

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 besitzen allgemeine Eigenschaften für $n \rightarrow \infty$.

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Informationsungleichungen

- I. $\theta \in \mathbb{R}$ (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 $f(x|\theta)$ Fisher-regulär.

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

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

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

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

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

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

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

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

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

bezüglich θ , und Verwendung der Fisher-Regularität liefert:

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

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

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

Also:

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



2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Bemerkung.

Die Gleichheit wird genau dann angenommen, wenn eine einparametrische Exponentialfamilie

$f(x|\theta) = h(x) \exp(b(\theta) + \gamma(\theta)T(x))$ vorliegt. In diesem Fall ist $T(x)$ 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 $f(x|\theta)$ Fisher-regulär.

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

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

wobei sich „ \geq “ auf die Löwner-Ordnung bezieht (vgl. F. 121).

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

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

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

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

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Bemerkung. Obige Bemerkung für skalares θ gilt analog für

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

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

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

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

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

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 auf Folie 147 wissen wir, dass $I(\mu) = n/\sigma^2$ und somit $I^{-1}(\mu) = \sigma^2/n = \text{Var}(\bar{X})$. Dann ist \bar{X} UMVU für μ .

Aber

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

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)

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

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

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

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

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

gilt:

1. $\hat{\theta}_{RB}$ ist erwartungstreu für θ .
2. $\text{Var}_\theta(\hat{\theta}_{RB}) \leq \text{Var}_\theta(\hat{\theta})$.
3. In 2. gilt die Gleichheit, wenn $\hat{\theta}$ nur von 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 $T = T(X)$ suffizient und vollständig (also minimal suffizient) und $\hat{\theta} = \hat{\theta}(x)$ ein erwartungstreuer Schätzer, so ist

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

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

2.1 Klassische Schätztheorie

2.1.4 Erwartungstreue Schätzer

Beispiel Satz von Lehmann-Scheffé

In Beispiel 2.16 (lineares Modell) ist $\hat{\sigma}^2$ erwartungstreu für σ^2 .

Außerdem lässt sich 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:

$$\hat{\theta}_n \text{ ist MSE-konsistent} \Leftrightarrow \text{Var}_\theta(\hat{\theta}_n) \rightarrow 0 \text{ und}$$

$$\text{Bias}_\theta(\hat{\theta}_n) \rightarrow 0 \text{ für alle } \theta.$$

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 $n \rightarrow \infty$ 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 $\theta = (\mu, \sigma)$ und $g(\theta) = \sigma^2/\mu$ wieder der Stetigkeitssatz benutzt werden kann.
5. $\hat{\pi}_n$ ist konsistent für π (im Bernoulli-Experiment).
6. $\hat{\beta}_{KQ}, \hat{\beta}_{Ridge}$ sind konsistent für β 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

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

mit (approximativer) Kovarianzmatrix

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

die durch

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

geschätzt wird.

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

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

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

der Komponenten $\theta_j, j = 1, \dots, p$, von θ .

⇒ "Üblicher" Output statistischer Software ist

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

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 , sondern z.B. die Verteilungsfunktion von $B(\pi)$ 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 $y_1|x_1, \dots, y_n|x_n$ in Regressionssituationen benötigt man bei \sqrt{n} -Normierung Voraussetzungen, die (teilweise) unnötig restriktiv sind.

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

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Einschub: Wurzel einer positiv definiten Matrix

- ▶ \mathbf{A} 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:

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

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

► Zwei gebräuchliche Wurzeln sind:

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

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

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

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

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

$\mathbf{Z} = (z_1, \dots, z_p)^\top$, berechne $\mathbf{Y} = \Sigma^{1/2} \mathbf{Z}$. Dann ist $\mathbf{Y} = (Y_1, \dots, Y_p)^\top$ ein $N_p(\mathbf{0}, \Sigma)$ -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

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

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

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

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

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

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

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:

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

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:

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

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

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

bzw.

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

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:

$$(\mathbf{X}_n^\top \mathbf{X}_n)^{-1} \rightarrow \mathbf{0}.$$

Eine äquivalente Forderung ist:

$$\lambda_{\min}(\mathbf{X}_n^\top \mathbf{X}_n) \rightarrow \infty,$$

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:

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

(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

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

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

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

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 $\theta \stackrel{\text{def}}{\Leftrightarrow}$ es existiert eine Folge von Matrizen \mathbf{A}_n mit $\lambda_{\min}(\mathbf{A}_n) \rightarrow \infty$, so dass

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

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

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

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

2.1 Klassische Schätztheorie

2.1.5 Asymptotische Eigenschaften und Kriterien

Bemerkung.

1. Praxisformulierung:

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

bzw.

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

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

2. Oft: $V(\theta) = \mathbf{I}_k$ 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 normal für σ^2 mit $V(\theta) = \mu_4 - \sigma^4$,
 $\mu_4 = \mathbb{E}[(X_i - \mu)^4] < \infty$. 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

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

der Schätzer $h(\hat{\theta})$ für $h(\theta)$ 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 2.28 (fortgeführt)

2. θ vektoriell: Sei h gegeben durch

$$\theta = (\theta_1, \dots, \theta_p)^\top \mapsto h(\theta) = (h_1(\theta), \dots, h_k(\theta))^\top$$

mit Funktionalmatrix

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

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

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

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

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 X_n

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

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

Asymptotische Cramer-Rao Schranke und asymptotische Effizienz

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

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

die erwartete Fisher-Information einer Beobachtung X_j .

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

$$I(\theta) = n \cdot i(\theta).$$

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

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

mit " \geq " 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:

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

Mit der Delta-Regel folgt unmittelbar:

Satz 2.30 (Transformation von BAN-Schätzern)

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

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

$$I^{1/2}(\theta)(\hat{\theta}_n - \theta) \xrightarrow{d} N(0, I)$$

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