underbrace{\mathbf{Q}\mathbf{Q}^\top}_{=\mathbf{I}_m} \mathbf{A}^{\frac{1}{2}} = \mathbf{A}.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

► Zwei gebräuchliche Wurzeln sind:

1. **Symmetrische Wurzel:** Betrachte die Spektralzerlegung von $\mathbf{A} \in \mathbb{R}^{m \times m}$. Mit der Matrix $\mathbf{P} \in \mathbb{R}^{m \times m}$ der orthonormalen Eigenvektoren als Spalten ist

$$\mathbf{P}^\top \mathbf{A} \mathbf{P} = \mathbf{\Lambda} = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_m \end{pmatrix},$$

wobei für alle i die $\lambda_i > 0$ die Eigenwerte von \mathbf{A} sind.
(Diese Zerlegung ist numerisch aufwändig!) Dann gilt auch

$$\mathbf{A} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^\top = \underbrace{\mathbf{P} \mathbf{\Lambda}^{\frac{1}{2}}}_{=\mathbf{A}^{\frac{1}{2}}} \underbrace{(\mathbf{\Lambda}^{\frac{1}{2}})^\top \mathbf{P}^\top}_{=\mathbf{A}^{\frac{1}{2}}},$$

und $\mathbf{A}^{\frac{1}{2}}$ heißt *symmetrische Wurzel von \mathbf{A}* .

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

- Cholesky-Wurzel:** Sei $\mathbf{A}^{\frac{1}{2}} := \mathbf{C}$ untere Dreiecksmatrix mit positiven Diagonalelementen und $\mathbf{C}\mathbf{C}^{\top} = \mathbf{A}$. Dann ist \mathbf{C} die *eindeutig* bestimmte *Cholesky-Wurzel* von \mathbf{A} .
(Diese ist numerisch vergleichsweise einfach zu erhalten!)

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

► Anwendungen in der Statistik

1. Erzeugen von $N_m(\mathbf{0}, \Sigma)$ -verteilten Zufallszahlen (Σ vorgegeben): Falls $\mathbf{Z} \sim N_m(\mathbf{0}, \mathbf{I}_m)$, ist einfache Simulation möglich, indem m unabhängige $N(0, 1)$ -verteilte Zufallsvariablen Z_1, \dots, Z_m simuliert werden. Dann gilt auch

$$\Sigma^{1/2} \mathbf{Z} \sim N_m(\mathbf{0}, \underbrace{\Sigma^{1/2} \mathbf{I}_m \Sigma^{\top/2}}_{\Sigma}).$$

Also: Berechne Cholesky-Wurzel von Σ , ziehe m $N(0, 1)$ -verteilte Zufallsvariablen

$\mathbf{Z} = (Z_1, \dots, Z_m)^{\top}$, berechne $\mathbf{Y} = \Sigma^{1/2} \mathbf{Z}$. Dann ist $\mathbf{Y} = (Y_1, \dots, Y_m)^{\top}$ ein $N_m(\mathbf{0}, \Sigma)$ -verteilter Zufallsvektor.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

2. Matrixnormierung bei asymptotischer Normalverteilung:

Beispiel 2.19 (Asymptotische Normalität des KQ-Schätzers im linearen Modell)

Seien $y_1|\mathbf{x}_1, \dots, y_n|\mathbf{x}_n$ unabhängig. Dann gilt

$$\mathbb{E}[y_i|\mathbf{x}_i] = \mathbf{x}_i^\top \boldsymbol{\beta}, \quad \text{Var}(y_i|\mathbf{x}_i) = \sigma^2, \quad i = 1, \dots, n,$$

$$\Leftrightarrow \mathbf{y}_n = \mathbf{X}_n \boldsymbol{\beta} + \boldsymbol{\varepsilon}_n, \quad \mathbb{E}[\boldsymbol{\varepsilon}_n] = \mathbf{0}, \quad \text{Cov}(\boldsymbol{\varepsilon}_n) = \sigma^2 \mathbf{I}_n,$$

wobei hier \mathbf{X}_n die Design-Matrix mit Zeilen $\mathbf{x}_1, \dots, \mathbf{x}_n$ bezeichnet. Der KQ-Schätzer ist

$$\hat{\boldsymbol{\beta}}_n = (\mathbf{X}_n^\top \mathbf{X}_n)^{-1} \mathbf{X}_n^\top \mathbf{y}_n, \quad \mathbb{E}[\hat{\boldsymbol{\beta}}_n] = \boldsymbol{\beta}, \quad \text{Cov}(\hat{\boldsymbol{\beta}}_n) = \sigma^2 (\mathbf{X}_n^\top \mathbf{X}_n)^{-1}.$$

Die Informationsmatrix unter der Normalverteilungsannahme ist

$$\mathcal{I}(\boldsymbol{\beta}) = \frac{\mathbf{X}_n^\top \mathbf{X}_n}{\sigma^2} = \text{Cov}(\hat{\boldsymbol{\beta}}_n)^{-1}.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

Zentrale Grenzwertsätze (für unabhängige, nicht identisch verteilte Zufallsvariablen, kurz: i.n.i.d.) liefern unter geeigneten Voraussetzungen (informell):

$$\hat{\beta}_n \stackrel{a}{\sim} N_p(\beta, \sigma^2(\mathbf{X}_n^\top \mathbf{X}_n)^{-1}).$$

Genauere Formulierungen nehmen an, dass

$$(p\text{-})\lim_{n \rightarrow \infty} \frac{1}{n} \mathbf{X}_n^\top \mathbf{X}_n =: \mathbf{A} > 0 \quad (1)$$

existiert (also: $\mathbf{X}_n^\top \mathbf{X}_n \approx n\mathbf{A} \Leftrightarrow (\mathbf{X}_n^\top \mathbf{X}_n)^{-1} \approx \mathbf{A}^{-1}/n$ für große n).

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

Anwendung des (multivariaten) zentralen Grenzwertsatzes liefert dann:

$$\sqrt{n}(\hat{\beta}_n - \beta) \xrightarrow{d} N_p(\mathbf{0}, \sigma^2 \mathbf{A}^{-1})$$

bzw.

$$\begin{aligned}\hat{\beta}_n &\stackrel{a}{\sim} N_p(\beta, \sigma^2 \mathbf{A}^{-1}/n) \\ \hat{\beta}_n &\stackrel{a}{\sim} N_p(\beta, \sigma^2 (\mathbf{X}_n^\top \mathbf{X}_n)^{-1}).\end{aligned}$$

Die Annahme (1) ist zum Beispiel erfüllt, wenn \mathbf{x}_i , $i = 1, \dots, n$, i.i.d. Realisierungen stochastischer Kovariablen $\mathbf{X} = (X_1, \dots, X_p)^\top$ sind.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

Dann gilt nach dem Gesetz der großen Zahlen:

$$\frac{1}{n} \mathbf{X}_n^\top \mathbf{X}_n = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top \xrightarrow[n \rightarrow \infty]{\mathbb{P}} \mathbb{E}[\mathbf{X}\mathbf{X}^\top] =: \mathbf{A}.$$

Typischerweise ist die Annahme (1) *nicht* erfüllt bei deterministischen Regressoren mit Trend. Das einfachste Beispiel hierfür ist ein linearer Trend: $x_i = i$ für $i = 1, \dots, n$ und $y_i = \beta_1 i + \varepsilon_i$. Dann ist

$$\mathbf{X}_n^\top \mathbf{X}_n = \sum_{i=1}^n i^2$$

und daher

$$\frac{1}{n} \mathbf{X}_n^\top \mathbf{X}_n = \frac{\sum_{i=1}^n i^2}{n} \geq n \xrightarrow{n \rightarrow \infty} \infty.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

In diesem Fall ist eine andere Normierung nötig, zum Beispiel eine Matrixnormierung mit

$$\mathbf{C}_n = (\mathbf{X}_n^\top \mathbf{X}_n).$$

Dann lässt sich die asymptotische Normalität des KQ-Schätzers

$$\mathbf{C}_n^{1/2}(\hat{\beta}_n - \beta) \xrightarrow{d} N_p(\mathbf{0}, \sigma^2 \mathbf{I}_p)$$

bzw.

$$\tilde{\mathbf{C}}_n^{1/2}(\hat{\beta}_n - \beta) := \frac{\mathbf{C}_n^{1/2}}{\sigma}(\hat{\beta}_n - \beta) \xrightarrow{d} N_p(\mathbf{0}, \mathbf{I}_p)$$

unter folgenden, sehr schwachen Bedingungen zeigen:

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

(D) Divergenzbedingung: Für $n \rightarrow \infty$ gilt:

$$(\mathbf{X}_n^\top \mathbf{X}_n)^{-1} \xrightarrow{(\mathbb{P})} \mathbf{0}_{\mathbf{p} \times \mathbf{p}}.$$

Eine äquivalente Forderung ist:

$$\lambda_{\min}(\mathbf{X}_n^\top \mathbf{X}_n) \xrightarrow{(\mathbb{P})} \infty,$$

wobei λ_{\min} den kleinsten Eigenwert von $\mathbf{X}_n^\top \mathbf{X}_n$ bezeichnet.

Die Divergenzbedingung sichert, dass die „Informationsmatrix“

$$\mathbf{X}_n^\top \mathbf{X}_n = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top$$

für $n \rightarrow \infty$ gegen ∞ divergiert, die Information mit $n \rightarrow \infty$ also laufend wächst.

Es gilt: (D) ist hinreichend und notwendig für die (schwache und starke) Konsistenz des KQ-Schätzers $\hat{\beta}_n$.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

(N) Normalitätsbedingung:

$$\max_{i=1, \dots, n} \mathbf{x}_i^\top (\mathbf{X}_n^\top \mathbf{X}_n)^{-1} \mathbf{x}_i \xrightarrow{(\mathbb{P})} 0 \quad \text{für } n \rightarrow \infty.$$

(N) sichert, dass die Information jeder Beobachtung i asymptotisch gegenüber der Gesamtinformation $\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top$ vernachlässigbar ist.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.19 fortgeführt

Unter (D) und (N) gilt

$$(\mathbf{X}_n^\top \mathbf{X}_n)^{1/2}(\hat{\boldsymbol{\beta}}_n - \boldsymbol{\beta}) \xrightarrow{d} N_p(\mathbf{0}, \sigma^2 \mathbf{I}_p)$$

(Beweis mit Grenzwertsätzen für unabhängige, nicht identisch verteilte Zufallsvariablen), d.h. für praktische Zwecke:

$$\hat{\boldsymbol{\beta}}_n \overset{a}{\approx} N_p(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}_n^\top \mathbf{X}_n)^{-1})$$

für genügend großen Stichprobenumfang n . Dabei darf zusätzlich σ^2 durch einen konsistenten Schätzer $\hat{\sigma}^2$ ersetzt werden.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Definition 2.26 (Asymptotische Normalität)

$\hat{\theta}_n$ heißt *asymptotisch normalverteilt* für θ $\stackrel{\text{def}}{\Leftrightarrow}$ es existiert eine Folge von Matrizen \mathbf{A}_n mit $\lambda_{\min}(\mathbf{A}_n) \xrightarrow{(\text{P})} \infty$, so dass

$$\mathbf{A}_n^{1/2}(\hat{\theta}_n - \theta) \xrightarrow{d} N_k(\mathbf{0}, \mathbf{V}(\theta)) \quad \text{für } n \rightarrow \infty$$

mit nicht-negativ definiten (in der Regel positiv definiten) Matrix $\mathbf{V}(\theta)$.

Für den Spezialfall $\mathbf{A}_n = n\mathbf{I}_k$ entspricht dies der \sqrt{n} -Normierung

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N_k(\mathbf{0}, \mathbf{V}(\theta)) \quad \text{für } n \rightarrow \infty.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Bemerkung.

1. Praxisformulierung:

$$\hat{\boldsymbol{\theta}}_n \stackrel{a}{\sim} N_k(\boldsymbol{\theta}, \mathbf{V}(\boldsymbol{\theta})/n)$$

bzw.

$$\hat{\boldsymbol{\theta}}_n \stackrel{a}{\sim} N_k(\boldsymbol{\theta}, (\mathbf{A}_n^{1/2})^{-1} \mathbf{V}(\boldsymbol{\theta}) (\mathbf{A}_n^{1/2})^{-\top}).$$

Dabei darf $\boldsymbol{\theta}$ in $\mathbf{V}(\boldsymbol{\theta})$ durch $\hat{\boldsymbol{\theta}}_n$ ersetzt werden.

2. Oft: $\mathbf{V}(\boldsymbol{\theta}) = \mathbf{I}_k$ möglich, wenn geeignet normiert wird, zum Beispiel bei ML-Schätzung.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.20.

Seien X_1, \dots, X_n i.i.d. Zufallsvariablen mit (bekanntem) Erwartungswert μ und Varianz σ^2 .

$$S_{\mu}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

ist asymptotisch normalverteilt (für σ^2) mit $V(\sigma^2) = \mu_4 - \sigma^4$, $\mu_4 = \mathbb{E}[(X_i - \mu)^4] < \infty$. S_{μ}^2 ist erwartungstreu.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel 2.20 fortgeführt.

Für die Varianz erhält man:

$$\begin{aligned}\text{Var}(S_{\mu}^2) &= \text{Var}\left(\frac{1}{n}\sum_{i=1}^n(X_i - \mu)^2\right) \\ &= \frac{1}{n^2} \cdot n \cdot \text{Var}[(X_1 - \mu)^2] \\ &= \frac{1}{n}\left(\mathbb{E}[(X_1 - \mu)^4] - (\mathbb{E}[(X_1 - \mu)^2])^2\right) \\ &= \frac{1}{n}(\mu_4 - \sigma^4).\end{aligned}$$

Es liegen die Voraussetzungen zur Anwendung des zentralen Grenzwertsatzes vor. Aus ihm folgt:

$$S_{\mu}^2 \stackrel{a}{\sim} N(\sigma^2, (\mu_4 - \sigma^4)/n) \quad \text{bzw.} \quad \sqrt{n}(S_{\mu}^2 - \sigma^2) \xrightarrow{d} N(0, \mu_4 - \sigma^4).$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Die Delta-Methode

$\hat{\theta}_n$ sei asymptotisch normalverteilter Schätzer für θ .

Frage: Wie ist für eine gegebene Abbildung

$$\mathbf{h} : \mathbb{R}^k \rightarrow \mathbb{R}^r, r \leq k$$

der Schätzer $\mathbf{h}(\hat{\theta})$ für $\mathbf{h}(\theta)$ verteilt?

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Satz 2.27 (Delta-Methode)

Sei h wie oben.

1. θ skalar: Für alle θ , für die h stetig differenzierbar ist mit $h'(\theta) \neq 0$, gilt:

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, V(\theta))$$

$$\Rightarrow \sqrt{n}(h(\hat{\theta}_n) - h(\theta)) \xrightarrow{d} N(0, [h'(\theta)]^2 V(\theta))$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Satz 2.27 (fortgeführt)

2. $\boldsymbol{\theta}$ vektoriell: Sei \mathbf{h} gegeben durch

$$\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^\top \mapsto \mathbf{h}(\boldsymbol{\theta}) = (h_1(\boldsymbol{\theta}), \dots, h_r(\boldsymbol{\theta}))^\top$$

mit Funktionalmatrix

$$(\mathbf{H}(\boldsymbol{\theta}))_{ij} = \frac{\partial h_i(\boldsymbol{\theta})}{\partial \theta_j}$$

mit vollem Rang r . Für alle $\boldsymbol{\theta}$, für die $\mathbf{h}(\boldsymbol{\theta})$ komponentenweise stetig partiell differenzierbar ist und jede Zeile von $\mathbf{H}(\boldsymbol{\theta})$ ungleich dem Nullvektor ist, gilt:

$$\sqrt{n}(\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}) \xrightarrow{d} N_k(\mathbf{0}, \mathbf{V}(\boldsymbol{\theta}))$$

$$\Rightarrow \sqrt{n}(\mathbf{h}(\hat{\boldsymbol{\theta}}_n) - \mathbf{h}(\boldsymbol{\theta})) \xrightarrow{d} N_r(\mathbf{0}, \mathbf{H}(\boldsymbol{\theta})\mathbf{V}(\boldsymbol{\theta})\mathbf{H}(\boldsymbol{\theta})^\top).$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beweisskizze für skalares θ

Taylorentwicklung von $h(\hat{\theta}_n)$ um θ liefert:

$$h(\hat{\theta}_n) = h(\theta) + (\hat{\theta}_n - \theta)h'(\theta) + o(\hat{\theta}_n - \theta)^2.$$

Dabei ist für eine Folge von Zufallsvariablen Z_n

$$Z_n = o(a_n) \quad \text{falls } Z_n/a_n \xrightarrow{\mathbb{P}} 0 \text{ für } n \rightarrow \infty.$$

Also:

$$h(\hat{\theta}_n) \approx h(\theta) + (\hat{\theta}_n - \theta)h'(\theta)$$

bzw.

$$\sqrt{n}(h(\hat{\theta}_n) - h(\theta)) \approx \sqrt{n}(\hat{\theta}_n - \theta)h'(\theta)$$

Aus $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, V(\theta))$ folgt dann, dass

$$\sqrt{n}(h(\hat{\theta}_n) - h(\theta)) \xrightarrow{d} N(0, h'(\theta)^2 V(\theta)).$$



2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Beispiel Delta-Methode

Seien $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} B(\pi)$. Für den Schätzer $\hat{\pi} = \frac{1}{n} \sum_{i=1}^n X_i$ gilt:

$$\sqrt{n}(\hat{\pi} - \pi) \xrightarrow{d} N(0, \pi(1 - \pi))$$

(vgl. Bsp. 2.18). Betrachte nun die Odds $h(\pi) = \frac{\pi}{1-\pi}$ und den Schätzer $h(\hat{\pi}) = \frac{\hat{\pi}}{1-\hat{\pi}}$. Nach der Delta-Regel gilt dann

$$\sqrt{n} \left(\frac{\hat{\pi}}{1-\hat{\pi}} - \frac{\pi}{1-\pi} \right) \xrightarrow{d} N \left(0, \frac{\pi}{(1-\pi)^3} \right),$$

und daher $\frac{\hat{\pi}}{1-\hat{\pi}} \stackrel{a}{\sim} N \left(\frac{\pi}{1-\pi}, \frac{\pi}{n(1-\pi)^3} \right)$, da

$$[h'(\pi)]^2 \pi(1-\pi) = \left[\frac{1}{(1-\pi)^2} \right]^2 \pi(1-\pi) = \frac{\pi}{(1-\pi)^3}.$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Asymptotische Cramer-Rao Schranke und asymptotische Effizienz

Seien $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f(x|\boldsymbol{\theta})$ und

$$\mathbf{i}(\boldsymbol{\theta}) = -\mathbb{E} \left[\frac{\partial^2 \log f(x|\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^\top} \right]$$

die erwartete Fisher-Information einer Beobachtung X_j .

Die Information der gesamten Stichprobe X_1, \dots, X_n ist dann

$$\mathcal{I}(\boldsymbol{\theta}) = n \cdot \mathbf{i}(\boldsymbol{\theta}).$$

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Satz 2.28 (Asymptotische Cramer-Rao Ungleichung)

Unter Fisher-Regularität sowie leichten Zusatzannahmen gilt:

1. Aus $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N_k(\mathbf{0}, \mathbf{V}(\theta))$ folgt $\mathbf{V}(\theta) \geq \mathbf{i}^{-1}(\theta)$.
2. Aus $\sqrt{n}(\mathbf{h}(\hat{\theta}_n) - \mathbf{h}(\theta)) \xrightarrow{d} N_r(\mathbf{0}, \mathbf{D}(\theta))$ folgt

$$\mathbf{D}(\theta) \geq \mathbf{H}(\theta)\mathbf{i}^{-1}(\theta)\mathbf{H}(\theta)^\top$$

mit "≥" die Löwner-Ordnung (und den Bezeichnungen aus der Delta-Regel, Satz 2.27).

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Definition 2.29 (Bester asymptotisch normaler (BAN)-Schätzer)

$\hat{\theta}_n$ heißt BAN-Schätzer, falls in 1. oben gilt:

$$\mathbf{V}(\theta) = \mathbf{i}^{-1}(\theta).$$

Mit der Delta-Regel folgt unmittelbar:

Satz 2.30 (Transformation von BAN-Schätzern)

Ist $\hat{\theta}_n$ BAN-Schätzer für θ , so ist $\mathbf{h}(\hat{\theta}_n)$ BAN-Schätzer für $\mathbf{h}(\theta)$.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Bemerkung. Das Konzept der asymptotischen Effizienz lässt sich auf die Matrix-Normierung übertragen: $\hat{\theta}$ ist BAN-Schätzer für θ genau dann, wenn

$$\mathcal{I}^{1/2}(\theta)(\hat{\theta}_n - \theta) \xrightarrow{d} N_k(\mathbf{0}, \mathbf{I}_k)$$

bzw. $\hat{\theta}_n \stackrel{a}{\sim} N_k(\theta, \mathcal{I}^{-1}(\hat{\theta}_n))$, mit $\mathcal{I}^{1/2}(\theta)$ Wurzel der Fisher-Information $\mathcal{I}(\theta)$ der Stichprobe X_1, \dots, X_n . Anstelle der erwarteten kann auch die beobachtete Fisher-Information $\mathbf{J}(\theta)$ verwendet werden.