

## Probe-Klausur zur Vorlesung Ökonometrie

Theorie-Teil: Aufgaben 1-3: 30 Punkte

Programmier-Teil: Aufgaben 4-8: 60 Punkte

(die eigentliche Klausur wird deutlich kürzer)

**1. Aufgabe (10 Punkte):** Es sei

$$\vec{x} = (-5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5)$$

und  $\vec{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_{11})$  seien mit Mittelwert 0 und Standardabweichung  $\sigma$  normalverteilte Zufallszahlen.

a) Betrachten Sie das Regressionsproblem

$$\vec{y} = \beta_1 \vec{x} + \vec{\varepsilon}$$

Geben Sie den Maximum-Likelihood-Schätzer  $\hat{\beta}_1$  an und vereinfachen Sie den Ausdruck soweit wie möglich. Benutzen Sie dazu die konkreten Werte der  $x_i$  (die  $y_i$  sollen variabel sein, da haben Sie also Buchstaben, keine Zahlen).

b) Betrachten Sie das Regressionsproblem ( $i = 1, 2, \dots, 11$ )

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

Geben Sie die Maximum-Likelihood-Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  an und vereinfachen Sie die Ausdrücke soweit wie möglich.

c) Geben Sie Formeln für die Varianzen von  $\hat{\beta}_0$  und  $\hat{\beta}_1$  aus Teil (b) an und vereinfachen Sie die Ausdrücke soweit wie möglich.

**2. Aufgabe (10 Punkte):** (ÜBlatt4, Aufg.1) Gegeben sei die Matrix  $X$  der Regressoren  $\vec{x}_1$  und  $\vec{x}_2$ ,

$$X = \begin{pmatrix} | & | \\ \vec{x}_1 & \vec{x}_2 \\ | & | \end{pmatrix} := \begin{pmatrix} 1 & 1 \\ 1 & -1 \\ 0 & 1 \end{pmatrix}$$

und

$$\vec{y} := \begin{pmatrix} 6 \\ 0 \\ 0 \end{pmatrix}$$

- a) Berechnen Sie die orthogonale Projektion  $P_X \in \mathbb{R}^{3 \times 3}$  auf den durch  $\vec{x}_1$  und  $\vec{x}_2$  aufgespannten Unterraum  $L_X$ .
- b) Berechnen Sie die Bestapproximation in  $L_X$

$$\vec{y}_{\min} = P_X \vec{y}$$

an das  $\vec{y}$ .

- c) Berechnen Sie die Regressionskoeffizienten  $\beta_1$  und  $\beta_2$  für die Bestapproximation, also die Koeffizienten  $\beta_1$  und  $\beta_2$  so dass gilt

$$\vec{y}_{\min} = \beta_1 \vec{x}_1 + \beta_2 \vec{x}_2 .$$

**3.Aufgabe (10 Punkte):** Zufallszahlen  $x_1, x_2, \dots, x_n$  heissen Poisson-verteilt mit Parameter  $\lambda > 0$ , wenn sie ganzzahlig sind,  $x_i \in \mathbb{N}_0 = \{0, 1, 2, \dots\}$  für alle  $i$ , und wenn

$$\text{Prob}[x_i = k] = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, 2, \dots$$

Von der Stichprobe  $x_1, x_2, \dots, x_n$  sei bekannt, dass es mit Parameter  $\lambda > 0$  Poisson-verteilte Zufallszahlen sind, aber der Wert von  $\lambda$  sei unbekannt.

- a) Schätzen Sie  $\lambda$  mit Hilfe der Maximum-Likelihood-Methode, d.h. geben Sie den Maximum-Likelihood-Schätzer  $\hat{\lambda}_{\text{ML}} = \hat{\lambda}_{\text{ML}}(x_1, \dots, x_n)$  für  $\lambda$  an.
- b) Ist der Schätzer aus (a) erwartungstreu? Was müssten Sie hier genau zeigen? Versuchen Sie, möglichst weit zu rechnen.

**Aufgabe 4 (10 Punkte):** Bestimmen Sie die Koeffizienten  $\{c_k\}_{k=0}^{10}$  der Potenzreihenentwicklung

$$\log[1+x] = \sum_{k=0}^{10} c_k x^k + \text{error}$$

numerisch mit Hilfe einer linearen Regression. Gehen Sie dazu folgendermassen vor:

- a) Legen Sie die Variablen  $n = 1000$ ,  $m = 10$  und den Vektor

$$\mathbf{x} = \text{seq}(\text{from} = -0.5, \text{to} = 0.5, \text{length} = \mathbf{n})$$

in R an, wir diskretisieren also das Intervall  $[-0.5, 0.5]$  mit  $n = 1000$  Punkten.

- b) Legen Sie die Matrix  $X$  der Regressoren  $x, x^2, \dots, x^m$  an.
- c) Legen Sie den Vektor  $y = \log[1+x]$  an und führen Sie schliesslich die lineare Regression durch.
- d) Plotten Sie die Grössen  $\{c_k\}_{k=0}^{10}$  und  $\{k c_k\}_{k=0}^{10}$  als Funktion von  $k = 0, 1, \dots, 10$ .
- e) Plotten Sie die Funktion  $\log[1+x]$  und den Regression-Fit über dem Intervall  $[-0.5, 0.5]$  in einem Diagramm, den Regression-Fit in rot.

### Aufgabe 5 (10 Punkte):

- a) Erzeugen Sie  $N = 10000$   $t_4$ -verteilte Zufallszahlen in R und stellen Sie sie in einem Histogramm dar. Wählen Sie die Skalierung des Histogramms so, dass die empirische Verteilung der Zufallszahlen mit der theoretischen Dichte der  $t_4$ -Verteilung vergleichbar ist. Stellen Sie beides in einem Diagramm dar, die theoretische Dichte in rot. Benutzen Sie den `breaks`-Parameter, um die Anzahl der dargestellten Rechtecke im Histogramm zu erhöhen.
- b) Nehmen wir an, Sie wüssten von den Zufallszahlen aus (b) nur, dass sie  $t_n$ -verteilt sind, kennen aber den Wert von  $n$  nicht. Berechnen Sie die log-Likelihood-Funktion zum Schätzen von  $n$  und plotten Sie sie als Funktion von  $n \in \{1, 2, 3, \dots, 19, 20\}$ . Das Maximum sollte dann also in der Nähe von  $n = 4$  liegen.

**Aufgabe 6 (18 Punkte):** Laden Sie sich von der Vorlesungshomepage die Datei `co2levels-MaunaLoa.csv` herunter. Sie enthält Zahlen zur  $\text{CO}_2$ -Konzentration in der Atmosphäre für den Zeitraum 1958 - 2015.

- a) Importieren Sie die Daten nach R und speichern Sie sie in dem Dataframe `co2levels`. Informieren Sie sich über den `na.omit()`-Befehl und eliminieren Sie dann sämtliche Zeilen, die NA's enthalten. Wieviele Observations bleiben dann noch übrig?
- b) Speichern Sie die Daten der Spalte `co2 level` in dem Vektor `yfull` und die Daten der Spalte `trend comp` in dem Vektor `ytrend`. Speichern Sie weiterhin die Daten der Spalte `decimal date` in den Vektor `zeit`. Plotten Sie dann `yfull` und `ytrend` als Funktion von `zeit`. Dabei soll der Plot jeweils aus einer durchgezogenen Linie bestehen, also keine einzelnen Punkte.
- c) Fitten Sie folgende Modelle (mit  $t_0 = 1958.208 = \text{zeit}[1]$ )

$$\text{ytrend}(t) = C_{t_0} e^{r(t-t_0)} \quad (1)$$

$$\text{ytrend}(t) = a_0 + a_1(t - t_0) \quad (2)$$

$$\text{ytrend}(t) = b_0 + b_1(t - t_0) + b_2(t - t_0)^2 \quad (3)$$

an die Daten, d.h., berechnen Sie die Koeffizienten  $C_{t_0}, r, a_0, a_1, b_0, b_1$  und  $b_2$ .

- d) Stellen Sie den Regression-Fit für alle drei Modelle, in rot, grün und blau, zusammen mit den Original-Daten in einem Diagramm dar.
- e) Geben Sie für die Koeffizienten  $a_1$  und  $b_1$  jeweils ein 90%-Vertrauensintervall an.

**Aufgabe 7 (15 Punkte):** Betrachten Sie das Regressionsproblem

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (4)$$

mit

$$\vec{x} = (-5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5)$$

und

$$\begin{aligned}\beta_0 &= 4 \\ \beta_1 &= -1\end{aligned}$$

und  $\sigma = 2$ . Generieren Sie  $N = 10000$  Datenvektoren  $\vec{y}$  mit der Spezifikation (4) und führen Sie für jedes dieser  $\vec{y}$ 's eine lineare Regression für das Modell (4) durch. Zeigen Sie dann, dass die Grösse (für jedes Regressions-Resultat können Sie ein  $\xi$  berechnen)

$$\xi := \frac{(\vec{y} - X\hat{\beta})^2}{\sigma^2} = \frac{(\vec{y} - \hat{y})^2}{\sigma^2} = [n - (p + 1)] \frac{\hat{\sigma}^2}{\sigma^2} = (11 - 2) \frac{\hat{\sigma}^2}{2^2}$$

$\chi_{11-2}^2 = \chi_9^2$ -verteilt ist, indem Sie ein Histogramm der  $\xi$ 's erzeugen und dann diesem Histogramm ein Plot der Dichte der  $\chi_9^2$ -Verteilung, in rot, hinzufügen.

**Aufgabe 8 (7 Punkte):** Wie lautet die Dichte-Funktion  $p_{\mu,\sigma}(x)$  der Normalverteilung mit Mittelwert  $\mu$  und Standardabweichung  $\sigma$ ? Erzeugen Sie  $N = 10000$  mit Parametern  $(\mu, \sigma) = (20, 4)$  normalverteilte Zufallszahlen und stellen Sie sie in einem Histogramm dar. Stellen Sie ebenfalls die theoretische Dichte, in rot, in diesem Histogramm dar. Wählen Sie die Skalierung so, dass Histogramm-Daten und theoretische Dichte miteinander vergleichbar sind.