

# Kapitel 2: Das einfache Regressionsmodell



Moodle



Lehrbuch

# Übersicht:

Definition des einfachen Regressionsmodells

Herleitung der gewöhnlichen Kleinste-Quadrate-Schätzer

OLS: Eigenschaften bei beliebigen Stichproben

Maßeinheiten und die funktionale Form

Erwartungswerte und Varianzen der OLS-Schätzer

# Definition des einfachen Regressionsmodells

# Definition des einfachen Regressionsmodells

Das einfache Regressionsmodell erklärt die Variable  $y$  durch die Variable  $x$ .

Drei Aspekte:

- ▶ Wie modellieren wir die Wirkung von anderen Faktoren auf  $y$ ?
- ▶ Was ist die funktionale Beziehung zwischen  $y$  und  $x$ ?
- ▶ Wie können wir ein Ceteris-Paribus Zusammenhang sicherstellen?

$$y = \beta_0 + \beta_1 x + u$$

$y$  : Abhängige/erklärte Variable, Regressand

$\beta_0$  : Achsenabschnitt (unbekannter Parameter)

$\beta_1$  : Steigung (unbekannter Parameter)

$x$  : Unabhängige/erklärende Variable, Regressor

$u$  : Störterm ( $u$ : unbeobachtbar)

# Interpretation des einfachen Regressionsmodells

$$y = \beta_0 + \beta_1 x + u$$

Das einfache Regressionsmodell erklärt inwiefern  $y$  in Veränderungen von  $x$  variiert.

Ceteris Paribus-Annahme:

Nehme an, dass sich  $x$  verändert ( $\Delta x \neq 0$ ) und alle anderen erklärenden aber unbeobachtbaren Größen konstant bleiben ( $\Delta u = 0$ ).

Dann gilt

$$\frac{\Delta y}{\Delta x} = \beta_1$$

$$(x_{\text{new}}, y_{\text{new}}), (x_{\text{act}}, y_{\text{act}}) \quad y = \beta_0 + \beta_1 x + u$$

$$\Delta y = y_{\text{new}} - y_{\text{act}}$$

$$\Delta x = x_{\text{new}} - x_{\text{act}}$$

$$\begin{aligned} \Delta y = y_{\text{new}} - y_{\text{act}} &= \overbrace{\beta_0 + \beta_1 x_{\text{new}} + u_{\text{new}}}^{y_{\text{new}}} - \overbrace{(\beta_0 + \beta_1 x_{\text{act}} + u_{\text{act}})}^{y_{\text{act}}} \\ &= \beta_1 \underbrace{(x_{\text{new}} - x_{\text{act}})}_{\Delta x} + \underbrace{u_{\text{new}} - u_{\text{act}}}_{\Delta u} \end{aligned}$$

$$\Delta y = \beta_1 \Delta x + \Delta u$$

$$\text{Ceteris Paribus: } \Delta x \neq 0 \Rightarrow \Delta u = 0$$

$$\Delta y = \beta_1 \underbrace{\Delta x}_{\neq 0} \Leftrightarrow \frac{\Delta y}{\Delta x} = \beta_1$$

## Beispiel: Sojabohnen und Dünger

„Wie wirkt sich die Düngemenge auf den Ernteerfolg aus?“

$$yield = \beta_0 + \beta_1 fertilizer + u ,$$

sodass  $y = yield$  und  $x = fertilizer$ .

Der Störterm  $u$  beinhaltet andere Größen wie Landqualität, Niederschlag, Parasiten.

Unter der Ceteris Paribus-Annahme gilt:

$$\Delta yield = \beta_1 \Delta fertilizer$$

## Beispiel: Eine einfache Lohngleichung

„Wie wirkt sich Bildung auf den Stundenlohn aus?“

$$wage = \beta_0 + \beta_1 educ + u ,$$

sodass  $y = wage$  und  $x = educ$ .

Der Störterm  $u$  beinhaltet andere Größen wie Berufserfahrung, Talent, etc.

Der unbekannte Parameter  $\beta_1$  misst (unter der Ceteris Paribus-Annahme), wie sich ein zusätzliches Bildungsjahr auf den Stundenlohn auswirkt.



# Diskussion der Linearität des einfachen Regressionsmodells

Die Gleichung

$$y = \beta_0 + \beta_1 x + u$$

impliziert, dass die Variable  $x$  immer den gleichen (linearen) Effekt auf  $y$  hat.

Diese Unzulänglichkeit kann durch Transformation der Variablen geheilt werden.

Der schwierigste Aspekt ist die Ceteris Paribus Annahme.

Um diese Annahme zu rechtfertigen interpretieren wir zunächst  $x$  und  $u$  (und damit auch  $y$ ) als Zufallsvariablen.

Nun können wir eine statistische Annahme an  $x$  und  $u$  treffen.

Ein (scheinbar nicht-lineares Modell)

$$\tilde{y} = A \cdot \tilde{x}^{\tilde{\beta}_1} \cdot \tilde{u}$$

*Annotations:* A red arrow points from the word "const" above to the variable A. Another red arrow points from the word "error" above to the variable  $\tilde{u}$ .

$$\begin{aligned} \ln(\tilde{y}) &= \ln(A \cdot \tilde{x}^{\tilde{\beta}_1} \cdot \tilde{u}) = \ln(A) + \ln(\tilde{x}^{\tilde{\beta}_1}) + \ln(\tilde{u}) \\ &= \underbrace{\ln(A)}_{=: \beta_0} + \underbrace{\tilde{\beta}_1}_{\beta_1} \underbrace{\ln(\tilde{x})}_{\text{Regressor}} + \underbrace{\ln(\tilde{u})}_{\text{Störterm}} \end{aligned}$$

*Annotations:* A red circle highlights  $\tilde{\beta}_1$  in the second line, with a red arrow pointing from it to the  $\tilde{\beta}_1$  in the third line.

## Strikte Exogenität

In Kenntnis der erklärenden Variable  $x$  gibt es keine zusätzliche Information über den Erwartungswert der unbeobachtbaren Variable  $u$ :

$$E[u|x] = E[u]$$

Im Düngerbeispiel:

Die unterschiedlichen Düngermengen werden zufällig auf die einzelnen Ackerflächen verteilt. Demnach enthält die Düngermenge keine Information über die unbeobachtbare Bodenqualität der einzelnen Ackerfläche. (✓)

Im Bildungsbeispiel:

Die unterschiedlichen Bildungsniveaus können durchaus von den zugrundeliegenden intellektuellen Fähigkeiten abhängen. Daher enthält das Bildungsniveau (statistische) Informationen über die zu erwartenden unbeobachtbaren Fähigkeiten. (!)

# Annahme: Strikte Exogenität

Im ersten Teil der Vorlesung werden wir die Annahme der **strikten Exogenität der Regressoren** (auch: mean independence) aufrechterhalten:

$$E[u|x] = E[u]$$

Erst in späteren Kapiteln gehen wir genauer auf die Implikationen und Lösungen bei einer Verletzungen dieser Annahme ein.

## Ohne Beschränkung der Allgemeinheit: $E[u] = 0$

$$y = \beta_0 + \beta_1 x + u$$

Wir nehmen des Weiteren an, dass der Erwartungswert des unbeobachtbaren Störterms null beträgt:

$$E[u] = 0$$

Diese Annahme erfolgt jedoch ohne Beschränkung der Allgemeinheit!

Wäre  $E[u] \neq 0$ , so könnten wir das Modell mit  $\tilde{u} = u - E[u]$  und  $\tilde{\beta}_0 = \beta_0 + E[u]$  modifizieren.

Für das modifizierte Modell

$$y = \tilde{\beta}_0 + \beta_1 x + \tilde{u}$$

wäre  $E[\tilde{u}] = E[u - E[u]] = E[u] - E[u] = 0$  erfüllt.

# Annahme: Bedingter Null-Erwartungswert

Engl.: zero conditional mean assumption

Mit den beiden Annahmen

$$E[u] = 0$$

und

$$E[u|x] = E[u]$$

folgt direkt:

$$E[u|x] = 0$$

Oft wird direkt diese Gleichung (ohne Vordiskussion) angenommen.

# Population Regression Function (PRF)

Bilden wir den bedingten Erwartungswert des Regressionsmodells

$$y = \beta_0 + \beta_1 x + u$$

erhalten wir

$$\begin{aligned} E[y|x] &= E[\beta_0 + \beta_1 x + u|x] \\ &= E[\beta_0|x] + E[\beta_1 x|x] + \underbrace{E[u|x]}_{=0} \end{aligned}$$


und mit  $E[u|x] = 0$  also

$$E[y|x] = \beta_0 + \beta_1 x$$

Eine Erhöhung von  $x$  um eine Einheit erhöht den **bedingten Erwartungswert** von  $y$  um  $\beta_1$  Einheiten.

# Population Regression Function (PRF)

Für einen gegebenen Wert  $x$  ist  $E[y|x] = \beta_0 + \beta_1 x$  der Gravitationspunkt der bedingten Dichte von  $y$ .



Die Gleichung  $E[y|x] = \beta_0 + \beta_1 x$  beschreibt den erwarteten Wert von  $y$ . Der tatsächliche Wert von  $y$  streut um  $E[y|x]$ .



# Herleitung der gewöhnlichen Kleinste-Quadrate-Schätzer

# Herleitung von gewöhnlichen Schätzern

Um die unbekannt Parameter  $\beta_0$  und  $\beta_1$  des einfachen linearen Regressionsmodells zu schätzen, benötigen wir neben den Annahmen

$$y = \beta_0 + \beta_1 x + u$$

und

$$E[u|x] = 0$$

Daten: die **Zufallsstichprobe**

- $(x_1, y_1)$  : Erste Beobachtung
- $(x_2, y_2)$  : Zweite Beobachtung
- $\vdots$
- $(x_n, y_n)$  :  $n$ -te Beobachtung

# Herleitung von gewöhnlichen Schätzern

Sei

$$\{(x_i, y_i) \in \mathbb{R}^2 : i = 1, \dots, n\}$$

eine Zufallsstichprobe des Umfangs  $n \in \mathbb{N}$ .

Für  $i = 1, \dots, n$ :

$x_i$ : Wert der erklärenden Variable der  $i$ -ten Beobachtung

$y_i$ : Wert der erklärten Variable der  $i$ -ten Beobachtung

Das Regressionsmodell lässt sich nun schreiben als

$$y_i = \beta_0 + \beta_1 x_i + u_i, \quad i = 1, \dots, n$$

$u_i$ : Störterm für Beobachtung  $i$ .

Enthält alle Einflussfaktoren auf  $y_i$ , die nicht in  $x_i$  enthalten sind.

## Die Momentenmethode (Method of Moments, MM)

Seien  $n$  Paare von Zufallsvariablen  $(A_i, B_i)$  unabhängig und identisch verteilt mit theoretischen Momenten  $E[A|\theta]$ ,  $E[B|\theta]$ ,  $E[AB|\theta]$ ,  $E[A^2|\theta]$  und  $E[B^2|\theta]$ , wobei  $\theta$  ein Vektor von unbekanntem Parametern darstellt.

Dann gilt mit dem Gesetz der großen Zahlen

$$\frac{1}{n} \sum_{i=1}^n A_i \xrightarrow{n \rightarrow \infty} E[A|\theta], \quad \frac{1}{n} \sum_{i=1}^n A_i B_i \xrightarrow{n \rightarrow \infty} E[AB|\theta], \quad \text{usw.}$$

Die Momentenmethode approximiert nun die theoretischen Momente durch die empirischen Momente und schätzt hier die unbekanntem Parameter  $\theta$  durch die implizit definierten Schätzer  $\hat{\theta}$ :

$$\frac{1}{n} \sum_{i=1}^n A_i = E[A|\hat{\theta}], \quad \frac{1}{n} \sum_{i=1}^n A_i B_i = E[AB|\hat{\theta}], \quad \text{usw.}$$

## Die Momentenmethode mit $E[u|x] = 0$

Für  $y_i = \beta_0 + \beta_1 x_i + u_i$ ,  $i = 1, \dots, n$ , sei angenommen, dass  $u_i$  unabhängig und identisch verteilt seien mit  $E[u_i|x_i] = 0$ .

Zunächst schreiben wir  $u_i = y_i - \beta_0 - \beta_1 x_i$ .

Das theoretische Moment  $E[u_i|x_i] = E[y_i|x_i] - \beta_0 - \beta_1 x_i$  enthält die unbekannt Parameter  $\beta_0$  und  $\beta_1$ . Für diese definieren wir die Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  implizit durch die Schätzung des theoretischen Moments durch das empirische Moment


$$\frac{1}{n} \sum_{i=1}^n u_i \approx \frac{1}{n} \sum_{i=1}^n y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i = 0 = E[u_i|x_i]$$

Mit  $\bar{y} := \frac{1}{n} \sum_{i=1}^n y_i$  und  $\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$ :

$$\Rightarrow \bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$$

$$\frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} \sum_{i=1}^n \hat{\beta}_0 - \frac{1}{n} \sum_{i=1}^n \hat{\beta}_1 x_i = 0$$

$$\frac{1}{n} \sum_{i=1}^n y_i - \hat{\beta}_0 - \hat{\beta}_1 \frac{1}{n} \sum_{i=1}^n x_i = 0$$
$$\bar{y} - \hat{\beta}_0 - \hat{\beta}_1 \bar{x} = 0$$



## Die Momentenmethode mit $E[u|x] = 0$

Für das Moment  $E[xu]$  gilt aufgrund der Annahme  $E[u|x] = 0$ :

$$E[xu] = E[x \underbrace{E[u|x]}_{=0}] = 0$$

Die Eigenschaft  $E[xu] = 0$  wird auch mit **Orthogonalität** von  $x$  und  $u$  bezeichnet.

Mit  $u_i = y_i - \beta_0 - \beta_1 x_i$  schätzen wir  $E[xu]$  durch

$$\frac{1}{n} \sum_{i=1}^n x_i u_i \approx \frac{1}{n} \sum_{i=1}^n x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = E[xu] = 0$$

Mit  $\overline{xy} := \frac{1}{n} \sum_{i=1}^n x_i y_i$  und  $\overline{xx} := \frac{1}{n} \sum_{i=1}^n x_i^2$ :

$$\Rightarrow \overline{xy} = \hat{\beta}_0 \bar{x} + \hat{\beta}_1 \overline{xx}$$

## Die Momentenmethode mit $E[u|x] = 0$

Die Momentenmethode liefert also über die Annahme  $E[u|x] = 0$  zwei Gleichungen für die beiden Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$ :

$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$$

und

$$\overline{xy} = \hat{\beta}_0 \bar{x} + \hat{\beta}_1 \overline{xx}$$

Unter der Voraussetzung  $\overline{xx} \neq \bar{x}\bar{x}$  ergibt sich:

$$\hat{\beta}_0 = \bar{y} - \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}} \bar{x}$$

und

$$\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}}$$



# Die gewöhnliche Kleinste-Quadrate-Methode (OLS)

Eine andere Schätzmöglichkeit besteht in der Vorgabe einer Zielfunktion.

Die gebräuchlichste ist:

Minimiere die Summe der quadrierten Abweichungen zwischen der erklärten Variablen und ihren durch die Schätzung vorhergesagten Werten.

Dies ist das gewöhnliche Kleinste-Quadrate-Prinzip (**OLS, ordinary least squares**).

# Die gewöhnliche Kleinste-Quadrate-Methode (OLS)

Schätze die unbekannt Parameter  $\beta_0$  und  $\beta_1$  des Regressionsmodells

$$y_i = \beta_0 + \beta_1 x_i + u_i, \quad i = 1, \dots, n$$

zunächst durch beliebige Zahlen  $b_0$  und  $b_1$ .

→ Prognostizierte Werte  $\hat{y}_i$  (**fitted values**) mit

$$\hat{y}_i = b_0 + b_1 x_i, \quad i = 1, \dots, n$$

Definiere **Residuen**  $\hat{u}_i$  mit


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

Je besser die Zahlen  $b_0$  und  $b_1$ , desto „kleiner“ die Residuen.


# Prognose und Residuen

Vermutete Parameter:  $b_0, b_1$

Schätzfehler (hängt von  $b_0, b_1$  ab):  $\hat{u}_i = y_i - \hat{y}_i = y_i - b_0 - b_1 x_i$



# Die gewöhnliche Kleinste-Quadrate-Methode (OLS)



Der Vektor  $\hat{u} = (\hat{u}_1, \hat{u}_2, \dots, \hat{u}_n)$  hat die Länge

$$\|\hat{u}\| = \sqrt{\hat{u}_1^2 + \hat{u}_2^2 + \dots + \hat{u}_n^2}$$

$$\hat{u}_1^2 + \hat{u}_2^2 = \|\hat{u}\|^2 \\ \Rightarrow \|\hat{u}\| = \sqrt{\hat{u}_1^2 + \hat{u}_2^2}$$

Wähle nun  $b_0$  und  $b_1$ , sodass die Norm  $\|\hat{u}\|$  minimal wird!

$\Rightarrow$  Zielfunktion  $S(b_0, b_1) = \sum_{i=1}^n (y_i - \underbrace{(b_0 + b_1 x_i)}_{\hat{u}_i})^2$

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

$$\min_{b_0, b_1 \in \mathbb{R}} \sum_{i=1}^n (y_i - \underbrace{(b_0 + b_1 x_i)}_{\hat{y}_i})^2 = S(b_0, b_1)$$

$$\frac{\partial S}{\partial b_0} = \sum_{i=1}^n 2(y_i - b_0 - b_1 x_i) \cdot (-1) \quad \text{BEO}$$

$$= -2 \sum_{i=1}^n y_i - b_0 - b_1 x_i \stackrel{!}{=} 0 \quad || : (-2)$$

$$\Leftrightarrow \sum_{i=1}^n y_i - b_0 - b_1 x_i = 0$$

∴ (siehe Momente Methode)

$$\Leftrightarrow \bar{y} = b_0 + b_1 \bar{x}$$

$$\min_{b_0, b_1 \in \mathbb{R}} \sum_{i=1}^n (y_i - \underbrace{(b_0 + b_1 x_i)}_{\hat{y}_i})^2 = S(b_0, b_1)$$

$$\frac{\partial S}{\partial b_1} = \sum_{i=1}^n 2 (y_i - b_0 - b_1 x_i) (-x_i)$$

$$\rightarrow = -2 \sum_{i=1}^n (y_i - b_0 - b_1 x_i) x_i \stackrel{!}{=} 0 \quad \begin{array}{l} | \text{BEO} \\ \cdot \\ \parallel (-2) \end{array}$$

$$\Leftrightarrow \sum_{i=1}^n (y_i - b_0 - b_1 x_i) x_i = 0$$

∴ (siehe MM)

$$\Leftrightarrow \overline{xy} = b_0 \overline{x} + b_1 \overline{xx}$$

Hesse matrix

$$H = \begin{pmatrix} \frac{\partial^2 S}{(\partial b_0)^2} & \frac{\partial^2 S}{\partial b_0 \partial b_1} \\ \frac{\partial^2 S}{\partial b_1 \partial b_0} & \frac{\partial^2 S}{(\partial b_1)^2} \end{pmatrix} = \begin{pmatrix} 2n & 2n \bar{x} \\ 2n \bar{x} & 2n \overline{xx} \end{pmatrix}$$

$$\frac{\partial^2 S}{(\partial b_0)^2} = -2 \sum_{i=1}^n (-1) = 2 \sum_{i=1}^n 1 = 2n$$

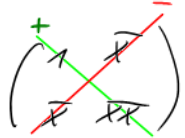
$$\frac{\partial^2 S}{\partial b_0 \partial b_1} = -2 \sum_{i=1}^n (-x_i) = n 2 \underbrace{\frac{1}{n} \sum_{i=1}^n x_i}_{\bar{x}} = 2 \cdot n \cdot \bar{x}$$

$$\frac{\partial^2 S}{(\partial b_1)^2} = -2 \sum_{i=1}^n (-x_i \cdot x_i) = n 2 \underbrace{\frac{1}{n} \sum_{i=1}^n x_i \cdot x_i}_{= \overline{xx}} = 2 \cdot n \cdot \overline{xx}$$

$$H = 2n \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{xx} \end{pmatrix} \quad \text{positiv definit? } \checkmark$$

$$\det(2n) = 2n > 0 \quad \checkmark$$

$$\det \left( 2n \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{xx} \end{pmatrix} \right) = (2n)^2 \det \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{xx} \end{pmatrix}$$



$$= (2n)^2 (1 \cdot \overline{xx} - \bar{x} \cdot \bar{x}) > 0 \quad \checkmark$$

$\Rightarrow S$  streng konvex

$\Rightarrow \hat{\beta}_0, \hat{\beta}_1$  Minimumstelle von  $S(\beta_0, \beta_1)$



# Die gewöhnliche Kleinste-Quadrate-Methode (OLS)

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

Die optimalen Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  erfüllen die Bedingungen erster Ordnung:

$$\sum_{i=1}^n 2(y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)(-1) = 0$$

$$\sum_{i=1}^n 2(y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)(-x_i) = 0$$

Hessematrix:

$$H = \begin{pmatrix} 2n & 2 \sum_{i=1}^n x_i \\ 2 \sum_{i=1}^n x_i & 2 \sum_{i=1}^n x_i^2 \end{pmatrix} = 2n \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{xx} \end{pmatrix}$$

# Die gewöhnliche Kleinste-Quadrate-Methode (OLS)

Die Hessematrix ist positiv definit, falls  $\overline{xx} > \bar{x}\bar{x}$ .

Die Bedingungen erster Ordnung sind äquivalent zu

$$\begin{aligned}\bar{y} &= \hat{\beta}_0 + \hat{\beta}_1 \bar{x} \\ \overline{xy} &= \hat{\beta}_0 \bar{x} + \hat{\beta}_1 \overline{xx}\end{aligned}$$

Unter der Voraussetzung  $\overline{xx} > \bar{x}\bar{x}$  ergibt sich also auch hier:

$$\hat{\beta}_0 = \bar{y} - \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}} \bar{x}$$

und

$$\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}}$$

# Orthogonale Projektion

Das Regressionsmodell

$$y_i = \beta_0 + \beta_1 x_i + u_i, \quad i = 1, \dots, n$$

liefert mit  $E[u|x] = 0$  die funktionale Beziehung

$$E[y_i|x] = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

Geometrische Interpretation:

$$\begin{pmatrix} E[y_1|x] \\ E[y_2|x] \\ \vdots \\ E[y_n|x] \end{pmatrix} = \beta_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} + \beta_1 \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}$$

Der Vektor  $E[\mathbf{y}|x]$  ist eine Linearkombination des **Einsvektors  $\iota$**  und des Regressorvektors  $\mathbf{x}$ .

# Orthogonale Projektion

Falls die beiden  $n$ -Vektoren  $\boldsymbol{\iota}$  und  $\mathbf{x}$  linear unabhängig sind, spannen sie eine Ebene im  $n$ -Dimensionalen Raum auf.


Die  $n$ -Vektoren  $\boldsymbol{\iota}$  und  $\mathbf{x}$  sind genau dann linear unabhängig, falls es kein  $\lambda \in \mathbb{R}$  gibt, sodass  $\mathbf{x} = \lambda \boldsymbol{\iota}$ . Dies ist äquivalent zu  $\overline{\mathbf{x}\mathbf{x}} \neq \overline{\mathbf{x}}\overline{\mathbf{x}}$ .

Jedes Paar  $(b_0, b_1)$  definiert einen Punkt  $b_0\boldsymbol{\iota} + b_1\mathbf{x}$  auf der von  $\boldsymbol{\iota}$  und  $\mathbf{x}$  aufgespannten Ebene.

Gesucht ist derjenige Punkt  $\hat{\mathbf{y}} = \hat{\beta}_0\boldsymbol{\iota} + \hat{\beta}_1\mathbf{x}$ , welcher in der Ebene am nächsten zum Vektor  $\mathbf{y}$  ist.

Dieser Punkt  $\hat{\mathbf{y}}$  ist die orthogonale Projektion von  $\mathbf{y}$  auf die durch  $\boldsymbol{\iota}$  und  $\mathbf{x}$  aufgespannte Ebene.

# Orthogonale Projektion



$$\hat{u} \cdot x = 0$$

$$\hat{u} \cdot \hat{l} = 0$$

## Orthogonale Projektion

Der Vektor von  $\hat{\mathbf{y}}$  zu  $\mathbf{y}$ , also  $\mathbf{y} - \hat{\mathbf{y}}$  muss demnach orthogonal zu den Vektoren  $\mathbf{1}$  und  $\mathbf{x}$  sein.

Es muss also gelten:

$$\mathbf{1}'(\mathbf{y} - \hat{\mathbf{y}}) = \sum_{i=1}^n 1(y_i - \hat{y}_i) = \sum_{i=1}^n \hat{u}_i = 0 \Leftrightarrow \bar{y} = b_0 + b_1 \bar{x}$$

$$\mathbf{x}'(\mathbf{y} - \hat{\mathbf{y}}) = \sum_{i=1}^n x_i(y_i - \hat{y}_i) = \sum_{i=1}^n x_i \hat{u}_i = 0 \Leftrightarrow \overline{x y} = b_0 \bar{x} + b_1 \overline{x^2}$$

Wie wir wissen implizieren diese beiden Bedingungen

$$\hat{\beta}_0 = \bar{y} - \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}} \bar{x}$$

und

$$\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}}$$

## Diskussion: $\overline{xx} > \bar{x}\bar{x}$

Der Ausdruck  $\overline{xx} - \bar{x}\bar{x}$  ist die **Stichprobenvarianz von  $x$** :

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

Die Stichprobenvarianz von  $x_i$  ist positiv, falls mindestens eine Beobachtung  $x_i$  vom Stichprobendurchschnitt  $\bar{x}$  abweicht, falls also nicht alle Beobachtungen  $x_i$  identisch sind.

Wären alle Beobachtungen  $x_i$  identisch, hätte  $\mathbf{x}$  keinen Erklärungsgehalt für die Variation von  $\mathbf{y}$ .

## Diskussion: $\overline{xy} - \bar{x}\bar{y}$

$\overline{xy} - \bar{x}\bar{y}$  ist die **Stichprobenkovarianz von x und y**:

$$\overline{xy} - \bar{x}\bar{y} = \frac{1}{n} \sum_{i=1}^n x_i y_i - \left( \frac{1}{n} \sum_{i=1}^n x_i \right) \left( \frac{1}{n} \sum_{i=1}^n y_i \right) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

Wäre  $y_i$  eine lineare Funktion von  $x_i$ , also z.B.

$$y_i = \beta_0 + \beta_1 x_i ,$$

dann würde gelten:  $\bar{y} = \beta_0 + \beta_1 \bar{x}$  und

$$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \beta_1 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \beta_1 (\overline{xx} - \bar{x}\bar{x})$$

und

$$\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}} = \beta_1 \frac{\overline{xx} - \bar{x}\bar{x}}{\overline{xx} - \bar{x}\bar{x}} = \beta_1$$



## Der Korrelationskoeffizient

Der (theoretische) Korrelationskoeffizient:

$$\rho_{xy} = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x)}\sqrt{\text{Var}(y)}}$$

Der empirische Korrelationskoeffizient ersetzt die theoretischen Momente durch die empirischen Momente:


$$\hat{\rho}_{x,y} := \frac{\overline{xy} - \bar{x}\bar{y}}{\sqrt{(\overline{xx} - \bar{x}\bar{x})}\sqrt{(\overline{yy} - \bar{y}\bar{y})}}$$

Mit  $\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}}$  ergibt sich

$$\hat{\beta}_1 = \hat{\rho}_{x,y} \frac{\sqrt{\overline{yy} - \bar{y}\bar{y}}}{\sqrt{\overline{xx} - \bar{x}\bar{x}}}$$

Die gewöhnliche Regressionsanalyse misst also nur Korrelation und nicht Kausalität!

# Die OLS Regressionsgerade



Die Regressionsgerade  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$  schätzt die unbekannte Population Regression Function  $E[y|x] = \beta_0 + \beta_1 x$ .

# Beispiele der einfachen Regression

## CEO-Gehälter und Eigenkapitalrentabilität

Population Regression Function

$$salary = \beta_0 + \beta_1 roe + u$$

*salary* : Gehalt in tausend \$

*roe* : durchschnittliche Eigenkapitalrentabilität (return on equity)


Regressionsgerade:

$$\widehat{salary} = 963.191 + 18.501 roe$$

Datensatz: CEOSAL1 ( $n = 209$ )

Die Regressionsgerade hängt von der Stichprobe ab.

Die Population Regression Function ist unbekannt!



# Beispiele der einfachen Regression

## Stundenlohn und Bildung

Population Regression Function

$$wage = \beta_0 + \beta_1 educ + u$$


*wage* : Stundenlohn in \$

*educ* : Bildungsjahre

Regressionsgerade:

$$\widehat{wage} = -0.90 + 0.54educ$$

Datensatz: WAGE1 ( $n = 526$ )



# Beispiele der einfachen Regression

## Wahlergebnisse und Wahlkampfausgaben

Population Regression Function

$$voteA = \beta_0 + \beta_1 shareA + u$$


*votaA* : % Kandidat:in A

*shareA* : Anteil Wahlkampfausgaben für Kandidat:in A

Regressionsgerade:

$$\widehat{voteA} = 26.81 + 0.464shareA$$

Datensatz: VOTE1 ( $n = 173$ )





# OLS: Eigenschaften bei beliebigen Stichproben

# Prognose und Residuen

Für eine beliebige<sup>1</sup> Stichprobe  $\{(x_i, y_i)\}_{i=1}^n$  liefern die OLS-Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  die Prognose

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

und damit die Residuen

$$\hat{u}_i = y_i - \hat{y}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i$$

für  $i = 1, \dots, n$

---

<sup>1</sup>Die Stichprobe muss verschiedene Werte  $x_i$  enthalten.

## Beispiel: Managergehälter (Daten: CEOSAL1)

obsno	roe	salary	$\widehat{\text{salary}}$	$\hat{u}$
1	14.1	1095	1224.058	-129.0581
2	10.9	1001	1164.854	-163.8542
3	23.5	1122	1397.969	-275.9692
4	5.9	578	1072.348	-494.3484
5	13.8	1368	1218.508	149.4923
6	20.0	1145	1333.215	-188.2151
7	16.4	1078	1266.611	-188.6108
8	16.3	1094	1264.761	-170.7606
9	10.5	1237	1157.454	79.54626
10	26.3	833	1449.773	-616.7726
11	25.9	567	1442.372	-875.3721
12	26.8	933	1459.023	-526.0231
13	14.8	1339	1237.009	101.9911
14	22.3	937	1375.768	-438.7678
15	56.3	2011	2004.808	6.191895

# Algebraische Eigenschaften der OLS-Statistiken

1. Die Summe der OLS-Residuen ergibt null:

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

2. Die Stichprobenkovarianz des Regressors und der OLS-Residuen ist null:

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

3. Die Durchschnitte des Regressors und des Regressanden liegen auf der Regressionsgeraden:

$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$$

Diese drei Gleichungen folgen direkt aus der Definition der OLS-Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$ .

zu 2.

Stichproben Kovarianz von  $x$  und  $\hat{u}$ :

$$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(\hat{u}_i - \bar{\hat{u}}) = \frac{1}{n} \sum_{i=1}^n \hat{u}_i \Rightarrow \bar{\hat{u}} = 0$$

$$= \frac{1}{n} \sum_{i=1}^n (x_i \cdot \hat{u}_i - \bar{x} \cdot \hat{u}_i - x_i \cdot \underbrace{\bar{\hat{u}}}_{=0} + \bar{x} \cdot \underbrace{\hat{u}_i}_{=0})$$

$$= \frac{1}{n} \sum_{i=1}^n x_i \hat{u}_i - \frac{1}{n} \sum_{i=1}^n \bar{x} \hat{u}_i = \frac{1}{n} \sum_{i=1}^n x_i \hat{u}_i - \bar{x} \cdot \frac{1}{n} \sum_{i=1}^n \hat{u}_i$$

$$= \frac{1}{n} \sum_{i=1}^n x_i \hat{u}_i$$

## OLS-Zerlegung

$$u_i = y_i - \hat{y}_i$$

Wir können die Beobachtungen  $y_i$  in einen erklärten und einen unerklärten Teil zerlegen:

$$y_i = \hat{y}_i + \hat{u}_i = \hat{y}_i + y_i - \hat{y}_i \quad \checkmark$$

Aus den Eigenschaften

$$\sum_{i=1}^n \hat{u}_i = 0 \quad \text{und} \quad \sum_{i=1}^n x_i \hat{u}_i = 0$$

folgt, dass der erklärte Teil  $\hat{y}_i$  und der unerklärte Teil  $\hat{u}_i$  unkorreliert sind:

$$\sum_{i=1}^n (\hat{y}_i - \bar{y})(\hat{u}_i - \bar{\hat{u}}) = \sum_{i=1}^n \hat{y}_i \hat{u}_i = \hat{\beta}_0 \sum_{i=1}^n \hat{u}_i + \hat{\beta}_1 \sum_{i=1}^n x_i \hat{u}_i = 0$$

## OLS-Zerlegung

Ebenso können wir die Stichprobenvarianz der Beobachtungen in einen erklärten und in einen unerklärten Teil zerlegen.

### Total Sum of Squares

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

### Explained Sum of Squares

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

### Residual Sum of Squares

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

Es gilt:

$$SST = SSE + SSR$$

## Das Bestimmtheitsmaß / Coefficient of Determination

Die Güte der Anpassung einer OLS-Regression ist der erklärte Anteil der Stichprobenvarianz der erklärten Variable.

Je größer  $SSE$  im Vergleich zu  $SSR$ , desto besser die Güte der Anpassung.

Mit  $SST = SSE + SSR$  definieren wir das **Bestimmtheitsmaß**  $R^2$ :

$$R^2 = SSE/SST = 1 - SSR/SST$$

Das Bestimmtheitsmaß nimmt Werte zwischen null und eins an und kann wie folgt interpretiert werden:

Der Regressor erklärt  $100 \cdot R^2\%$  der Streuung des Regressanden.



# Das Bestimmtheitsmaß der Beispiele

## CEO-Gehälter und Eigenkapitalrentabilität

$$\widehat{salary} = 963.191 + 18.501roe$$

$$n = 209, R^2 = 0.0132$$

Die Regression erklärt nur 1.3% der Streuung der Gehälter!

## Wahlergebnisse und Wahlkampfausgaben

$$\widehat{voteA} = 26.81 + 0.464shareA$$

$$n = 173, R^2 = 0.856$$

Der Anteil der Wahlkampfausgaben erklärt 86% der Streuung der Wahlergebnisse!

# Maßeinheiten und die funktionale Form

# Lineare Transformationen (Veränderung der Maßeinheiten)

Multiplikation der Variablen des linearen Regressionsmodells mit Konstanten impliziert eine entsprechende Transformation der Schätzer:

Seien  $\tilde{x}_i = c \cdot x_i$  und  $\tilde{y}_i = d \cdot y_i$  für  $c, d \in \mathbb{R}$ ,  $c, d \neq 0$ ,  $i = 1, \dots, n$ .

Dann gilt:

$$\tilde{y}_i = \tilde{\beta}_0 + \tilde{\beta}_1 \tilde{x}_i$$

$\Leftrightarrow$

$$d y_i = \tilde{\beta}_0 + \tilde{\beta}_1 c x_i \quad \parallel : d$$

$\Leftrightarrow$

$$y_i = \frac{1}{d} \tilde{\beta}_0 + \frac{c}{d} \tilde{\beta}_1 x_i$$

dass

$$\tilde{\beta}_0 = d \hat{\beta}_0 \quad \text{und} \quad \tilde{\beta}_1 = \frac{d}{c} \hat{\beta}_1$$

Das Bestimmtheitsmaß  $R^2$  ist invariant!

## Die Semi-logarithmische Form

$$\ln\left(1 + \frac{w_2 - w_1}{w_1}\right) = \ln\left(1 + \frac{w_2}{w_1} - 1\right) = \ln\left(\frac{w_2}{w_1}\right) = \beta_0 + \beta_1 e_2 + u_2 - \beta_0 - \beta_1 e_1 - u_1 = \beta_1(e_2 - e_1) + u_2 - u_1 = \beta_1 \cdot \Delta e + \Delta u$$

Die Semi-logarithmische Form misst die prozentuale Veränderung des Regressanden bei absoluter Veränderung des Regressors.

Das ökonometrische Modell

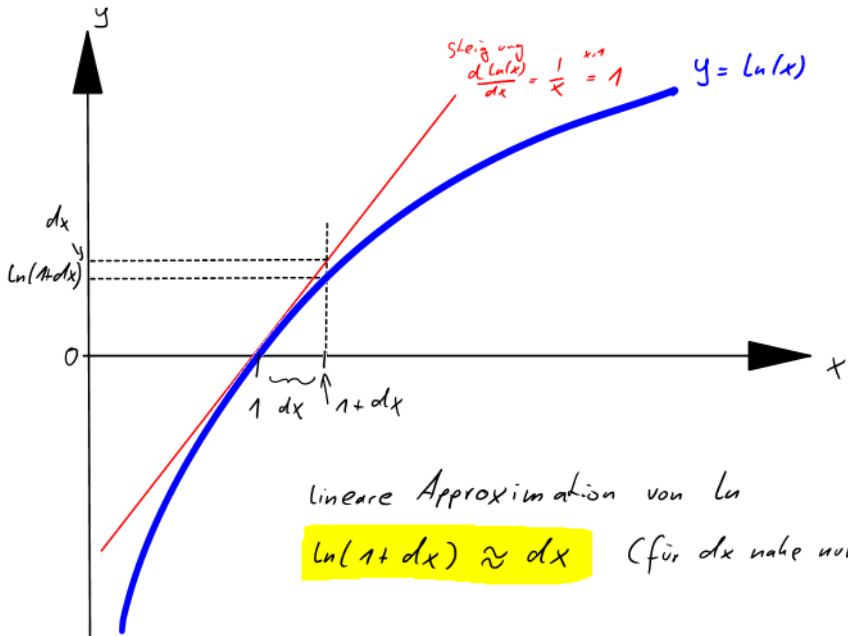
$$\ln(\text{wage}) = \beta_0 + \beta_1 \text{educ} + u$$

misst (falls  $\Delta u = 0$ ):

$$\frac{\text{relative Veränderung von wage}}{\text{von wage}} \cdot \frac{\Delta \text{wage}}{\text{wage}} \approx \beta_1 \Delta \text{educ} \quad \left\{ \begin{array}{l} \text{absolute Veränderung} \\ \text{von educ} \end{array} \right.$$

Eine Erhöhung der Bildung um ein Jahr geht einher mit einem Anstieg des Lohnes um  $100 \cdot \beta_1$  %.

$$\ln\left(1 + \frac{\Delta w}{w}\right) = \beta_1 \Delta e + \underbrace{\Delta u}_{=0 \text{ (c.p.)}}$$



# Log-Stundenlohn und Bildung

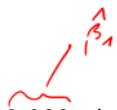
## Population Regression Function

$$\ln(\text{wage}) = \beta_0 + \beta_1 \text{educ} + u$$

$\ln(\text{wage})$  : natürlicher Logarithmus des Stundenlohns in \$

$\text{educ}$  : Bildungsjahre

Regressionsgerade:

$$\widehat{\ln(\text{wage})} = 0.584 + 0.083 \text{educ}$$


$$n = 526, R^2 = 0.186$$

Im Vergleich:

Wird  $\text{wage}$  anstelle von  $\ln(\text{wage})$  erklärt, beträgt  $R^2 = 0,165$ .

## Die Log-Logarithmische Form

Die Log-logarithmische Form misst die prozentuale Veränderung des Regressanden bei prozentualer Veränderung des Regressanden.

Im ökonomische Modell

$$\text{salary} = e^{\beta_0} \cdot \text{sales}^{\beta_1} \cdot e^u$$

$$\ln(\text{salary}) = \beta_0 + \beta_1 \ln(\text{sales}) + u$$

ist  $\beta_1$  die Elastizität von *salary* in Bezug auf *sales*:

Wenn sich *sales* um 1% ändert, ändert sich *salary* um  $\beta_1\%$ .

Die OLS-Regression ergibt

$$\widehat{\ln(\text{salary})} = 4.822 + 0.257 \ln(\text{sales})$$

$$n = 209, R^2 = 0.211$$

Diese Form wird auch **Modell mit konstanten Elastizitäten** genannt.

# Nichtlineare Transformationen

## Zusammenfassung:

Modell	Regressand	Regressor	Interpretation $\beta_1$
Level-Level	$y$	$x$	$\Delta y = \beta_1 \Delta x$
Level-Log	$y$	$\ln(x)$	$\Delta y \approx \beta_1 \frac{\Delta x}{x}$
Log-Level	$\ln(y)$	$x$	$\frac{\Delta y}{y} \approx \beta_1 \Delta x$
Log-Log	$\ln(y)$	$\ln(x)$	$\frac{\Delta y}{y} \approx \beta_1 \frac{\Delta x}{x}$

*"absolute Veränderung"*

*"relative Veränderung"*



# Erwartungswerte und Varianzen der OLS-Schätzer

Die Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  des einfachen linearen Regressionsmodells sind Funktionen der Daten der Stichprobe.

Wenn wir die Stichprobe als Zufallsgröße betrachten, so sind auch  $\hat{\beta}_0$  und  $\hat{\beta}_1$  Zufallsvariablen und haben statistische Eigenschaften.

Um diese Eigenschaften herzuleiten, benötigen wir einige Annahmen.

Die Abkürzung *SLR* steht hierbei für „simple linear regression“.

# Annahme SLR 1

## Linearität in den Parametern

Im ökonometrischen Modell steht die abhängige Variable  $y$  in Relation zu der unabhängigen Variable  $x$  und dem Störterm  $u$ :

$$y = \beta_0 + \beta_1 x + u ,$$

wobei  $\beta_0$  und  $\beta_1$  unbekannte aber feste Parameter sind.

*Bemerkungen:*

- ▶ Erlaubt, dass wir die Variablen nichtlinear transformieren.
- ▶ Fordert additive Separabilität.

# Annahme SLR 3

## **Variation der erklärenden Variable**

Die Stichprobenwerte  $x_1, x_2, \dots, x_n$  sind nicht alle identisch.

*Bemerkung:*

Mit SLR 3 folgt:  $\overline{xx} - \bar{x}\bar{x} > 0$

### **Bedingter Nullerwartungswert**

Bei gegebenen Werten  $x$  beträgt der bedingte Erwartungswert des Störterms  $u_i = y_i - \beta_0 - \beta_1 x_i$ ,  $i = 1, \dots, n$ , null:

$$E[u_i|x] = 0, \quad i = 1, \dots, n$$

*Bemerkung:*

Mit SLR 1 folgt:  $E[y_i|x] = \beta_0 + \beta_1 x_i$ ,  $i = 1, \dots, n$ .

# Erwartungstreue

Die beiden Schätzer

$$\hat{\beta}_0 = \bar{y} - \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}} \bar{x}$$
$$\hat{\beta}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{xx} - \bar{x}\bar{x}}$$

sind erwartungstreu:

## Theorem 2.1

Unter den Annahmen SLR 1, SLR 3 und SLR 4 gilt

$$E[\hat{\beta}_0] = \beta_0 \text{ und } E[\hat{\beta}_1] = \beta_1$$

für beliebige Werte  $\beta_0$  und  $\beta_1$ .

## Beweis Theorem 2.1 für $E[\hat{\beta}_1] = \beta_1$

$$\begin{aligned} E[\hat{\beta}_1|x] &\stackrel{SLR\ 3}{=} E \left[ \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \middle| x \right] \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x}) E[y_i|x]}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ &\stackrel{SLR\ 1,4}{=} \frac{\sum_{i=1}^n (x_i - \bar{x}) (\beta_0 + \beta_1 x_i)}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ &= \beta_0 \frac{\sum_{i=1}^n (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} + \beta_1 \frac{\sum_{i=1}^n (x_i - \bar{x}) x_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \beta_1 \end{aligned}$$

Mit der Teleskopeigenschaft für Erwartungswerte gilt

$$E[\hat{\beta}_1] = E[E[\hat{\beta}_1|x]] = \beta_1$$

## Beweis Theorem 2.1 für $E[\hat{\beta}_0] = \beta_0$

$$\begin{aligned} E[\hat{\beta}_0|x] &= E[\bar{y} - \hat{\beta}_1\bar{x} | x] \\ &= E[\bar{y}|x] - E[\hat{\beta}_1|x]\bar{x} \\ &= \frac{1}{n} \sum_{i=1}^n E[y_i|x] - \beta_1\bar{x} \\ &\stackrel{SLR\ 1,4}{=} \beta_0 + \beta_1\bar{x} - \beta_1\bar{x} = \beta_0 \end{aligned}$$

Mit der Teleskopeigenschaft für Erwartungswerte gilt

$$E[\hat{\beta}_0] = E[E[\hat{\beta}_0|x]] = \beta_0$$



# Annahmen

## Annahme SLR 5

### Homoskedastizität

Für beliebige gegebene Regressordaten  $x$  ist die bedingte Varianz des Störterms  $u_i$ ,  $i = 1, \dots, n$  identisch:

$$\text{Var}(u_i|x) = \sigma^2 > 0, \quad i = 1, \dots, n$$

*Bemerkungen:*

Da  $\text{Var}(u_i|x)$  nicht von  $x$  abhängt, gilt außerdem  $\text{Var}(u_i) = \sigma^2$ .

Ist SLR 5 verletzt, heißt der Störterm **heteroskedastisch**.

### Annahme SLR 5b

Wir fordern zusätzlich:  $\text{Cov}(u_i, u_j|x) = 0$  für  $i, j = 1, \dots, n$ ,  $i \neq j$

Definition Varianz einer Zufallsvariablen  $v_i$

$$\text{Var}(v_i) = E[(v_i - E[v_i])^2]$$

Falls  $E[v_i] = 0 \Rightarrow \text{Var}(v_i) = E[v_i^2]$

$$= E[v_i^2 - 2v_i E[v_i] + E[v_i]^2]$$

$$= E[v_i^2] - 2E[v_i]E[v_i] + E[v_i]^2$$

$$= E[v_i^2] - E[v_i]^2$$

Rechenregel

$$\text{Var}(a + b v_i) = E[(a + b v_i - E[a + b v_i])^2]$$

$$\begin{aligned} &= E[(\cancel{a} + \delta v_i - \cancel{a} - \delta E[v_i])^2] \\ &= E[(\delta v_i - \delta E[v_i])^2] \\ &= E[\delta^2 (v_i - E[v_i])^2] \\ &= \delta^2 E[(v_i - E[v_i])^2] \\ &\quad \text{Var}(v_i) \end{aligned}$$

$$\underline{\underline{\text{Var}(a + \delta v_i) = \delta^2 \text{Var}(v_i)}}$$

Definition Kovarianz zweier Zufallsvariablen  $U, V$

$$\begin{aligned}\text{Cov}(U, V) &= E[(U - E[U])(V - E[V])] \\ &= \dots \\ &= E[U \cdot V] - E[U] \cdot E[V]\end{aligned}$$

Rechenregel

$$\text{Cov}(a + bU, c + dV) = b \cdot d \cdot \text{Cov}(U, V)$$

---

$$\text{Var}(a + bU + c + dV)$$

Zwischenrechnung:  $E[a + b \cdot U + c + d \cdot V] = a + bE[U] + c + d \cdot E[V]$

$$\rightarrow E[(a + bU + c + dV - E[a + bU + c + dV])^2]$$

$$= E[(\cancel{a} + b \cdot U + \cancel{c} + dV - \cancel{a} - bE[U] - \cancel{c} - dE[V])^2]$$

$$= E[(\underline{b} \cdot u - \underline{b} E[u] + dv - dE[v])^2]$$


$$= E[(b(u - E[u]) + d(v - E[v]))^2]$$

$$= E[(b(u - E[u]))^2 + 2b(u - E[u])d(v - E[v]) + (d(v - E[v]))^2]$$

$$= b^2 E[(u - E[u])^2] + 2bd E[(u - E[u])(v - E[v])] + d^2 E[(v - E[v])^2]$$

$$= b^2 \text{Var}(u) + 2bd \text{Cor}(u, v) + d^2 \text{Var}(v)$$
$$= \text{Var}(a + b \cdot u + c + d \cdot v)$$

## Bedingte Verteilung von $y$ unter Homoskedastizität



Aus  $\text{Var}(u_i|x) = \sigma^2$  für  $i = 1, \dots, n$  und SLR 1 folgt

$$\text{Var}(y_i|x) = \text{Var}(\beta_0 + \beta_1 x_i + u_i|x_i) = \text{Var}(u_i|x_i) = \sigma^2 \text{ für } i = 1, \dots, n$$

## Theorem 2.2

### Stichprobenvarianzen der OLS-Schätzer

Unter den Annahmen SLR 1, SLR 3, SLR 4 und SLR 5+b gilt:

$$\text{Var}(\hat{\beta}_0 | \mathbf{x}) = \sigma^2 \frac{1}{n} \frac{\overline{xx}}{\overline{xx} - \bar{x}\bar{x}}$$

$$\text{Var}(\hat{\beta}_1 | \mathbf{x}) = \sigma^2 \frac{1}{n} \frac{1}{\overline{xx} - \bar{x}\bar{x}}$$

## Beweis Theorem 2.2 für $\text{Var}(\hat{\beta}_1|x)$

$$\begin{aligned}\text{Var}(\hat{\beta}_1|x) &\stackrel{\text{SLR 3}}{=} \text{Var}\left(\frac{\sum_{i=1}^n (x_i - \bar{x})y_i}{\sum_{i=1}^n (x_i - \bar{x})^2}\right) \\ &\stackrel{\text{SLR 1}}{=} \text{Var}\left(\frac{\sum_{i=1}^n (x_i - \bar{x})(\beta_0 + \beta_1 x_i)}{\sum_{i=1}^n (x_i - \bar{x})^2} + \frac{\sum_{i=1}^n (x_i - \bar{x})u_i}{\sum_{i=1}^n (x_i - \bar{x})^2}\right) \\ &\stackrel{\text{SLR 2,5b}}{=} \frac{\sum_{i=1}^n (x_i - \bar{x})^2 \text{Var}(u_i|x)}{(\sum_{i=1}^n (x_i - \bar{x})^2)^2} \\ &\stackrel{\text{SLR 5}}{=} \frac{\sum_{i=1}^n (x_i - \bar{x})^2 \sigma^2}{(\sum_{i=1}^n (x_i - \bar{x})^2)^2} \\ &= \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{1}{n} \sigma^2 \frac{1}{\overline{xx} - \bar{x}\bar{x}}\end{aligned}$$

Je stärker der Regressor streut und je größer die Stichprobe ist, desto genauer ist  $\hat{\beta}_1$ .



## Beweis Theorem 2.2 für $\text{Var}(\hat{\beta}_0|x)$ Schritt 1

$$\begin{aligned}\text{Var}(\bar{y}|x) &\stackrel{\text{SLR } 1}{=} \text{Var}\left(\frac{1}{n}\sum_{i=1}^n \beta_0 + \beta_1 x_i + u_i \middle| x\right) \\ &= \text{Var}\left(\frac{1}{n}\sum_{i=1}^n u_i \middle| x\right) \\ &\stackrel{\text{SLR } 5b}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(u_i|x) \\ &\stackrel{\text{SLR } 5}{=} \frac{1}{n} \sigma^2\end{aligned}$$

## Beweis Theorem 2.2 für $\text{Var}(\hat{\beta}_0|x)$ Schritt 2

$$\begin{aligned}\text{Cov}(\bar{y}, \hat{\beta}_1|x) &\stackrel{\text{SLR 1}}{=} \text{Cov}\left(\frac{1}{n} \sum_{i=1}^n y_i, \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \middle| x\right) \\ &= \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n \frac{x_j - \bar{x}}{\sum_{k=1}^n (x_k - \bar{x})^2} \text{Cov}(y_i, y_j|x) \\ &\stackrel{\text{SLR 5b}}{=} \frac{1}{n} \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum_{k=1}^n (x_k - \bar{x})^2} \text{Cov}(y_i, y_i|x) \\ &\stackrel{\text{SLR 5}}{=} \sigma^2 \frac{1}{n} \frac{\sum_{i=1}^n x_i - \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} = 0\end{aligned}$$

## Beweis Theorem 2.2 für $\text{Var}(\hat{\beta}_0|x)$ Schritt 3

$$\begin{aligned}\text{Var}(\hat{\beta}_0|x) &= \text{Var}(\bar{y} - \hat{\beta}_1\bar{x}|x) \\ &= \text{Var}(\bar{y}|x) - 2\text{Cov}(\bar{y}, \hat{\beta}_1|x)\bar{x} + \text{Var}(\hat{\beta}_1|x)\bar{x}\bar{x} \\ &= \frac{1}{n}\sigma^2 - 2 \cdot 0 + \frac{1}{n}\sigma^2 \frac{1}{\overline{xx} - \bar{x}\bar{x}} \bar{x}\bar{x} \\ &= \frac{1}{n}\sigma^2 \frac{\bar{x}\bar{x}}{\overline{xx} - \bar{x}\bar{x}}\end{aligned}$$

## Schätzung der Varianz des Störterms

Bei einer gegebenen Stichprobe sind die Ausdrücke

$$\overline{xx} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

und

$$\bar{x}\bar{x} = \left( \frac{1}{n} \sum_{i=1}^n x_i \right)^2$$

bekannt.

Bei  $\sigma^2$  handelt es sich aber um einen unbekanntem Parameter, der zu schätzen ist.

## Theorem 2.3

### Unverzerrter Schätzer für $\sigma^2$

Sei der Schätzer für  $\sigma^2$  definiert durch:

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

Unter den Annahmen SLR 1, SLR 3, SLR 4 und SLR 5+b gilt:

$$E[\hat{\sigma}^2|x] = \sigma^2$$

## Begründung für Theorem 2.3

Der Beweis ist etwas aufwendiger und wird später nachgeholt.

Warum gilt nicht  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2$ ?

Durch die beiden Gleichungen

$$\sum_{i=1}^n \hat{u}_i = 0$$

$$\sum_{i=1}^n x_i \hat{u}_i = 0$$

werden zwei Freiheitsgrade „verbraucht“.

Daher teilen wir die Summe der quadrierten Residuen durch  $n - 2$ .

# Schätzer für die Varianzen der Schätzer

Mit dem Schätzer

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

ergibt sich

$$\widehat{\text{Var}}(\hat{\beta}_0|x) = \hat{\sigma}^2 \frac{1}{n} \frac{\overline{xx}}{\overline{xx} - \bar{x}\bar{x}}$$

$$\widehat{\text{Var}}(\hat{\beta}_1|x) = \hat{\sigma}^2 \frac{1}{n} \frac{1}{\overline{xx} - \bar{x}\bar{x}}$$

Mit den Standardfehlern der Schätzer der Regressionskoeffizienten

$$se(\hat{\beta}_0) = \sqrt{\widehat{\text{Var}}(\hat{\beta}_0|x)} \text{ und } se(\hat{\beta}_1) = \sqrt{\widehat{\text{Var}}(\hat{\beta}_1|x)}$$

können wir später Intervallschätzungen für die Regressionskoeffizienten vornehmen.

## Begriffe aus Kapitel 2

- ▶ einfaches Regressionsmodell
- ▶ Regressor, Regressand, Störterm
- ▶ strikte Exogenität
- ▶ Population Regression Funktion (PRF)
- ▶ gewöhnliche Kleinste Quadrate Schätzer
- ▶ Momentenmethode, orthogonale Projektion
- ▶ Prognose und Residuen
- ▶ Stichproben(ko)varianz, Korrelationskoeffizient, Bestimmtheitsmaß
- ▶ Erwartungstreue
- ▶ Homoskedastizität, Heteroskedastizität