

## Vorlesung: Lineare Modelle

Prof. Dr. Helmut Küchenhoff

Institut für Statistik, LMU München

SoSe 2014

- Einführung und Beispiele
- ① Das einfache lineare Regressionsmodell
- ② Das multiple lineare Regressionsmodell
- **Quadratsummenzerlegung und statistische Inferenz im multiplen linearen Regressionsmodell**
- Diskrete Einflußgrößen: Dummy- und Effektkodierung, Mehrfaktorielle Varianzanalyse

Navigation

Navigation

## Quadratsummenzerlegung

Gegeben sei das Modell (2.1) mit Design-Matrix  $X$  und

$$rg(X) = p + 1 =: p'. \quad (3.1)$$

Dann gilt:

$$\underbrace{(Y - \bar{Y})'(Y - \bar{Y})}_{SST} = \underbrace{(Y - \hat{Y})'(Y - \hat{Y})}_{SSE} + \underbrace{(\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y})}_{SSM} \quad (3.2)$$

### Interpretation:

- $SST$  : Gesamt-Streuung, (korrigierte) Gesamt-Quadratsumme, "Total"
- $SSE$  : Fehler-Quadratsumme, "Error"
- $SSM$  : Modell-Quadratsumme, "Model"

## Zerlegung ohne Absolutglied

Die Zerlegung (3.2) setzt ein Absolutglied in der Regression voraus.

Weitere Zerlegung, die nicht notwendig ein Absolutglied in der Regression voraussetzt:

$$\underbrace{Y'Y}_{SST^*} = \underbrace{(Y - \hat{Y})'(Y - \hat{Y})}_{SSE} + \underbrace{\hat{Y}'\hat{Y}}_{SSM^*} \quad (3.3)$$

- $SST^*$  : nicht korrigierte Gesamt-Quadratsumme  
Erfasst auch Abweichungen von  $Y = 0$  und nicht nur von  $\bar{Y}$ .
- $SSE$  : Fehler-Quadratsumme, wie bei (3.2)
- $SSM^*$  : nicht korrigierte Modell-Quadratsumme

Navigation

Navigation

# Nachweis der Quadratsummenzerlegung (3.3)

$$\begin{aligned}
 Y'Y &= Y'IY \\
 &= Y'(Q + P)Y \\
 &= Y'QY + Y'PY \\
 &= Y'Q'QY + Y'P'PY \\
 &= \hat{\epsilon}'\hat{\epsilon} + \hat{Y}'\hat{Y} \qquad \text{qed}
 \end{aligned}$$

P und Q Projektionsmatrizen.

# Nachweis der Quadratsummenzerlegung (3.2) II

$$\begin{aligned}
 (*) \quad Q_e QY &= Q_e \hat{\epsilon} = \hat{\epsilon} = QY \\
 &\quad \uparrow \\
 &\quad \text{„Residuen haben Mittelwert 0“} \\
 (*) \quad Q_e P Q_e P Y &= Q_e P Q_e \hat{Y} = Q_e P (\hat{Y} - \bar{Y}) \\
 &= Q_e P \hat{Y} - Q_e P \bar{Y} = Q_e \hat{Y} - Q_e \bar{Y} = Q_e \hat{Y} - 0 \\
 &\quad \uparrow \\
 &\quad \text{„Regression auf } \hat{Y} \text{ und } \bar{Y} \text{ liefert Identität“}
 \end{aligned}$$

$$\begin{aligned}
 (Y - \bar{Y})'(Y - \bar{Y}) &= Y'Q_e'Q_e Y = Y'Q_e Y \\
 &= Y'Q_e(Q + P)Y = Y'Q_e QY + Y'Q_e P Y \\
 &\stackrel{(*)}{=} Y'QY + Y'Q_e P Q_e P Y \\
 &= \hat{\epsilon}'\hat{\epsilon} + Y'P'Q_e P Y \\
 &= (\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y})
 \end{aligned}$$

# Nachweis der Quadratsummenzerlegung (3.2) I

Wir definieren:

$$P_e = e(e'e)^{-1}e', \quad Q_e = I - P_e \text{ mit } e = (1, 1, \dots, 1)'. \quad (3.4)$$

$P_e$  entspricht der Regression auf eine Konstante ( $E(Y) = \beta_0$ )

$$\begin{aligned}
 P_e Y &= \bar{Y} \quad (\text{„Mittelwert bilden“}) \\
 Q_e Y &= Y - \bar{Y} \quad (\text{„Mittelwertsbereinigung“})
 \end{aligned}$$

$$\begin{aligned}
 (Y - \bar{Y})'(Y - \bar{Y}) &= Y'Q_e'Q_e Y = Y'Q_e Y \\
 &= Y'Q_e(Q + P)Y = Y'Q_e QY + Y'Q_e P Y \\
 &\stackrel{(*)}{=} \dots
 \end{aligned}$$

# Erwartungswerte der Quadratsummen

Wir betrachten das multiple Regressionsmodell (2.1) mit (2.2) bis (2.4) und

$$P_e = e(e'e)^{-1}e', \quad Q_e = I - P_e \text{ mit } e = (1, 1, \dots, 1)'.$$

Dann gilt für die Erwartungswerte der Quadratsummen:

$$\begin{aligned}
 E(SST^*) &= E(Y'Y) = \sigma^2 n + \beta'X'X\beta & (3.5) \\
 E(SST) &= E(Y - \bar{Y})'(Y - \bar{Y}) = \sigma^2(n - 1) + \beta'(Q_e X)'(Q_e X)\beta & (3.6) \\
 E(SSE) &= E(\hat{\epsilon}'\hat{\epsilon}) = \sigma^2(n - p') & (3.7) \\
 E(SSM^*) &= E(\hat{Y}'\hat{Y}) = \sigma^2 p' + \beta'X'X\beta & (3.8) \\
 E(SSM) &= E(\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y}) = \sigma^2 p + \beta'(Q_e X)'(Q_e X)\beta & (3.9)
 \end{aligned}$$

# Bemerkungen

- 1 Die stochastischen Eigenschaften der Quadratsummen werden zur Konstruktion von Tests bezüglich  $\beta$  genutzt
- 2  $\beta = 0 \implies E(Y'Y) = \sigma^2 n$
- 3  $\beta_1, \dots, \beta_p = 0 \implies E(SSM) = \sigma^2 p$

Zum Nachweis von 3. benutzt man, dass  $Q_e$  der „Mittelwertsbereinigungs- Operator“ ist:

$$Q_e x = (I - P_e)x = x - \bar{x}$$

Die erste Spalte von  $Q_e X$  ist also der Nullvektor.

# Mittlere Quadratsummen

Wir definieren entsprechend der Zahl der Freiheitsgrade die **mittleren Quadratsummen**:

$$MST^* := \frac{SST^*}{n} \tag{3.10}$$

$$MST := \frac{SST}{n-1} \tag{3.11}$$

$$MSE := \frac{SSE}{n-p'} \tag{3.12}$$

$$MSM^* := \frac{SSM^*}{p'} \tag{3.13}$$

$$MSM := \frac{SSM}{p} \tag{3.14}$$

# Beweisidee

Allgemein berechnet man den Erwartungswert von quadratischen Formen wie folgt:

$$\begin{aligned}
 E(Y'AY) &= E\left(\sum_{i=1}^n \sum_{j=1}^n a_{ij} Y_i Y_j\right) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} E(Y_i Y_j) \\
 &= \sum_{i=1}^n \sum_{j=1}^n a_{ij} E(Y_i)E(Y_j) + \sum_{i=1}^n \sum_{j=1}^n a_{ij} Cov(Y_i, Y_j) \\
 &= E(Y)'AE(Y) + Sp(AV(Y)) \\
 V(Y) &:= \text{Varianz-Kovarianzmatrix von } Y
 \end{aligned}$$

Unter Benutzung von  $Sp(AV(Y)) = sp(A) * \sigma^2 = rang(A) * \sigma^2$  für Projektionsmatrizen erhält man obige Identitäten.

# Verteilungsdefinitionen

## Normalverteilung

Ein n-dimensionaler Zufallsvektor  $Z$  heißt multivariat normalverteilt, falls für seine Dichtefunktion gilt:

$$f_z(z) = \frac{1}{\sqrt{\det \Sigma} \sqrt{(2\pi)^n}} \exp\left[-\frac{1}{2}(z - \mu)' \Sigma^{-1} (z - \mu)\right] \tag{3.15}$$

mit positiv definiten, symmetrischer Matrix  $\Sigma$ .

**Bezeichnung:**  $Z \sim N_n(\mu, \Sigma)$

# Eigenschaften der Normalverteilung

Ist  $Z \sim N_n(\mu, \Sigma)$ , so gilt:

**1 Momente:**

$$\begin{aligned} E(Z) &= \mu \\ V(Z) &= \Sigma \end{aligned}$$

**2 Lineare Transformationen:**

Ist  $A : R^n \rightarrow R^m$  eine lineare Transformation mit  $rg(A) = m$

$$\implies AZ \sim N_m(A\mu, A\Sigma A') \quad (3.16)$$

**3 Orthogonale Transformation in unabhängige Komponenten (Spektralzerlegung)**

Es existiert eine Matrix  $T \in R^{n \times n}$  mit  $T'T = I$  und  $T\Sigma T' = \text{diag}(\lambda_1, \dots, \lambda_n)$ , so dass

$$TZ \sim N_n(T\mu, \text{diag}(\lambda_1, \dots, \lambda_n)) \text{ gilt.} \quad (3.17)$$

# Chi-Quadrat-Verteilung II

**Eigenschaften:** Ist  $X \sim \chi^2(n, \delta)$ , so gilt:

**1 Momente:**

$$\begin{aligned} E(X) &= n + \delta \\ V(X) &= 2n + 4\delta \end{aligned}$$

**2 Allgemeiner Bezug zur Normalverteilung**

$$Z \sim N_n(\mu, \Sigma) \implies Z'\Sigma^{-1}Z \sim \chi^2(n, \mu'\Sigma^{-1}\mu) \quad (3.18)$$

# Chi-Quadrat-Verteilung I

Ist  $Z \sim N_n(\mu, I)$  so heißt  $X = Z'Z$  (nicht-zentral) Chi-Quadrat-verteilt.

**Bezeichnung:**  $X \sim \chi^2(n, \delta)$

$n$ : Zahl der Freiheitsgrade  
 $\delta := \mu'\mu$ : Nichtzentralitätsparameter

Im Fall  $\delta = 0$  erhält man die zentrale  $\chi^2(n)$ -Verteilung.

# t-Verteilung

Seien  $Z$  und  $W$  voneinander unabhängige Zufallsgrößen mit

$$\begin{aligned} Z &\sim N(\delta, 1), \\ W &\sim \chi^2(n). \end{aligned}$$

Dann heißt  $X = \frac{Z}{\sqrt{\frac{W}{n}}}$  (nicht-zentral) t-verteilt.

**Bezeichnung:**  $X \sim t(n, \delta)$

$n$ : Zahl der Freiheitsgrade,  
 $\delta$ : Nicht-Zentralitätsparameter

**Erwartungswert:** Ist  $X \sim t(n, \delta)$ , so gilt:

$$E(X) = \delta \sqrt{\frac{n}{2}} \frac{\Gamma(\frac{n-1}{2})}{\Gamma(\frac{n}{2})} \quad \text{für } n > 1. \quad (3.19)$$

# F-Verteilung

Seien  $W_1$  und  $W_2$  voneinander unabhängige Zufallsgrößen mit

$$W_1 \sim \chi^2(n_1, \delta)$$

$$W_2 \sim \chi^2(n_2)$$

Dann heißt  $X = \frac{W_1/n_1}{W_2/n_2}$  (nicht-zentral) F-verteilt.

**Bezeichnung:**  $X \sim F(n_1, n_2, \delta)$

- $n_1$ : Zählerfreiheitsgrade
- $n_2$ : Nennerfreiheitsgrade
- $\delta$ : Nichtzentralitätsparameter

**Erwartungswert:** Ist  $X \sim F(n_1, n_2, \delta)$ , so gilt:

$$E(X) = \frac{n_2}{n_2 - 2} (1 + \delta/n_1) \text{ für } n_2 > 2. \tag{3.20}$$

## Beweis von (3.21)

Spektralzerlegung von A (3.17)

$$A = T \Sigma T'$$

$$\Sigma = \underbrace{\begin{pmatrix} 1 & & & & \\ & \ddots & & & \\ & & 1 & & \\ & & & 0 & \\ & & & & 0 \end{pmatrix}}_r \text{ da } A^2 = A$$

$$\Rightarrow Z'AZ = Z'T \Sigma T'Z$$

$$\text{Var}(T'Z) = T'IT = I$$

$$\Rightarrow Z'AZ = \tilde{Z} \Sigma Z = \sum_{i=1}^r \tilde{z}_i^2 \sim \chi^2(r, \mu' A \mu)$$

# Unabhängigkeit von Quadratsummen (Satz von Cochran)

Sei  $Z \sim N(\mu, I)$ ,  $\dim Z = n$ ,  
 $A \in R^{n \times n}$ ,  $A' = A$ ,  $\text{rg}(A) = r$ ,  $A^2 = A$ ,  
 $B \in R^{n \times n}$ ,  $B^2 = B$ ,  $B = B'$ ,  
 $C \in R^{m \times n}$ .

Dann gilt:

$$Z'AZ \sim \chi^2(r, \mu' A \mu) \tag{3.21}$$

$$CA = 0 \Rightarrow CZ \text{ und } Z'AZ \text{ sind unabh.} \tag{3.22}$$

$$AB = 0 \Rightarrow Z'AZ \text{ und } Z'BZ \text{ sind unabh.} \tag{3.23}$$

## Beweis von (3.22) und (3.23)

$$\text{Cov}(CZ, Z'A) = C \text{Cov}(Z, Z')A = CA = 0$$

Damit sind CZ und Z'A unabhängig (NV-Annahme!)  
 $\Rightarrow CZ$  und  $(Z'A)(Z'A)' = Z'AZ$  unabh.

qed

$$\text{Cov}(AZ, Z'B) = A \text{Cov}(Z, Z')B = AB = 0$$

Damit sind AZ und Z'B unabhängig (NV-Annahme!)  
 $\Rightarrow (AZ)'(AZ) = Z'AZ$  und  $(Z'B)(Z'B)' = Z'BZ$  unabh.

qed

# Verteilung des KQ-Schätzers unter Normalverteilung

Sei multiples Regressionsmodell (2.1) mit (2.5) und  $rg(X) = p'$  gegeben. Für den KQ-Schätzer  $\hat{\beta}$  gilt:

$$\hat{\beta} \sim N(\beta, \sigma^2(X'X)^{-1}) \tag{3.24}$$

$$\hat{\Sigma}_{\hat{\beta}} := \hat{\sigma}^2(X'X)^{-1} \tag{3.25}$$

$$(n - p') \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi^2(n - p') \tag{3.26}$$

$\hat{\sigma}$  und  $\hat{\beta}$  sind unabhängig (3.27)

$$\hat{\sigma}_{\hat{\beta}_k} := \sqrt{c_{kk}} \hat{\sigma}, \tag{3.28}$$

( $c_{kk}$  entspr. Diagonalelement von  $(X'X)^{-1}$ )

$$\frac{\hat{\beta}_k - \beta_k}{\hat{\sigma}_{\hat{\beta}_k}} \sim t(n - p', 0) \tag{3.29}$$

## Overall-Tests

Sei Modell (2.1) mit (2.5) und  $rg(X) = p'$  gegeben. Dann gilt für die mittlere Quadratsummen:

$$F_O = \frac{MSM}{MSE} \sim F(p, n - p', \sigma^{-2} \beta'(Q_e X)'(Q_e X)\beta) \tag{3.30}$$

(3.30) folgt aus (3.21) und (3.23) mit

$$\begin{aligned} MSM &= SSM/p = Y'(P - P_e)Y/p \\ MSE &= SSE/(n - p') = Y'QY/(n - p') \\ Q(P - P_e) &= QP - QP_e = 0 \end{aligned}$$

Die Verteilung wird zur Konstruktion des folgenden Tests benutzt:

$$H_0^O : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

Lehne  $H_0^O$  ab, falls

$$F_O > F_{1-\alpha}(p, n - p') \tag{3.31}$$

# Beweis

(3.24) (Normalverteilung von  $\beta$ ) folgt aus Eigenschaften der NV (3.16)

(3.26) folgt aus (3.21), da  $\hat{\sigma}^2 = \frac{1}{n-p'} \hat{\varepsilon}'\hat{\varepsilon} = \frac{1}{n-p'} Y'QY$   
 $rg(Q) = sp(Q)$

(3.27) folgt aus (3.22):

$$C \in R^{p' \times n}, CA = 0 \implies CZ \text{ und } Z'AZ \text{ sind unabh.}$$

mit

$$\begin{aligned} C &:= (X'X)^{-1}X', \quad A := Q, \quad Z := Y \\ CA &= (X'X)^{-1}X'Q = (X'X)^{-1}X'(I - P) = \\ &= (X'X)^{-1}X' - (X'X)^{-1}X'X(X'X)^{-1}X' = 0. \end{aligned}$$

## Overall Test mit $\beta_0 = 0$

$$F_O^* = \frac{MSM^*}{MSE} \sim F(p', n - p', \sigma^{-2} \beta'(X'X)\beta) \tag{3.32}$$

$$H_0^{O*} : \beta_0 = \beta_1 = \dots = \beta_p = 0$$

Lehne  $H_0^{O*}$  ab, falls

$$F_O^* > F_{1-\alpha}(p', n - p') \tag{3.33}$$

$F_{1-\alpha}(p, n - p')$  :  $(1 - \alpha)$ -Quantil der zentralen  $F(p, n - p')$ -Verteilung.

Dieser Test wird nur in Ausnahmefällen angewendet.

# Lineare Hypothesen

Es sollen Hypothesen, die sich mit Hilfe linearer Transformationen von  $\beta$  darstellen lassen, betrachtet werden:

$$A \in R^{a \times (p+1)}, c \in R^a,$$

$$A\beta = c \text{ mit } rg(A) = a$$

Beispiele:

$$p = 2 \quad \beta_1 = \beta_2 \quad \leftrightarrow \quad A = \begin{pmatrix} 0 & 1 & -1 \end{pmatrix}, c = 0$$

$$p = 4 \quad \beta_3 = \beta_4 = 0 \quad \leftrightarrow \quad A = \begin{pmatrix} 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}, c = 0$$

$$p = 4 \quad \beta_2 = 3 \quad \beta_3 + \beta_4 = 1 \quad \leftrightarrow \quad A = \begin{pmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 \end{pmatrix}, c = \begin{pmatrix} 3 \\ 1 \end{pmatrix}$$

# Overall-Test und zweiseitiger t-Test

Die Overall-Tests aus (3.31) und (3.33) sind spezielle Wald-Tests.

Nachweis von (3.33) erfolgt direkt, da hier  $A = I$  ist.

Der Nachweis von (3.31) erfolgt später.

Der mit Hilfe von (3.29) konstruierte zweiseitige Test auf  $\beta_k = \beta_k^0$  ist ebenfalls ein Wald-Test.

Der Nachweis erfolgt direkt unter Benutzung von  $A = (0 \dots 1 \dots 0)$

# Allgemeine lineare Hypothese, Wald-Test

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

$$V(A\hat{\beta} - c) = \sigma^2 A(X'X)^{-1}A' \tag{3.34}$$

$$SSH := (A\hat{\beta} - c)'(A(X'X)^{-1}A')^{-1}(A\hat{\beta} - c) \tag{3.35}$$

$$\sigma^{-2}SSH \sim \chi^2(a, \sigma^{-2}(A\beta - c)'(A(X'X)^{-1}A')^{-1}(A\beta - c)) \tag{3.36}$$

$$MSH := \frac{SSH}{a} \tag{3.37}$$

$$\frac{MSH}{MSE} \sim F(a, n - p', \sigma^{-2}(A\beta - c)'(A(X'X)^{-1}A')^{-1}(A\beta - c)) \tag{3.38}$$

SSH: Quadratsumme, die die Abweichung von der Hypothese  $A\beta = c$  beschreibt.

Test nach Wald:  $H_0 : A\beta = c$ . Lehne  $H_0$  ab, falls:

$$TF = MSH/MSE > F_{1-\alpha}(a, n - p') \tag{3.39}$$

# Lineare Hypothese und Modell mit Restriktion

Wir betrachten das lineare Modell mit der linearen Restriktion  $A\beta = c$ . Alle Schätzungen aus diesem Modell werden mit  $\hat{\beta}$  gekennzeichnet.

Wir lösen das Minimierungsproblem:

$$(y - X\beta)'(y - X\beta) \rightarrow \min \text{ unter } A\beta = c$$

mit der Lagrange-Methode:

$$S(\beta, \lambda) = (y - X\beta)'(Y - X\beta) + 2\lambda'(A\beta - c)$$

$\lambda$  ist der Vektor der Lagrange-Multiplikationen.

$$\begin{aligned} \frac{\partial S}{\partial \beta} &= 0 \Leftrightarrow -2X'Y + 2X'X\hat{\beta} + 2A'\lambda = 0 \\ \frac{\partial S}{\partial \lambda} &= 0 \Leftrightarrow A\hat{\beta} = c \\ A'\lambda &= X'Y - X'X\hat{\beta} \quad | \cdot (X'X)^{-1} \\ (X'X)^{-1}A'\lambda &= \hat{\beta} - \hat{\beta} \quad | \cdot A (*) \\ \Rightarrow A(X'X)^{-1}A'\lambda &= A\hat{\beta} - c \quad (A\hat{\beta} = c) \\ \Rightarrow \lambda &= (A(X'X)^{-1}A')^{-1}(A\hat{\beta} - c) \\ (*) \Rightarrow \hat{\beta} &= \hat{\beta} - (X'X)^{-1}A'[A(X'X)^{-1}A']^{-1}(A\hat{\beta} - c) \\ w &:= (X'X)^{-1}A'[A(X'X)^{-1}A']^{-1}(A\hat{\beta} - c) \end{aligned}$$

$$\begin{aligned} \hat{Y} &= X\hat{\beta} = \hat{Y} - Xw \\ \hat{\varepsilon} &= Y - \hat{Y} = \varepsilon + Xw \\ \Rightarrow \hat{\varepsilon}'\hat{\varepsilon} &= \varepsilon'\varepsilon + w'X'Xw \quad (\text{da } X'\varepsilon = 0) \\ &= \varepsilon'\varepsilon + (A\hat{\beta} - c)'[A(X'X)^{-1}A']^{-1}(A\hat{\beta} - c) \\ \Rightarrow SSH &= \hat{\varepsilon}'\hat{\varepsilon} - \varepsilon'\varepsilon \end{aligned}$$

Damit haben wir eine andere Möglichkeit, SSH aus den Residuenquadratsummen zu berechnen.

## Lineare Hypothese (alternative Durchführung)

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

$$H_0 : A\beta = c$$

Berechne SSE des Modells und des Modells unter  $H_0$ :

$$\begin{aligned} SSE &= \hat{\varepsilon}'\hat{\varepsilon} \\ SSE(H_0) &:= \hat{\varepsilon}'\hat{\varepsilon} \end{aligned} \quad (3.40)$$

$$SSH = SSE(H_0) - SSE \quad (3.41)$$

$$MSH = SSH/a$$

$$TF := MSH/MSE = \frac{(SSE(H_0) - SSE)/a}{SSE/(n - p')} \quad (3.42)$$

$$TF \sim F(a, n - p') \text{ unter } H_0 \quad (3.43)$$

Das Vorgehen entspricht dem Wald- Test (3.39).

## Spezialfall: Overall - Test

### Overall- Test

$$H_0^O : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

Das Modell unter  $H_0$  ist  $y = \beta_0$

$$\begin{aligned} SSE(H_0) &= (Y - \hat{\beta}_0)'(Y - \hat{\beta}_0) = SST \\ SSH &= SSE(H_0) - SSE = SSM \end{aligned}$$

Damit entspricht hier der Wald -Test dem Test (3.31)

# Weglassen von Einflussgrößen

Lineare Hypothese:

$$H_0 : \beta_k = \beta_{k+1} = \dots = \beta_p = 0$$

Das Modell unter  $H_0$  ist M1:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_{k-1} x_{k-1}$$

$$\begin{aligned} SSE(H_0) &= SSE(M1) \\ SSH &= SSE(M1) - SSE \end{aligned}$$

Vergleich der SSE der beiden Modelle.

## Modell

$$Y = \beta_0 + \beta_1 * GE + \beta_2 * JG + \beta_3 * LZ + \beta_4 * WOL + \beta_5 * WOG + \beta_6 * WOTV$$

- Y: Anzahl der Fehler
- GE: Indikator für männlich (= 1 für männlich, 0 sonst)
- JG: Indikator für Klassenstufe (=1 für 3. Klasse, 0 für 4.Klasse)
- LZ: Lesezeit in der Schule
- WOL: Wie oft wird sonst gelesen
- WOG: Wie oft wird Gameboy gespielt
- WOTV: Wie oft TV

Interpretation der Parameter, z.B  $\beta_1$  : Geschlechtsunterschied

Annahme: Bei WOL ist der durchschnittliche Unterschied in der Fehlerzahl zwischen den Stufen 1-5 gleich groß (Änderung um 1 entspricht  $\beta_4$ )

# Beispiel: Welche Faktoren stehen in Zusammenhang mit den Fehlern bei einem Lesetest

Daten von Christa Kieferle (Pädagogik, LMU)  
Daten von 180 Kindern aus den 8 Klassen (3. und 4. Klassen Grundschule)

Zielgröße:  
Anzahl der Fehler bei einem Lesetest

potentielle Einflussgrößen:  
Geschlecht, Jahrgang, Leseförderzeit, sonstiges lesen (1= oft,.. 5= fast nie), Gameboy (1= oft,.. 5= fast nie), Jahrgang.

## Auswertung

- 1 Schätzung des Gesamtmodells
- 2 Gibt es einen Zusammenhang zwischen den Variablen WOL, WOG, WOTV und Y ?
- 3 Ist der Einfluss von WOG und WOTV auf die Fehlerzahl gleich ?
- 4 Gibt es einen Zusammenhang von Lesezeit und WOL und der Fehlerzahl ?
- 5 Wie lässt die Assoziation zur Lesezeit quantifizieren?

Fragen 2-4 lassen sich als lineare Hypothesen in dem Modell formulieren. Fragen 1 und 5 betreffen die Schätzung des Modells.

# Reparametrisierung des Modells unter linearer Restriktion

Wir betrachten das Modell (2.1) mit (2.5) unter der linearen Restriktion  $A\beta = c$  mit  $A \in R^{a \times p'}$ ,  $rg(A) = a$ ,  $c \in R^a$ .

Dann gibt es Matrizen  $B \in R^{p' \times (p'-a)}$  und  $d \in R^{p'}$  mit:

$$V = Z\gamma + \varepsilon \tag{3.44}$$

$$V := Y - Xd \tag{3.45}$$

$$Z := XB \tag{3.46}$$

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:  $\varepsilon$  stimmt mit dem aus dem Grundmodell überein!

# 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)

$$\hat{\sigma}^2 = \frac{\sum \hat{\varepsilon}_i^2}{n} \tag{3.49}$$

$$MaxL = C * \hat{\sigma}^{-n} = C * (SSE/n)^{(n/2)} \tag{3.50}$$

# Zusammenhang Reparametrisierung und Modell unter linearer Restriktion

Es gilt:

$$\hat{\beta} = B\hat{\gamma} + d \tag{3.47}$$

$$SSH = \hat{\varepsilon}'\hat{\varepsilon} - \varepsilon'\hat{\varepsilon} \tag{3.48}$$

- mit  $\hat{\beta}$ : KQ-Schätzer unter Restriktion  $A\beta = c$
- $\hat{\gamma}$ : KQ-Schätzer aus Modell (3.44)
- $\hat{\varepsilon}$ : Residuenvektor aus Modell (3.44) = Residuenvektor aus KQ-Schätzung unter Restriktion.

# 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:

$$\tau_{LQ} = \left( \frac{\hat{\sigma}}{\hat{\sigma}} \right)^{-n} = \left( \frac{\hat{\varepsilon}'\hat{\varepsilon}}{\hat{\varepsilon}'\hat{\varepsilon}} \right)^{-n/2} \tag{3.51}$$

# 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:

$$\tau_{LQ} = g \left[ \frac{MSH}{MSE} \right] \tag{3.52}$$

$g$  streng monoton

# Sequentielle und Partielle Quadratsummen

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

$$R(\beta_{i1}, \dots, \beta_{ik} | \beta_{j1}, \dots, \beta_{jl}) = SSH = SSE(M1) - SSE(M2) \tag{3.53}$$

- 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  $\tau_{LQ}$  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**:

$$R(\beta_i | \beta_0, \dots, \beta_{i-1}, \beta_{i+1}, \dots, \beta_p) = SSE(M_{-i}) - SSE \tag{3.54}$$

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

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

$$SST \neq \sum_{k=1}^p R(\beta_k | \beta_0, \dots, \beta_{k-1}, \beta_{k+1}, \dots, \beta_p) + SSE \tag{3.55}$$

# Sequentielle Quadratsummen

Wir betrachten die Folge von Modellen:

$$M_0 : Y = \beta_0 + \varepsilon \tag{3.56}$$

$$M_1 : Y = \beta_0 + \beta_1 x_1 + \varepsilon \tag{3.57}$$

...

$$M_p : Y = X\beta + \varepsilon \tag{3.58}$$

$$R(\beta_k | \beta_0, \dots, \beta_{k-1}) = SSE(M_{k-1}) - SSE(M_k) \tag{3.59}$$

heißen **sequentielle Quadratsummen** und es gilt:

$$SST = \sum_{k=1}^p R(\beta_k | \beta_0, \dots, \beta_{k-1}) + SSE \tag{3.60}$$

## 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:

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

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

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

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

Analog:  $QQ_2 = Q$

# Bereinigung

Wir betrachten folgende Zerlegung des Modells (2.1):

$$Y = X\beta + \varepsilon \tag{3.61}$$

$$Y = (X_1 \ X_2)(\beta_1' \ \beta_2')' + \varepsilon = X_1\beta_1 + X_2\beta_2 + \varepsilon \tag{3.62}$$

$$\hat{\beta} = (X'X)^{-1}X'Y = (\hat{\beta}_1', \hat{\beta}_2')' \tag{3.63}$$

$$Q_2 := I - X_2(X_2'X_2)^{-1}X_2' \tag{3.64}$$

$$Y^* := Q_2Y \tag{3.65}$$

$$X_1^* := Q_2X_1 \tag{3.66}$$

$$\Rightarrow \hat{\beta}_1 = (X_1^{*'}X_1^*)^{-1}X_1^{*'}Y^* \tag{3.67}$$

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

## Beweis von (3.67) II

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

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

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

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

$\Rightarrow \hat{\beta}_1$  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

# Bonferroni-Konfidenzintervalle

Gegeben sei das Modell (2.1) mit der Normalverteilungsannahme (2.5). Dann sind für die Parameter  $\beta_{i1}, \dots, \beta_{ik}$

$$\hat{\beta}_{il} \pm \hat{\sigma}_{\hat{\beta}_{il}} t_{1-\alpha/2k}(n - p'), \quad l = 1, \dots, k \tag{3.68}$$

simultane Konfidenzintervalle zum Sicherheitsniveau  $1 - \alpha$ :

$$P(\text{es gibt } l : |\beta_{il} - \hat{\beta}_{il}| > \hat{\sigma}_{\hat{\beta}_{il}} t_{1-\alpha/2k}(n - p')) \leq \alpha \tag{3.69}$$

Die Parameter  $\beta_{il}$  können durch Linearkombinationen  $\gamma_l = a' \beta$  mit den entsprechenden geschätzten Standardabweichungen ersetzt werden.

# 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

# Konfidenzellipsoide

Sei das Modell (2.1) mit NV-Annahme (2.5) gegeben. Dann ist

$$\left\{ \beta \mid (\beta - \hat{\beta})'(X'X)(\beta - \hat{\beta}) \leq p' \hat{\sigma}^2 F_{1-\alpha}(p', n - p') \right\} \tag{3.70}$$

eine Konfidenzregion für  $\beta$ .

Entsprechendes gilt für lineare Transformationen  $\gamma = A\beta$ :

$$\left\{ \gamma \mid (\gamma - \hat{\gamma})' \widehat{V}(\hat{\gamma})^{-1} (\gamma - \hat{\gamma}) < \dim \gamma \cdot F_{1-\alpha}(\dim(\gamma), n - p') \right\}$$

ist Konfidenzregion zum Sicherheitsniveau  $1 - \alpha$ .

Sei Modell (2.1) mit NV-Annahme (2.5) gegeben.  
Dann sind

$$\hat{\beta}_j \pm \sqrt{p' F_{1-\alpha}(p', n - p')} \hat{\sigma}_{\hat{\beta}_j} \tag{3.71}$$

für die Parameter  $\beta_j$  und

$$\hat{\gamma} \pm \sqrt{p' F_{1-\alpha}(p', n - p')} \hat{\sigma}_{\hat{\gamma}}$$

für beliebige Linearkombinationen  $\gamma = a'\beta$  simultane Konfidenzintervalle.

- Die KIs nach Scheffe sind bei einer Vielzahl von Parametern sinnvoll
- Die KIs nach Scheffe sind z.B zur Bestimmung von simultanen Konfidenzregionen für Y geeignet
- Es gibt in Analogie zu den KIs einen entsprechenden multiplen Test
- Allgemeine Strategie für KI siehe Hothorn, Bretz und Westfall: Simultaneous inference in general parametric models. Biometrical Journal, 2008; R-package „multcomp“

## Das Gauss-Markov-Theorem

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

Ist  $\tilde{\beta}$  ein weiterer Schätzer von  $\beta$  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  $n \geq p$

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

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

$$\hat{\beta}^{(n)} \xrightarrow{P} \beta. \quad (3.72)$$

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

$$\hat{\beta}^{(n)} \xrightarrow{\text{f.s.}} \beta. \quad (3.73)$$

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  $\hat{\beta}$

$$\sigma^{-1}(X_n'X_n)^{1/2}(\hat{\beta}^{(n)} - \beta) \xrightarrow{d} N(0, I). \quad (3.74)$$