

Musterlösung zur Übung 4

$$\begin{aligned}
1. \quad \text{a)} \quad P[X_i = x_i] &= \binom{n}{x_i} p^{x_i} (1-p)^{n-x_i} \\
&= \binom{n}{x_i} e^{x_i \log(\frac{p}{1-p}) + n \log(1-p)} \quad (\text{exponentielle Familie}) \\
P[X_1 = x_1, \dots, X_r = x_r] &= \prod_{i=1}^r P[X_i = x_i] \\
&= e^{\sum_{i=1}^r x_i \log(\frac{p}{1-p}) + nr \log(1-p)} \cdot \prod_{i=1}^r \binom{n}{x_i}
\end{aligned}$$

Also ist $S = \sum X_i$ suffizient. Da S nichts anderes darstellt als die Anzahl defekter Stücke in einer Stichprobe des Umfangs $n \cdot r$, ist $S \sim \text{Bin}(nr, p)$.

$$\begin{aligned}
\text{b)} \quad \tilde{T} &= \mathbf{E}[T|S = s] = \mathbf{E}[I_{\{X_1 \leq 1\}}|S = s] = P[X_1 \leq 1|S = s] \\
&= \frac{P[X_1 \leq 1 \cap S = s]}{P[S = s]} \\
&= \frac{P[X_1 = 0] \cdot P[\sum_{i=2}^r X_i = s] + P[X_1 = 1] \cdot P[\sum_{i=2}^r X_i = s-1]}{P[S = s]} \\
&= \frac{(1-p)^n \cdot \binom{n(r-1)}{s} p^s (1-p)^{n(r-1)-s} + np(1-p)^{n-1} \cdot \binom{n(r-1)}{s-1} p^{s-1} (1-p)^{n(r-1)-s+1}}{\binom{nr}{s} p^s (1-p)^{nr-s}} \\
&= \frac{\binom{n(r-1)}{s} + n \binom{n(r-1)}{s-1}}{\binom{nr}{s}}
\end{aligned}$$

c) $T = I_{\{X_1 \leq 1\}}$ ist erwartungstreu für $P[X_1 \leq 1]$, da $\mathbf{E}[T] = \mathbf{E}[I_{\{X_1 \leq 1\}}] = P[X_1 \leq 1]$. Gemäss Satz 3.2 ist S vollständig, da $c(p) = \log(\frac{p}{1-p})$ eine offene "Kugel" in \mathbb{R} enthält.

Aus Korollar 3.1 (Lehmann-Scheffé) folgt, dass $\tilde{T} = \mathbf{E}[T|S]$ UMVU für $P[X_1 \leq 1]$ ist.

2. a) Durch Ableiten und Nullsetzen des Ausdrucks $(Y - X\beta)^\top (Y - X\beta)$ erhält man $(-2)X^\top (Y - X\beta) = 0$ beziehungsweise die p Normalgleichungen

$$X^\top X\beta = X^\top Y.$$

Die Behauptung folgt, da die $p \times p$ -Matrix $X^\top X$ regulär ist.

- b) Das Modell $y_i = \sum_{j=1}^p x_{ij}\beta_j + \varepsilon_i$, ε_i i.i.d. $\sim \mathcal{N}(0, \sigma^2)$ bedeutet nichts anderes als $Y \sim \mathcal{N}_n(X\beta, \Sigma)$ mit Kovarianzmatrix $\Sigma = \text{diag}(\sigma^2, \dots, \sigma^2)$. Die Dichte des Beobachtungsvektors ist also (nach Definition A.1)

$$p_\beta(Y) = (2\pi)^{-\frac{1}{2}}(\det \Sigma)^{-\frac{1}{2}} \exp\left(-\frac{1}{2}(Y - X\beta)^\top \Sigma^{-1}(Y - X\beta)\right).$$

Mit der Bezeichnung $\frac{\partial}{\partial \beta} = \left(\frac{\partial}{\partial \beta_1}, \dots, \frac{\partial}{\partial \beta_p}\right)^\top$ folgt

$$\frac{\partial}{\partial \beta} \log p_\beta(Y) = X^\top \Sigma^{-1}(Y - X\beta)$$

und

$$\begin{aligned} I(\beta) &= \mathbf{E}_\beta \left[\frac{\partial}{\partial \beta} \log p_\beta(Y) \left(\frac{\partial}{\partial \beta} \log p_\beta(Y) \right)^\top \right] \\ &= \mathbf{E}_\beta [X^\top \Sigma^{-1}(Y - X\beta) (X^\top \Sigma^{-1}(Y - X\beta))^\top] \\ &= \mathbf{E}_\beta [X^\top \Sigma^{-1}(Y - X\beta) (Y - X\beta)^\top \Sigma^{-1} X] \\ &= X^\top \Sigma^{-1} \underbrace{\mathbf{E}_\beta [(Y - X\beta) (Y - X\beta)^\top]}_{\Sigma} \Sigma^{-1} X \\ &= \Sigma^{-1} X^\top X. \end{aligned}$$

- c) $\hat{\beta}$ ist erwartungstreu wegen

$$\mathbf{E}_\beta[\hat{\beta}] = \mathbf{E}_\beta[(X^\top X)^{-1} X^\top Y] = (X^\top X)^{-1} X^\top \mathbf{E}_\beta[Y] = (X^\top X)^{-1} X^\top X \beta = \beta.$$

Ausserdem erreicht $\hat{\beta}$ die mehrdimensionale Cramér-Rao-Schranke:

$$\begin{aligned} \text{Var}_\beta(\hat{\beta}) &= \text{Var}_\beta((X^\top X)^{-1} X^\top Y) = (X^\top X)^{-1} X^\top \text{Var}_\beta(Y) ((X^\top X)^{-1} X^\top)^\top \\ &= (X^\top X)^{-1} X^\top \Sigma ((X^\top X)^{-1} X^\top)^\top = (X^\top X)^{-1} X^\top X (X^\top X)^{-1} \Sigma \\ &= (X^\top X)^{-1} \Sigma = I(\beta)^{-1} \end{aligned}$$

Wegen $\text{Var}_\beta(a^\top \hat{\beta}) = a^\top \text{Var}_\beta(\hat{\beta}) a = a^\top I(\beta)^{-1} a$ und der Schranke aus Korollar 3.2 folgt daraus sofort, dass für alle $a = (a_1, \dots, a_p)$ der Schätzer $a^\top \hat{\beta} = \sum_{j=1}^p a_j \hat{\beta}_j$ UMVU ist für $a^\top \beta = \sum_{j=1}^p a_j \beta_j$.

3. a) Wir zeigen zuerst f.s.-Konvergenz und Beschränktheit der betrachteten Folge, dann, dass daraus Konvergenz in $L_2(P_\theta)$ folgt.

i)

Sei ein P_θ fix. Für alle $x \neq \theta$ ist $p_\theta(x)$ nach θ differenzierbar, d. h. die Folge $\frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta}$ konvergiert für $\Delta \rightarrow 0$ gegen $\frac{\partial}{\partial \theta} p_\theta(x)$. Folglich konvergiert die Folge $\frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta p_\theta(x)} = \frac{1}{p_\theta(x)} \cdot \frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta}$ gegen

$$\frac{\frac{\partial}{\partial \theta} p_\theta(x)}{p_\theta(x)} = \frac{\partial}{\partial \theta} \log p_\theta(x) = \begin{cases} 1 & \text{falls } x > \theta \\ -1 & \text{falls } x < \theta \end{cases}.$$

Da $\{x|x = \theta\}$ bezüglich P_θ eine Nullmenge ist, konvergiert also $\frac{p_{\theta+\Delta}(x)-p_\theta(x)}{\Delta p_\theta(x)}$ P_θ -f.s. für $\Delta \rightarrow 0$.

ii)

Beh.: Für jedes Δ mit $|\Delta| \leq \Delta_0$ ist $|\frac{p_{\theta+\Delta}(x)-p_\theta(x)}{\Delta p_\theta(x)}| \leq \frac{e^{|\Delta|}-1}{|\Delta|} \leq \frac{e^{\Delta_0}-1}{\Delta_0} =: c$.

Bew.: Sei zuerst $\Delta > 0$. Wir unterscheiden drei Fälle:

- $\theta < \theta + \Delta < x$:

$$\left| \frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta p_\theta(x)} \right| = \left| \frac{e^{-(x-(\theta+\Delta))} - e^{-(x-\theta)}}{\Delta e^{-(x-\theta)}} \right| = \left| \frac{e^\Delta - 1}{\Delta} \right| = \frac{|e^{|\Delta|} - 1|}{|\Delta|} = \frac{e^{|\Delta|} - 1}{|\Delta|}$$

- $\theta < x < \theta + \Delta$:

$$\begin{aligned} \left| \frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta p_\theta(x)} \right| &= \left| \frac{e^{-(\theta+\Delta-x)} - e^{-(x-\theta)}}{\Delta e^{-(x-\theta)}} \right| = \left| \frac{e^{2x-2\theta-\Delta} - 1}{\Delta} \right| \\ &= \frac{\overbrace{|e^{2x-2\theta-\Delta} - 1|}^{\in |\Delta|}}{|\Delta|} \end{aligned}$$

Für $y \in [0, \Delta[$ ist $|e^y - 1| = e^y - 1 \leq e^\Delta - 1$, da $e^y - 1$ monoton wächst. Für $y \in]-\Delta, 0]$ ist $|e^y - 1|$ ebenfalls $\leq e^\Delta - 1$, denn e^y bewegt sich in positiver Richtung schneller von der 1 weg als in negativer. Also gilt oben weiter

$$\left| \frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta p_\theta(x)} \right| = \frac{|e^{2x-2\theta-\Delta} - 1|}{|\Delta|} \leq \frac{e^{|\Delta|} - 1}{|\Delta|}.$$

- $x < \theta < \theta + \Delta$:

$$\left| \frac{p_{\theta+\Delta}(x) - p_\theta(x)}{\Delta p_\theta(x)} \right| = \left| \frac{e^{-(\theta+\Delta-x)} - e^{-(\theta-x)}}{\Delta e^{-(\theta-x)}} \right| = \left| \frac{e^{-\Delta} - 1}{\Delta} \right| = \frac{|e^{-\Delta} - 1|}{|\Delta|} \leq \frac{e^{|\Delta|} - 1}{|\Delta|}$$

Für $\Delta < 0$ erhält man die Aussage durch analoge Überlegungen in den Fällen $x < \theta + \Delta < \theta$, $\theta + \Delta < x < \theta$ und $\theta + \Delta < \theta < x$. \square

iii)

Sei $f_\Delta(x) := \frac{p_{\theta+\Delta}(x)-p_\theta(x)}{\Delta p_\theta(x)}$. Die $L_2(P_\theta)$ -Konvergenz folgt dann aus dem folgenden Lemma.

Lemma: $f_\Delta \rightarrow f$ P_θ -f.s., $\sup_x |f_\Delta(x)| \leq c$ P_θ -f.s. $\forall \Delta$
 $\implies f_\Delta \rightarrow f$ in $L_p(P_\theta)$ ($\forall p \geq 1$).

Bew.: Sei $\delta > 0$.

$P_\theta[|f(x)| > c + \delta] \leq P_\theta[|f(x)| > |f_\Delta(x)| + \delta] \leq P_\theta[|f_\Delta(x) - f(x)| > \delta] \rightarrow 0$, denn f.s.-Konvergenz impliziert Konvergenz in Wahrscheinlichkeit.

Es folgt $P_\theta[|f(x)| > c + \delta] = 0$ bzw. $|f(x)| \leq c + \delta$ \mathcal{P}_θ -f.s.. Da dies für alle δ gilt, folgt $|f(x)| \leq c$ \mathcal{P}_θ -f.s.. Daraus folgt $|f_\Delta - f| \leq |f_\Delta| + |f| \leq 2c$ \mathcal{P}_θ -f.s. oder $g_\Delta := |f_\Delta - f|^p \leq (2c)^p$ \mathcal{P}_θ -f.s.. Zusammen mit $g_\Delta := |f_\Delta - f|^p \rightarrow 0$ \mathcal{P}_θ -f.s. sind somit die Voraussetzungen für den Satz von der majorisierten Konvergenz (H. Lebesgue) für die Folge g_Δ erfüllt. Also

$$\lim_{\Delta \rightarrow 0} \mathbf{E}[|f_\Delta - f|^p] = \mathbf{E}[\lim_{\Delta \rightarrow 0} |f_\Delta - f|^p] = 0.$$

□

Bemerkungen: Der Nachweis von $|f| \leq c$ f.s. im Beweis des Lemmas wäre hier nicht nötig gewesen, da in unserem Fall sowieso $|f| \leq 1$ f.s. gilt. Die Aussage des Lemmas gilt auch unter den schwächeren Voraussetzungen „Konvergenz in Wahrscheinlichkeit“ und einer zufälligen L_p -integrierbaren Schranke. Für Beziehungen zwischen den verschiedenen Konvergenzbegriffen siehe z. B. Serfling, R. J. (1980), *Approximation Theorems of Mathematical Statistics*, Wiley, New York.

- b) Aus $I(\theta) = \mathbf{E}_\theta[(\frac{\partial}{\partial \theta} \log p_\theta(x))^2] = \mathbf{E}_\theta[(\text{sign}(x - \theta))^2] = 1$ folgt die Cramér-Rao-Schranke

$$\frac{g'(\theta)^2}{I_n(\theta)} = \frac{g'(\theta)^2}{nI(\theta)} = \frac{1}{n}.$$

$$\begin{aligned} \text{Var}_\theta \left(\frac{1}{n} \sum_{i=1}^n X_i \right) &= \frac{1}{n} \text{Var}_\theta(X_1) = \frac{1}{n} \text{Var}_0(X_1) = \frac{1}{n} \mathbf{E}_0[X_1^2] \\ &= \frac{1}{n} \int_{-\infty}^{\infty} x^2 \frac{1}{2} e^{-|x|} dx = \frac{1}{n} \int_0^{\infty} x^2 e^{-x} dx = \frac{2}{n} \int_0^{\infty} x e^{-x} dx \\ &= \frac{2}{n} \int_0^{\infty} e^{-x} dx = -\frac{2}{n} e^{-x} \Big|_0^{\infty} = \frac{2}{n} \end{aligned}$$

$\text{Var}_\theta(\frac{1}{n} \sum_{i=1}^n X_i)$ liegt also um $\frac{1}{n}$ über der Cramér-Rao-Schranke.

- c) Wir geben zuerst eine heuristische Herleitung, weshalb der Hinweis korrekt ist. (Eine saubere Herleitung wäre, zuerst die Verteilungsfunktion von $X_{(3)}$ herzuleiten und dann diese abzuleiten.) OEA sei $\theta = 0$. Das Ereignis $x \leq X_{(3)} \leq x + dx$ tritt genau dann auf, wenn 2 Beobachtungen kleiner als x sind, eine im Intervall $[x, x + dx]$ liegt und 2 Beobachtungen grösser als x sind. Eine Anordnung dieser Art hat Wahrscheinlichkeit $p_0(x)P_0(x)^2(1 - P_0(x))^2$ und es gibt $\frac{5!}{2!2!}$ solcher Anordnungen, womit der Hinweis bewiesen ist.

Nun zur Berechnung von $\text{Var}_\theta(X_{(3)})$:

$$\begin{aligned} \text{Var}_\theta(X_{(3)}) &= \mathbf{E}[(X_{(3)} - \theta)^2] = \frac{15}{16} \int_{-\infty}^{\infty} x^2 e^{-3|x|} (2 - e^{-|x|})^2 dx \\ &= 2 \cdot \frac{15}{16} \int_0^{\infty} x^2 e^{-3x} (4 - 4e^{-x} + e^{-2x}) dx \end{aligned}$$

Unter Verwendung von $\int_0^{\infty} x^2 e^{-kx} dx = \frac{2}{k^3}$ für $k \in \mathbb{N}$ (via partielle Integration) ergibt sich

$$\text{Var}_\theta(X_{(3)}) = \frac{30}{16} \left(\frac{8}{3^3} - \frac{8}{4^3} + \frac{2}{5^3} \right) \approx 0.35.$$

Für $n = 5$ ist die Varianz des Maximum Likelihood Schätzer $X_{(3)}$ also ungefähr 0.15 von der Cramér-Rao-Schranke entfernt. Dies ist besser als das arithmetische Mittel, dessen Varianz 0.2 von der Cramér-Rao-Schranke entfernt ist.

Ausblick: In Kapitel 6 wird gezeigt, dass asymptotisch (d.h. für $n \rightarrow \infty$) gilt $\text{med}(X_i) \sim \mathcal{N}(\theta, \frac{1}{nI(\theta)}) = \mathcal{N}(\theta, \frac{1}{n})$ und $\bar{X} \sim \mathcal{N}(\theta, \frac{2}{n})$. Asymptotisch erreicht also der Median die Cramér-Rao-Schranke. Dies gilt allgemein für den Maximum Likelihood Schätzer (siehe Abschnitt 6.3.1), aber (wie dieses Beispiel zeigt) nicht für Momentenschätzer.

Wir begnügen uns hier mit einer Grafik, die die Varianzen von $\text{med}(X_i)$ und \bar{X} , sowie die Cramér-Rao-Schranke für n zwischen 10 und 100 zeigt. Weil sich die Varianzen von $\text{med}(X_i)$ nicht ohne weiteres exakt berechnen lassen, wurden sie durch Simulation bestimmt.

