

## Ökonometrie - Übungsblatt 4

Abgabe am 16. 6. vor Beginn der Übung

- Am Dienstag, dem 9. Juni findet statt der Übung eine Vorlesung statt.
- Am Dienstag, dem 16. Juni findet dann statt der Vorlesung die Besprechung des 4. Übungsblattes statt. Gleichzeitig wird das 5. Übungsblatt veröffentlicht und eine Woche später (am 23. Juni) besprochen.

### Aufgabe 1 (1+4+1,5+1,5+3 Punkte)

Die folgende Aufgabe soll ohne die Verwendung von  $\mathbf{R}$  bearbeitet werden.

Von 8 Angestellten wurden der Stundenlohn in € und die Berufserfahrung in Jahren dokumentiert. Zusätzlich gibt eine Dummy-Variable an, ob die betreffenden Angestellten überdurchschnittlich gut aussehen. Es wird angenommen, dass folgender Zusammenhang gilt:  $\log(y) = \beta_0 + \beta_1 x_1 + \beta_2 x_2$ .

| Stundenlohn ( $y$ ) in € | überdurchschnittliches Aussehen ( $x_1$ ) | Berufserfahrung ( $x_2$ ) in Jahren |
|--------------------------|---|-------------------------------------|
| 11,4                     | 1   | 30                                  |
| 8,5                      | 0   | 28                                  |
| 16                       | 1   | 35                                  |
| 23,1                     | 0   | 38                                  |
| 22,8                     | 0   | 27                                  |
| 7,8                      | 0   | 20                                  |
| 17,6                     | 0   | 12                                  |
| 9,2                      | 1   | 20                                  |

- (a) Welche der folgenden Fälle könnten dazu führen, dass die für Tests der Regressionsparameter betrachteten  $t$ -Statistiken nicht länger  $t$ -verteilt sind:
- (i) Auftreten von Heteroskedastizität,
  - (ii) die Stichprobenkorrelation zwischen zwei unabhängigen Variablen beträgt 0,95,
  - (iii) eine wichtige erklärende Variable wurde weggelassen.
- (b) Bestimme die Regressionsparameter und interpretiere ihre Bedeutung in Worten.
- (c) Schätze die Varianz der Störterme.
- (d) Teste zum Niveau  $\alpha = 0,01$  ob man durch überdurchschnittlich gutes Aussehen einen Gehaltsvorteil erreichen kann.
- (e) Teste zum Niveau  $\alpha = 0,05$  die allgemeine Signifikanz des Modells, d.h. die Nullhypothese  $H_0 : \beta_1 = \beta_2 = 0$ . Berechne die Testgröße auf zwei verschiedenen Wegen: (1) als Funktion des Bestimmtheitsmaßes und (2) als Spezialfall des Tests für mehrere Linearkombinationen der Parameter, d.h. ohne das Bestimmtheitsmaß oder  $SSR$  zu verwenden.

Hinweis: Für  $A \in \mathbb{R}^{2 \times 2}$  gilt, dass

$$A^{-1} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{\det A} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

und  $\det A = ad - bc$ .

Eine Formel für die Inverse einer Matrix  $A \in \mathbb{R}^{3 \times 3}$  kann auf Übungsblatt 3 gefunden werden.

### Aufgabe 2 (1,5+2+1+2+1,5 Punkte)

Die Datei `ergebnisse.txt` enthält folgende Daten über die Ergebnisse von 680 Studenten in einer Vorlesung:

- $y$  = erzielte Punkte in der Klausur (Ergebnisse)
- $x_1$  = bisherige Durchschnittsnote im Studium (Gesamtnote)
- $x_2$  = erzielte Punkte im Zulassungstest der Universität (Zulassung)
- $x_3$  = Anteil der Vorlesungen bei denen der Student anwesend war (Anteil)
- $x_4$  = Indikator, ob es sich um einen Studenten im ersten Studienjahr handelt (Anfaenger)

Es wird folgender linearer Zusammenhang vermutet:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 \log x_2 + \beta_4 x_3 + \beta_5 x_1 x_3 + \beta_6 x_4$$

- Schätze die Regressionsparameter in  $\mathbf{R}$  ohne die Funktion `lm` zu verwenden.
- Beschreibe für alle unabhängigen Variablen, welchen Einfluss eine Änderung der Variablen auf die erzielten Klausurpunkte hat. Falls das für manche Variablen nicht pauschal möglich ist, begründe warum.
- Ein Student hat eine Durchschnittsnote von 2,2 und war bei 85% der Vorlesungen anwesend. Wie würde sich sein erwartetes Prüfungsergebnis ändern, wenn er noch vor der Klausur seine Durchschnittsnote auf 2,0 herabsenken könnte?
- Teste in  $\mathbf{R}$  die Nullhypothese  $H_0 : \beta_4 + 2\beta_5 = 0, \beta_1 = \beta_3, \beta_0 = 10$  zum Niveau  $\alpha = 0,01$ .
- Führe in  $\mathbf{R}$  einen White-Test zum Niveau  $\alpha = 0,05$  durch, um zu überprüfen, ob in diesem Modell Heteroskedastizität vorliegt. Dabei soll eine Regression von  $\hat{u}_i^2$  auf  $\hat{y}_i, \hat{y}_i^2$  und  $\hat{y}_i^3$  durchgeführt werden. Es darf die  $\mathbf{R}$ -Funktion `lm` verwendet werden.  
Hinweis: Möchte man in `lm` eine Potenz (z.B. Quadrat) einer Variablen  $x$  oder ein Produkt zweier Variablen  $x$  und  $y$  betrachten, so muss man `I(x^2)` bzw. `I(x*y)` anstatt nur `x^2` bzw. `x*y` verwenden.

### Aufgabe 3 (1+3,5+1,5+2 Punkt)

Die Datei `schule.txt` enthält folgende Daten über 1.692 Schulen in Michigan:

- $y$  = Anteil der Viertklässler (in %) die eine ausreichende Note in Mathe erreicht haben (Bestehen)
- $x_1$  = Anteil der Schüler (in %) die ein kostenloses Mittagessen erhalten haben (Lunch)
- $x_2$  = Anzahl der Schüler (Schueler)
- $x_3$  = Ausgaben (in \$) der Schule pro Schüler (Ausgaben)

Es wird folgender linearer Zusammenhang vermutet:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2 + \beta_4 \log x_3$$

- (a) Welche der folgenden Probleme können durch das Auftreten von Heteroskedastizität entstehen?
- (i) Die Schätzer für die Regressionsparameter sind inkonsistent.
  - (ii) Die üblicherweise verwendeten  $F$ -Statistiken sind nicht länger  $F$ -verteilt.
  - (iii) Der Schätzer für die Regressionsparameter ist nicht länger "BLUE" (best linear unbiased estimator).
- (b) Schätze die Regressionsparameter in  $\mathbf{R}$  mit Hilfe von `lm` und interpretiere  $\beta_1, \beta_2$  und  $\beta_4$  in Worten. Wie sollte man das lineare Modell ändern um  $\beta_1$  und  $\beta_2$  besser interpretieren zu können.
- (c) Teste mit Hilfe des Breusch-Pagan-Tests zum Niveau  $\alpha = 0,01$ , ob in diesem linearen Modell Heteroskedastizität vorliegen könnte. (Es soll keine  $\mathbf{R}$ -Funktion verwendet werden, die den Test automatisch durchführt, `lm` kann aber verwendet werden.)
- (d) Schätze die normale Kovarianzmatrix von  $\hat{\beta}$  und die robuste White-Kovarianzmatrix von  $\hat{\beta}$ . Vergleiche die Standardfehler von  $\hat{\beta}_0, \dots, \hat{\beta}_4$ .

### Aufgabe 4 (3 Punkte)

Es kann vorkommen, dass nicht nur Heteroskedastizität auftritt, sondern die Störterme auch noch beliebig korreliert sind, d.h. die (bedingte) Kovarianzmatrix der Störterme  $u = (u_1, \dots, u_n)$  ist gegeben durch  $V(u|X) = \sigma^2 V$ , wobei  $\sigma^2 > 0$  und  $V$  eine beliebige symmetrische und positiv definite Matrix ist. Wir betrachten den Schätzer  $\hat{\beta} = (X^\top V^{-1} X)^{-1} X^\top V^{-1} Y$  für den Vektor  $\beta$  der Regressionsparameter. Zeige, dass  $\mathbb{E}(\hat{\beta}|X) = \beta$  und berechne die Kovarianzmatrix  $V(\hat{\beta}|X)$ .

Hinweis: Dieses Verfahren wird auch als *generalized least squares (GLS)* bezeichnet und ist eine Verallgemeinerung des von uns genutzten *ordinary least squares (OLS)*.