

2. Computerübung zur Mathematischen Statistik

Aufgabe 1 (Einfache Lineare Regression)

- Lesen Sie den Datensatz `miete.sav` in einen Data-Frame `miete` ein. Schauen Sie sich den Datensatz mit dem Befehl `brush(miete)` an.
- Stellen Sie für die stetigen Variablen den Zusammenhang zur Nettomiete pro Quadratmeter jeweils in einem Streudiagramm dar.
- Testen Sie, ob sich die Mittelwerte der Nettomiete pro Quadratmeter in den beiden Kategorien der binären Variablen unterscheiden. Hinweis: Verwenden Sie die Funktion `t.test()`
- Betrachten Sie bei den Mietspiegeldaten die Einfachregression

$$NMQM = \alpha + \beta * FLAECHE$$

Schätzen Sie die Koeffizienten der Regression und die Varianz.

- Verwenden Sie die erhaltenen Schätzungen $\hat{\alpha}$, $\hat{\beta}$ und $\hat{\sigma}^2$ um neue Daten `nmqm.sim` zu simulieren:
 $nmqm.sim_i \approx N(\hat{\alpha} + \hat{\beta} * FLAECHE_i, \hat{\sigma}^2)$
- Berechnen Sie anschließend die Regression

$$nmqm.sim = \alpha^* + \beta^* * FLAECHE$$

und vergleichen Sie die Regressionsergebnisse des simulierten Datensatzes mit denen der Originaldaten.

Aufgabe 2 (Multiple Regression) Verwenden Sie die Daten aus Aufgabe 1!

- Schätzen Sie ein multiples Regressionsmodell für die Nettomiete pro Quadratmeter (ohne die Variable `MIETE`)
- Untersuchen und interpretieren Sie die Ergebnisse mit den Funktionen `summary()` und `plot()`. Welche Variablen sind als Einflussgrößen sinnvoll?

Aufgabe 3 (MSE Kriterium von Schätzern)

Gegeben sei eine Stichprobe vom Umfang n einer Binomialverteilung $B(n, p)$ mit unbekanntem Parameter $0 < p < 1$. Der Maximum-Likelihood-Schätzer ist gegeben durch $\hat{p}_{ML} := \bar{X}_n$. Als alternativen Schätzer betrachten wir

$$\hat{p}_a := \frac{\sum_{i=1}^n x_i + 1}{n + 2}$$

- Ist \hat{p}_a erwartungstreu?
- Bestimmen Sie die mittlere quadratische Abweichung (MSE) von \hat{p}_a .
[$MSE(\hat{p}_a) = \text{Var}(\hat{p}_a) + \text{Bias}^2$, $\text{Bias} = E(\hat{p}_a - p)$]
- Vergleichen Sie Ihr Ergebnis aus (b) mit der mittleren quadratischen Abweichung von \hat{p}_{ML} für $n=8$ und $n=40$. Stellen Sie dazu den MSE als Funktion des wahren Parameters p dar. Was schließen Sie aus dem Vergleich?

Die Datensätze finden sie auf <http://www.math.uni-konstanz.de/~beran/MathstatistikWS07.html>.