

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.

Eigenschaften positiv definiter Matrizen

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

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:

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

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 $P = Z^{-1}$.

Bevor wir das zentrale Resultat, das

Gauß-Markov-Aitken-Theorem

für allgemeine pds-Matrizen Ω besprechen, widmen wir uns zwei *Spezialfällen*:

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

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 Ω :

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

Zerlegung von Ω^{-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:

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

$$\begin{aligned} \Sigma(\mathbf{u}|X) &= \begin{pmatrix} \sigma^2 & \text{Cov}(u_1, u_2|X) & \dots & \text{Cov}(u_1, u_n|X) \\ \text{Cov}(u_2, u_1|X) & \sigma^2 & \dots & \text{Cov}(u_2, u_n|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n, u_1|X) & \text{Cov}(u_n, u_2) & \dots & \sigma^2 \end{pmatrix} \\ &= \sigma^2 \underbrace{\begin{pmatrix} 1 & \text{corr}(u_1, u_2|X) & \dots & \text{corr}(u_1, u_n|X) \\ \text{corr}(u_2, u_1|X) & 1 & \dots & \text{corr}(u_2, u_n|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{corr}(u_n, u_1|X) & \text{corr}(u_n, u_2|X) & \dots & 1 \end{pmatrix}}_{\Omega} \end{aligned}$$

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:

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

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

auf die OLS-Schätzer?

Wir schätzen den Parametervektor β zunächst mit OLS:

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'y && \text{(mit MLR 3)} \\ &= (X'X)^{-1}X'(X\beta + \mathbf{u}) && \text{(mit MLR 1)} \\ &= \beta + (X'X)^{-1}X'\mathbf{u}\end{aligned}$$

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

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

Der OLS-Schätzer ist also nach wie vor erwartungstreu!

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 Ω 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 Ω in $\Sigma(\mathbf{u}|X) = \sigma^2\Omega$ 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!

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 β , 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 $\check{\beta} = Cy$ erfüllt also $CX = I$.

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

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

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

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

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

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 σ^2 und Ω

Die Varianz des GLS-Schätzers beträgt

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

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

GLS: Schätzer für σ^2

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

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.