



Vorlesung: Lineare Modelle

Prof. Dr. Helmut Küchenhoff

Institut für Statistik, LMU München

SoSe 2014

- Einführung und Beispiele
- ① Das einfache lineare Regressionsmodell
- Das multiple lineare Regressionsmodell
- Quadratsummenzerlegung und statistische Inferenz im multiplen linearen Regressionsmodell



- Einführung und Beispiele
- ① Das einfache lineare Regressionsmodell
- Das multiple lineare Regressionsmodell
- Quadratsummenzerlegung und statistische Inferenz im multiplen linearen Regressionsmodell

Quadratsummenzerlegung

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

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

Dann gilt:

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

Interpretation:

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

Nachweis der Quadratsummenzerlegung (3.3)

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

P und Q Projektionsmatrizen.

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:

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

- 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 (3.2) I

Wir definieren:

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

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

- $P_e Y = \bar{Y}$ („Mittelwert bilden“)
- $Q_e Y = Y - \bar{Y}$ („Mittelwertsbereinigung“)

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

Nachweis der Quadratsummenzerlegung (3.2) II

(*) $Q_e QY = Q_e \hat{\varepsilon} = \hat{\varepsilon} = QY$
 ↑
 „Residuen haben Mittelwert 0“

(*) $Q_e P Q_e P Y = Q_e P Q_e \hat{Y} = Q_e P (\hat{Y} - \bar{Y})$
 $= Q_e P \hat{Y} - Q_e P \bar{Y} = Q_e \hat{Y} - Q_e \bar{Y} = Q_e \hat{Y} - 0$
 ↑
 „Regression auf \hat{Y} und \bar{Y} liefert Identität“

$$(Y - \bar{Y})'(Y - \bar{Y}) = Y' Q_e' Q_e Y = Y' Q_e Y$$

$$= Y' Q_e (Q + P) Y = Y' Q_e Q Y + Y' Q_e P Y$$

$$\stackrel{(*)}{=} Y' Q Y + Y' Q_e P Q_e P Y$$

$$= \hat{\varepsilon}' \hat{\varepsilon} + Y' P' Q_e P Y$$

$$= (\hat{Y} - \bar{Y})' (\hat{Y} - \bar{Y})$$

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.

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:

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

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

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

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

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

Beweisidee

Allgemein berechnet man den Erwartungswert von quadratischen Formen wie folgt:

$$E(Y'AY) = E \left(\sum_{i=1}^n \sum_{j=1}^n a_{ij} Y_i Y_j \right) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} E(Y_i Y_j)$$

$$= \sum_{i=1}^n \sum_{j=1}^n a_{ij} E(Y_i) E(Y_j) + \sum_{i=1}^n \sum_{j=1}^n a_{ij} Cov(Y_i, Y_j)$$

$$= E(Y)' A E(Y) + Sp(AV(Y))$$

$$V(Y) := \text{Varianz-Kovarianzmatrix von } Y$$

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

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

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

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

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

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

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

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 $rg(A) = m$

$$\implies AZ \sim N_m(A\mu, A\Sigma A') \tag{3.16}$$

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

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

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 Σ .

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

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**

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

F-Verteilung

Seien W_1 und W_2 voneinander unabhängige Zufallsgrößen mit

$$\begin{aligned} W_1 &\sim \chi^2(n_1, \delta) \\ W_2 &\sim \chi^2(n_2) \end{aligned}$$

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:

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

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 $X = \frac{Z}{\sqrt{W/n}}$ (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:

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

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)

$$A = T\Sigma T'$$

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

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

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

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