

## Übung 12

**Abgabe: 10.07.2019 in die entsprechenden Briefkästen bis 18 Uhr (siehe Homepage).**

**Aufgabe 1** (4 Punkte). Gegeben seien i.i.d. Gamma-verteilte Zufallsvariablen  $X_1, \dots, X_m$  mit der Dichte

$$p_{a,\lambda}(x) = \frac{\lambda^a}{\Gamma(a)} x^{a-1} e^{-\lambda x} 1_{\mathbb{R}_{\geq 0}}(x)$$

und Parametern  $a > 0$  und  $\lambda > 0$ .

(a) Zeigen Sie für ein positives  $n \in \mathbb{N}$

$$EX_i^n = \frac{a \cdot \dots \cdot (n + a - 1)}{\lambda^n}.$$

Dabei können Sie die Identität  $\Gamma(a + 1) = a\Gamma(a)$ ,  $a \in \mathbb{R} \setminus \{-1, -2, \dots\}$ , verwenden.

(b) Berechnen Sie einen Momentenschätzer für die Parameter  $a$  und  $\lambda$  basierend auf der Beobachtung von  $(X_1, \dots, X_m)$ .

*Proof.* (a)

$$\begin{aligned} EX^n &= \int_0^\infty x^n \frac{\lambda^a}{\Gamma(a)} x^{a-1} e^{-\lambda x} dx \\ &= \frac{a \cdot \dots \cdot (a + n - 1)}{\lambda^n} \int_0^\infty \frac{\lambda^{a+n}}{\Gamma(n + a)} x^{a+n-1} e^{-\lambda x} dx \\ &= \frac{a \cdot \dots \cdot (a + n - 1)}{\lambda^n} \\ &= \frac{\Gamma(a + n)}{\lambda^n \Gamma(a)}. \end{aligned}$$

(b) Die Momentenschätzer für die Parameter  $a$  und  $\lambda$  sind

$$\begin{aligned} EX &= \frac{a}{\lambda}, \\ EX^2 &= \frac{a(a + 1)}{\lambda^2}, \\ \implies EX^2 &= \frac{a(a + 1)}{a^2} (EX)^2 \\ \iff EX^2 &= \left(1 + \frac{1}{a}\right) (EX)^2 \\ \iff a &= \frac{(EX)^2}{EX^2 - (EX)^2}, \\ \lambda &= \frac{EX}{EX^2 - (EX)^2}. \end{aligned}$$

Die Schätzer für die Parameter  $a, \lambda$  erhält man nun durch obige Gleichungen indem man bekanntlich die Momente mit den Daten gleichsetzt:  $m_1 \stackrel{!}{=} \frac{1}{m} \sum_{i=1}^m X_i$  und  $m_2 \stackrel{!}{=} \frac{1}{m} \sum_{i=1}^m X_i^2$ . □

**Aufgabe 2** (4 Punkte). Seien  $X_1, \dots, X_n$  i.i.d. mit der Dichte

$$p_\theta(x) = \sqrt{\frac{2\theta^3}{\pi}} x^2 e^{-\frac{\theta}{2}x^2} 1_{\mathbb{R}_{>0}}(x)$$

wobei der Parameter  $\theta > 0$  unbekannt ist. Finden Sie den Maximum-Likelihood-Schätzer für  $\theta$  und klären Sie, ob dieser eindeutig ist.

*Proof.* Wir berechnen den MLS für die oben angegebene Familie von Verteilungen indem wir die Log-Likelihood-Funktion maximieren.

Die Likelihood-Funktion der Familie ist gegeben durch

$$L(\theta, x) = \left(\frac{2\theta^3}{\pi}\right)^{\frac{n}{2}} \prod_{i=1}^n x_i^2 \exp\left(-\frac{\theta}{2}x_i^2\right).$$

Für die Log-Likelihood-Funktion gilt

$$\begin{aligned} l(\theta, x) &= \frac{n}{2} (\log 2 + 3 \log \theta - \log \pi) + 2 \sum_{i=1}^n \log x_i - \frac{\theta}{2} \sum_{i=1}^n x_i^2 \\ \frac{\partial}{\partial \theta} l(\theta, x) &= \frac{3n}{2\theta} - \frac{1}{2} \sum_{i=1}^n x_i^2 \\ \frac{\partial^2}{\partial \theta^2} l(\theta, x) &= -\frac{3n}{2} \frac{1}{\theta^2} < 0 \quad \forall \theta \in \mathbb{R}_{>0}. \end{aligned}$$

Somit ergibt sich die Formel für den MLS

$$\begin{aligned} \frac{\partial}{\partial \theta} l(\theta, x) &= \frac{3n}{2\theta} - \frac{1}{2} \sum_{i=1}^n x_i^2 = 0 \\ \hat{\theta} &= \frac{3}{\frac{1}{n} \sum_{i=1}^n x_i^2}. \end{aligned}$$

Wegen  $\frac{\partial^2}{\partial \theta^2} l(\theta, x) < 0$  ist der MLS  $\hat{\theta}$  auch eindeutig. □

**Aufgabe 3** (4 Punkte). Seien  $X_1, \dots, X_n$  i.i.d. und Beta( $\theta + 1, 1$ )-verteilt mit dem Parameter  $\theta \in \Theta = \{\eta \in \mathbb{R} : \eta > -1\}$ . Die Dichte von  $X_i$  ist also

$$p_\theta(x) = (\theta + 1)x^\theta 1_{[0,1]}(x).$$

- Bestimmen Sie den Maximum-Likelihood-Schätzer für  $\theta$  basierend auf der Beobachtung von  $(X_1, \dots, X_n)$ . Zeigen Sie dabei, dass der von Ihnen gefundene Schätzer  $\hat{\theta}$  das Maximum der Likelihood-Funktion ist.
- Kann der Maximum-Likelihood-Schätzwert  $\hat{\theta}(x_1, \dots, x_n)$  auf dem Rand des Parameter-raumes liegen?

*Proof.* (a) Die Likelihoodfunktion für eine Beobachtung  $(X_1, \dots, X_n)$  ist

$$\begin{aligned} L(\theta, X) &= (\theta + 1)^n \left(\prod_{i=1}^n X_i\right)^\theta \\ l(\theta, X) &= n \log(\theta + 1) + \theta \sum_{i=1}^n \log X_i \\ \frac{\partial}{\partial \theta} l(\theta, X) &= \frac{n}{\theta + 1} + \sum_{i=1}^n \log X_i \\ \frac{\partial^2}{\partial \theta^2} l(\theta, X) &= -\frac{n}{(\theta + 1)^2} < 0. \end{aligned}$$

$\frac{\partial}{\partial \theta} l(\theta, X) = 0$  liefert

$$\hat{\theta} = -1 - \frac{n}{\sum_i \log X_i}.$$

$\hat{\theta}$  ist eindeutiger MLS.

(b) Nein, denn  $\Theta$  offen ist. □

**Aufgabe 4.** Seien  $X_1, \dots, X_n$  i.i.d. und Paretoverteilt mit der Dichte

$$p_\theta(x) = \frac{\theta a^\theta}{x^{\theta+1}} 1_{\mathbb{R}_{>a}}(x),$$

wobei  $\theta > 0$  und  $a$  fix und bekannt sei.

- (a) Finden Sie eine reellwertige suffiziente Statistik  $T(X_1, \dots, X_n)$  für  $\theta$ .
- (b) Finden Sie den Maximum-Likelihood-Schätzer  $\hat{\theta}(X_1, \dots, X_n)$  für  $\theta$ .
- (c) Zeigen Sie, dass der von Ihnen gefundene Schätzer  $\hat{\theta}$  suffizient ist.

*Proof.* (a) Die suffiziente Statistik  $T = \prod_{i=1}^n \frac{1}{x_i}$  erhalten wir aus

$$p_\theta(X_1, \dots, X_n) = \theta^n a^{n\theta} \left( \prod_{i=1}^n \frac{1}{x_i} \right)^{\theta+1} \prod_{i=1}^n 1_{\mathbb{R}_{>a}}(x_i)$$

mit Hilfe des Faktorisierungssatzes.

(b) Die Berechnung folgt der üblichen Prozedur des Minimierens der Log-Likelihood-Funktion.

$$l(x, a, \theta) = n \log \theta + n\theta \log a - (\theta + 1) \sum_{i=1}^n \log x_i$$

$$\frac{\partial}{\partial \theta} l(x, a, \theta) = \frac{n}{\theta} + n \log a - \sum_{i=1}^n \log x_i$$

$$\frac{\partial^2}{\partial \theta^2} l(x, a, \theta) = -\frac{n}{\theta^2} < 0$$

$$\hat{\theta} = \frac{n}{\sum_{i=1}^n (\log x_i - \log a)} = \frac{n}{\log \left( \prod_{i=1}^n \frac{x_i}{a} \right)}$$

(c) Die suffiziente Statistik  $T = \eta(\hat{\theta})$  ist eine Funktion des MLS, wobei

$$\eta(x) = \frac{1}{\exp\left(\frac{n}{x}\right) a^n}. \tag{1}$$

Daher ist der MLS  $\hat{\theta}$  auch suffizient. □

**Aufgabe 5** (2 Bonuspunkte). Sei  $\{p_\theta : \theta \in \Theta\}$  ein reguläres statistisches Modell und  $T(X)$  eine suffiziente Statistik für  $\theta$ . Weisen Sie nach, dass ein Maximum-Likelihood-Schätzer für  $\theta$  eine Funktion von  $T(X)$  ist.

*Proof.* Es sei  $\hat{\theta}$  ein MLS für  $\theta$  in einem regulären Modell  $(p_\theta)_{\theta \in \Theta}$ . Dann maximiert  $\hat{\theta}$  die Likelihood-Funktion  $L(\theta, x) = p_\theta(x)$  für alle  $x \in \mathbb{R}^n$  nach Voraussetzung. Da die Statistik  $T$  suffizient ist, gilt mit Hilfe des Faktorisierungssatzes

$$L_\theta(x) = p_\theta(x) = g(T(x), \theta) h(x).$$

Wir stellen weiterhin fest, dass die Likelihood Funktion nicht negativ ist und dass  $h$  nicht negativ gewählt werden kann. Das bedeutet daher, dass es genügt  $\tilde{L}_\theta(x) := g(T(x), \theta)$  zu betrachten.  $\tilde{L}_\theta$  hängt von  $(x_1, \dots, x_n)$  nur über  $T(x)$  ab, d.h.  $\hat{\theta}$  kann als diejenige Funktion verstanden werden, die für jede Realisierung  $T(x)$  die Funktion  $\tilde{L}_\theta$  maximiert. Also ist  $\hat{\theta}$  eine Funktion von  $T$ . □