

9. Übungsblatt „Einführung in die Statistik“

Abgabe bis Dienstag 18.6.

1. (Benfordsches Gesetz) Welcher Verteilung gehorcht die erste Ziffer einer Zahl?

- a) Wir betrachten folgende Stichprobe: Aus einem Ortsverzeichnis wurde zufällig eine Seite aufgeschlagen. Diese enthält 305 Orte. In der Tabelle unten ist nun aufgeführt, in wie vielen Orten die Einwohnerzahl mit den Ziffern $1, 2, \dots, 9$ beginnt.

Erste Ziffer	1	2	3	4	5	6	7	8	9
Häufigkeit	107	55	39	22	13	18	13	23	15

- (i) Testen Sie die Hypothese, dass diese Ziffern auf der Menge $\{1, 2, \dots, 9\}$ gleichverteilt sind.
- (ii) Testen Sie die Hypothese, dass die Ziffern der Benford-Verteilung gehorchen, d.h.

$$\mathbb{P}(\text{Erste Ziffer} = k) = \log_{10}(1 + 1/k) \quad \text{für } k = 1, 2, \dots, 9.$$

- b) Hinter der Benford-Verteilung steht ein allgemeines Phänomen: Ist X eine Zufallsvariable mit stetiger Verteilungsfunktion F auf \mathbb{R} , und ist diese Verteilung „recht diffus“, dann ist die Zufallsvariable $Y = X - \lfloor X \rfloor$ „näherungsweise“ gleichverteilt auf $[0, 1)$. Diese vage Aussage lässt sich mathematisch präzisieren. Sei Z eine Zufallsvariable mit stetiger Verteilung auf $(0, \infty)$. Diese schreiben wir als Dezimalzahl

$$Z = Z_0, Z_1 Z_2 Z_3 \dots \cdot 10^W = (Z_0 + 10^{-1} Z_1 + 10^{-2} Z_2 + 10^{-3} Z_3 + \dots) \cdot 10^W$$

mit Ziffern $Z_0 \in \{1, \dots, 9\}$, $Z_1, Z_2, Z_3, \dots \in \{0, 1, \dots, 9\}$ und einem ganzzahligen Exponenten W . Wir gehen davon aus, dass $X = \log_{10}(Z)$ „recht diffus“ verteilt ist. Wie kann man nun aus dem oben beschriebenen Phänomen ableiten, dass

$$\mathbb{P}(Z_0 = k) \approx \log_{10}(1 + 1/k) \quad \text{für } k = 1, 2, \dots, 9 ?$$

Anmerkung: Das Benfordsche Gesetz wird beispielsweise bei Steuerprüfungen verwendet, um Manipulationen von Datenmaterial aufzuspüren.

2. (Monte-Carlo- p -Werte) Für eine Teststatistik $t = T(\text{Daten})$ betrachten wir den p -Wert

$$p := 1 - F_0(t-)$$

für eine gegebene Verteilungsfunktion F_0 sowie den Monte-Carlo- p -Wert

$$\hat{p} := \frac{\#\{s \in \{1, \dots, B\} : T_s \geq t\} + 1}{B + 1}.$$

Dabei sind T_1, T_2, \dots, T_B untereinander (und von den Daten) unabhängige, nach F_0 verteilte Zufallsvariablen. Nun vergleichen wir p und \hat{p} bei gegebenen Daten, berücksichtigen also nur den Zufall in den (simulierten) Variablen T_1, \dots, T_B . Zeigen Sie, dass

$$\mathbb{E} [(\hat{p} - p)^2] \leq \frac{1}{4B + 1} \quad \text{falls } B \geq 2.$$

3. (Bootstrap-Konfidenzintervalle für Korrelationskoeffizienten) Auf der Vorlesungshomepage finden Sie unter “Vergleich Abiturnoten Bachelornoten” einen Datensatz, in dem die Abiturnoten und die Bachelorabschlussnoten von 15 Studierenden verglichen werden.

- a) Berechnen Sie einen Plug-in-Schätzer $\hat{\rho}$ für die Korrelation ρ zwischen Abitur- und Bachelornoten.
- b) Geben Sie in Pseudocode einen Algorithmus zur Simulation von $B = 1000$ Bootstrap-Replikationen des Datensatzes an.
- c) Implementieren Sie den Algorithmus und berechnen Sie die entsprechenden Bootstrap-Schätzwerte für die Korrelation. Stellen Sie die empirische Verteilung der Bootstrap-Stichprobe graphisch als Histogramm dar.
- d) Berechnen Sie einen Bootstrap-Schätzer für die Standardabweichung von $\hat{\rho}$, und bestimmen Sie Bootstrap-Konfidenzintervalle für ρ zum Niveau 95% mit und ohne Verwendung einer Normalapproximation.
- e) Diskutieren Sie die Ergebnisse.

4. (Computer-Experiment zum Bootstrap-Verfahren) Seien $X_1, \dots, X_n \sim \mathcal{N}(m, 1)$. Zum Schätzen von $g(m) = e^m$ verwenden wir den Plug-in-Schätzer $\hat{g} = e^{\bar{X}_n}$

- a) Simulieren Sie für $m = 5$ eine Stichprobe $x = (x_1, \dots, x_n)$ mit $n = 100$ Stichprobenwerten, und berechnen Sie den Wert von \hat{g} .
- b) Schätzen Sie mithilfe eines Bootstrap-Verfahrens die Standardabweichung von \hat{g} und berechnen Sie ein Bootstrap-Konfidenzintervall für e^m zum Niveau 95%.
- c) Erstellen Sie ein Histogramm der Bootstrap-Replikationen, und vergleichen Sie dieses mit der tatsächlichen Verteilung von \hat{g} .
- d) Diskutieren Sie die Ergebnisse.