

## Übung 1

1. a) Sei  $\hat{\mu}_n$  das  $\alpha$ -gestutzte Mittel von  $(X_1, \dots, X_n)$ . Berechne seine Veränderung bei Hinzufügen einer zusätzlichen Beobachtung bei  $x$ , d. h.

$$\hat{\mu}_{n+1}(x_1, \dots, x_n, x) - \hat{\mu}_n(x_1, \dots, x_n)$$

im Fall  $[n\alpha] = [(n+1)\alpha]$ . Gib auch die Sensitivität des  $\alpha$ -gestutzten Mittels an.

- b) Wir betrachten das Modell  $Y_i = \beta X_i + \epsilon_i$ ,  $i = 1, \dots, n$  mit  $X_i > 0$  zufällig. Das heisst, dass  $Y$  bis auf einen zufälligen Fehler proportional ist zu  $X$ . Berechne den empirischen Bruchpunkt des Schätzers

$$\hat{\beta} = \operatorname{argmin}_{\beta} \sum_{i=1}^n |y_i - \beta x_i|,$$

d. h. den minimalen Anteil von Ausreissern unter den Paaren  $(y_i, x_i)$ , der zum Zusammenbruch von  $\hat{\beta}$  führt.

*Hinweis:* Schreibe  $\hat{\beta} = \operatorname{argmin}_{\beta} \sum_{i=1}^n w_i |z_i - \beta|$ , wobei  $z_i = y_i/x_i$ ,  $w_i = \frac{x_i}{x_1 + \dots + x_n}$ . Wenn wir die Zufallsvariable  $Z$  einführen, die den Wert  $z_i$  mit Wahrscheinlichkeit  $w_i$  annimmt, dann können wir  $\hat{\beta}$  berechnen mithilfe von Satz A.8.

- c) Wir betrachten das Modell  $Y_i = \beta x_i + \epsilon_i$ ,  $i = 1, \dots, n$  mit  $x_i = \frac{i}{n}$  fest. Berechne den empirischen Bruchpunkt des oben angegebenen Schätzers für  $n \rightarrow \infty$ .

2. Sei  $X_i = \mu + \epsilon_i$   $i = 1, 2, \dots$ , wobei die  $\epsilon_i$  i.i.d. sind mit Dichte

$$f_{\lambda}(x) = \frac{1}{\pi} \frac{\lambda}{\lambda^2 + x^2}$$

( $\lambda$  ist ein Parameter, der die Streuung der  $\epsilon_i$  beschreibt). Diese Verteilung heisst Cauchyverteilung.

- a) (freiwillig) Es gilt, dass  $\sum_{i=1}^n \epsilon_i$  Cauchy( $n\lambda$ )-verteilt ist. Zeige dies im Falle, wo  $\lambda = 1$ ,  $n = 2$ , d.h. berechne die Dichte von  $\epsilon_1 + \epsilon_2$  mit der Faltungsformel.

*Hinweis:* Benütze die folgende Partialbruchzerlegung

$$\frac{1}{1+y^2} - \frac{1}{1+(x-y)^2} = \frac{1}{x(4+x^2)} \left[ \frac{2y+x}{1+y^2} + \frac{2(x-y)+x}{1+(x-y)^2} \right].$$

- b) Folgere aus a), dass  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  die gleiche Verteilung hat wie  $X_1$ . Ist das ein Widerspruch zum Gesetz der grossen Zahlen?

- c) Sei  $\hat{\mu}_n = \operatorname{median}(X_1, \dots, X_n)$ . Berechne  $\lim_{n \rightarrow \infty} P[|\hat{\mu}_{2n+1} - \mu| > c]$  ( $c > 0$ ).  
*Hinweis:* Überlege, dass

$$P[\hat{\mu}_{2n+1} > \mu + c] = P\left[\sum_{i=1}^{2n+1} 1_{\{X_i > \mu + c\}} > n\right]$$

gilt, und wende das Gesetz der grossen Zahlen an.

- d) Welcher der beiden Schätzer, arithmetisches Mittel oder Median, ist also in diesem Fall vorzuziehen, wenn man  $P[|\hat{\mu}_n - \mu| \leq c]$  als Genauigkeitsmass verwendet?

3. Wir definieren (mit  $\tilde{X} = (X_1, \dots, X_n)$ ):

$$\text{MAD}(\tilde{X}) = \text{median}(|X_1 - \text{median}(\tilde{X})|, \dots, |X_n - \text{median}(\tilde{X})|),$$

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

Die ersten 10 Werte des Lichtgeschwindigkeits-Datensatzes aus der Vorlesung sind 28 26 33 24 34 -44 27 16 40 -2.

Berechne für diesen Teildatensatz

- a) arithmetisches Mittel,
- b) arithmetisches Mittel der nicht verworfenen Daten unter folgender Verwerfungsregel: Verwerfe alle Daten, die weiter als  $5\text{MAD}(\tilde{X})$  entfernt vom Median sind,
- c) arithmetisches Mittel der nicht verworfenen Daten unter folgender Verwerfungsregel: Verwerfe alle Daten, die weiter als  $2.29\sqrt{S_n}$  entfernt vom arithmetischen Mittel aller Daten sind,
- d) 0.1- und 0.2-gestutztes Mittel,
- e) (freiwillig) eine sinnvolle Näherung des Huber-Schätzers mit dem im Skript angegebenen Wert von  $c$ ,
- f) den Vertrauensbereich zum Niveau 0.95 für  $\mu$  basierend auf dem t-verteilten Pivot auf Skript S. 5 unten (die benötigten oberen und unteren Quantile der t-Verteilung mit 9 Freiheitsgraden sind  $\pm 2.26$ ),
- g) den Vertrauensbereich zum Niveau 0.95 für  $\mu$  basierend auf dem Binomial-verteilten Pivot auf Skript S. 6 oben ( $k_{0.025} = 2$ ).

Trage den Datensatz und alle berechneten Schätzer und Bereiche auf eine Zahlengerade auf. Diskutiere die Schätzer im Lichte des gesamten Lichtgeschwindigkeits-Datensatzes.

**Abgabe:** Montag, 12. November