

Reparametrisierung des Modells

Gegeben sei das Modell (2.1) mit (2.5) unter der linearen Restriktion

$A\beta = c$ mit $A \in R^{a \times p'}$, $rg(A) = a$, $c \in R^a$.

Wir betrachten die lineare Restriktion als Gleichungssystem. Die Lösungsmenge des Gleichungssystems ist wie folgt darstellbar:

$$\beta = B\gamma + d \quad (3.44)$$

mit Matrizen $B \in R^{p' \times (p'-a)}$, $d \in R^{p'}$ und $\gamma \in R^{p'-a}$ Es folgt:

$$Y = X\beta + \varepsilon = XB\gamma + Xd + \varepsilon$$

$$V = Z\gamma + \varepsilon$$

$$V := Y - Xd$$

$$Z := XB$$

Das Modell ist das **reparametrisierte** Modell mit:

Zielgröße: $V = Y - Xd \in R^n$

Design-Matrix: Z , $Z \in R^{n \times (p'-a)}$; $rgZ = p' - a$

Parameter: $\gamma \in R^{p'-a}$

Störterm: ε stimmt mit dem aus dem Grundmodell überein!

Zusammenhang Reparametrisierung und Modell unter linearer Restriktion

Es gilt:

$$\hat{\beta} = B\hat{\gamma} + d \quad (3.45)$$

$$SSH = \hat{\varepsilon}'\hat{\varepsilon} - \hat{\varepsilon}'\hat{\varepsilon} \quad (3.46)$$

mit $\hat{\beta}$: KQ-Schätzer unter Restriktion $A\beta = c$
 $\hat{\gamma}$: KQ-Schätzer aus Modell (3.45)
 $\hat{\varepsilon}$: Residuenvektor aus Modell (3.45) =
 Residuenvektor aus KQ-Schätzung unter Restriktion.

ML-Schätzung

Die maximierte Likelihood des Modells ist:

$$(2\pi)^{-n/2} \cdot \hat{\sigma}^{-n} \cdot \exp \left[-\sum_{i=1}^n \frac{\hat{\varepsilon}_i^2}{2\hat{\sigma}^2} \right]$$

Es folgt (siehe Nachweis ML = KQ aus Kapitel 1)

$$\hat{\sigma}^2 = \frac{\sum \hat{\varepsilon}_i^2}{n} \quad (3.47)$$

$$\text{MaxL} = C * \hat{\sigma}^n = C * (SSE/n)^{(n/2)} \quad (3.48)$$

Likelihood Quotienten-Test

Grundidee des Likelihood-Quotienten-Tests:

Vergleiche (Bilde den Quotienten) maximierte Likelihood des Modells unter H_0 mit maximierter Likelihood ohne H_0

Wir betrachten also den ML - Schätzer mit und ohne die Restriktion $A\beta = c$:

$\hat{\varepsilon}$: Residuen unter dem Modell mit H_0

$\hat{\varepsilon}$: Residuen unter dem Modell ohne Einschränkung

Die LQ- Teststatistik lautet dann:

$$\tau_{LQ} = \left(\frac{\hat{\sigma}}{\hat{\sigma}} \right)^{-n} = \left(\frac{\hat{\varepsilon}'\hat{\varepsilon}}{\hat{\varepsilon}'\hat{\varepsilon}} \right)^{-n/2} \quad (3.49)$$

Wald-Test ist Likelihood-Quotienten-Test

Sei das Modell (2.1) mit (2.5) und $A \in R^{a \times p'}$, $rg(A) = a$, $c \in R^a$ gegeben.

$$H_0 : A\beta = c \text{ gegen } H_1 : A\beta \neq c$$

Dann ist der Wald-Test zu dem Likelihood-Quotienten-Test äquivalent, d. h. :

Die Testgröße des LQ-Tests ist eine streng monotone Funktion der Testgröße des Wald-Tests:

$$\tau_{LQ} = g \left[\frac{MSH}{MSE} \right] \tag{3.50}$$

g streng monoton

Sequentielle und Partielle Quadratsummen

Gegeben sei das Modell (2.1). Wir betrachten nun Teilmodelle, die durch Nullrestriktionen von Komponenten des Vektors β entstehen und deren Residuenquadratsummen.

$$R(\beta_{i1}, \dots, \beta_{ik} | \beta_{j1}, \dots, \beta_{jl}) = SSH = SSE(M1) - SSE(M2) \tag{3.51}$$

- M2: Modell, das die Parameter $\beta_{i1}, \dots, \beta_{ik}, \beta_{j1}, \dots, \beta_{jl}$ enthält.
- M1: Modell, das die Parameter $\beta_{j1}, \dots, \beta_{jl}$ enthält.
- SSH: Hypothesenquadratsumme zur Hypothese $(\beta_{i1} = \dots = \beta_{ik} = 0)$ im Modell M2.

Beweis

Damit ist τ_{LQ} eine monotone Funktion der Testgröße des Wald-Tests:

$$\frac{MSH}{MSE} = \frac{(\hat{\epsilon}'\hat{\epsilon} - \hat{\epsilon}'\hat{\epsilon})/a}{\hat{\epsilon}'\hat{\epsilon}/(n-p')} =: \tau_W$$

$$\Rightarrow \left[\tau_W \cdot \frac{a}{(n-p)'} + 1 \right]^{-n/2} = \tau_{LQ}$$

Partielle Quadratsummen

Die zu der Hypothese $\beta_i = 0$ gehörigen Quadratsummen bzgl. des Gesamtmodells heißen **partielle Quadratsummen**:

$$R(\beta_i | \beta_0, \dots, \beta_{i-1}, \beta_{i+1}, \dots, \beta_p) = SSE(M_{-i}) - SSE \tag{3.52}$$

M_{-k} : Modell mit $\beta_k = 0$.

Beachte: Die partiellen Quadratsummen führen im Allgemeinen zu keiner Zerlegung von SST, d.h.

$$SST \neq \sum_{k=1}^p R(\beta_k | \beta_0, \dots, \beta_{k-1}, \beta_{k+1}, \dots, \beta_p) + SSE \tag{3.53}$$

Wir betrachten die Folge von Modellen:

$$M_0 : Y = \beta_0 + \varepsilon \tag{3.54}$$

$$M_1 : Y = \beta_0 + \beta_1 x_1 + \varepsilon \tag{3.55}$$

...

$$M_p : Y = X\beta + \varepsilon \tag{3.56}$$

$$R(\beta_k | \beta_0, \dots, \beta_{k-1}) = SSE(M_{k-1}) - SSE(M_k) \tag{3.57}$$

heißen **sequentielle Quadratsummen** und es gilt:

$$SST = \sum_{k=1}^p R(\beta_k | \beta_0, \dots, \beta_{k-1}) + SSE \tag{3.58}$$

Beweis von (3.67) I

$$Y = X_1\beta_1 + X_2\beta_2 + \varepsilon \quad X = (X_1 \ X_2) \quad \beta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix}$$

KQ:
 $Y = X_1\hat{\beta}_1 + X_2\hat{\beta}_2 + \hat{\varepsilon}$

$$Q_2 = I - P_2 = I - X_2(X_2'X_2)^{-1}X_2'$$

Es gilt: $Q_2Q = (I - P_2)(I - P) = I - P_2 - P + \underbrace{P_2P}_{P_2} = I - P = Q$

(Residuen von Regression auf $(Y_1 \ Y_2)$ und Residuen bzgl. Y_2)

Analog: $QQ_2 = Q$

Wir betrachten folgende Zerlegung des Modells (2.1):

$$Y = X\beta + \varepsilon \tag{3.59}$$

$$Y = (X_1X_2)(\beta_1'\beta_2')' + \varepsilon = X_1\beta_1 + X_2\beta_2 + \varepsilon \tag{3.60}$$

$$\hat{\beta} = (X'X)^{-1}X'Y = (\hat{\beta}_1', \hat{\beta}_2')' \tag{3.61}$$

$$Q_2 := I - X_2(X_2'X_2)^{-1}X_2' \tag{3.62}$$

$$Y^* := Q_2Y \tag{3.63}$$

$$X_1^* := Q_2X_1 \tag{3.64}$$

$$\Rightarrow \hat{\beta}_1 = (X_1^{*'}X_1^*)^{-1}X_1^{*'}Y^* \tag{3.65}$$

Y^*, X_1^* : von X_2 bereinigte Variablen

Beweis von (3.67) II

$$Q_2Y = Q_2X_1\hat{\beta}_1 + \underbrace{Q_2X_2\hat{\beta}_2}_0 + \underbrace{Q_2\hat{\varepsilon}}_{Q_2QY}$$

$$\Rightarrow Q_2Y = Q_2X_1\hat{\beta}_1 + \hat{\varepsilon}$$

$Y^* = X_1^*\hat{\beta}_1 + \hat{\varepsilon}$ **Bereinigte Variablen**

$$X_1^{*'}\hat{\varepsilon} = (Q_2X_1)'\hat{\varepsilon} = X_1'Q_2Q\hat{\varepsilon} = X_1'\hat{\varepsilon} = 0$$

$\Rightarrow \hat{\beta}_1$ ist KQ-Lösung der Regression von Y^* auf X^* .

Beispiele zur Bereinigung

Mittelwerts-Bereinigung beim einfachen linearen Regressionsmodell

$$\begin{aligned}
X_2 &= (1 \dots 1)' \\
X_1 &= (x_1 \dots x_n)' \\
Y^* &= Y - \bar{y} \\
X_1^* &= x - \bar{x} \\
(X'^* X^*)^{-1} X'^* Y^* &= S_x^{-2} S_{xy}
\end{aligned}$$

Geschlechtseffekt, Trendbereinigung

Prognose

In Modell (2.1) betrachten wir eine weitere Beobachtung mit bekanntem Vektor der x-Werte x_{n+1} und zugehörigem unbekanntem Y_{n+1} . Der Prognosewert von Y_{n+1} ist gegeben durch

$$\hat{Y}_{n+1} = x'_{n+1} \hat{\beta} \tag{3.66}$$

Für den Erwartungswert und die Varianz des Prognosefehlers gilt:

$$E [\hat{Y}_{n+1} - Y_{n+1}] = 0 \tag{3.67}$$

$$V [\hat{Y}_{n+1} - Y_{n+1}] = \sigma^2 (1 + x'_{n+1} (X'X)^{-1} x_{n+1}) \tag{3.68}$$

Der Nachweis verläuft analog zum einfachen linearen Modell unter Berücksichtigung von

$$V(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

Beispiel: Zusammenhang zwischen Fehleranzahl bei Test zu starken Verben

Zielgröße : Anzahl der Fehler bei Test
 Einflussgrößen : Geschlecht Alter Leseverhalten, Fernsehverhalten, etc.
 Regression auf binäre Variable Geschlecht entspricht Mittelwertsschätzung
 Bereinigung nach Geschlecht: Abziehen des jeweiligen Gruppenmittelwertes

Prognoseintervalle und Konfidenzintervalle

Das Prognoseintervall für eine zukünftige Beobachtung y_{n+1} bei gegebenem x_{n+1} erhält man mit Hilfe der Normalverteilung von $\hat{\beta}$ und standardisieren:

$$[\hat{Y}_{n+1} - \hat{\sigma}_{\hat{Y}_{n+1}} t_{1-\alpha/2}(n-p'); \hat{Y}_{n+1} + \hat{\sigma}_{\hat{Y}_{n+1}} t_{1-\alpha/2}(n-p')] \tag{3.69}$$

$$\text{mit } \hat{\sigma}_{\hat{Y}_{n+1}}^2 = \hat{\sigma}^2 (1 + x'_{n+1} (X'X)^{-1} x_{n+1})$$

Das Konfidenzintervall für den Erwartungswert μ_{n+1} einer zukünftige Beobachtung y_{n+1} bei gegebenem x_{n+1} ist:

$$[\hat{Y}_{n+1} - \hat{\sigma}_{\hat{\mu}_{n+1}} t_{1-\alpha/2}(n-p'); \hat{Y}_{n+1} + \hat{\sigma}_{\hat{\mu}_{n+1}} t_{1-\alpha/2}(n-p')] \tag{3.70}$$

$$\text{mit } \hat{\sigma}_{\hat{\mu}_{n+1}}^2 = \hat{\sigma}^2 (x'_{n+1} (X'X)^{-1} x_{n+1})$$

- Prognoseintervalle enthalten die Zufallsschwankung durch den Störterm ε_{n+1} **und** die Unsicherheit bezüglich der Modellparameter
- Die entsprechenden Konfidenzintervalle enthalten nur die Unsicherheit bezüglich der Modellparameter. Sie können gut zur Darstellung der Modellschätzung verwendet werden.
- Um den geschätzten Effekt einer Einflussgröße x_1 darzustellen, werden die anderen Einflussgröße auf einen festen Wert (z.B. Modus, Median oder Mittelwert) gesetzt. Wann wird der Zusammenhang von $x_{1,n+1}$ und \hat{Y}_{n+1} und die entsprechenden Konfidenzintervalle geplottet. (R- Paket effects)

Sei das Modell

$$\begin{aligned} Y &= X\beta + \varepsilon, & \text{rg } X &= p' \\ E(\varepsilon) &= 0 \\ V(\varepsilon) &= \sigma^2 I \end{aligned}$$

gegeben.

Dann ist der KQ-Schätzer $\hat{\beta}$ unter den erwartungstuen linearen Schätzern derjenige mit der kleinsten Varianz: $\hat{\beta}$ ist BLUE-Schätzer (**best linear unbiased estimator**).

Ist $\tilde{\beta}$ ein weiterer Schätzer von β mit $E(\tilde{\beta}) = \beta$ und $\tilde{\beta} = CY$, so gilt:

$$V(\tilde{\beta}) \geq V(\hat{\beta})$$

$V(\tilde{\beta}) \geq V(\hat{\beta}) \Leftrightarrow V(\tilde{\beta}) = V(\hat{\beta}) + M$ mit M positiv semidefinit.

Konsistenz des KQ-Schätzers I

Sei das Modell (2.1) - (2.4) gegeben. Wir betrachten nun das Modell mit steigendem Stichprobenumfang n . Da die Einflussgrößen fest sind, gehen wir von einer gegebenen Folge x_n der Einflussgrößen aus.

Sei zu jedem $n > p'$

X_n : Designmatrix, die aus den ersten n Beobachtungen besteht
 $\hat{\beta}^{(n)}$: KQ-Schätzer aus den ersten n Beobachtungen

Vor.: X_n hat vollen Rang für alle $n \geq p$

$$\lim_{n \rightarrow \infty} (X_n' X_n)^{-1} = 0.$$

Konsistenz des KQ-Schätzers II

Dann folgt die schwache Konsistenz des KQ-Schätzers (Konvergenz in Wahrscheinlichkeit):

$$\hat{\beta}^{(n)} \xrightarrow{P} \beta. \quad (3.71)$$

Sind die Störgrößen zusätzlich identisch verteilt, so folgt die starke Konsistenz (fast sichere Konvergenz)

$$\hat{\beta}^{(n)} \xrightarrow{\text{f.s.}} \beta. \quad (3.72)$$

Asymptotische Normalität des KQ-Schätzers

Sei das Modell (2.1) - (2.4) gegeben.

Sei zu jedem $n > p'$

X_n : Designmatrix, die aus den ersten n Beobachtungen besteht.
 $\hat{\beta}^{(n)}$: KQ- Schätzer aus den ersten n Beobachtungen

Vor.: X_n hat vollen Rang für alle $n \geq p$

$$\lim_{n \rightarrow \infty} \max_{1 \leq i \leq n} x_i'(X_n'X_n)^{-1}x_i = 0.$$

Dann folgt die asymptotische Normalität von β

$$\sigma^{-1}(X_n'X_n)^{1/2}(\hat{\beta}^{(n)} - \beta) \xrightarrow{d} N(0, I). \quad (3.73)$$

