

Wahrscheinlichkeit & Statistik

Serie 11

Die Übungen mit (*) markiert sind fakultativ.

Aufgabe 11.1 [Schätzer I: gleichverteilte Zufallsvariablen]

Seien X_1, \dots, X_n unabhängige, identisch verteilte Zufallsvariablen mit $X_i \sim \mathcal{U}([\theta - 1, \theta])$ unter \mathbb{P}_θ , wobei $\theta \in \mathbb{R}$ ein unbekannter Parameter ist. Für θ bieten sich

$$T_1^{(n)} = \frac{1}{n} \sum_{i=1}^n (X_i + 1/2) \quad \text{und} \quad T_2^{(n)} = \max(X_1, \dots, X_n)$$

als Schätzer an. Wir untersuchen in dieser Aufgabe, welche Eigenschaften diese beiden Schätzer besitzen.

- (a) Untersuche, ob die Schätzer erwartungstreu sind.
- (b) Berechne die Varianzen der Schätzer $\text{Var}_\theta[T_1^{(n)}]$ und $\text{Var}_\theta[T_2^{(n)}]$.
- (c) Berechne die mittleren quadratischen Schätzfehler

$$\text{MSE}_\theta[T_i^{(n)}] := E_\theta[(T_i^{(n)} - \theta)^2]$$

für $i = 1, 2$.

Lösung 11.1

- (a) Sei $\theta \in \mathbb{R}$ fixiert. Aus der Gleichverteilung folgt, dass

$$E_\theta[T_1^{(n)}] = \left(\frac{1}{n} \sum_{i=1}^n E_\theta[X_i] \right) + \frac{1}{2} = E_\theta[X_1] + \frac{1}{2} = \theta - \frac{1}{2} + \frac{1}{2} = \theta.$$

Somit folgt, dass der Schätzer $T_1^{(n)}$ erwartungstreu ist.

Um die Rechnung für den anderen Schätzer zu vereinfachen, führen wir die Zufallsvariablen $Y_i = X_i - (\theta - 1)$ ein. Unter \mathbb{P}_θ sind Y_1, \dots, Y_n unabhängig und $\mathcal{U}([0, 1])$ -verteilt. Insbesondere ist

$$Y^{(n)} := \max\{Y_1, \dots, Y_n\} = \max\{X_1, \dots, X_n\} - (\theta - 1) = T_2^{(n)} - (\theta - 1).$$

Um den Erwartungswert von $Y^{(n)}$ unter \mathbb{P}_θ zu bestimmen, berechnen wir zunächst die Verteilungsfunktion und die Dichte von $Y^{(n)}$. Es gilt

$$\begin{aligned} F_{Y^{(n)}}(a) &= \mathbb{P}_\theta[Y^{(n)} \leq a] = \mathbb{P}_\theta[Y_1 \leq a, \dots, Y_n \leq a] = \prod_{i=1}^n \mathbb{P}_\theta[Y_i \leq a] = \mathbb{P}_\theta[Y_1 \leq a]^n \\ &= \begin{cases} 0, & \text{für } a < 0, \\ a^n, & \text{für } a \in [0, 1], \\ 1, & \text{für } a > 1, \end{cases} \end{aligned}$$

und somit

$$f_{Y^{(n)}}(a) = na^{n-1} \mathbb{1}_{a \in [0,1]}.$$

Es folgt, dass

$$\begin{aligned} E_{\theta}[Y^{(n)}] &= \int_0^1 a \cdot na^{n-1} da = n \int_0^1 a^n da \\ &= n \left[\frac{1}{n+1} a^{n+1} \right]_{a=0}^{a=1} = \frac{n}{n+1} = 1 - \frac{1}{n+1}. \end{aligned}$$

Also ist

$$E_{\theta}[T_2^{(n)}] = E_{\theta}[Y^{(n)}] + (\theta - 1) = 1 - \frac{1}{n+1} + (\theta - 1) = \theta - \frac{1}{n+1}.$$

Der Schätzer $T_2^{(n)}$ ist somit nicht erwartungstreu.

- (b) Wir erinnern zuerst daran, dass $\text{Var}[Z + b] = \text{Var}[Z]$ für eine beliebige Zufallsvariable Z und $b \in \mathbb{R}$ gilt. Also folgt wegen der Unabhängigkeit von X_1, \dots, X_n und $Y_1 \sim \mathcal{U}(0, 1)$, dass

$$\text{Var}_{\theta}[T_1^{(n)}] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}_{\theta}[X_i - (\theta - 1)] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}_{\theta}[Y_i] = \frac{1}{n} \text{Var}_{\theta}[Y_1] = \frac{1}{12n}.$$

Um die Varianz des anderen Schätzers zu bestimmen, berechnen wir zuerst $\text{Var}_{\theta}[Y^{(n)}]$. Auf ähnliche Weise wie in a) erhalten wir

$$\begin{aligned} E_{\theta}[(Y^{(n)})^2] &= n \int_0^1 a^2 a^{n-1} da \\ &= n \int_0^1 a^{n+1} da \\ &= n \left[\frac{1}{n+2} a^{n+2} \right]_{a=0}^{a=1} \\ &= \frac{n}{n+2}. \end{aligned}$$

Also ist

$$\begin{aligned} \text{Var}_{\theta}[T_2^{(n)}] &= \text{Var}_{\theta}[Y^{(n)} + (\theta - 1)] = \text{Var}_{\theta}[Y^{(n)}] \\ &= E_{\theta}[(Y^{(n)})^2] - (E_{\theta}[Y^{(n)}])^2 = \frac{n}{n+2} - \left(\frac{n}{n+1} \right)^2 = \frac{n}{(n+1)^2(n+2)}. \end{aligned}$$

- (c) Aus den Teilaufgaben (a) und (b) erhalten wir den mittleren quadratischen Schätzfehler der beiden Schätzer:

$$\begin{aligned} \text{MSE}_{\theta}[T_1^{(n)}] &= \text{Var}_{\theta}[T_1^{(n)} - \theta] + (E_{\theta}[T_1^{(n)}] - \theta)^2 \\ &= \frac{1}{12n} + 0 = \frac{1}{12n} \end{aligned}$$

$$\begin{aligned} \text{MSE}_{\theta}[T_2^{(n)}] &= \text{Var}_{\theta}[T_2^{(n)} - \theta] + (E_{\theta}[T_2^{(n)}] - \theta)^2 \\ &= \frac{n}{(n+1)^2(n+2)} + \left(\theta - \frac{1}{n+1} - \theta \right)^2 = \frac{2}{(n+1)(n+2)} \end{aligned}$$

Aufgabe 11.2 [Schätzer II: Hochwasser im Zürichsee]

Wir betrachten Pegelstände bei Hochwasser im Zürichsee. Hochwasser bedeute dabei, dass der Pegelstand die kritische Marke von 140 cm über Normalniveau überschreitet. Die Zufallsvariable X messe die Wasserhöhe in cm über der kritischen Marke. Zur Modellierung von X können wir eine sogenannte verallgemeinerte Pareto-Verteilung mit Dichte

$$f_X(x; \theta) = \begin{cases} \frac{1}{\theta}(1+x)^{-(1+\frac{1}{\theta})} & \text{falls } x > 0, \\ 0 & \text{falls } x \leq 0 \end{cases}$$

verwenden. Dabei ist $\theta > 0$ ein unbekannter Parameter, der auf Basis von Daten x_1, \dots, x_n geschätzt werden soll; diese Daten werden wie üblich als Realisierungen von Zufallsvariablen X_1, \dots, X_n aufgefasst, die für jede Wahl des Parameters θ unter \mathbb{P}_θ u.i.v. sind mit Dichte $f_X(x; \theta)$. Als Schätzer für θ verwenden wir

$$T^{(n)} = \sum_{i=1}^n \frac{\log(1 + X_i)}{n}.$$

- (a) Berechne den Erwartungswert und die Varianz von $T^{(n)}$ im Modell \mathbb{P}_θ für jedes $\theta > 0$.
Hinweis: Benutze, dass $Y_i := \log(1 + X_i) \sim \text{Exp}(\frac{1}{\theta})$ ist, d.h. Y_i hat unter \mathbb{P}_θ die Dichte $f_Y(y) = \frac{1}{\theta} e^{-\frac{1}{\theta}y} \mathbb{1}_{\{y \geq 0\}}$.
- (b) Ist $T^{(n)}$ ein erwartungstreuer Schätzer für θ ?
- (c) Berechne den mittleren quadratischen Schätzfehler

$$\text{MSE}_\theta[T^{(n)}] := E_\theta[(T^{(n)} - \theta)^2] = E_\theta[T^{(n)} - \theta]^2 + \text{Var}_\theta[T^{(n)}]$$

im Modell \mathbb{P}_θ für jedes $\theta > 0$.

- (d) Zeige, dass $T^{(n)}$ der Maximum-Likelihood-Schätzer für θ ist.

Lösung 11.2

- (a) Die Linearität des Erwartungswertes liefert

$$E_\theta[T^{(n)}] = E_\theta \left[\frac{1}{n} \sum_{i=1}^n \log(1 + X_i) \right] = \frac{1}{n} \sum_{i=1}^n E_\theta[\log(1 + X_i)] = E_\theta[\log(1 + X_1)].$$

Nach dem Hinweis ist $Y_1 := \log(1 + X_1) \sim \text{Exp}(\frac{1}{\theta})$. Also ist $E_\theta[Y_1] = \theta$ und $\text{Var}_\theta[Y_1] = \theta^2$. Daher gilt $E_\theta[T^{(n)}] = E_\theta[Y_1] = \theta$.

Die Varianz rechnen wir auf eine ähnliche Weise aus:

$$\begin{aligned} \text{Var}_\theta[T^{(n)}] &= \text{Var}_\theta \left[\frac{1}{n} \sum_{i=1}^n \log(1 + X_i) \right] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}_\theta[\log(1 + X_i)] \\ &= \frac{1}{n} \text{Var}_\theta[\log(1 + X_1)] = \frac{1}{n} \text{Var}_\theta[Y_1] = \frac{1}{n} \theta^2. \end{aligned}$$

- (b) Aus (a) folgt, dass $E_\theta[T^{(n)}] = \theta$, d.h. $T^{(n)}$ ist erwartungstreu für θ .
- (c) Da der Schätzer erwartungstreu ist (siehe (b)), erhalten wir

$$\text{MSE}_\theta[T^{(n)}] = \text{Var}_\theta[T^{(n)}] = \frac{\theta^2}{n}.$$

(d) Die log-Likelihood-Funktion ist gegeben durch

$$\begin{aligned}\log L(x_1, \dots, x_n; \theta) &= \log \left(\frac{1}{\theta^n} \prod_{i=1}^n (1 + x_i)^{-(1 + \frac{1}{\theta})} \right) \\ &= -n \log \theta - \left(1 + \frac{1}{\theta}\right) \sum_{i=1}^n \log(1 + x_i).\end{aligned}$$

Ableiten nach θ und Nullsetzen ergibt

$$\frac{\partial}{\partial \theta} \log L(x_1, \dots, x_n; \theta) = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n \log(1 + x_i) = 0$$

für

$$\theta^* = \frac{1}{n} \sum_{i=1}^n \log(1 + x_i).$$

Die zweite Ableitung ist

$$\frac{n}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n \log(1 + x_i),$$

also strikt kleiner als 0 an der Stelle θ^* und somit handelt es sich also um das Maximum. Der Maximum-Likelihood-Schätzer für θ ist also

$$T_{ML} = \frac{1}{n} \sum_{i=1}^n \log(1 + X_i) = T^{(n)}.$$

Aufgabe 11.3 [MLE I: Stetige Verteilung]

Wir betrachten eine stetige Verteilung mit Dichte

$$f(x) = \begin{cases} \frac{\theta}{x^{\theta+1}} & x \geq 1, \\ 0 & x < 1, \end{cases}$$

wobei $\theta > 0$ ein unbekannter Parameter ist. Wir wollen den Parameter θ mit Hilfe eines Datensatzes schätzen.

- (a) Sei X_1, \dots, X_n eine Stichprobe von unabhängigen Zufallsvariablen, welche alle die Dichte f besitzen. Bestimme die Likelihood- und log-Likelihood-Funktion.
- (b) Bestimme den zugehörigen Maximum-Likelihood-Schätzer für θ . Schreibe zuerst die allgemeine Formel für n Beobachtungen hin und berechne dann den Schätzwert für die folgende konkrete Stichprobe:

x_1	x_2	x_3	x_4	x_5
12.0	4.0	6.9	27.9	15.4

Lösung 11.3

- (a) Die Likelihood-Funktion ergibt sich aus dem Produkt der Dichten. Für $x_1, \dots, x_n \geq 1$ erhalten wir

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i) = \prod_{i=1}^n \frac{\theta}{x_i^{\theta+1}} = \theta^n \frac{1}{(\prod_{i=1}^n x_i)^{\theta+1}}.$$

Falls $x_i < 1$ für ein $1 \leq i \leq n$, ist die Likelihood-Funktion gleich 0, wir können uns also auf den Fall $x_1, \dots, x_n \geq 1$ beschränken.

Die log-Likelihood-Funktion erhalten wir durch Logarithmieren obiger Formel als

$$\ell(x_1, \dots, x_n; \theta) = \log L(x_1, \dots, x_n; \theta) = n \log \theta - (\theta + 1) \sum_{i=1}^n \log x_i.$$

- (b) Ableiten und Nullsetzen der log-Likelihood-Funktion ergibt

$$\frac{\partial}{\partial \theta} \ell(x_1, \dots, x_n; \theta) = \frac{n}{\theta} - \sum_{i=1}^n \log x_i = 0$$

für $\theta^* = \frac{n}{\sum_{i=1}^n \log x_i}$. Für $\theta < \theta^*$ ist die Ableitung strikt positiv, für $\theta > \theta^*$ strikt negativ, es handelt sich also um das Maximum. Also ist der Maximum-Likelihood-Schätzer

$$T_{ML} = \frac{n}{\sum_{i=1}^n \log X_i} = \frac{1}{\frac{1}{n} \sum_{i=1}^n \log X_i}.$$

Der realisierte Schätzwert für die gegebenen Daten ist dann

$$t_{ML} = \frac{5}{\sum_{i=1}^5 \log x_i} = 0.4214.$$

Hinweis: Wir verwenden den natürlichen Logarithmus.