

Musterlösung für den 10. Übung zur Vorlesung

Stochastik I

Wintersemester 2011/2012

1. Aufgabe (Parameterschätzung I, 4 Punkte)

In einer Urne sind $N \geq 2$ Lose mit den Nummern $1, \dots, N$, wobei N unbekannt ist. Es wird $n \leq N$ mal ohne Zurücklegen gezogen mit den Ergebnissen x_1, \dots, x_n .

- Bestimmen Sie den Maximum-Likelihood-Schätzer T für N .
- Berechnen Sie $\mathbb{E}_N(T)$ und konstruieren Sie daraus einen erwartungstreuen Schätzer T^* für N .
Tipp: Sie können Aufgabe 3 vom 5. Übungszettel und die Formel $\sum_{k=n}^N \binom{k}{n} = \binom{N+1}{n+1}$ verwenden.

Lösung:

a) Ein Schätzer T ist definitionsgemäß Maximum-Likelihood-Schätzer für N , falls

$$\mathbb{P}_{T(x)}(X = x) = \max_N \mathbb{P}_N(X = x),$$

wobei \mathbb{P}_N das Wahrscheinlichkeitsmaß in Abhängigkeit des unbekanntes Parameters N ist und $x = (x_1, \dots, x_n)$ das Ergebnis der Stichprobe. Für festes N gibt es $\binom{N}{n}$ mögliche gleichwahrscheinliche Ergebnisse, so dass

$$\mathbb{P}_N(X = x) = \frac{1}{\binom{N}{n}} = \frac{n!}{N \cdot (N-1) \cdot \dots \cdot (N-n+1)}.$$

Dieser Bruch wird umso größer, je kleiner N ist. N ist aber mindestens so groß wie $\max(x_1, \dots, x_n)$. Daher ist $T(x) = \max(x_1, \dots, x_n)$ der Maximum-Likelihood-Schätzer.

b) Betrachte den Schätzer $T(x) = \max(x_1, \dots, x_n)$ aus a). Nach Aufgabe 3 vom 5. Übungszettel gilt $\mathbb{E}_N(T) = \sum_{i=1}^{\infty} \mathbb{P}_N(T \geq i)$. Da $\mathbb{P}_N(T \geq i) = 0$ für $i > N$ folgt

$$\mathbb{E}_N(T) = \sum_{i=1}^N \mathbb{P}_N(T \geq i).$$

Dies lässt sich weiter umschreiben zu

$$\mathbb{E}_N(T) = \sum_{i=1}^N (1 - \mathbb{P}_N(T < i)) = N - \sum_{i=1}^N \mathbb{P}_N(T < i).$$

Es gilt

$$\mathbb{P}_N(T < i) = \begin{cases} 0 & : i \leq n \\ \frac{\binom{i-1}{n}}{\binom{N}{n}} & : n < i \leq N \end{cases},$$

und somit

$$\mathbb{E}_N(T) = N - \sum_{i=n+1}^N \frac{\binom{i-1}{n}}{\binom{N}{n}} = N - \frac{1}{\binom{N}{n}} \sum_{i=n}^{N-1} \binom{i}{n} = N - \frac{1}{\binom{N}{n}} \binom{N}{n+1},$$

wobei im letzten Schritt der Tipp verwendet wurde. Lösen wir die Binomialkoeffizienten auf, erhalten wir

$$\mathbb{E}_N(T) = N - \frac{N-n}{n+1} = \frac{n}{n+1} \cdot (N+1)$$

und somit $\mathbb{E}_N(T) \neq N$ (für $N \neq n$), d.h. T ist nicht erwartungstreu. Um einen erwartungstreuen Schätzer zu konstruieren, nutzen wir die Linearität des Erwartungswertes und definieren $T^* = \frac{n+1}{n} \cdot T - 1$, denn dann gilt

$$\mathbb{E}_N(T^*) = \frac{n+1}{n} \cdot \mathbb{E}_N(T) - 1 = N.$$

2. Aufgabe (Parameterschätzung II, 4 Punkte)

Anhand von n unabhängigen Stichproben x_1, \dots, x_n soll die Varianz einer Zufallsvariable mit unbekannter Verteilung und unbekanntem Erwartungswert geschätzt werden. Vorausgesetzt wird nur, dass Erwartungswert und Varianz existieren. Konstruieren Sie einen erwartungstreuen Schätzer für die Varianz.

Lösung:

Wir schätzen den Erwartungswert mit dem erwartungstreuen Schätzer $\bar{X} = \frac{1}{n}(X_1 + \dots + X_n)$. Die Varianz ist die mittlere quadratische Abweichung vom Erwartungswert. Da liegt es nahe, die Varianz durch

$$T(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

zu schätzen - das ist die mittlere quadratische Abweichung vom geschätzten Erwartungswert. Jedoch ist

$$\begin{aligned} \mathbb{E}(T(X)) &= \mathbb{E}\left(\frac{1}{n} \sum_i (X_i - \bar{X})^2\right) \\ &= \frac{1}{n} \sum_i (\mathbb{E}(X_i^2) - 2\mathbb{E}(X_i \bar{X}) + \mathbb{E}(\bar{X}^2)) \\ &= \frac{1}{n} \sum_i \mathbb{E}(X_i^2) - 2 \frac{1}{n^2} \sum_i \sum_j \mathbb{E}(X_i X_j) + \frac{1}{n^2} \sum_i \sum_j \mathbb{E}(X_i X_j) \\ &= \frac{1}{n} \sum_i \mathbb{E}(X_i^2) - \frac{1}{n^2} \sum_i \sum_j \mathbb{E}(X_i X_j) \\ &= \frac{1}{n} \sum_i \mathbb{E}(X_i^2) - \frac{1}{n^2} \sum_i \mathbb{E}(X_i^2) - \frac{1}{n^2} \sum_i \sum_{j \neq i} \mathbb{E}(X_i X_j) \\ &= \frac{1}{n} n \mathbb{E}(X^2) - \frac{1}{n^2} n \mathbb{E}(X^2) - \frac{1}{n^2} n(n-1) \mathbb{E}(X)^2 \\ &= \frac{n-1}{n} \mathbb{E}(X^2) - \frac{n-1}{n} \mathbb{E}(X)^2 \\ &= \frac{n-1}{n} \text{Var}(X), \end{aligned}$$

d.h., der Schätzer T ist nicht erwartungstreu. Um einen erwartungstreuen Schätzer T^* für die Varianz zu erhalten, müssen wir den Vorfaktor $\frac{n-1}{n}$ loswerden. Dies machen wir durch die Wahl von

$$T^*(X) = \frac{n}{n-1} T(X) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

Dann ist

$$\mathbb{E}(T^*(X)) = \mathbb{E}\left(\frac{n}{n-1} T(X)\right) = \frac{n}{n-1} \mathbb{E}(T(X)) = \text{Var}(X),$$

und T^* ist erwartungstreu.

3. Aufgabe (Konfidenzintervall, 4 Punkte)

Bei einer Prüfung mit Notenvergabe 1, 2, 3, 4, 5 gibt es eine gewisse (unbekannte) Verteilung $\mathbb{P}(X = i) = p_i$, $i = 1, \dots, 5$. Es soll $\mathbb{E}(X)$ geschätzt werden, wobei bekannt ist, dass $\text{Var}(X) \leq 0.5$ gilt. Bei einer Prüfung von 25 unabhängigen Kandidaten entsteht folgender Notenspiegel:

1	2	3	4	5
2	7	4	6	6

Konstruieren Sie mithilfe der Tschebyschev-Ungleichung ein Konfidenzintervall für $\mathbb{E}(X)$ um den Mittelwert \bar{x} zum Niveau $\alpha = 0.25$. Ist der Wert $\mathbb{E}(X) = 3$ noch plausibel?

Lösung:

Es ist $\bar{x} = \frac{1}{n}(x_1 + \dots + x_n) = 3.28$. Das gesuchte Konfidenzintervall hat die Form $C(\bar{x}) = (\bar{x} - \varepsilon, \bar{x} + \varepsilon)$, wobei ε bestimmt werden soll. Der unbekannte Parameter ist $\nu = \mathbb{E}(X)$, und es soll gelten

$$\mathbb{P}_\nu(\nu \in C(\bar{x})) = \mathbb{P}_\nu(|\bar{x} - \nu| < \varepsilon) = 1 - \mathbb{P}_\nu(|\bar{x} - \nu| \geq \varepsilon) \geq 1 - \alpha = 0.75,$$

d.h. $\mathbb{P}_\nu(|\bar{x} - \nu| \geq \varepsilon) \leq 0.25$. Mit Tschebyschev gilt

$$\mathbb{P}_\nu(|\bar{x} - \nu| \geq \varepsilon) \leq \frac{\text{Var}(\bar{x})}{\varepsilon^2} = \frac{\text{Var}(X)}{n\varepsilon^2} \leq \frac{0.5}{n\varepsilon^2}.$$

Ein $\varepsilon > 0$ funktioniert also, sobald

$$\frac{0.5}{n\varepsilon^2} \leq 0.25 \Leftrightarrow \varepsilon^2 \geq \frac{0.5}{0.25 \cdot n} = \frac{0.5}{0.25 \cdot 25} = 0.08$$

d.h. $\varepsilon \geq 0.2828$. Der Wert $\mathbb{E}(X) = 3$ ist damit gerade noch plausibel, d.h. er liegt in $C(\bar{x})$. (Die Bedingung $\varepsilon \geq 0.2828$ ist hinreichend, aber nicht unbedingt notwendig: Es kann sein, dass auch noch kleinere ε möglich sind. Dies liegt daran, dass die Tschebyschev-Ungleichung nur eine Abschätzung nach oben liefert.)

4. Aufgabe (Hypothesentest, 4 Punkte)

Es werden n unabhängige Stichproben x_1, \dots, x_n aus der Gleichverteilung auf dem Intervall $[0, \nu]$ ($\nu > 0$) gezogen. Dabei soll der Test ϕ mit $H_0: \nu = 1$ gegen $H_1: \nu \neq 1$ durchgeführt werden, wobei der Annahmehereich als $A = \{(x_1, \dots, x_n) : \frac{1}{2} < \max(x_1, \dots, x_n) \leq 1\}$ festgelegt wird. Stellen Sie die Gütefunktion $G_\phi(\nu)$ auf. Welches Niveau hat der Test?

Lösung:

Der Ablehnungsbereich ist $R = \mathbb{R}^+ \setminus A = [0, \frac{1}{2}] \cup (1, \infty)$. Die zugehörige Testregel ist

$$\varphi(x) = \begin{cases} 0 & : x \in (\frac{1}{2}, 1] \\ 1 & : \text{sonst} \end{cases},$$

wobei $x = \max(x_1, \dots, x_n)$. Da es sich um einen deterministischen Test handelt, gilt für die Gütefunktion $G_\varphi(\nu) = \mathbb{E}_\nu(\varphi) = \mathbb{P}_\nu(x \in R)$, d.h.

$$\begin{aligned} G_\varphi(\nu) &= \mathbb{P}_\nu(x \in R) \\ &= \mathbb{P}_\nu(x \leq 0.5) + \mathbb{P}(x > 1) \\ &= \begin{cases} 1 & : \nu \leq 0.5 \\ \left(\frac{0.5}{\nu}\right)^n & : 0.5 < \nu \leq 1 \\ \left(\frac{0.5}{\nu}\right)^n + \left(\frac{\nu-1}{\nu}\right)^n & : \nu > 1 \end{cases}. \end{aligned}$$

Demnach ist $G_\varphi(1) = \left(\frac{1}{2}\right)^n$, und dies ist die Wahrscheinlichkeit für einen Fehler erster Art und damit auch das Niveau des Testes.