



LUDWIG-
MAXIMILIANS-
UNIVERSITÄT
MÜNCHEN

Institut für Statistik



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

Quadratsummenzerlegung

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

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

Dann gilt:

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

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

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“

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

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:

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

Unter Benutzung von $\text{Sp}(AV(Y)) = \text{sp}(A) * \sigma^2 = \text{rang}(A) * \sigma^2$ 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

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

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 (3.17)

$$A = T\Sigma T'$$

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

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

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

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

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):

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

Reparametrisierung des Modells unter linearer Restriktion

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

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

$$V = Z\gamma + \varepsilon \quad (3.44)$$

$$V := Y - Xd \quad (3.45)$$

$$Z := XB \quad (3.46)$$

Das Modell ist das reparametrisierte Modell mit:

Zielgröße: $V = Y - Xd \in R^n$

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

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

Störterm : ε stimmt mit dem aus dem Grundmodell überein!

Zusammenhang Reparametrisierung und Modell unter linearer Restriktion

Es gilt:

$$\hat{\hat{\beta}} = B\hat{\gamma} + d \quad (3.47)$$

$$SSH = \hat{\hat{\varepsilon}}'\hat{\hat{\varepsilon}} - \hat{\varepsilon}'\hat{\varepsilon} \quad (3.48)$$

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

$$\hat{\sigma}^2 = \frac{\sum \hat{\varepsilon}_i^2}{n} \quad (3.49)$$

$$\text{Max}L = C * \hat{\sigma}^n = C * (SSE/n)^{(n/2)} \quad (3.50)$$

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:

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

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:

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

g streng monoton

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

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

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.

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

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.

Partielle Quadratsummen

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

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

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

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

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

Sequentielle Quadratsummen

Wir betrachten die Folge von Modellen:

$$M_0 : \quad Y = \beta_0 + \varepsilon \quad (3.56)$$

$$M_1 : \quad Y = \beta_0 + \beta_1 x_1 + \varepsilon \quad (3.57)$$

...

$$M_p : \quad Y = X\beta + \varepsilon \quad (3.58)$$

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

heißen **sequentielle Quadratsummen** und es gilt:

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

Bereinigung

Wir betrachten folgende Zerlegung des Modells (2.1):

$$Y = X\beta + \varepsilon \quad (3.61)$$

$$Y = (X_1 X_2)(\beta_1' \beta_2')' + \varepsilon = X_1 \beta_1 + X_2 \beta_2 + \varepsilon \quad (3.62)$$

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

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

$$Y^* := Q_2 Y \quad (3.65)$$

$$X_1^* := Q_2 X_1 \quad (3.66)$$

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

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

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:

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

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

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

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

$$\text{Analog: } QQ_2 = Q$$

Beweis von (3.67) II

$$Q_2 Y = Q_2 X_1 \hat{\beta}_1 + \underbrace{Q_2 X_2}_{0} \hat{\beta}_2 + \underbrace{Q_2 \hat{\varepsilon}}_{\underbrace{Q_2 Q Y}_Q}$$

$$\Rightarrow Q_2 Y = Q_2 X_1 \hat{\beta}_1 + \hat{\varepsilon}$$

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

$$X_1^{*'} \hat{\varepsilon} = (Q_2 X_1)' \hat{\varepsilon} = X_1' Q_2 Q \hat{\varepsilon} = X_1' \hat{\varepsilon} = 0$$

$\Rightarrow \hat{\beta}_1$ 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

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

Bonferroni-Konfidenzintervalle

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

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

simultane Konfidenzintervalle zum Sicherheitsniveau $1 - \alpha$:

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

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

Konfidenzellipsoide

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

Dann ist

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

eine Konfidenzregion für β .

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 $1 - \alpha$.

Konfidenzintervalle nach Scheffe

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

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

für die Parameter β_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.

Bemerkungen

- 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 (**b**est **l**inear **u**nbiased **e**stimator).

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):

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

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

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

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

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