

## Simulations

Sie möchten den Zusammenhang zwischen einer skalaren Zielgröße  $y$  und zwei Einflussgrößen mittels eines linearen Regressionsmodells beschreiben. Dabei gilt:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i, \quad i = 1, \dots, n, \quad \epsilon_i \sim N(0, \sigma^2)$$

- a) Schreiben Sie eine Funktion `sim_data()`, die Daten  $(\mathbf{y}, \mathbf{X})$  gemäß des obigen Modells für beliebige Werte von  $n, \sigma^2, \beta_0, \beta_1$  und  $\beta_2$  erzeugt. Dabei soll gelten:

$$x_{i1} \sim B(0.5) \quad \text{und} \quad x_{i2} \sim N(0, 1), \quad i = 1, \dots, n$$

Die Funktion soll einen Datensatz zurückgeben, der die Spalten `y`, `x1` und `x2` enthält.

- b) Schreiben Sie eine Funktion `est_model()`, die ein lineares Modell der Daten aus a) berechnet und den MSE  $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$  der Schätzung zurückgibt.
- c) Schreiben Sie eine Funktion `get_MSEs()`, die für beliebige (skalare) Parameter  $n, \sigma^2, \beta_0, \beta_1, \beta_2$  und eine beliebige Anzahl an Wiederholungen (`n_rep`) Daten gemäß des obigen Modells simuliert und den MSE für alle Wiederholungen berechnet. Output der Funktion soll ein Vektor aller MSEs sein.
- d) Führen Sie die Funktion aus c) mit verschiedenen Stichprobenumfängen  $n \in \{100, 200, \dots, 1000\}$  und festen Parametern  $\sigma^2 = 2, \beta_0 = 1, \beta_1 = 0.5, \beta_2 = 1.5$  sowie  $n_{rep} = 200$  durch und speichern Sie die Ergebnisse als Matrix.
- e) Visualisieren Sie Ihre Ergebnisse aus d), z.B. mithilfe von Boxplots, und vergleichen Sie diese.

Hinweis: Es ist hilfreich, wenn Sie jede einzelne Funktion jeweils durch geeignete Funktionsaufrufe testen.

*\* Durch Lösen dieser Übungsaufgabe kann ein Teil der Prüfungsleistung erbracht werden.*

**Abgabetermin: 05.07.2016/06.07.2016**