

12. Kleinste-Quadrate-Schätzer und Konfidenzintervalle

12.1 Kleinste-Quadrate (KQ)- Schätzung

12.2 Erwartungswert

12.3 Varianz

12.4 Konfidenzintervalle

$$\frac{2 \sigma_{\varepsilon}}{\sqrt{n}}$$

12.1 Kleinste-Quadrate (KQ)- Schätzung

- ▶ Gegeben: lineares Modell der Form

$$y(\mathbf{x}) = \boldsymbol{\beta}'\mathbf{x} + \epsilon = \hat{y}(\mathbf{x}) + \epsilon, \quad \epsilon \sim i.i.d.$$

welches *alle Gauß-Markow-Annahmen mit Ausnahme der gaußverteilten Residualterme* erfüllt

- ▶ Gegeben sind ebenfalls n vollständige Datensätze aller exogenen Faktoren und der endogenen Variablen, welche die Datenspezifikation erfüllen:

$$\{\mathbf{p}_i = (x_{i0}, \dots, x_{iJ}, y_i)'\}, \quad i = 1, \dots, n\}$$

- ▶ Gesucht ist ein Parameterschätzer $\hat{\boldsymbol{\beta}}$, welcher die Fehlerquadratsumme zwischen den deterministischen Modellvoraussagen $\mathbf{x}'_i\boldsymbol{\beta}$ und der beobachteten endogenen Variable y_i bezüglich der Parameter minimiert:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} S(\boldsymbol{\beta})$$

wobei

$$S(\boldsymbol{\beta}) = \boldsymbol{\epsilon}'\boldsymbol{\epsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}).$$

Bestimmung des KQ-Schätzers

$$\begin{aligned} S &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ \text{[Distributivität } \rightarrow] &= \mathbf{y}'\mathbf{y} - (\mathbf{X}\boldsymbol{\beta})'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}\boldsymbol{\beta})'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \\ \text{[Transpositionsregeln } \rightarrow] &= \mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'(\mathbf{X}'\mathbf{y}) + \boldsymbol{\beta}'(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} \end{aligned}$$

Ableiten nach $\boldsymbol{\beta}$ und Nullsetzen mit den Regeln $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{a}) = \mathbf{a}$ und $\frac{\partial}{\partial \boldsymbol{\beta}}(\boldsymbol{\beta}'\mathbf{A}\boldsymbol{\beta}) = (\mathbf{A} + \mathbf{A}')\boldsymbol{\beta}$, wobei $\mathbf{A} = \mathbf{X}'\mathbf{X}$:

$$\frac{\partial S(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}} = 0 - 2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \stackrel{!}{=} 0$$

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y} \quad | \cdot (\mathbf{X}'\mathbf{X})^{-1}$$

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

12.2 Erwartungswert des KQ-Schätzers

- ▶ Einzige Zufallsquelle: Residualterm ϵ gemäß $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \epsilon$
- ▶ Berücksichtige, dass der KQ-Schätzer linear in \mathbf{y} ist:

$$\begin{aligned}\hat{\boldsymbol{\beta}} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'(\mathbf{X}\boldsymbol{\beta} + \epsilon) \\ &= \underline{\underline{\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\epsilon}}\end{aligned}$$

Erwartungswert

$$E(\hat{\boldsymbol{\beta}}) = E(\boldsymbol{\beta}) + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'E(\epsilon) = \boldsymbol{\beta}$$

Der KQ-Schätzer ist **unverzerrt** unter der milden Bedingung $E(\epsilon) = \mathbf{0}$

12.3 Varianz des KQ-Schätzers

- ▶ Gauß-Markow Bedingungen $\rightarrow \epsilon \sim \text{i.i.d}N(0, \sigma^2) \rightarrow \hat{\beta}$ ist normalverteilt (**Warum?**)
- ▶ \Rightarrow komplette Verteilung ist vollständig definiert durch die **Varianz-Kovarianz-Matrix** $\mathbf{V}_{\hat{\beta}}$

$$\begin{aligned}
 \mathbf{V}_{\hat{\beta}} &\stackrel{\text{def}}{=} E \left((\hat{\beta} - \beta)(\hat{\beta} - \beta)' \right) \\
 \text{[setze } \hat{\beta} = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\epsilon \rightarrow] &= E \left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\epsilon ((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\epsilon)' \right) \\
 \text{[Matrixregeln } \rightarrow] &= E \left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\epsilon \epsilon' \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \right) \\
 \text{[} E(\cdot) \text{ wirkt nur auf } \epsilon \rightarrow] &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' E(\epsilon \epsilon') \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \\
 \text{[Gauß-Markow } \rightarrow] &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \sigma_{\epsilon}^2 \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \\
 \text{[Def Matrixinverse } \rightarrow] &= \sigma_{\epsilon}^2 (\mathbf{X}'\mathbf{X})^{-1}
 \end{aligned}$$

Die Varianz-Kovarianz-Matrix hängt nur von den *exogenen* Daten ab!

Ergebnisse

- ▶ KQ-Schätzer:

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

- ▶ Falls $\epsilon \sim \text{i.i.d.}$ \Rightarrow **Varianz-Kovarianz-Matrix** der Schätzfehler kann als **Hesse-Matrix H** der Fehlerquadratsumme $S(\beta)$ geschrieben werden:

$$\begin{aligned} \mathbf{V}_{\hat{\beta}} &= E\left((\hat{\beta} - \beta)(\hat{\beta} - \beta)'\right) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} = 2\sigma^2 \mathbf{H}^{-1}, \\ H_{jk} &= \left. \frac{\partial^2 S}{\partial \beta_j \partial \beta_k} \right|_{\beta = \hat{\beta}} = 2(\mathbf{X}'\mathbf{X})_{jk} \end{aligned}$$

- ▶ Varianz der Schätzfehler: $V(\hat{\beta}_j) = V_{jj}$
- ▶ Korrelation der Schätzfehler: $\text{Corr}(\hat{\beta}_j, \hat{\beta}_k) = \frac{V_{jk}}{\sqrt{V_{jj}V_{kk}}}$
- ▶ Die normalisierten Schätzfehler sind standardnormalverteilt:

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{V_{jj}}} \sim N(0, 1)$$

Schätzung der Residualvarianz

Residualvarianz σ^2 ist nicht bekannt \Rightarrow muss ebenfalls geschätzt werden!

$$\hat{\sigma}^2 = \frac{1}{n - J - 1} \sum_i (y_i - \hat{y}(x_i))^2 = \frac{S(\hat{\beta})}{n - J - 1}$$

$$\text{bzw } \hat{\sigma}^2 = \frac{\mathbf{y}'(\mathbf{1} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{y}}{n - J - 1} \Rightarrow \begin{array}{l} \text{Summe} \\ \text{quadrierter} \\ \text{Normalverteilungen} \end{array}$$

\Rightarrow geschätzte Fehlerstatistik ("nicht einmal der Fehler ist genau bekannt"):


- ▶ Schätzung der Varianz-Kovarianz-Matrix:

$$\hat{\mathbf{V}}_{\hat{\beta}} = 2\hat{\sigma}^2\mathbf{H}^{-1} = \hat{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$$


- ▶ Die normalisierten geschätzten Fehler sind **student-t** verteilt:

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{V}_{jj}}} \sim T(n - 1 - J)$$



Dichtefunktionen der Student-t Verteilungen vs. Standardnormalverteilung



Verteilungsfunktionen der Student-t Verteilungen vs. Standardnormalverteilung




Beispiel korrelierter Schätzfehler: die bekannte Hotelbuchungsaufgabe




- ▶ Hotelbuchungen aus VL 11:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

- ▶ Exogene Faktoren: $x_0 = 1$, x_1 : Qualitäts-Proxy [# stars]; x_2 : Preis [€/Nacht].
- ▶ Endogene Variable: Buchungsrate [%]
- ▶ Nachfrage positiv mit Qualitätsproxy und Preis korreliert




Residualfehler bei KQ-Fit der Parameter



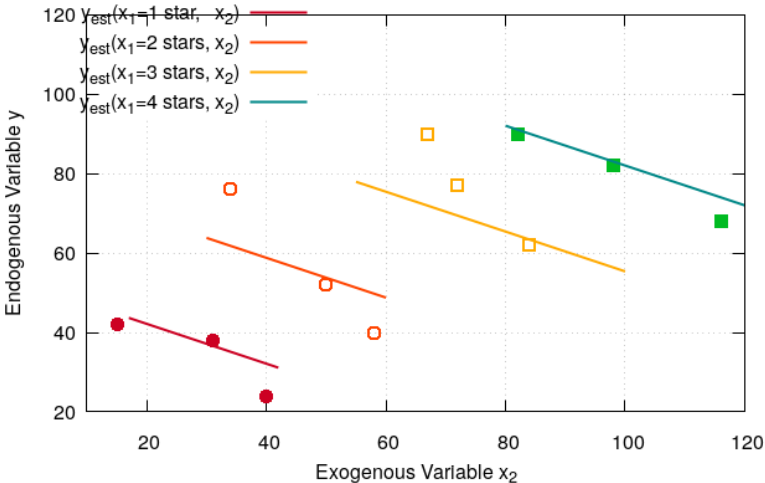
Abweichung vom Fit I: kleiner Effekt, falls β_1 und β_2 gegensätzlich fehlgefittet sind

β_1 and β_2 shifted by $\Delta\beta_1$ and $-\Delta\beta_2$, respectively




Abweichung vom Fit II: kleiner Effekt, falls β_1 und β_2 gegensätzlich fehlgefittet sind

β_1 and β_2 shifted by $-\Delta\beta_1$ and $+\Delta\beta_2$, respectively

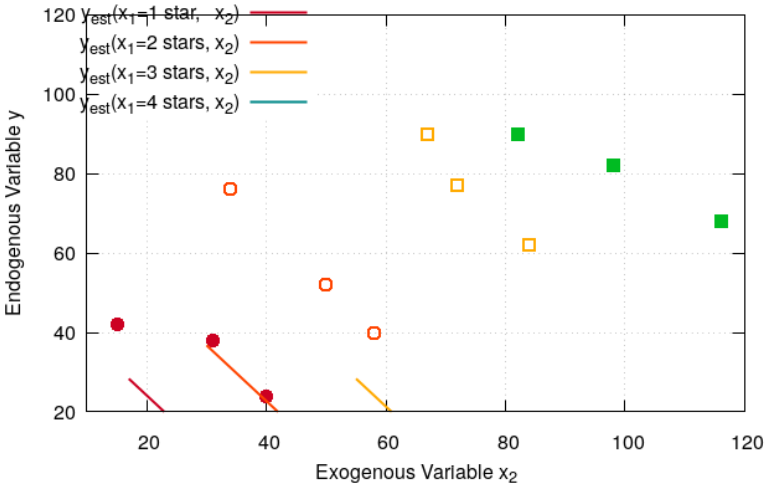


Abweichung vom Fit III: Großer Effekt bei positiven Abweichungen von β_1 und β_2




Abweichung vom Fit IV: Großer Effekt bei negativen Abweichungen von β_1 und β_2

β_1 and β_2 shifted by $-\Delta\beta_1$ and $-\Delta\beta_2$, respectively



Ergebnis: negative Korrelation zwischen den Schätzfehlern von β_1 und β_2

Density $\hat{f}(\hat{\beta}_1, \hat{\beta}_2) \mid \beta_1=38.21, \beta_2=-0.95$



Spezialfall 1: Mittelwertschätzung (keine exogenen Faktoren)

- ▶ Model: $y = \beta_0 + \epsilon := \mu + \epsilon$
- ▶ System matrix: $\mathbf{X} = (1, 1, \dots, 1)'$
- ▶ KQ estimator:

$$(\mathbf{X}'\mathbf{X})^{-1} = \frac{1}{n}, \quad \mathbf{X}'\mathbf{y} = \sum_i y_i = n\bar{y},$$
$$\hat{\beta}_0 = \hat{\mu} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = \bar{y}$$

- ▶ Variance: $V_{00} = V(\hat{\mu}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} = \frac{\sigma^2}{n}, \quad \hat{V}_{00} = \frac{\hat{\sigma}^2}{n}$
- ▶ Distribution of the estimator (if $\epsilon \sim i.i.d.N(\mu, \sigma^2)$)

$$\frac{\hat{\beta}_0 - \beta_0}{\sqrt{V_{00}}} = \frac{\bar{y} - \mu}{\sigma} \sqrt{n} \sim N(0, 1),$$
$$\frac{\hat{\beta}_0 - \beta_0}{\sqrt{\hat{V}_{00}}} = \frac{\bar{y} - \mu}{\hat{\sigma}} \sqrt{n} \sim T(n-1)$$

Spezialfall 2: Lineare Einfachregression

- ▶ Model (with $x_1 = x$): $y = \beta_0 + \beta_1 x + \epsilon$
- ▶ System matrix:

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \mathbf{X}'\mathbf{X} = \begin{pmatrix} n & n\bar{x} \\ n\bar{x} & \sum x_i^2 \end{pmatrix}$$

- ▶ KQ estimator (with $s_x^2 = 1/n(\sum x_i^2 - n\bar{x})$):

$$(\mathbf{X}'\mathbf{X})^{-1} = \frac{1}{ns_x^2} \begin{pmatrix} \frac{\sum x_i^2}{n} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}, \quad \mathbf{X}'\mathbf{y} = \begin{pmatrix} n\bar{y} \\ \sum x_i y_i \end{pmatrix}$$

$$\hat{\beta}_1 = \begin{pmatrix} -\frac{\bar{x}}{ns_x^2}, \frac{1}{ns_x^2} \end{pmatrix} \begin{pmatrix} n\bar{y} \\ \sum x_i y_i \end{pmatrix} = \frac{\sum_i x_i y_i - n\bar{x}\bar{y}}{\sum x_i^2 - n\bar{x}} = \frac{s_{xy}}{s_x^2},$$

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

Simple linear regression (ctnd)

- ▶ Variance-covariance matrix (assuming w/o loss of generality $\bar{x} = 0$):

$$\mathbf{V}(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} = \sigma^2 \begin{pmatrix} \frac{1}{n} & 0 \\ 0 & \frac{1}{ns_x^2} \end{pmatrix}$$

- ▶ Variance of the estimator $\hat{y}(x)$ (x is deterministic):


$$V(\hat{y}(x)) = V(\hat{\beta}_0 + \hat{\beta}_1 x) = V_{00} + x^2 V_{11} + 2x V_{01} = \frac{\sigma^2}{n} \left(1 + \frac{x^2}{s_x^2} \right)$$

- ▶ Distribution of the estimator for $y(x)$:

$$\hat{y}(x) \sim N(y(x), V(\hat{y}(x)))$$

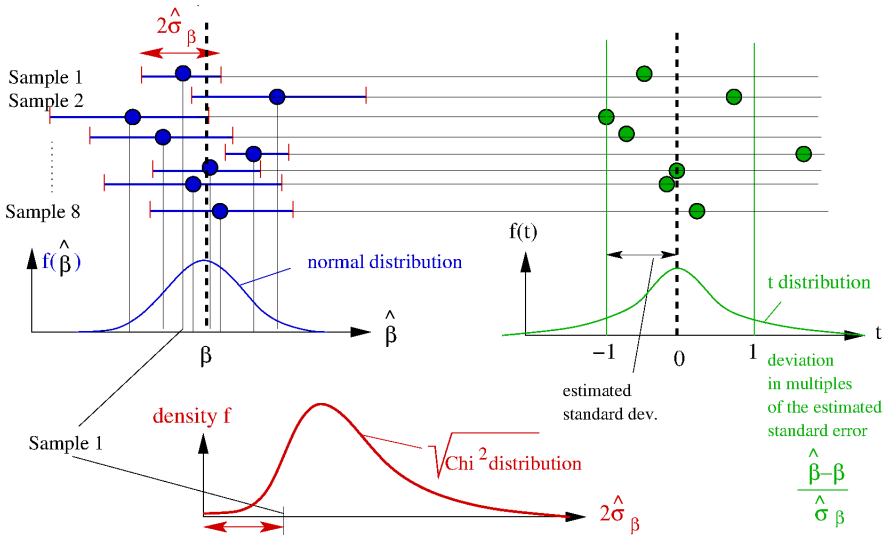
If σ^2 has to be estimated by $\hat{\sigma}^2$, the normalized estimators for β_0 , β_1 and $y(x)$ are $\sim T(n - 2)$.

Probability density for $\hat{y}(x)$ for simple linear regression




- ▶ If the Gauß-Markov assumptions apply, the model estimation errors $\hat{y}(x) - y(x)$ are Gaussian distributed
- ▶ The expectation and variance depends on x ; the standard error is hyperbola-shaped.


12.4 Konfidenzintervalle der Parameterwerte: Herkunft der 1 Student-t Verteilung



Dichtefunktionen der Student-t Verteilungen vs. Standardnormalverteilung




Verteilungsfunktionen der Student-t Verteilungen vs. Standardnormalverteilung





Konfidenzintervalle (KI)

$$CI_{\beta_j}^{(\alpha)} : \beta_j \in \left[\hat{\beta}_j - \Delta \hat{\beta}_j, \hat{\beta}_j + \Delta \hat{\beta}_j \right], \quad \Delta \hat{\beta}_j = t_{1-\alpha/2}^{(n-J-1)} \hat{\sigma}_{\hat{\beta}_j}.$$

- ▶ $t_{1-\alpha/2}$: Quantil (Inverse der Verteilungsfunktion)
- ▶ “Unschärferelation der KI: Eine schärfere Aussage (ein kleineres KI) impliziert größere (α -) Fehler und umgekehrt”



Hotelbeispiel: KI für die Wertschätzung der Qualität bzw Sternezahl β_1



Modell: $y(\mathbf{x}) = \sum_j \beta_j x_j + \epsilon$

Faktoren:

$x_0 = 1$, x_1 : #stars, x_2 : price

Konfidenzintervall CI:

$$\beta_1 \in \left[\hat{\beta}_1 - \Delta \hat{\beta}_1^{(\alpha)}, \hat{\beta}_1 + \Delta \hat{\beta}_1^{(\alpha)} \right]$$

$$\Delta \hat{\beta}_1^{(\alpha)} = t_{1-\alpha/2}^{(n-3)} \sqrt{\hat{V}(\hat{\beta}_1)}$$

$$\hat{V}(\hat{\beta}_1) = \hat{\sigma}_\epsilon^2 \left[(\mathbf{X}'\mathbf{X})^{-1} \right]_{11}$$

$$\hat{\sigma}_\epsilon^2 = \frac{1}{n-3} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$