



11. Übungsblatt zur „Mathematik und Statistik für Biologie“

Aufgabe 41

Ward und Quinn sammelten Eikapseln der Raubschneckenart "Ipsosiphonia vinosa" in unterschiedlichen Gebieten einer felsigen Gezeitenküste. Untersucht wurden Unterschiede bei der Fruchtbarkeit der Schneckenart in den verschiedenen Gebieten. In einem bestimmten Gebiet wurden 37 Eikapseln gesammelt. Bei den in diesem Gebiet gesammelten Kapseln lag die durchschnittliche Anzahl der Eier pro Kapsel bei 8.07 bei einer empirischen Standardabweichung von 2.03. Wir nehmen an, dass die ermittelten Werte Realisierungen von unabhängigen und identisch verteilten Zufallsvariablen X_1, \dots, X_{37} sind. Außerdem können wir auf Grund weiterer Untersuchungen davon ausgehen, dass die empirische Standardabweichung mit der wirklichen Standardabweichung übereinstimmt.

Wir möchten nun ein *zweiseitiges Konfidenzintervall* $K_n(x_1, \dots, x_n)$ zum Niveau $\alpha = 0.95$ für den Erwartungswert der Zufallsvariablen X_1 bestimmen. D.h. es soll gelten:

$$\mathbf{P}[\mathbf{E}X_1 \in K_n(x_1, \dots, x_n)] \geq \alpha = 0.95.$$

- (a) Zeigen Sie mit Hilfe von bekannten Rechenregeln für Erwartungswert und Varianz, dass

$$\frac{\sum_{i=1}^n X_i - \mathbf{E}(\sum_{i=1}^n X_i)}{\sqrt{V(\sum_{i=1}^n X_i)}} = \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right).$$

- (b) Zeigen Sie nun, dass (für $u > 0$) aus $\left| \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right) \right| \leq u$ folgt, dass

$$\mathbf{E}X_1 \in \left[\frac{1}{n} \sum_{i=1}^n X_i - \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u, \frac{1}{n} \sum_{i=1}^n X_i + \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \right].$$

- (c) Benutzen Sie nun den *zentralen Grenzwertsatz* und dass für eine standardnormalverteilte (d.h. $\mathcal{N}(0, 1)$ -verteilte) Zufallsvariable Z

$$P(|Z| \leq u_{0.025}) \geq 0.95 \quad \text{mit} \quad u_{0.025} \approx 1.96$$

ist, um das gesuchte Konfidenzintervall zu bestimmen.

Lösung:

- (a) Nach der Vorlesung ist $\mathbf{E}(\sum_{i=1}^n X_i) = \sum_{i=1}^n \mathbf{E}X_i = n \cdot \mathbf{E}X_1$ und $V(\sum_{i=1}^n X_i) = \sum_{i=1}^n V(X_i) = n \cdot V(X_1)$, falls X_1, \dots, X_n unabhängig und identisch verteilt sind. Damit ergibt sich:

$$\begin{aligned} \frac{\sum_{i=1}^n X_i - \mathbf{E}(\sum_{i=1}^n X_i)}{\sqrt{V(\sum_{i=1}^n X_i)}} &= \frac{\sum_{i=1}^n X_i - n \cdot \mathbf{E}X_1}{\sqrt{n \cdot V(X_1)}} = \frac{n \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right)}{\sqrt{n} \sqrt{V(X_1)}} \\ &= \frac{\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right)}{\sqrt{V(X_1)}} = \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right). \end{aligned}$$

(b) Auflösen des Betrages ergibt:

$$\begin{aligned} & \left| \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right) \right| \leq u \\ \Leftrightarrow & \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right) \leq u \quad \wedge \quad -\frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right) \leq u \\ \Leftrightarrow & \frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \leq \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \quad \wedge \quad \frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \geq -\frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \\ \Leftrightarrow & \frac{1}{n} \sum_{i=1}^n X_i - \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \leq \mathbf{E}X_1 \quad \wedge \quad \frac{1}{n} \sum_{i=1}^n X_i + \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \geq \mathbf{E}X_1 \end{aligned}$$

Was aber natürlich gleichbedeutend ist zu:

$$\mathbf{E}X_1 \in \left[\frac{1}{n} \sum_{i=1}^n X_i - \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u, \frac{1}{n} \sum_{i=1}^n X_i + \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u \right].$$

(c) Nach dem zentralen Grenzwertsatz und Teil (a) ist $Z := \frac{\sqrt{n}}{\sqrt{V(X_1)}} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbf{E}X_1 \right)$ eine annähernd $\mathcal{N}(0, 1)$ -verteilte Zufallsvariable. Damit gilt mit Teil (b):

$$P(|Z| \leq u_{0.025}) = P\left(\mathbf{E}X_1 \in \left[\frac{1}{n} \sum_{i=1}^n X_i - \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u_{0.025}, \frac{1}{n} \sum_{i=1}^n X_i + \frac{\sqrt{V(X_1)}}{\sqrt{n}} \cdot u_{0.025} \right]\right) \geq 0.95$$

Also ist das gesuchte Konfidenzintervall gegeben durch:

$$\left[8.07 - \frac{2.03}{\sqrt{37}} \cdot 1.96, 8.07 + \frac{2.03}{\sqrt{37}} \cdot 1.96 \right] \approx [7.4159, 8.7241].$$

Aufgabe 42

Gegeben seien auf dem Intervall $[a, 3a]$ unabhängig identisch gleichverteilte Zufallsvariablen X_1, \dots, X_n , $n \in \mathbb{N}$ und $a \in \mathbb{R}$. Wir möchten nun den Parameter

$$a = \frac{1}{2} \mathbf{E}X_1$$

mit Hilfe von Realisierungen von X_1, \dots, X_n schätzen. Geben Sie eine geeignete Schätzung dafür an und zeigen Sie, dass die Schätzung erwartungstreu und konsistent ist.

Hinweis: Modifizieren Sie den Schätzer aus der Vorlesung.

Lösung: Es ist bekannt, dass eine auf dem Intervall $[a, b]$ gleichverteilte Zufallsvariablen den Erwartungswert $\frac{a+b}{2}$ haben, wobei der Schätzer für den Erwartungswert aus der Vorlesung bekannt ist. Damit ist der gesuchte Schätzer

$$T(x_1, \dots, x_n) = \frac{1}{2} \cdot \frac{x_1 + \dots + x_n}{n}$$

mit

$$\mathbf{E}(T(X_1, \dots, X_n)) = \mathbf{E}\left(\frac{1}{2n} \sum_{i=1}^n X_i\right) = \frac{1}{2n} \sum_{i=1}^n \mathbf{E}(X_i) = \frac{1}{2} \mathbf{E}(X_1) = a$$

erwartungstreu. Er ist auch konsistent, weil $2 \cdot T(X_1, \dots, X_n)$ nach Vorlesung ein konsistenter Schätzer ist.

Aufgabe 43

Im Rahmen einer Studie möchte Biologie B. untersuchen, wie weit ein bestimmtes Merkmal bei Honigbienen verbreitet ist. Dazu betrachtet er zufällig ausgewählte Bienen mehrerer Bienenstöcke. B. überlegt sich folgende Modellannahmen: Jede Biene hat das untersuchte Merkmal mit der selben Wahrscheinlichkeit p unabhängig von allen anderen Tieren. Die Zufallsvariable X_i verwendet er zur mathematischen Modellierung der i -ten Beobachtung. X_i erhält den Wert 1, falls die i -te Biene das Merkmal aufweist und 0 sonst. Die Gesamtanzahl aller betrachteten Bienen sei n .

Geben Sie einen erwartungstreuen und konsistenten Schätzer für den Parameter p an und begründen Sie, dass der von ihnen angegebene Schätzer diese Eigenschaften hat.

Lösung: X_1, \dots, X_n sind jeweils binomialverteilt mit Parametern 1 und p . Außerdem sind sie wegen der gemachten Modellannahmen unabhängig. Für die Binomialverteilung mit Parametern 1 und p gilt

$$p = \mathbf{E}X.$$

Nach der Vorlesung ist

$$T(x_1, \dots, x_n) = \frac{x_1 + \dots + x_n}{n}$$

ein konsistenter und erwartungstreuer Schätzer für den Erwartungswert, deshalb haben wir mit $T(X_1, \dots, X_n)$ einen erwartungstreuen und konsistenten Schätzer für p .

Aufgabe 44

Wir wollen bei einem Multiple-Choice-Test überprüfen, ob ein Teilnehmer die Antworten durch einfaches Raten ermittelt hat. Dazu beschreiben wir die (richtige) Beantwortung jeder Frage mit einer $b(1, p)$ -verteilten Zufallsvariable und nehmen an, dass die Fragen unabhängig von einander beantwortet wurden. Bei jeder der $n = 8$ Aufgaben war genau eine der 4 angegebenen Antworten richtig. Um nun zwischen den beiden Hypothesen

$$H_0 : p = 0.25 \quad H_1 : p > 0.25$$

zu entscheiden, soll der Test

$$\varphi(x_1, \dots, x_n) = \begin{cases} 1 & \text{falls } \sum_{i=1}^n x_i \geq c \\ 0 & \text{falls } \sum_{i=1}^n x_i < c \end{cases}$$

verwendet werden. Bestimmen Sie den kleinsten Parameter $c \in \{1, \dots, n\}$ so, dass dies zu einem Test zum Niveau $\alpha = 0.05$ wird.

Lösung: Für unabhängige $b(1, p)$ -verteilte Zufallsvariablen X_1, \dots, X_n ist $\sum_{i=1}^n X_i$ eine $b(n, p)$ -verteilte Zufallsvariable. Daher ist die Fehlerwahrscheinlichkeit erster Art dieses Tests gegeben durch:

$$\begin{aligned} \mathbf{P}_{p=0.25}[\varphi(X_1, \dots, X_n) = 1] &= \mathbf{P}_{p=0.25}\left[\sum_{i=1}^n X_i \geq c\right] \\ &= \mathbf{P}_{p=0.25}\left[\sum_{i=1}^n X_i = n\right] + \mathbf{P}_{p=0.25}\left[\sum_{i=1}^n X_i = n-1\right] + \dots + \mathbf{P}_{p=0.25}\left[\sum_{i=1}^n X_i = c\right] \\ &= \binom{n}{n} \cdot p^n \cdot (1-p)^0 + \binom{n}{n-1} \cdot p^{(n-1)} \cdot (1-p)^1 + \dots + \binom{n}{c} \cdot p^{(n-c)} \cdot (1-p)^c \end{aligned}$$

Für $n = 8$ und $p = 0.25$ erhalten wir:

$$\binom{8}{8} \cdot 0.25^8 \cdot 0.75^0 = 0.000015$$

$$\binom{8}{7} \cdot 0.25^7 \cdot 0.75^1 = 0.000366$$

$$\binom{8}{6} \cdot 0.25^6 \cdot 0.75^2 = 0.003845$$

$$\binom{8}{5} \cdot 0.25^5 \cdot 0.75^3 = 0.023071$$

$$\binom{8}{4} \cdot 0.25^4 \cdot 0.75^4 = 0.086517$$

Also ist $c = 5$ der kleinste Parameter, so dass $\mathbf{P}_{p=0.25}[\varphi(X_1, \dots, X_n) = 1] \leq \alpha = 0.05$.