


## Kapitel 3 Multiple Regression

Vorteile: 1. allgemeinere funktionale Formen

Bsp:  $x$ : Alter

$$z = x^2$$



2. zusätzlicher Erklärungsgehalt

Bsp  $\text{Lohn} = \beta_0 + \beta_1 \text{Bildung} + \beta_2 \text{Talent}$

3. strikte Exogenität ist plausibler

Nachteil Matrix Notation!

Kleinste Quadrate (KQ) mit zwei Regressoren

$X$ : 1. Regressor

$Z$ : 2. Regressor

Annahme:  $X, Z$  streuen,  $S_{XX} > 0$   $S_{ZZ} > 0$

$Z$  ist keine lineare Funktion von  $X$

$$S_{XZ} = \frac{\text{Cor}(X, Z)}{\sqrt{\text{Var}(X)} \cdot \sqrt{\text{Var}(Z)}} \quad , \quad |S_{XZ}| \neq 1$$

Regressionsmodell

$$y_i = \beta_0 + \beta_1 X_i + \beta_2 Z_i + u_i$$

Annotations in red:

- Regressand (points to  $y_i$ )
- Parameter (points to  $\beta_0, \beta_1, \beta_2$ )
- Regressoren (points to  $X_i, Z_i$ )
- Störterm (points to  $u_i$ )

Prognose  $\hat{y}$

$b_0, b_1, b_2$ : Vermutungen für  $\beta_0, \beta_1, \beta_2$

$$\hat{y}_i = b_0 + b_1 x_i + b_2 z_i$$

Prognosefehler Residuum  $\hat{u}$

$$\hat{u}_i = y_i - \hat{y}_i = y_i - b_0 - b_1 x_i - b_2 z_i$$

Summe der quadrierten Residuen SSR

$$SSR(b_0, b_1, b_2) = \sum_{i=1}^n \hat{u}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - b_0 - b_1 x_i - b_2 z_i)^2$$

$$\min_{b_0, b_1, b_2 \in \mathbb{R}} \sum_{i=1}^n (y_i - b_0 - b_1 x_i - b_2 z_i)^2$$

notw. Bed. 1. Ordnung

$$\frac{\partial SSR(b_0, b_1, b_2)}{\partial b_0} = \sum_{i=1}^n 2 \cdot (y_i - b_0 - b_1 x_i - b_2 z_i) \cdot (-1) \stackrel{!}{=} 0$$

$$\frac{\partial SSR(b_0, b_1, b_2)}{\partial b_1} = \sum_{i=1}^n 2 (y_i - b_0 - b_1 x_i - b_2 z_i) (-x_i) \stackrel{!}{=} 0$$

$$\frac{\partial SSR(b_0, b_1, b_2)}{\partial b_2} = \sum_{i=1}^n 2 (y_i - b_0 - b_1 x_i - b_2 z_i) (-z_i) \stackrel{!}{=} 0$$

Es gibt hier eine eindeutige Lösung  $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2$   
 „kleinste Quadrate Schätzer“

Hesse matrix

$$H_{SSR} = \begin{pmatrix} \frac{\partial^2 SSR}{(\partial b_0)^2} & \frac{\partial^2 SSR}{\partial b_0 \partial b_1} & \frac{\partial^2 SSR}{\partial b_0 \partial b_2} \\ \frac{\partial^2 SSR}{\partial b_1 \partial b_0} & \frac{\partial^2 SSR}{\partial b_1 \partial b_1} & \frac{\partial^2 SSR}{\partial b_1 \partial b_2} \\ \frac{\partial^2 SSR}{\partial b_2 \partial b_0} & \frac{\partial^2 SSR}{\partial b_2 \partial b_1} & \frac{\partial^2 SSR}{\partial b_2 \partial b_2} \end{pmatrix}$$

$$= \begin{pmatrix} \sum_{i=1}^n 2 & \sum_{i=1}^n 2x_i & \sum_{i=1}^n 2z_i \\ \sum_{i=1}^n 2x_i & \sum_{i=1}^n 2x_i^2 & \sum_{i=1}^n 2x_i z_i \\ \sum_{i=1}^n 2z_i & \sum_{i=1}^n 2x_i z_i & \sum_{i=1}^n 2z_i^2 \end{pmatrix}$$

$$= 2 \begin{pmatrix} \sum_{i=1}^n 1 & \sum_{i=1}^n x_i & \sum_{i=1}^n z_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i z_i \\ \sum_{i=1}^n z_i & \sum_{i=1}^n x_i z_i & \sum_{i=1}^n z_i^2 \end{pmatrix}$$

$$2 \cdot n \cdot \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n 1 & \frac{1}{n} \sum_{i=1}^n x_i & \frac{1}{n} \sum_{i=1}^n z_i \\ \frac{1}{n} \sum_{i=1}^n x_i & \frac{1}{n} \sum_{i=1}^n x_i^2 & \frac{1}{n} \sum_{i=1}^n x_i z_i \\ \frac{1}{n} \sum_{i=1}^n z_i & \frac{1}{n} \sum_{i=1}^n x_i z_i & \frac{1}{n} \sum_{i=1}^n z_i^2 \end{pmatrix}$$

1. empirische Momente

$$= 2n \cdot \begin{pmatrix} 1 & \bar{x} & \bar{z} \\ \bar{x} & \overline{xx} & \overline{xz} \\ \bar{z} & \overline{xz} & \overline{zz} \end{pmatrix}$$

2. empirischen Momente

Momente Matrix

$$S_{xx} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \overline{xx} - \bar{x} \cdot \bar{x}$$

$$S_{zz} = \overline{zz} - \bar{z} \cdot \bar{z}$$

$$S_{xz} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z}) = \overline{xz} - \bar{x} \cdot \bar{z}$$

# Matrizen & Vektoren

$A$  mit Ordnung  $m \times n$

$m$ : # Zeilen

$n$ : # Spalten

Kurz:  $A \in \mathbb{R}^{m \times n}$

$$\underline{A}_{m \times n} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{pmatrix}$$

Zeile  $\swarrow$   $a_{12}$   $\nwarrow$  Spalte

Spaltenvektor  $\underline{a} \in \mathbb{R}^m$   
 $m \times 1$

Zeilenvektor  $\underline{b} \in \mathbb{R}^n$   
 $1 \times n$

Stichprobengröße  $n$

# Regressionsmodell

$$y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

$$x_{\cdot j} = \begin{pmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{nj} \end{pmatrix}$$

$$j = 1, \dots, K$$

↑  
Anzahl der  
Regressoren

$$u = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

# Regressormatrix

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1K} \\ 1 & x_{21} & x_{22} & \dots & x_{2K} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nK} \end{pmatrix}$$

"iota"

$$I = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$$

$A$  ist quadratisch, falls  $m=n$   
 $m \times n$

Transponierte Matrix  $A'$  ( $A^T$ )

$$A' = \begin{pmatrix} a_{11} & a_{21} & \dots & a_{n1} \\ a_{12} & a_{22} & \dots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1m} & a_{2m} & \dots & a_{nm} \end{pmatrix}$$

$A$  ist symmetrisch, falls  $A = A'$

# Besondere Matrizen

$$I_n = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}$$

Einheitsmatrix  
(Identität)

$$N = \begin{pmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{pmatrix}$$

Nullmatrix

$$e_i = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix} \quad \begin{array}{l} i\text{-te} \\ \text{Zeile} \end{array}$$

# Addition von Matrizen

$$A, B \\ m \times n, m \times n$$

$$A + B = B + A = C$$

$$c_{ij} = a_{ij} + b_{ij}$$

# Multiplikation mit Skalar

$$A, b \in \mathbb{R} \\ m \times n$$

$$A \cdot b = b \cdot A = C$$

$$c_{ij} = b \cdot a_{ij}$$

# Linearkombination von Vektoren

$$x, z \in \mathbb{R}^n, \quad b_1, b_2 \in \mathbb{R}$$

$$b_1 \cdot x + b_2 z = b_1 \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} + b_2 \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{pmatrix}$$

$$= \begin{pmatrix} b_1 x_1 \\ b_1 x_2 \\ \vdots \\ b_1 x_n \end{pmatrix} + \begin{pmatrix} b_2 z_1 \\ b_2 z_2 \\ \vdots \\ b_2 z_n \end{pmatrix}$$

$$= \begin{pmatrix} b_1 x_1 + b_2 z_1 \\ b_1 x_2 + b_2 z_2 \\ \vdots \\ b_1 x_n + b_2 z_n \end{pmatrix}$$

# Multiplikation zweier Vektoren (Skalarprodukt)

$$V, W \in \mathbb{R}^n$$

$$V \cdot W = (v_1, v_2, \dots, v_n) \begin{pmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{pmatrix} = \sum_{i=1}^n v_i \cdot w_i$$

Für  $V = W$ :

$$V \cdot V = \sum_{i=1}^n \underbrace{v_i^2}_{\geq 0} \geq 0$$

Norm (Länge eines Vektors)

$$\|V\| = \sqrt{V \cdot V} = \sqrt{\sum_{i=1}^n v_i^2}$$

28.4.26

$$y_i = \beta_0 + \beta_1 X_i + \beta_2 Z_i + u_i$$

$$(1, X_i, Z_i) \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} = 1 \cdot \beta_0 + X_i \cdot \beta_1 + Z_i \cdot \beta_2$$

↑  
i. te Zeile von  $X$

# Matrix multiplication

Zeilen  $\rightarrow$   $m \times n$   $\leftarrow$  Spalten

$$A \in \mathbb{R}$$

$$B \in \mathbb{R}^{n \times o}$$

$$A \cdot B = \begin{matrix} m \times n & n \times o \end{matrix}$$

$$= C \begin{matrix} m \times o \end{matrix}$$

jte Spalte von B

$$C_{ij} = (a_{i1}, a_{i2}, \dots, a_{in})$$

lter Zeilenvektor von A

$$\begin{pmatrix} b_{1j} \\ b_{2j} \\ \vdots \\ b_{nj} \end{pmatrix}$$

Spezialfall:  $B$  ist ein Spaltenvektor:  $0=1$

$$\begin{matrix} A \cdot B & = & C \\ m \times n & n \times 1 & m \times 1 \end{matrix}$$

$$\begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & & & \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{pmatrix} \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix} = \begin{pmatrix} a_{11}b_1 + a_{12}b_2 + \dots + a_{1n}b_n \\ a_{21}b_1 + a_{22}b_2 + \dots + a_{2n}b_n \\ \vdots \\ a_{m1}b_1 + a_{m2}b_2 + \dots + a_{mn}b_n \end{pmatrix}$$

$$\begin{pmatrix} a_{11}b_1 \\ a_{21}b_1 \\ \vdots \\ a_{m1}b_1 \end{pmatrix} + \begin{pmatrix} a_{12}b_2 \\ a_{22}b_2 \\ \vdots \\ a_{m2}b_2 \end{pmatrix} + \dots + \begin{pmatrix} a_{1n}b_n \\ a_{2n}b_n \\ \vdots \\ a_{mn}b_n \end{pmatrix} = \begin{pmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{m1} \end{pmatrix} b_1 + \begin{pmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{m2} \end{pmatrix} b_2 + \dots + \begin{pmatrix} a_{1n} \\ a_{2n} \\ \vdots \\ a_{mn} \end{pmatrix} b_n$$

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} \beta_0 + \begin{pmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{n1} \end{pmatrix} \beta_1 + \dots + \begin{pmatrix} x_{1k} \\ x_{2k} \\ \vdots \\ x_{nk} \end{pmatrix} \beta_k + \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

$$= \begin{pmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & & x_{2k} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & & x_{nk} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

$$\begin{aligned}
 (=) \quad \underset{n \times 1}{y} &= \underset{n \times \underline{k+1}}{X} \underset{\underline{k+1} \times 1}{\beta} + \underset{n \times 1}{u}
 \end{aligned}$$

Die Transponierte eines Matrixproduktes

$$\begin{matrix} (A \cdot B)' \\ m \times n & n \times o \end{matrix} = \begin{matrix} B' \cdot A' \\ o \times n & n \times m \end{matrix}$$

# 1.4. Stochastische Matrizen & Vektoren

$A$  zufällige Matrix  
 $m \times n$

Erwartungswert

$$E[A] = \begin{pmatrix} E[a_{11}] & E[a_{12}] & \dots & E[a_{1n}] \\ E[a_{m1}] & E[a_{m2}] & \dots & E[a_{mn}] \end{pmatrix}$$

$B$   $n \times 0$ ,  $C$   $m \times 0$  fest, nicht zufällig

$$E[A \cdot B + C] = E[A] \cdot B + C$$

$V, w$  zufällige Vektoren  
 $n \times 1$   $n \times 1$

Varianz - Kovarianz - Matrix

$$\Sigma(V, w) = E \left[ \underbrace{(v - E[v])}_{n \times 1} \underbrace{(w - E[w])'}_{1 \times n} \right]$$

$n \times n$

$$= \begin{pmatrix} \underbrace{E[(v_1 - E[v_1])(w_1 - E[w_1])]}_{\text{Cov}(v_1, w_1)} & \dots & \underbrace{E[(v_1 - E[v_1])(w_n - E[w_n])]}_{\text{Cov}(v_1, w_n)} \\ \underbrace{E[(v_n - E[v_n])(w_1 - E[w_1])]}_{\text{Cov}(v_n, w_1)} & \dots & \underbrace{E[(v_n - E[v_n])(w_n - E[w_n])]}_{\text{Cov}(v_n, w_n)} \end{pmatrix}$$

$$\begin{aligned}
 \Sigma(v, v) &= \begin{pmatrix} \underbrace{\text{Cor}(v_1, v_1)}_{\text{Var}(v_1)} & \dots & \text{Cor}(v_1, v_n) \\ \vdots & & \vdots \\ \underbrace{\text{Cor}(v_n, v_n)}_{\text{Var}(v_n)} & \dots & \dots \end{pmatrix} \\
 &= \Sigma(v)
 \end{aligned}$$

$$\begin{aligned}
 (\Sigma(v))' &= \left( E \left[ (v - E[v])(v - E[v])' \right] \right)' \\
 &= E \left[ \left( (v - E[v])(v - E[v])' \right)' \right] \\
 &= E \left[ \left( (v - E[v])' \right)' (v - E[v]) \right] = E \left[ (v - E[v])(v - E[v])' \right] \\
 &= \Sigma(v)
 \end{aligned}$$

$$\mathbf{u}_{n \times 1} = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

Zufallsvektor

Annahmen

$$E[\mathbf{u}] = \begin{pmatrix} E[u_1] \\ E[u_2] \\ \vdots \\ E[u_n] \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$\text{Cov}(\mathbf{u}) = \begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{pmatrix} = \sigma^2 \mathbf{I}_n$$

$\text{Var}(u_i) = \sigma^2 \quad i=1, \dots, n$   
homoskedastisch

$\text{Cor}(u_i, u_j) = 0 \quad i \neq j$   
seriell unkorreliert

# Rechenregeln für Varianz-Kovarianz-Matrizen

$$\underbrace{A}_{m \times n} \underbrace{v}_{n \times 1} + \underbrace{b}_{m \times 1} \quad A, b \text{ fest, } v \text{ zufällig}$$

$$\mathbb{E}[(Av + b)] = A \mathbb{E}[v] \cdot A'$$

$$= \mathbb{E}[(Av + b - \mathbb{E}[Av + b])(Av + b - \mathbb{E}[Av + b])']]$$

$$= \mathbb{E}[(Av - \mathbb{E}[Av])(Av - \mathbb{E}[Av])']]$$

$$= \mathbb{E}[A(v - \mathbb{E}[v])(v - \mathbb{E}[v])' A']$$

Lineare Unabhängigkeit von Vektoren

Zwei Vektoren  $v, w, x$  sind linear abhängig, falls

$$v = a \cdot w + b \cdot x \leftarrow \text{Vektor}$$

↑            ↑            ↑            ↑  
Vektor    Zahl    Vektor    Zahl

$k$  Vektoren sind linear unabhängig, falls  
keiner der Vektoren als Linearkombination der  
anderen Vektoren dargestellt werden kann.

$x_1, x_2, \dots, x_k \in \mathbb{R}^n$  lin. unabh. falls

$$\sum_{i=1}^k x_i \cdot \lambda_i = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \Rightarrow \lambda_i = 0 \quad i=1, \dots, k$$

$\mathbb{R}^2$

$$\begin{pmatrix} 8 \\ 4 \end{pmatrix}$$


$$\begin{pmatrix} 6 \\ 8 \end{pmatrix}$$

$$\begin{pmatrix} -u \\ -u \end{pmatrix}$$

Gibt es  $\lambda_1, \lambda_2, \lambda_3$  mit

$$\begin{pmatrix} 8 \\ 4 \end{pmatrix} \lambda_1 + \begin{pmatrix} 6 \\ 8 \end{pmatrix} \lambda_2 + \begin{pmatrix} -u \\ -u \end{pmatrix} \lambda_3 = 0$$

$$\Leftrightarrow \begin{pmatrix} 8 \\ 4 \end{pmatrix} \lambda_1 + \begin{pmatrix} 6 \\ 8 \end{pmatrix} \lambda_2 = \begin{pmatrix} u \\ u \end{pmatrix} \lambda_3$$



$$8\lambda_1 + 6 \cdot 2\lambda_1 = u$$

$$\lambda_1 = \frac{1}{20} \cdot u$$

$$\lambda_2 = \frac{1}{10} \cdot u$$

für  $\lambda_2 = 1$ :

$$8\lambda_1 + 6\lambda_2 = u$$

$$4\lambda_1 + 8\lambda_2 = u$$

$$8\lambda_1 + 6\lambda_2 = 4\lambda_1 + 8\lambda_2$$

$$4\lambda_1 = 2\lambda_2$$

$$2\lambda_1 = \lambda_2$$

Rang einer Matrix

# linear unabhängigen Zeilen oder Spalten der Matrix

Regressormatrix  $\underline{X}$   
 $n \times k+1$

Annahme: voller Spaltenrang  $\text{rk}(\underline{X}) = k+1$

Alle Spalten von  $\underline{X}$  müssen linear unabhängig sein

# Beispiel

$y_i$ : Zeit, die zur Vorbereitung auf  
die Vorlesung Ökonometrie benutzt wird

$$L = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$$

$$x_i = \begin{cases} 1, & \text{falls } \text{♂} \\ 0, & \text{falls } \text{♀} \end{cases}$$

$$z_i = \begin{cases} 0, & \text{falls } \text{♂} \\ 1, & \text{falls } \text{♀} \end{cases}$$

$$X = \begin{matrix} & L & X & Z \\ \begin{pmatrix} 1 & 0 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} \end{matrix}$$

gibt es Zahlen  $\lambda_1, \lambda_2$  für die gilt:

$$L = \lambda_1 \cdot X + \lambda_2 \cdot Z$$

$$\text{ja: } \lambda_1 = \lambda_2 = 1 \quad \checkmark$$

# Modellannahmen

5.5.2025

MLR 1 "linear in Parametern  $\beta$ "

$$y = X\beta + u$$

erlaubt: z.B.  $x_i^2$

verboten:  $\beta_1^2$  oder  $\beta_1\beta_2$

MLR 2 "Zufallsstichprobe"

$y, X$  sind zufällige Beobachtungen

ex ante:  $X$  zufällig & unbekannt z.B.  $E[\hat{\beta}]$

ex post:  $X$  Stichprobe steht fest z.B.  $E[\hat{\beta} | X]$

MLR 3 "voller Spaltenrang von  $X$ "

$$\text{rk}(X) = k+1, \quad X \in \mathbb{R}^{n \times (k+1)}$$

Alle  $k+1$  Spalten von  $X$  sind linear unabhängig.

MLR 4 "strikte Exogenität"

$$E[u | X] = E[u] = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \in \mathbb{R}^n$$

↑  
oBdA

MLR 4  $\Rightarrow \text{Cov}(u, X_j) = 0$  für  $j = 1, \dots, k+1$   
"schwache Exogenität"

MLR 5 "Homoskedastizität & serielle Unkorreliertheit"  
"gleiche Varianz"

$$E(u | X) = \sigma^2 \cdot I_n$$

Dies bedeutet:  $\text{Var}(u_i | X) = \sigma^2$   $i = 1, \dots, n$

$\text{Cov}(u_i, u_j | X) = 0$   $i, j = 1, \dots, n$   
 $i \neq j$

MLR 6 "normalverteilte Störterme"

$$u \sim \mathcal{N}(0, \sigma^2 \cdot I_n)$$

# Schätzer für $\beta$

Lineare Funktion

$$f: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

• Additivität:  $f(x_1 + x_2) = f(x_1) + f(x_2)$ ,  $x_1, x_2 \in \mathbb{R}^n$

• Homogenität:  $f(t \cdot x) = t \cdot f(x)$ ,  $x \in \mathbb{R}^n$ ,  $t \in \mathbb{R}$

$$A \in \mathbb{R}^{m \times n}, \quad x \in \mathbb{R}^n$$

$$f(x) = A \cdot x \quad \text{ist linear}$$

Jacobi Matrix : Matrix der 1. Ableitungen

$$f: \mathbb{R}^m \rightarrow \mathbb{R}^n$$

$$J_f = \begin{pmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_m} \\ \vdots & & \vdots \\ \frac{\partial f_n}{\partial x_1} & \dots & \frac{\partial f_n}{\partial x_m} \end{pmatrix}$$

Falls  $f(x) = A \cdot x$  dann  $J_f = A'$ ,  $A \in \mathbb{R}^{m \times n}$

Spezialfall  $m=1$  (A Zeilenvektor) Jacobi Matrix = "Gradient"

# Quadratische Form & positive Definitheit

$$f: \mathbb{R}^n \rightarrow \mathbb{R}$$

$$f(x) = x^T \cdot A \cdot x, \quad x \in \mathbb{R}^n, \quad A \in \mathbb{R}^{n \times n}$$

Jacobimatrix = Gradient

$$J_f = \nabla f = (A^T + A)x$$

Hessematrix (Matrix der 2. Ableitungen)

$$H_f = (A^T + A)^T = (A^T)^T + A^T = A + A^T = A^T + A$$

symmetrisch

falls  $A \in \mathbb{R}^{n \times n}$  symmetrisch:  $H_f = 2 \cdot A$

$A \in \mathbb{R}^{n \times n}$  heißt positiv semi definit, falls  
 $x'Ax \geq 0$  für alle  $x \in \mathbb{R}^n$

$A$  positiv definit, falls

$x'Ax > 0$  für alle  $x \in \mathbb{R}^n$ ,  $x \neq \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}$

Falls  $A \in \mathbb{R}^{n \times n}$  pos. def.  $\Rightarrow \text{rk}(A) = n$

Anwendung

Linear

Schätzer für  $\beta$ :

$$f(y) = A \cdot y$$

↑  
berechnen wir mit  $X$

Linear in  $y$

quadratische Form

Zielfunktion  $S(b) : \mathbb{R}^{k+1} \rightarrow \mathbb{R}$

$$S(b) = b' A b$$

$$\text{BEO: } (A' + A)b = 0$$

BZ.O:  $A' + A$  positiv definit  
 $\Rightarrow S$  strikt konvex

Löwner kleiner

$$A, B \in \mathbb{R}^{n \times n}$$

$A$  "löwner kleiner"  $B$  ,  $A \leq B$  , falls

$$\underbrace{x'Ax}_{\in \mathbb{R}} \leq \underbrace{x'Bx}_{\in \mathbb{R}} \quad \text{für alle } x \in \mathbb{R}^n$$

$$\Leftrightarrow 0 \leq x'Bx - x'Ax$$

$$\Leftrightarrow 0 \leq (x'B - x'A)x$$

$$\Leftrightarrow 0 \leq x'(B-A)x$$

$\Leftrightarrow B-A$  pos. semi def.

Anwendung

$$\varphi(\hat{\beta} | x) \leq \varphi(\hat{\gamma} | x)$$

für alle Schätzer  $\hat{\gamma}$  mit  
 $\hat{\gamma}$  erwartungstreu für  $\beta$

Inverse einer Matrix

$$A \in \mathbb{R}^{m \times n}, \quad B \in \mathbb{R}^{n \times m}$$

$B$  Pseudoinverse von  $A$ , falls gilt

$$\underbrace{B}_{n \times m} \cdot \underbrace{A}_{m \times n} = \underbrace{I}_{n \times n}$$

$$A \in \mathbb{R}^{n \times n}, \quad B \in \mathbb{R}^{n \times n}$$

$B$  Inverse von  $A$ , falls gilt

$$B \cdot A = I \quad \text{und} \quad A \cdot B = I$$

- Inverse kann nur für quadratische Matrizen existieren
- Nicht jede quadratische Matrix hat eine Inverse.
- Falls Inverse existiert, dann eindeutig
- Inverse  $A^{-1}$  von  $A \in \mathbb{R}^{n \times n}$  existiert  $(\Leftrightarrow) \text{rk}(A) = n$
- $A$  pos. def  $\Rightarrow \text{rk}(A) = n \Leftrightarrow A^{-1}$  existiert.

# Schätzer

Ein Schätzer ist eine Funktion  $f$  der Stichprobe  $y, X$

Definitionsbereich : Alle Werte der Stichprobe

Wertebereich  $\xrightarrow{\beta}$  Alle Werte der Parameter  $\beta : \mathbb{R}^{k+1}$

$\searrow \sigma^2$  Alle Werte der Varianz  $\sigma^2 : \mathbb{R}_>$

## Schätzer für $\beta$

Schätzer  $f(y, X)$  ist linear in  $y \in \mathbb{R}^n$

$$f(y, X) = A \cdot y$$

$\uparrow$   $A$  hängt von  $X$  ab

$f(y, x) = A \cdot y$  ist erwartungstreu für  $\beta$

Falls  $E[f(y, x)] = \beta$  für alle  $\beta \in \mathbb{R}^{k+1}$

$f(y, x)$  ist effizient falls

1.  $f(y, x)$  ist erwartungstreu für  $\beta$

2.  $\nabla(f(y, x)) \in \nabla(g(y, x))$  für alle  
linearen

& erwartungstreuen Schätzer

Lineare erwartungstreuer Schätzer für  $\beta$

• Linearer Schätzer  $f(y, X) = A \cdot y$

• erwartungstreuer Schätzer

$$E[f(y, X)] = \beta \quad \text{für alle } \beta \in \mathbb{R}^{k+1}$$

zunächst:

$$E[f(y, X) | X] = E[A \cdot y | X] = A \cdot E[y | X]$$

gegeben  $x$ :  $x$  ist fest  $\Rightarrow A$  fest

$$E[y | X] \stackrel{\text{MLR 1}}{=} E[\overbrace{X\beta + u}^{=y} | X] = X\beta + \underbrace{E[u | X]}_{\substack{\text{MLR 4} \\ = 0}}$$

$\uparrow$   
unbekannt  
fest

$$E[f(y, X) | X] = E[A \cdot y | X] = \dots = AX\beta$$

Falls  $AX = I$ , dann  $E[Ag | X] = \beta$

$$E_x \left[ \underbrace{E_y[A \cdot y | X]} \right] = E[A \cdot y] = \beta$$

$= \beta$ , falls  $AX = I$

$AX = I$  ist eine hinreichende Bedingung  
für die Erwartungstreue von  $A \cdot y$  für  $\beta$ .

$A$  ist eine Pseudoinverse von  $X$ .

Varianz-Kovarianz-Matrix von  $A \cdot y$  mit  $AX=I$

$$\text{Var}(A \cdot y | X) = A \cdot \underbrace{\text{Var}(y | X)}_{?} \cdot A'$$

$$\text{Var}(y | X) \stackrel{\text{MLR 1}}{=} \text{Var}(X\beta + u | X) = \text{Var}(u | X)$$

$$\stackrel{\text{MLR 5}}{=} \sigma^2 \cdot I_n$$

$$\text{Var}(A \cdot y | X) = A \cdot \underbrace{\sigma^2 \cdot I_n}_{A'} \cdot A' = \sigma^2 \cdot A \cdot A'$$

wiederholung / Zusammenfassung

12.5.26

Stichprobe:  $X, y$

Ökonometrisches Modell:  $y = X\beta + u$

↑ unbekannt, gesucht

Linearer Schätzer:  $A \cdot y$    
 ↑ hängt von  $X$  ab

Falls  $A \cdot X = I$ :  $E[A \cdot y] = \beta$

Var( $u_i$ )

Varianz-Kovarianz-Matrix von  $A \cdot y$ :  $\text{Cov}(A \cdot y | X) = \sigma^2 \cdot A \cdot A'$

Gesucht: Matrix  $A$  mit  $AX = I$  für die gilt:

$$A \cdot A' \leq B \cdot B' \text{ für alle } B \text{ mit } BX = I$$

Kleinste Quadrate Schätzung

Vermutung  $b \in \mathbb{R}^{k+1}$  für  $\beta \in \mathbb{R}^{k+1}$

Prognose:  $\hat{y} = X \cdot b$

Schätzfehler (Residuum)  $\hat{u} = y - \hat{y}$

Zielfunktion  $S(b) = \hat{u}' \hat{u} = \sum_{i=1}^n \hat{u}_i^2$

$$= (y - \hat{y})' (y - \hat{y}) = (y - Xb)' (y - Xb)$$

$$= y'y + y'(-Xb) + (-Xb)'y + (-Xb)' \cdot (-Xb)$$

$$= y'y - y'Xb - b'X'y + b'X'Xb$$

$$\begin{aligned}
 S(b) = \dots &= y'y - \underline{y'Xb} - \underbrace{b'X'y}_{=(b'X'y)'} + b'X'Xb \\
 &= \underline{y'Xb}
 \end{aligned}$$

$$\begin{aligned}
 &= \underbrace{y'y}_{\text{Konstante}} - \underbrace{2y'Xb}_{\text{Linear in } b} + \underbrace{b'X'Xb}_{\text{Quadratische Form}}
 \end{aligned}$$

$$\frac{\partial (2y'Xb)}{\partial b} = (2y'X)' = 2X'y$$

$$\frac{\partial (b'X'Xb)}{\partial b} = \left( (X'X)' + X'X \right) b = 2X'Xb$$

$$(X'X)' = X'(X)' = X'X$$

$$\frac{\partial S(b)}{\partial b} = 0 - 2X'y + 2X'Xb \stackrel{BEO}{=} 0$$

$$\Leftrightarrow X'Xb = X'y \quad (*)$$

Hessematrix

$$\frac{\partial^2 S(b)}{(\partial b)^2} = H_S(b) = (2X'X)' = 2X'X \quad \text{positiv definit (Übung)}$$

# Momente Methode (mm)

Zufalls ~~variablen~~ <sup>Vektoren / Matrizen</sup>  $X$  &  $y$

mit MLR 1  $y = X\beta + u$

$u$  bestimmt  $y \Rightarrow$  theoretische Annahmen an  $u$  &  $X$

MLR 4  $E[u | X] = E[u] = 0$

$$\text{cov}(u, X_{\cdot j}) = E_{u, X_{\cdot j}} [(u - E[u]) (X_{\cdot j} - E[X_{\cdot j}])']$$

$$= E_{X_{\cdot j}} \left[ E_u \left[ \underbrace{(u - E[u])}_{E[u]=0} (X_{\cdot j} - E[X_{\cdot j}])' \mid X \right] \right]$$

$$= E_X \left[ \underbrace{E_u [(u - 0) \mid X]}_{=0} \cdot (X_{\cdot j} - E[X_{\cdot j}])' \right] = 0$$

$$\text{MLR 4} \quad E[u|X] = E[u] = 0$$

"Strikte Exogenität"

$$\Rightarrow \text{"Schwache Exogenität"}: \text{Cov}(u, X_{\cdot j}) = 0$$

für  $j = 1, \dots, k+1$

$$\text{Cov}(u, X_{\cdot j}) = E[u' \cdot X_{\cdot j}] - \underbrace{E[u]}_{=0}' \cdot E[X_{\cdot j}]$$

$$= E[u' \cdot X_{\cdot j}] = 0 \quad \text{für } j = 1, \dots, k+1$$

theoretische Annahme:  $E[X' \cdot u] = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$

theoretische Annahme:  $E[X' \cdot U] = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$   
„theoretischer Moment“

empirischer Moment:  $X' \cdot \hat{U}$

Momente Methode: Wähle  $b$  so, dass

$$X' \hat{U} = E[X' \cdot U]$$

$$\hat{U} = y - \hat{y}$$

$$\hat{y} = Xb$$

also

$$X'(y - Xb) = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$\Leftrightarrow X'y - X'Xb = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \Leftrightarrow X'y = X'Xb \quad (*)$$

# Orthogonale Projektion

$\hat{u}$  steht senkrecht auf  
Spaltenraum von  $X$


$$\Leftrightarrow \hat{u} \perp \mathcal{R}(X)$$

$$\Leftrightarrow \hat{u}' \cdot X_{\cdot j} = 0 \quad \text{für alle } j = 1, \dots, k+1$$

$$\Leftrightarrow X' \cdot \hat{u} = 0$$

$$\vdots$$
$$\Leftrightarrow X' y = X' x b \quad (*)$$

$P_y$  : Projektionsmatrix



Lösung von

$$(*) \quad X'Xb = X'y$$

$$\begin{array}{c} X' \\ \underbrace{X}_{k+1 \times n} \end{array} \begin{array}{c} \\ \underbrace{X}_{n \times k+1} \end{array} \quad \underbrace{\hspace{10em}}_{k+1 \times k+1}$$

hat vollen

$$r_k(X'X)$$

$X'X$  positiv definit, also  $r_k(X'X) = k+1$ .

$\Rightarrow (X'X)^{-1}$  existiert

$$\Leftrightarrow \underbrace{(X'X)^{-1} X'X}_{I} b = (X'X)^{-1} X'y$$

---

$$\Leftrightarrow b = (X'X)^{-1} X'y$$

Rang  $r_k(X'X) = k+1$

$$= \min \{ r_k(X), r_k(X) \} = k+1$$

MLR3:  $r_k(X) = k+1$   
 $r_k(X') = k+1$

Eindeutige Lösung von

$$X'X\beta = X'y$$

"Kleinste Quadrate Schätzer":

$$\hat{\beta} = (X'X)^{-1} X'y$$

Erwartungswert von  $\hat{\beta} = \underbrace{(X'X)^{-1}X'y}_{\text{MLR3}}$

$$E[(X'X)^{-1}X'y | X] = (X'X)^{-1}X'E[y | X]$$

$$= (X'X)^{-1}X'E[\underbrace{X\beta + u}_{\text{MLR1}} | X]$$

$$= (X'X)^{-1}X'(X\beta + \underbrace{E[u | X]}_{=0 \text{ (MLR4)})}$$

$$= \underbrace{(X'X)^{-1}X'X}_{I} \beta = \beta$$

$\hat{\beta}$  ist erwartungstreu  
für  $\beta$

$$E_x[E_y[\underbrace{(X'X)^{-1}X'y | X}_{= \beta}]] = E_x[\beta] = \beta$$

Erwartungstreue (kurzes Argument)

$$\hat{\beta} = \underbrace{(X'X)^{-1} X'y}_A$$

Resultat von vorher: Falls  $A \cdot X = I$   
 $\Rightarrow E[Ay] = \beta$

$$A \cdot X = (X'X)^{-1} X' \cdot X = I \quad \checkmark$$

Varianz - Kovarianz - Matrix von  $\hat{\beta}$

$$\Sigma(\hat{\beta} | X) = \Sigma\left(\left(x'x\right)^{-1}x'y \mid X\right)$$

$$= \left(x'x\right)^{-1}x' \underbrace{\Sigma(y | X)}_{\text{MLR 1}} \underbrace{\left(\left(x'x\right)^{-1}x'\right)'}_{\text{MLR 5}}$$

$$\Sigma(y | X) \stackrel{\text{MLR 1}}{=} \Sigma\left(\underbrace{X\beta}_{\text{fest}} + u \mid X\right) = \underbrace{\Sigma(u | X)}_{\sigma^2 \cdot I \text{ (MLR 5)}}$$

$$\left(\left(x'x\right)^{-1}x'\right)' = \left(x'\right)' \cdot \left(\left(x'x\right)^{-1}\right)' = X \left(\left(x'x\right)'\right)^{-1} = X \left(x'x\right)^{-1}$$

$$\text{Cov}(\hat{\beta}(X)) = (X'X)^{-1} X' \cdot \sigma^2 \cdot I \times (X'X)^{-1}$$

$$= \sigma^2 (X'X)^{-1} \underbrace{X' X (X'X)^{-1}}_I$$

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

# Gauss-Markov-Theorem

Unter den Annahmen MLR 1, 2, 3, 4, 5

gilt:  $\hat{\beta} = \underbrace{(X'X)^{-1} X'y}_A$  ist BLUE

E: estimator ✓

U: unbiased = erwartungstreu (für  $\beta$ ) ✓

L: linear (in  $y$ ) ✓

B: best = effizient = varianzminimal unter allen erwartungstreuen & linearen Schätzern

$$\text{var}(\hat{\beta}|X) = \sigma^2 (X'X)^{-1} \leq \text{var}(\tilde{\beta}|X) \text{ für alle } \tilde{\beta} \text{ mit } E[\tilde{\beta}] = \beta$$

$$\hat{\beta} = \underbrace{(X'X)^{-1}X'}_A y, \quad \tilde{\beta} = B \cdot y \quad \text{mit} \quad BX = \underline{I} \quad 19.5.26$$

$$\mathbb{E}(\hat{\beta} | X) = \sigma^2 A \cdot A', \quad \mathbb{E}(\tilde{\beta} | X) = \sigma^2 B \cdot B'$$

zu zeigen:  $A \cdot A' \leq B \cdot B'$  für alle  $B$  mit  $BX = \underline{I}$

$\Leftrightarrow BB' - AA'$  positiv semidefinit

zunächst:

$$AB' = (X'X)^{-1}X' \cdot B' = (X'X)^{-1} \underbrace{(BX)'}_{\underline{I}} = (X'X)^{-1}$$

$$BA' = B \left( (X'X)^{-1}X' \right)' = B (X')' \left( (X'X)^{-1} \right)' = \underbrace{BX}_{\underline{I}} (X'X)^{-1} = (X'X)^{-1}$$

$$AA' = (X'X)^{-1}X' \left( (X'X)^{-1}X' \right)' = \underbrace{(X'X)^{-1}X'X}_{\underline{I}} (X'X)^{-1} = (X'X)^{-1}$$

$$(B - A)(B - A)'$$

$$= BB' - AB' + B(-A)' - A(-A)'$$

$$= BB' - \underbrace{AB'}_{= AA'} - \underbrace{BA'}_{= AA'} + AA'$$

$$= BB' - AA' \leftarrow \text{positiv semidefinit}$$

$$\Rightarrow V'(BB' - AA')V$$

$$= \underbrace{V'(B - A)}_{z'} (B - A)' V = \underbrace{V'(B - A)}_{z'} \underbrace{[V'(B - A)]'}_z$$

$$= z' \cdot z \geq 0$$

# Schätzer für $\sigma^2$

---

$X_i$  Zufallsvariable  $i = 1, \dots, n$  iid

$$E[X_i] = \mu \quad \text{Var}(X_i) = \sigma^2$$

$$\bar{X} = \hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i \quad \hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

---

Regressionsmodell  $y = X\beta + u$ ,  $E[u] = 0$ ,  $\text{Cov}(u|X) = \sigma^2 I$

$$\hat{\sigma}^2 = \frac{1}{n-k-1} \sum_{i=1}^n (\hat{u}_i - \bar{\hat{u}})^2$$

mit  $\bar{\hat{u}} = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n-k-1} \sum_{i=1}^n \hat{u}_i^2$

# Projektion

BEO von  $\hat{\beta}$ :  $X' \hat{\beta} = 0$

Projektionsmatrix


$$P_X = X(X'X)^{-1}X'$$

idempotent:  $P_X \cdot P_X = P_X$

symmetrisch:  $P_X' = P_X$

$$\text{rk}(P_X) = \text{rk}(X) = k+1$$

$\mathbb{R}^n$



$$\hat{u} = y - \hat{y}$$

$$= y - P_X y$$

$$= \underbrace{(I - P_X)}_{M_X} y$$

$M_X$  Projektionsmatrix

$$\text{rk}(M_X) = n - k - 1$$

$$\hat{y} = X \hat{\beta}$$

$$= \underbrace{X(X'X)^{-1}X'}_{P_X} y$$

$$\hat{u} = M_X y \quad \text{mit } M_X = I - P_X$$

$$= M_X (X\beta + u) \quad P_X = X(X'X)^{-1}X'$$

MLR 1

$$y = X\beta + u$$

$$= M_X X\beta + M_X \cdot u$$

$$= [I - X(X'X)^{-1}X'] X\beta + M_X \cdot u$$

$$= [X - X \underbrace{(X'X)^{-1}X'}_I] \beta + M_X \cdot u$$

$$= [X - X] \beta + M_X u$$

$$= M_X \cdot u$$

# Streuungszerlegung

$$\hat{u} = y - \hat{y}$$

$$\Leftrightarrow \hat{y} + \hat{u} = y$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 = \bar{y}$$

$$SSR = \sum_{i=1}^n (\hat{u}_i - \bar{\hat{u}})^2 = 0$$

Es gilt  $SST = SSE + SSR$

Begründung für  $\hat{U} = 0$

BEQ für  $\hat{\beta}$ :  $X' \cdot \hat{U} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \in \mathbb{R}^{k+1}$  nullen

Erste Spalte von  $X$ :  $L = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$

$\leadsto$  erste Zeile von  $X'$

Erste Zeile von  $X' \hat{U}$ :  $(1, 1, \dots, 1) \cdot \begin{pmatrix} \hat{U}_1 \\ \hat{U}_2 \\ \vdots \\ \hat{U}_n \end{pmatrix} = 0$

$$\Leftrightarrow \sum_{i=1}^n 1 \cdot \hat{U}_i = 0$$

$$\Leftrightarrow \frac{1}{n} \sum_{i=1}^n \hat{U}_i = 0$$

Begründung für  $\hat{y} = y$

$$\hat{y} + \hat{u} = y$$


$$\Leftrightarrow C' \cdot \hat{y} + \underbrace{C' \hat{u}}_{=0} = C' y$$

$$\Leftrightarrow \frac{1}{n} \sum_{i=1}^n \hat{y}_i = \frac{1}{n} \sum_{i=1}^n y_i$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$SSR = \sum_{i=1}^n \hat{u}_i^2 = \hat{u}' \hat{u}$$



Begründung für  $SST = SSE + SSR$

$$y_i = \hat{y}_i + \hat{u}_i$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$= \sum_{i=1}^n (\hat{y}_i - \bar{y} + \hat{u}_i)^2$$

$$= \sum_{i=1}^n \left[ (\hat{y}_i - \bar{y})^2 + 2(\hat{y}_i - \bar{y})\hat{u}_i + \hat{u}_i^2 \right]$$

$$= \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{SSE} + \underbrace{2 \sum_{i=1}^n (\hat{y}_i - \bar{y})\hat{u}_i}_{\text{zu zeigen: } = 0} + \underbrace{\sum_{i=1}^n \hat{u}_i^2}_{SSR}$$

$$\sum_{i=1}^n (\hat{y}_i - \bar{y}) \hat{u}_i = \underbrace{\sum_{i=1}^n \hat{y}_i \cdot \hat{u}_i}_{= \hat{y}' \cdot \hat{u}} - \bar{y} \underbrace{\sum_{i=1}^n \hat{u}_i}_{=0}$$

kurze Begründung  $\hat{y} \in \mathcal{R}(X)$ ,  $\hat{u} \in \mathcal{R}^\perp(X)$

$$\Rightarrow \hat{y}' \hat{u} = 0$$

ausführliche Begründung

$$\hat{y} = P_X y, \quad \hat{y}' \hat{u} = (P_X \cdot y)' M_X y = \underbrace{y' P_X M_X}_{=0} \cdot y$$

$$\hat{u} = M_X \cdot y$$

---


$$P_X M_X = P_X (I - P_X) = P_X - P_X P_X = P_X - P_X = 0$$

Bestimmtheitsmaß

$R^2$

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST}$$

Aussage

$R^2 \cdot 100\%$  ist der Anteil

der erklärten Variation von  $y$ .

Vorteil von vielen Regressoren:  $R^2$  steigt.

ursprüngliche Regressor matrix  $X$

plus ein (linear unabhängiger) Regressor  $\tilde{X}$

neues Bestimmtheitsmaß  $\tilde{R}^2$

Behauptung  $\tilde{R}^2 \geq R^2$

OLS schätzer  $\hat{\beta}$  minimiert  $SSR$

neuer **Schätzer**  $\tilde{\beta}$  minimiert  $\tilde{SSR} \leq SSR$

$$\tilde{R}^2 = 1 - \frac{\tilde{SSR}}{\tilde{SST}} \geq 1 - \frac{SSR}{SST} = R^2$$

Spur einer Matrix (quadratisch)

$$\text{tr}(A) = \sum_{i=1}^n a_{ii}$$

Rechenregel:

$$\text{tr} \left( \underset{n \times n}{A} \underset{n \times n}{B} \right) = \text{tr} \left( \underset{n \times n}{B} \cdot \underset{n \times n}{A} \right)$$

$$\text{tr}(A B C) = \text{tr}(C A B) = \text{tr}(B C A)$$

(zyklische Vertauschung)

$P_x$  Projektionsmatrix:

$$\text{tr}(P_x) = \underbrace{\text{rk}(P_x)}_{= k+1}, \quad \text{tr}(M_x) = \underbrace{\text{rk}(M_x)}_{n-k-1}$$

Schätzer für  $\sigma^2$

$$\hat{\sigma}^2 = \frac{1}{n-k-1} \underbrace{\sum_{i=1}^n \hat{u}_i^2}_{SSR} = \frac{1}{n-k-1} \cdot \underbrace{\hat{u}' \cdot \hat{u}}_{SSR}$$

$$\hat{u} = M_x \cdot u$$

$$\hat{u}' \hat{u} = (M_x \cdot u)' M_x u = u' M_x' M_x u$$

$$= u' M_x \cdot M_x u = u' M_x u \in \mathbb{R}$$

$$= \text{tr}(u' M_x u)$$

$$= \text{tr}(u u' M_x)$$

$$E [ 0' 0 | X ] = E [ \text{tr} ( v v' M_x ) | X ]$$

$\text{tr}$  ist ein linearer Operator

$E$  ist auch ein linearer Operator

$\text{tr}$  und  $E$  können vertauscht werden

$$= \text{tr} ( E [ v v' M_x | X ] )$$

$$= \text{tr} ( E [ v v' | X ] M_x )$$

$$= \text{tr} ( \underbrace{E [ (v - \underbrace{E[v]}_{=0}) (v - \underbrace{E[v]}_{=0})' | X ]}_{\neq (v | X)} M_x )$$

$$= \text{tr} \left( \underbrace{\sigma^2(u|x)}_{= \sigma^2 \cdot I} \cdot M_x \right)$$

$$= \text{tr} \left( \sigma^2 \cdot M_x \right)$$

$$= \sigma^2 \text{tr} (M_x)$$

$$= \sigma^2 \cdot \text{rk} (M_x)$$

gezeigt:  $E[\sigma' \sigma | X] = \sigma^2 \cdot (n - k - 1)$

$$\Leftrightarrow E \left[ \underbrace{\frac{1}{n-k-1}}_{\hat{\sigma}^2} \cdot \sigma' \sigma \mid X \right] = \sigma^2$$

$$\sqrt{\hat{\sigma}^2} : \hat{\sigma}$$

"Standardfehler  
der Regression"