

Kapitel GLS:

# Das verallgemeinerte Regressionsmodell



Moodle



Lehrbuch

# Das klären wir in diesem Kapitel:

Verletzung von MLR 5: Konsequenzen für OLS-Schätzer

GLS: Generalized Least Squares

FGLS: Feasible Generalized Least Squares

## Klassisches Regressionsmodell (OLS)

$$MLR 1: \quad \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

$$MLR 3: \quad rk(\mathbf{X}) = k + 1$$

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

$$MLR 5: \quad \Sigma(\mathbf{u}|\mathbf{X}) = \sigma^2 \mathbf{I}$$

MLR 5 definiert klassische (homoskedastische und seriell unkorrelierte) Fehlerterme.

## Verallgemeinertes Regressionsmodell (GLS)

MLR 1, 3 & 4 wie OLS und

$$MLR 5': \quad \Sigma(\mathbf{u}|\mathbf{X}) = \sigma^2 \boldsymbol{\Omega}$$

wobei  $\boldsymbol{\Omega}$  eine positiv definit symmetrische (pds)  $n \times n$  - Matrix ist.

Varianz  
-Kovarianz  
Matrix



$n \times n$

$n$ -Komponente



$$\Sigma (U|X) =$$

$$\begin{pmatrix} \text{Var}(u_1|X) & \text{Cov}(u_1, u_2|X) & \dots & \text{Cov}(u_1, u_n|X) \\ \text{Cov}(u_2, u_1|X) & \text{Var}(u_2|X) & & \text{Cov}(u_2, u_n|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n, u_1|X) & \text{Cov}(u_n, u_2|X) & \dots & \text{Var}(u_n|X) \end{pmatrix}$$

$$\text{MLRS} = \begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{pmatrix} = \sigma^2 I_n$$

# Eigenschaften positiv definiter Matrizen

"quadratische Form"

Sei die  $n \times n$ -Matrix  $A$  positiv definit, d.h. es gelte  $\mathbf{x}'A\mathbf{x} > 0$  für alle  $\mathbf{x} \in \mathbb{R}^n$ ,  $\mathbf{x} \neq \mathbf{0}$ .

$\mathbf{x}'A\mathbf{x}$   
 $1 \times 1$

Dann hat  $A$  vollen Rang und es existiert die Inverse  $A^{-1}$ , welche ebenfalls positiv definit ist.

Für eine positiv definite Matrix  $A$  existiert eine reguläre Matrix  $Z$ , sodass  $A = ZZ'$ . Deswegen gilt:

Wurzel  
von  $A$

$$A' = (ZZ')' = (Z')' Z' = ZZ' = A,$$

d.h. jede positiv definite Matrix ist symmetrisch.

Da  $A^{-1}$  ebenfalls positiv definit ist, existiert auch eine reguläre Matrix  $P$ , sodass:

$$A^{-1} = P'P$$

Es gilt dann  $P = Z^{-1}$ .

# Spezialfälle

Bevor wir das zentrale Resultat, das

*OLS* *+ GLS*  
**Gauß-Markov-Aitken-Theorem**

für allgemeine pds-Matrizen  $\Omega$  besprechen, widmen wir uns zwei *Spezialfällen*:

- ▶ *Querschnittsdaten*  
heteroskedastische und seriell unkorrelierte Störterme
- ▶ homoskedastische und seriell korrelierte Störterme

*Zeitreihen*

## Spezialfall: $\mathbf{u}$ heteroskedastisch, seriell unkorreliert

Die Störterme sind seriell unkorreliert ( $\text{Cov}(u_i, u_j) = 0 \forall i \neq j$ ), die Varianzen variieren aber über die Beobachtungen ( $\text{Var}(u_i) = \sigma_i^2$ ).

Wir schreiben dann

$$\mathbb{V}(\mathbf{u}|\mathbf{X}) = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_n^2 \end{pmatrix} = \sigma^2 \underbrace{\begin{pmatrix} \frac{\sigma_1^2}{\sigma^2} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2^2}{\sigma^2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{\sigma_n^2}{\sigma^2} \end{pmatrix}}_{\Omega} = \sigma^2 \Omega$$

mit  $\sigma > 0$  und  $\sigma_i > 0 \forall i = 1, \dots, n$

Dieser Fall ist häufig in Querschnittsmodellen.

# Spezialfall heteroskedastisch, seriell unkorreliert

Inverse von  $\Omega$ :

$$\Omega^{-1} = \begin{pmatrix} \frac{\sigma_1^2}{\sigma_1^2} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2^2}{\sigma_2^2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{\sigma_n^2}{\sigma_n^2} \end{pmatrix}$$

Zerlegung von  $\Omega^{-1}$ :

$$\begin{pmatrix} \frac{\sigma_1^2}{\sigma_1^2} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2^2}{\sigma_2^2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{\sigma_n^2}{\sigma_n^2} \end{pmatrix} = \underbrace{\begin{pmatrix} \frac{\sigma_1}{\sigma_1} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2}{\sigma_2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{\sigma_n}{\sigma_n} \end{pmatrix}}_{\sqrt{\Omega^{-1}}} \underbrace{\begin{pmatrix} \frac{\sigma_1}{\sigma_1} & 0 & \dots & 0 \\ 0 & \frac{\sigma_2}{\sigma_2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{\sigma_n}{\sigma_n} \end{pmatrix}}_{\sqrt{\Omega^{-1}}}$$



## Spezialfall homoskedastisch, seriell korreliert

Die Störterme haben identische Varianzen, sind aber untereinander korreliert:

$$\text{Var}(u_i|X) = \sigma^2 > 0 \quad \forall i = 1, \dots, n \quad \& \quad \text{Cov}(u_s, u_t|X) \neq 0 \quad s \neq t$$

$$\Sigma(\mathbf{u}|X) = \begin{pmatrix} \sigma^2 & \text{Cov}(u_1, u_2|X) & \dots & \text{Cov}(u_1, u_n|X) \\ \text{Cov}(u_2, u_1|X) & \sigma^2 & \dots & \text{Cov}(u_2, u_n|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n, u_1|X) & \text{Cov}(u_n, u_2) & \dots & \sigma^2 \end{pmatrix}$$

$$= \underbrace{\frac{\text{Cov}(u_2, u_1|X)}{\sqrt{\text{Var}(u_2|X)} \cdot \sqrt{\text{Var}(u_1|X)}}}_{= \frac{\text{Cov}(u_2, u_1|X)}{\sqrt{\sigma^2} \cdot \sqrt{\sigma^2}} = \frac{\text{Cov}(u_2, u_1|X)}{\sigma^2}}_{\Omega} \begin{pmatrix} 1 & \text{corr}(u_1, u_2|X) & \dots & \text{corr}(u_1, u_n|X) \\ \text{corr}(u_2, u_1|X) & 1 & \dots & \text{corr}(u_2, u_n|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{corr}(u_n, u_1|X) & \text{corr}(u_n, u_2|X) & \dots & 1 \end{pmatrix}$$

Dieser Fall ist häufig in Zeitreihendaten.

# Verletzung von MLR 5: Konsequenzen für OLS-Schätzer

## Verletzung von MLR 5: Konsequenzen für OLS-Schätzer

Welche Konsequenzen hat die Verallgemeinerung von MLR 5:

$$\mathbb{E}(\mathbf{u}|X) = \sigma^2 I \text{ durch}$$

$$MLR 5' : \mathbb{E}(\mathbf{u}|X) = \sigma^2 \Omega$$

auf die OLS-Schätzer?

Wir schätzen den Parametervektor  $\beta$  zunächst mit OLS:

$$\hat{\beta} = (X'X)^{-1}X'y \quad (\text{mit MLR 3})$$

$$= (X'X)^{-1}X'(X\beta + \mathbf{u}) \quad (\text{mit MLR 1})$$

$$= \beta + (X'X)^{-1}X'\mathbf{u}$$

Mit MLR 4  $E[\mathbf{u}|X] = \mathbf{0}$  gilt:

$$E[\hat{\beta}|X] = E[\beta + (X'X)^{-1}X'\mathbf{u}|X] = \beta + (X'X)^{-1}X'\mathbf{0}$$

$E[\mathbf{u}|X]$



Der OLS-Schätzer ist also nach wie vor erwartungstreu!

Die Varianz des Schätzers  $\hat{\beta}$  unter MLRS'

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

$$\text{MLRS}' : \quad \mathbb{E}(u|X) = \sigma^2 \Omega, \quad \Omega \text{ p.d.s.}$$

$$\mathbb{E}(\hat{\beta}|X) = \mathbb{E}(\underbrace{\beta}_{\substack{\text{additiv} \\ \text{konstant}}} + (X'X)^{-1} X'u|X) = \mathbb{E}(\underbrace{(X'X)^{-1} X'u|X}_{\substack{\text{multiplikativ} \\ \text{konstant}}}) \quad (1)'$$

$$= (X'X)^{-1} X' \mathbb{E}(u|X) \left( \underline{(X'X)^{-1}} \underline{X'} \right)'$$

$$= (X'X)^{-1} X' \mathbb{E}(u|X) \left( \underline{X'} \right)' \left( \underline{(X'X)^{-1}} \right)'$$

$$= (X'X)^{-1} X' \mathbb{E}(u|X) X (X'X)^{-1}$$

$$\text{MLRS}' = \left( (X'X)^{-1} X' \sigma^2 \Omega \cdot X (X'X)^{-1} \right) = \sigma^2 (X'X)^{-1} X' \Omega X (X'X)^{-1}$$

Für MLRS  $\mathbb{E}(v|X) = \sigma^2 \cdot I$  ( $\Omega = I$ )

$$\Rightarrow \mathbb{E}(\hat{\beta}|X) = \sigma^2 (X'X)^{-1} \underline{X'X} (X'X)^{-1} = \sigma^2 (X'X)^{-1}$$

---

Rückblick

$$\hat{\beta} \text{ mit } \hat{\beta} = A \cdot y$$

• ist linear ✓

• ist erwartungstreu, falls

"pseudo inverse" von  $X$

$$\boxed{A \cdot X = I}$$

gesucht: GLS-schätzer

$$\tilde{\beta} \text{ mit } \tilde{\beta} = \tilde{A} \cdot y \quad : \quad \tilde{A} \cdot X = I$$

## Konsequenzen für OLS

Für die Varianz-Kovarianz-Matrix von  $\hat{\beta}$  gilt aber:

$$\begin{aligned}\mathbb{V}(\hat{\beta}|X) &= \mathbb{V}(\beta + (X'X)^{-1}X'u|X) \\ &= (X'X)^{-1}X' \mathbb{V}(u|X)X(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1}X'\Omega X(X'X)^{-1}\end{aligned}$$

Die übliche OLS-Varianz-Kovarianz-Matrix  $\sigma^2(X'X)^{-1}$  ist also für  $\Omega \neq I$  nicht mehr die korrekte Varianz-Kovarianz-Matrix der geschätzten Koeffizienten.

# Konsequenzen für OLS

Es gelte *MLR 5'* :  $\mathbb{E}(\mathbf{u}|X) = \sigma^2\Omega$  mit  $\Omega$  pds.

- ▶ man kann mit OLS die Parameter unverzerrt schätzen,
- ▶ aber OLS ist im Allgemeinen nicht mehr der BLUE (es gibt Schätzer mit geringerer Varianz),
- ▶ und die OLS - Kovarianzmatrix ist keine gute Schätzung der tatsächlichen Kovarianzmatrix, daher sind darauf basierende Standardfehler, t-Tests und F-Tests falsch.

**Fazit:** OLS liefert unverzerrte Parameter und falsche Standardfehler und Tests. Ob man also OLS anwenden sollte, hängt von der Anwendung ab (ist man an Tests interessiert oder nur an Parametern?)

# GLS: Generalized Least Squares



# GLS: Generalized Least Squares

Angenommen, die Matrix  $\Omega$  in  $\mathbb{E}(\mathbf{u}|\mathbf{X}) = \sigma^2\Omega$  wäre bekannt und positiv definit symmetrisch.

Dann existiert eine reguläre Matrix  $P$  mit:

$$P'P = \Omega^{-1} \text{ bzw. } P^{-1} (P^{-1})' = \Omega \text{ bzw. } P\Omega P' = I$$

Da  $P$  regulär ist, hat  $P$  vollen Rang. Ferner gilt  $n = rk(\Omega^{-1}) = rk(P'P) = rk(P)$ . Daher muss  $P$  der Ordnung  $n \times n$  sein.

Wir benutzen nun  $P$  um die Daten  $X$  und  $\mathbf{y}$  so zu transformieren, dass wir die bisherigen Techniken valide nutzen können!

# GLS: Generalized Least Squares

Lineare Transformation der Daten:

$$\tilde{\mathbf{y}} = P\mathbf{y}, \quad \tilde{X} = PX$$

Schätze das Modell

$$\tilde{\mathbf{y}} = \tilde{X}\boldsymbol{\beta} + \tilde{\mathbf{u}} \quad (\text{mit } \tilde{\mathbf{u}} = P\mathbf{u})$$

per OLS.

Beachte:  $\boldsymbol{\beta}$  wird nicht transformiert!

P : Wurzel von  $\Omega^{-1}$

$$\underline{P' \cdot P} = \underline{\Omega^{-1}}$$

$$\tilde{y} = P \cdot y, \quad \tilde{X} = P \cdot X$$

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

$$= ((PX)' PX)^{-1} (PX)' P y$$

$$= (X' \underline{P' P} X)^{-1} X' \underline{P' P} y$$

$$= (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} y \leftarrow \text{GLS-Schätzer}$$

MLR 5 für  $\tilde{u}$  ?  $\nabla (P \cdot U | X) = P \cdot \nabla (U | X) \cdot P'$

$$\begin{aligned} \text{MLR 5'} \\ &= P \cdot \sigma^2 \cdot \Omega \cdot P' = \sigma^2 \cdot \underline{P \cdot \Omega \cdot P'} \\ &= I \end{aligned}$$

$$\begin{aligned} \text{MLR 1: } \tilde{y} &= P \cdot y \\ &= P(X\beta + u) \\ &= PX\beta + Pu \\ &= \tilde{X}\beta + \tilde{u} \end{aligned}$$

$$\begin{aligned} E[\tilde{u} | X] &= E[P \cdot u | X] \\ &= P E[u | X] = 0 \\ &\quad \text{MLR 4} = 0 \end{aligned}$$

$$\begin{aligned} r_{\tilde{X}}^2(P \cdot X) &= \min \{ r_{\tilde{X}}^2(P), r_{\tilde{X}}^2(X) \} \\ &= \kappa + 1 \quad (\text{MLR 3}) \end{aligned}$$

$\tilde{x}$  erfüllt MLR 3

$\tilde{y}$  erfüllt MLR 1

$\tilde{u}$  erfüllt MLR 4, 5

$$\Rightarrow \tilde{\beta} = (\tilde{x}'\tilde{x})^{-1}\tilde{x}'\tilde{y} \quad \text{BLUE}$$

$$\begin{aligned} E[\tilde{\beta} | X] &= E[(\tilde{x}'\tilde{x})^{-1}\tilde{x}'\tilde{y} | X] \\ &= (\tilde{x}'\tilde{x})^{-1}\tilde{x}'E[\tilde{y} | X] \\ &= (\tilde{x}'\tilde{x})^{-1}\tilde{x}'E[\tilde{x}\beta + \tilde{u} | X] \\ &= \underbrace{(\tilde{x}'\tilde{x})^{-1}}_{= \beta} \underbrace{\tilde{x}'\tilde{x}}_{\checkmark} \beta + \underbrace{(\tilde{x}'\tilde{x})^{-1}\tilde{x}'E[\tilde{u} | X]}_{= 0} \end{aligned}$$

$$\begin{aligned} \hat{\beta} ( \tilde{\beta} | x ) &= \sigma^2 ( \tilde{x}' \tilde{x} )^{-1} \\ &= \sigma^2 ( (P_x)' P_x )^{-1} \\ &= \sigma^2 ( x' P' P x )^{-1} \\ &= \sigma^2 ( x' \Omega^{-1} x )^{-1} \end{aligned}$$

# GLS: Generalized Least Squares

Prüfe die klassischen Annahmen für das transformierte Modell:

## MLR 1:

Prämultiplikation von  $P$  ist eine lineare Transformation ✓

## MLR 3:

$$rk(\tilde{X}) = rk(PX) = \min\{rk(P), rk(X)\} = rk(X) = k + 1 \quad \checkmark$$

## MLR 4:

$$E[\tilde{\mathbf{u}}|\tilde{X}] = E[P\mathbf{u}|X] = PE[\mathbf{u}|X] = P\mathbf{0} \quad \checkmark$$

## MLR 5:

$$\mathbb{V}(\tilde{\mathbf{u}}|\tilde{X}) = \mathbb{V}(P\mathbf{u}|X) = P \mathbb{V}(\mathbf{u}|X)P' = \sigma^2 P\Omega P' = \sigma^2 I \quad \checkmark$$

Demnach ist der OLS-Schätzer für das transformierte Modell BLUE!

# GLS: Generalized Least Squares

Der OLS-Schätzer der Transformierten Daten  $\tilde{\beta}$  lautet demnach

$$\begin{aligned}\tilde{\beta} &= (\tilde{X}'\tilde{X})^{-1} \tilde{X}'\tilde{\mathbf{y}} \\ &= ((PX)'PX)^{-1} (PX)'P\mathbf{y} \\ &= (X'P'PX)^{-1} X'P'P\mathbf{y} \\ &= (X'\Omega^{-1}X)^{-1} X'\Omega^{-1}\mathbf{y}\end{aligned}$$

Wir nennen den **GLS-Schätzer**  $\tilde{\beta}$  auch **Aitken-Schätzer**.

## Die Varianz des Aitken-Schätzers $\tilde{\beta}$

Mit  $\tilde{\beta} = (X'\Omega^{-1}X)^{-1} X'\Omega^{-1}\mathbf{y}$  gilt:



## Die Varianz des Aitken-Schätzers $\tilde{\beta}$

Mit  $\tilde{\beta} = (X'\Omega^{-1}X)^{-1} X'\Omega^{-1}\mathbf{y}$  gilt:

$$\begin{aligned}\mathbb{V}(\tilde{\beta}|X) &= \mathbb{V}((X'\Omega^{-1}X)^{-1} X'\Omega^{-1}\mathbf{y}|X) \\ &= (X'\Omega^{-1}X)^{-1} X'\Omega^{-1} \mathbb{V}(\mathbf{u}|X) \left( (X'\Omega^{-1}X)^{-1} X'\Omega^{-1} \right)' \\ &= \sigma^2 (X'\Omega^{-1}X)^{-1} X'\Omega^{-1}\Omega\Omega^{-1}X (X'\Omega^{-1}X)^{-1} \\ &= \sigma^2 (X'\Omega^{-1}X)^{-1} \\ &= \sigma^2 (X'P'PX)^{-1} \\ &= \sigma^2 ((PX)'\ PX)^{-1} = \sigma^2 (\tilde{X}'\tilde{X})^{-1}\end{aligned}$$

# Das Gauss-Markov-Aitken Theorem

Unter den Annahmen *MLR* 1, 3, 4, 5' ist ein Schätzer innerhalb der Klasse der linearen und unverzerrten Schätzer varianzminimal (effizient), falls es sich um  $\tilde{\beta}$  handelt.

Die Struktur des Beweises ist die folgende:

- ▶ Definiere die Klasse der linearen Schätzer.
- ▶ Charakterisiere darin die Unterklasse der unverzerrten Schätzer.
- ▶ Zeige Effizienz von  $\tilde{\beta}$ .

## Beweis Gauss-Markov-Aitken („dann“)

Sei  $\check{\beta}$  ein Schätzer für  $\beta$ , welcher linear in  $\mathbf{y}$  ist, also

$$\check{\beta} = C\mathbf{y}$$

für eine geeignete Matrix  $C$ .

Der Erwartungswert von  $\check{\beta}$  beträgt

$$\begin{aligned} E[\check{\beta}|X] &= E[C\mathbf{y}|X] &&= CE[\mathbf{y}|X] \\ &= CE[X\beta + \mathbf{u}|X] &&= CX\beta + CE[\mathbf{u}|X] \\ &= CX\beta \end{aligned}$$

Erwartungstreue verlangt nun:

$$CX\beta = \beta \quad \forall \beta \in \mathbb{R}^{k+1}, \text{ also } CX = I$$

## Beweis Gauss-Markov-Aitken („dann“)

Ein linearer unverzerrter Schätzer  $\check{\beta} = C\mathbf{y}$  erfüllt also  $CX = I$ .

$$\begin{aligned}\text{Es gilt also: } \check{\beta} &= C\mathbf{y} &&= C(X\beta + \mathbf{u}) \\ & &&= CX\beta + C\mathbf{u} = \beta + C\mathbf{u}\end{aligned}$$

Die Varianz von  $\check{\beta}$  berechnet sich durch:

$$\mathbb{V}(\check{\beta}|\mathcal{X}) = \mathbb{V}(\beta + C\mathbf{u}|\mathcal{X}) = C \mathbb{V}(\mathbf{u}|\mathcal{X})C' = \sigma^2 C\Omega C'$$

Die Varianz von  $\tilde{\beta}$  ist gegeben durch:

$$\mathbb{V}(\tilde{\beta}|\mathcal{X}) = \sigma^2 (X'\Omega^{-1}X)^{-1}$$

## Beweis Gauss-Markov-Aitken („dann“)

Es bleibt nun zu Zeigen, dass

$$\mathbb{F}(\check{\beta}|X) = \sigma^2 C \Omega C' \geq \sigma^2 (X' \Omega^{-1} X)^{-1} = \mathbb{F}(\tilde{\beta}|X)$$

für alle  $C$  mit  $CX = I$  im Sinne der Loewner-Ordnung (s. Kap. 3)

Für die Argumentation benutzen wir folgende Eigenschaften:

- ▶  $CX = I$
- ▶  $\Omega = P^{-1} (P^{-1})'$  bzw.  $\Omega^{-1} = P'P$
- ▶ Falls für eine Matrix  $A$  das Produkt  $AA'$  definiert ist, so ist  $AA'$  psds. (Es gilt  $\mathbf{x}'AA'\mathbf{x} = (A'\mathbf{x})'A'\mathbf{x} = \|A'\mathbf{x}\|^2 \geq 0 \forall \mathbf{x}$ .)

## Begründung für: $\tilde{\beta}$ effizient

Definiere  $D := CP^{-1}$  und  $\tilde{X} := PX$ .

Es gilt dann:

- ▶  $D\tilde{X} = CP^{-1}PX = CX = I$
- ▶  $\sigma^2 DD' = \sigma^2 CP^{-1}(P^{-1})'C' = \sigma^2 C\Omega C' = \Sigma(\tilde{\beta}|X)$
- ▶  $\sigma^2(\tilde{X}'\tilde{X})^{-1} = \sigma^2(X'\Omega^{-1}X)^{-1} = \Sigma(\tilde{\beta}|X)$

## Begründung für: $\tilde{\beta}$ effizient

Schritt 1: Das Matrixprodukt

$$\left( D - (\tilde{X}'\tilde{X})^{-1} \tilde{X}' \right) \left( D - (\tilde{X}'\tilde{X})^{-1} \tilde{X}' \right)' \text{ ist psds.}$$

Schritt 2: Dieses Matrixprodukt lässt sich ausmultiplizieren zu:

$$\begin{aligned} DD' - D \left( (\tilde{X}'\tilde{X})^{-1} \tilde{X}' \right)' - (\tilde{X}'\tilde{X})^{-1} \tilde{X}' D' + (\tilde{X}'\tilde{X})^{-1} \tilde{X}' \tilde{X} (\tilde{X}'\tilde{X})^{-1} \\ = DD' - D \tilde{X} (\tilde{X}'\tilde{X})^{-1} - (\tilde{X}'\tilde{X})^{-1} (D \tilde{X})' + (\tilde{X}'\tilde{X})^{-1} \\ = DD' - (\tilde{X}'\tilde{X})^{-1} \\ = C \Omega C' - (X' \Omega^{-1} X)^{-1} \text{ psds} \end{aligned}$$

## Begründung für: $\tilde{\beta}$ effizient

Wir haben gezeigt:

Für eine gegebene Matrix  $C$  mit  $CX = I$  gilt

$$C\Omega C' - (X'\Omega^{-1}X) \text{ psds} \stackrel{\text{Loewner}}{:\Leftrightarrow} C\Omega C' \geq (X'\Omega^{-1}X)$$

Also gilt mit

$$\Sigma(\check{\beta}|X) = \sigma^2 C\Omega C'$$

und

$$\Sigma(\tilde{\beta}|X) = \sigma^2 (X'\Omega^{-1}X)^{-1},$$

dass die Varianz von  $\tilde{\beta}$  Loewner-kleiner ist als die Varianz von einem beliebigen linearen erwartungstreuen Schätzer  $\check{\beta}$ .  $\square$



## $t$ - und $F$ -Tests bei bekannten Parametern $\sigma^2$ und $\Omega$

Die Varianz des GLS-Schätzers beträgt

$$\text{Var}(\tilde{\beta}|X) = \sigma^2 (X' \Omega^{-1} X)^{-1}$$

Alle darauf basierenden Statistiken (Standardfehler,  $t$ -Test,  $F$ -Test) behalten ihre Gültigkeit.

## GLS: Schätzer für $\sigma^2$

Falls die Matrix  $\Omega$  bekannt ist, kann der Parameter  $\sigma^2$  analog zu OLS geschätzt werden.

GLS-Residuen:

$$\tilde{\mathbf{u}} = P\mathbf{y} - PX\tilde{\boldsymbol{\beta}} = P[\mathbf{I} - X(X'\Omega^{-1}X)^{-1}X'\Omega^{-1}]\mathbf{u}$$

Schätzer  $\tilde{\sigma}^2$  für  $\sigma^2$ :

$$\tilde{\sigma}^2 = \frac{1}{n - k - 1} \tilde{\mathbf{u}}' \tilde{\mathbf{u}}$$

# FGLS: Feasible Generalized Least Squares

## FGLS: Feasible Generalized Least Squares

- ▶ GLS ist nicht durchführbar (infeasible), weil  $\Omega$  bzw.  $P$ , mit der die Daten transformiert werden müssen, nicht bekannt ist.
- ▶ Um eine durchführbare (feasible) Variante zu erhalten, müssen zuerst die Elemente von  $\Omega$  geschätzt werden. Dies wird mit **feasible generalized least squares** (FGLS) bezeichnet.
- ▶ Nach Ausnutzung der Symmetrie von  $\Omega$  bleiben aber  $\frac{n(n+1)}{2}$  Elemente, die geschätzt werden müssten – das sind zu viele!
- ▶ Nehme an, dass Elemente von  $\Omega$  von einem Parameter-Vektor  $\alpha$  funktional abhängen und schätze  $\alpha$  durch  $\hat{\alpha}$ .
- ▶ Berechne nun  $\hat{\Omega} = \Omega(\hat{\alpha})$  und berechne  $\tilde{\beta}^{FGLS}$  mit  $\hat{\Omega}$ .

Beispiel Heteroskedastizität

$$\text{Var}(U_i | X) = \sigma^2 \cdot X_{i1}$$

$$\text{Cor}(U_i, U_j | X) = 0 \quad i \neq j$$

$$\sigma^2 \Omega = \begin{pmatrix} \sigma^2 \cdot X_{11} & 0 & & 0 \\ 0 & \sigma^2 X_{21} & & 0 \\ & 0 & 0 & \\ & & & \sigma^2 X_{n1} \end{pmatrix}$$

Beis piel Zeit reihen

$$U_t = \rho \cdot U_{t-1} + \varepsilon_t$$

nur noch ein Parameter  
in  $\Omega$  zu schätzen

$$\sigma^2 \Omega = \dots = \begin{pmatrix} \text{Var}(u_1) & \rho \cdot \text{Var}(u_1) & \dots \\ \rho \cdot \text{Var}(u_1) & ? & \\ & & \ddots \end{pmatrix}$$

## Eigenschaften der OLS-, GLS- und FGLS-Schätzer

- ▶ Der OLS-Schätzer ist auch unter MLR 5'  $\mathbb{E}(\mathbf{u}) = \mathbf{0}$  ( $\sigma^2\Omega$  (pds) erwartungstreu.
- ▶ Der OLS-Schätzer ist aber nicht mehr effizient.
- ▶ Der GLS-Schätzer ist BLUE (und damit effizient).
- ▶ Der GLS-Schätzer ist aber nicht feasible.
- ▶ Der FGLS-Schätzer basiert auf geschätzten Größen und ist daher nur asymptotisch effizienter als OLS.
- ▶ In kleinen Stichproben muss FGLS nicht zwangsläufig besser sein als OLS.
- ▶ Die Eigenschaften hängen davon ab, dass die korrekte Form  $\Omega(\alpha)$  unterstellt wird.