



LUDWIG-
MAXIMILIANS-
UNIVERSITÄT
MÜNCHEN

Institut für Statistik



Vorlesung: Lineare Modelle

Prof. Dr. Helmut Küchenhoff

Institut für Statistik, LMU München

SoSe 2015



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

Quadratsummenzerlegung

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

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

Dann gilt:

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

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

Nachweis der Quadratsummenzerlegung (3.3)

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

P und Q Projektionsmatrizen.

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 ($E(Y) = \beta_0$)

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

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

Nachweis der Quadratsummenzerlegung (3.2) II

$$(*) \quad Q_e QY = Q_e \hat{\varepsilon} = \hat{\varepsilon} = QY$$

↑
„Residuen haben Mittelwert 0“

$$(*) \quad \begin{aligned} Q_e P Q_e P Y &= Q_e P Q_e \hat{Y} = Q_e P (\hat{Y} - \bar{Y}) \\ &= Q_e P \hat{Y} - Q_e P \bar{Y} = Q_e \hat{Y} - Q_e \bar{Y} = Q_e \hat{Y} - 0 \end{aligned}$$

↑
„Regression auf \hat{Y} und \bar{Y} liefert Identität“

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

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:

$$E(SST^*) = E(Y'Y) = \sigma^2 n + \beta' X' X \beta \quad (3.5)$$

$$E(SST) = E(Y - \bar{Y})'(Y - \bar{Y}) = \sigma^2(n - 1) + \beta'(Q_e X)'(Q_e X)\beta \quad (3.6)$$

$$E(SSE) = E(\hat{\varepsilon}'\hat{\varepsilon}) = \sigma^2(n - p') \quad (3.7)$$

$$E(SSM^*) = E(\hat{Y}'\hat{Y}) = \sigma^2 p' + \beta' X' X \beta \quad (3.8)$$

$$E(SSM) = E(\hat{Y} - \bar{Y})'(\hat{Y} - \bar{Y}) = \sigma^2 p + \beta'(Q_e X)'(Q_e X)\beta \quad (3.9)$$

Bemerkungen

- 1 Die stochastischen Eigenschaften der Quadratsummen werden zur Konstruktion von Tests bezüglich β 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.

Beweisidee

Allgemein berechnet man den Erwartungswert von quadratischen Formen wie folgt:

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

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

Mittlere Quadratsummen

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

$$MST^* := \frac{SST^*}{n} \quad (3.10)$$

$$MST := \frac{SST}{n-1} \quad (3.11)$$

$$MSE := \frac{SSE}{n-p'} \quad (3.12)$$

$$MSM^* := \frac{SSM^*}{p'} \quad (3.13)$$

$$MSM := \frac{SSM}{p} \quad (3.14)$$

Verteilungsdefinitionen

Normalverteilung

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

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

mit positiv definiten, symmetrischer Matrix Σ .

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 $\text{rg}(A) = m$

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

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 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.

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

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

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,

δ : 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

δ : Nichtzentralitätsparameter

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

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

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:

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

$$CA = 0 \implies CZ \text{ und } Z'AZ \text{ sind unabh.} \quad (3.22)$$

$$AB = 0 \implies Z'AZ \text{ und } Z'BZ \text{ sind unabh.} \quad (3.23)$$



Beweis von (3.21)

Spektralzerlegung von A

$$A = T\Sigma T'$$

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

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

Für $\tilde{Z} := T'Z$ gilt: $\text{Var}(\tilde{Z}) = T'IT = I$

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

Beweis von (3.22) und (3.23)

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

Damit sind CZ und $Z'A$ unabhängig (NV-Annahme!)

$\Rightarrow CZ$ und $(Z'A)(Z'A)' = Z'AZ$ unabh.

qed

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

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:

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

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

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

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

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

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

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

Beweis

(3.24) (Normalverteilung von β) folgt aus Eigenschaften der NV (3.16)

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

(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-Tests

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

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

(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

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

Overall Test mit $\beta_0 = 0$

$$F_0^* = \frac{MSM^*}{MSE} \sim F(p', n - p', \sigma^{-2} \beta' (X' X) \beta) \quad (3.32)$$

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

Lehne H_0^{O*} ab, falls

$$F_0^* > F_{1-\alpha}(p', n - p') \quad (3.33)$$

$F_{1-\alpha}(p, n - p')$: $(1 - \alpha)$ -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 β darstellen lassen, betrachtet werden:

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

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

Beispiele:

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

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

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

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.

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

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

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

$$MSH := \frac{SSH}{a} \quad (3.37)$$

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

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:

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

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 $A = (0 \cdots 1 \cdots 0)$

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 $\hat{\cdot}$ gekennzeichnet.

Wir lösen das Minimierungsproblem:

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

mit der Lagrange-Methode:

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

λ ist der Vektor der Lagrange-Multiplikationen.

Berechnung der Lösung $\hat{\hat{\beta}}$

$$\frac{\partial S}{\partial \beta} = 0 \Leftrightarrow -2X'Y + 2X'X\hat{\hat{\beta}} + 2A'\lambda = 0$$

$$\frac{\partial S}{\partial \lambda} = 0 \Leftrightarrow A\hat{\hat{\beta}} = c$$

$$A'\lambda = X'Y - X'X\hat{\hat{\beta}} \quad | \cdot (X'X)^{-1}$$

$$(X'X)^{-1}A'\lambda = \hat{\beta} - \hat{\hat{\beta}} \quad | \cdot A (*)$$

$$\Rightarrow A(X'X)^{-1}A'\lambda = A\hat{\beta} - c \quad (A\hat{\hat{\beta}} = c)$$

$$\Rightarrow \lambda = (A(X'X)^{-1}A')^{-1}(A\hat{\beta} - c)$$

$$(*) \Rightarrow \hat{\hat{\beta}} = \hat{\beta} - (X'X)^{-1}A'[A(X'X)^{-1}A']^{-1}(A\hat{\beta} - c)$$

$$w := (X'X)^{-1}A'[A(X'X)^{-1}A']^{-1}(A\hat{\beta} - c)$$

Darstellung von SSH

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

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 :

$$\begin{aligned} SSE &= \hat{\varepsilon}'\hat{\varepsilon} \\ SSE(H_0) &:= \hat{\varepsilon}'_0\hat{\varepsilon}_0 \end{aligned} \quad (3.40)$$

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

$$MSH = SSH/a$$

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

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

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:

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

$$SSE(H_0) = SSE(M1)$$

$$SSH = SSE(M1) - SSE$$

Vergleich der SSE der beiden Modelle.

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.

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 β_1 : Geschlechtsunterschied

Annahme: Bei WOL ist der durchschnittliche Unterschied in der Fehlerzahl zwischen den Stufen 1-5 gleich groß (Änderung um 1 entspricht β_4)

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.