

4. Übungsblatt „Einführung in die Statistik“

Abgabe bis Dienstag 7.5, 13 Uhr, bei Ihrem Tutor.

Ab jetzt werden wir R als „Taschenrechner“ verwenden. Installieren Sie RStudio auf Ihrem Computer, und machen Sie sich damit vertraut, wie man statistische Datensätze darstellt (z.B. in einer Excel-Datei), in R einliest (z.B. als Datei-Import oder über die Zwischenablage), modifiziert (z.B. mit `fix()`), und wie man auf einzelne Variablen zugreift und diese graphisch darstellt. Literatur siehe Vorlesungshomepage, zum Beispiel Kapitel 2 im Skript „Datenanalyse mit R“ von T. Petzoldt.

1. (Dualität von Konfidenzbereichen und Hypothesentests)

Sei $(\Omega, \mathcal{A}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$ ein statistisches Modell, $X : \Omega \rightarrow S$ die Stichprobe, und $g : \Theta \rightarrow \mathbb{R}$.

- a) Zeigen Sie: Ist $C(x)$ ein Konfidenzbereich für $g(\vartheta)$ zum Niveau $1 - \alpha$, dann ist

$$A(m_0) = \{x \in S : m_0 \in C(x)\}$$

für $m_0 \in \mathbb{R}$ der Akzeptanzbereich eines Tests zum Niveau α der Hypothese $g(\theta) = m_0$.

- b) Umgekehrt sei $A(m_0)$ für jedes m_0 der Akzeptanzbereich eines Tests der Hypothese $g(\theta) = m_0$ zum Signifikanzniveau α . Konstruieren Sie einen Konfidenzbereich für $g(\theta)$ zum Niveau $1 - \alpha$.
- c) Illustrieren Sie die Aussagen anhand von Beispielen.

2. (Parameterschätzung im Poisson-Modell) Seien x_1, x_2, \dots, x_n unabhängige Stichproben von der Poisson-Verteilung mit unbekannter Intensität λ . Zum Beispiel beschreibt x_i die Anzahl der Schadensfälle, die bei einer Versicherung am Tag i gemeldet werden.

- a) Geben Sie ein statistisches Modell an, und zeigen Sie, dass die Statistik $S = X_1 + X_2 + \dots + X_n$ suffizient für λ ist.
- b) Bestimmen Sie den Maximum-Likelihood-Schätzer $\hat{\lambda}$.
- c) Zeigen Sie, dass n unabhängige Stichproben von $\text{Poisson}(\lambda)$ auch mit dem folgenden Zweistufenmodell erzeugt werden können:
- Ziehe eine Stichprobe s von der Poisson-Verteilung mit Parameter $n\lambda$.
 - Gegeben s , ziehe $(x_1, \dots, x_n) \sim \text{Mult}(s, \mathbf{p})$, wobei $\mathbf{p} = (p_k)_{k=1, \dots, n}$ mit $p_k = 1/n$ die Gleichverteilung auf der Menge $\{1, \dots, n\}$ ist.

3. (Minimale Suffizienz) Eine Statistik $T(X)$ heißt *minimal sufficient*, falls sie suffizient ist, und sich als Funktion von jeder anderen suffizienten Statistik darstellen lässt. Für ein reguläres statistisches Modell definieren wir eine Äquivalenzrelation auf dem Stichprobenraum S durch $x \sim y$ genau dann, wenn die Likelihood-Funktionen $\theta \mapsto L(\theta; x)$ und $\theta \mapsto L(\theta; y)$ zueinander proportional sind. Zeigen Sie:

a) Eine Statistik $T(X)$ ist genau dann suffizient, wenn für alle $x, y \in S$ gilt:

$$T(x) = T(y) \implies x \sim y.$$

b) $T(X)$ ist genau dann minimal sufficient, wenn für alle $x, y \in S$ gilt:

$$T(x) = T(y) \iff x \sim y.$$

c) Welche der folgenden Statistiken im Gaußschen Produktmodell sind suffizient bzw. minimal suffizient?

$$T_1(X) = (X_1, \dots, X_n), \quad T_2(X) = (\bar{X}_n, V_n^*), \quad T_3(X) = \bar{X}_n, \quad T_4(X) = (\bar{X}_n, V_n, X_1).$$

4. (Beispiele zu Konfidenzbereichen für einen Binomialparameter) Definieren Sie für die folgenden Anwendungssituationen jeweils einen geeigneten Wahrscheinlichkeitsparameter p und überlegen Sie, ob hierfür eine untere Konfidenzschranke, eine obere Konfidenzschranke oder ein Konfidenzintervall besonders geeignet wäre. Berechnen Sie jeweils approximative und exakte Konfidenzbereiche zum Niveau $1 - \alpha$ mit $\alpha = 5\%$.

- Wie verbreitet ist Flugangst? Anlässlich eines spektakulären ‘Fluchtversuches’ eines Flugpassagiers kurz vor dem Start äußerten sich 240 Schweizer zu der Frage, ob sie unter Flugangst leiden. Ergebnis: 41 Personen antworteten mit ‘ja’.
- Ein Anbieter eines WLAN-Routers möchte untermauern, dass die meisten Kunden mit der neuen Installationssoftware gut zurechtkommen. Zu diesem Zweck recherchiert er über sein Callcenter, wie viele von 1400 Neukunden die Service-Hotline in Anspruch nahmen. Ergebnis: 11 Kunden ließen sich wegen Problemen bei der Installation beraten.
- Möchte die Mehrheit der Wahlberechtigten gerne per Internet abstimmen? Man fragte 88 Personen, ob sie den Gang zur Urne, eine Briefwahl oder eine Online-Wahl bevorzugen würden. Ergebnis: 60 Personen bevorzugten die Online-Wahl.

Hinweis zu R: Mit den Befehlen

$$\text{binom.test}(x = H, n = n), \quad \text{binom.test}(x = H, n = n, \text{conf.level} = 1 - \alpha)$$

erhalten Sie das $(1 - \alpha)$ -Konfidenzintervall $[a_{\alpha/2}(H), b_{\alpha/2}(H)]$ für den Parameter p im Modell $H \sim \text{Bin}(n, p)$. Mit

$$\text{binom.test}(\dots, \text{alternative} = \text{'less'}), \quad \text{binom.test}(\dots, \text{alternative} = \text{'greater'})$$

erhalten Sie das Intervall $[0, b_\alpha(H)]$ bzw. $[a_\alpha(H), 1]$.