

8.1. Gegeben sei eine Stichprobe (y_1, y_2, y_3, \dots) und (x_1, x_2, x_3, \dots) . Zeigen Sie, dass die Varianz des GLS Schätzer $\tilde{\beta}_T$ eine monoton nicht wachsende Funktion der Stichprobengröße T ist, d.h. $\text{Var}(\tilde{\beta}_{T+1}) \leq \text{Var}(\tilde{\beta}_T)$. Hinweis: verwenden Sie das Gauss-Markov-Aitken Theorem.

8.2. Betrachten Sie ein einfaches Trendmodell $y_t = \alpha + \beta \cdot t + u_t$ mit AR(1) Fehlern $\mathbf{E}u_t u_s = \sigma^2 \rho^{|t-s|} / (1 - \rho^2)$. Berechnen Sie die relative Effizienz des OLS Schätzers $\hat{\beta}$ in Vergleich zum GLS Schätzer $\tilde{\beta}$: $\text{eff} := \text{Var}(\hat{\beta}) / \text{Var}(\tilde{\beta})$ für $T = 10$ und $\rho = -0.9, -0.8, \dots, 0.8, 0.9$. (Am einfachsten ist es, diese Effizienz numerisch zu berechnen. Es ist nicht nötig, dass Sie eine "analytische Formel" ableiten.)

8.3. Zeigen Sie, dass der OLS und der GLS Schätzer für das folgende inhomogene Modell übereinstimmen (equi-correlation):
$$y = \alpha + X\beta + u, \quad \mathbf{E}u = 0, \quad \text{Var}(u) = \sigma^2 \Omega$$

$$\Omega = (1 - \rho)I_T + \rho u u', \quad 0 \leq \rho \leq 1$$

8.4. Beweisen Sie Lemma 5.6. Es genügt, wenn Sie den Beweis für den Fall $k = 1$ (also für eine Folge von Zufallsvariablen) führen.

8.1

$$\mathbf{y}_{T+1} = \begin{pmatrix} y_1 \\ \vdots \\ y_T \\ y_{T+1} \end{pmatrix} = \beta \mathbf{x}_{T+1} + u_{T+1} \quad \text{Var } u_{T+1} = \sigma^2 \Omega_{T+1}$$

GMA-Theorem:

$$\tilde{\beta}_{T+1} = \begin{pmatrix} \mathbf{x}'_{T+1} & \Omega_{T+1}^{-1} \mathbf{x}'_{T+1} \end{pmatrix}^{-1} \mathbf{x}'_{T+1} \mathbf{y}_{T+1}$$

ist der BLUE im obigen Modell d.h.

$$\text{Var } \tilde{\beta}_{T+1} \leq \text{Var } \check{\beta}_{T+1} \quad \forall \check{\beta}_{T+1} \in \mathbb{R} \text{ mit } \check{\beta} = \mathbf{d} + \mathbf{D} \mathbf{y}_{T+1}$$

$$\text{sehr speziell f\"ur } \check{\beta} = \underbrace{\left((\mathbf{x}'_T \Omega_T^{-1} \mathbf{x}_T)^{-1} \mathbf{x}'_T, 0 \right)}_{\in \mathbb{R}^{1 \times T}} \underbrace{\begin{pmatrix} \mathbf{y}_T \\ \mathbf{y}_{T+1} \end{pmatrix}}_{\mathbf{y}_{T+1}} = \tilde{\beta}_T.$$

8.2

$$y_t = \alpha + \beta t + u_t$$

$$\mathbb{E}u_t u_s = \text{Cov } u_t u_s = \sigma^2 \frac{p^{|t-s|}}{(1-p)^2}$$

$$\Rightarrow \text{Var } u = \sigma^2 \frac{1}{1-p^2} \begin{pmatrix} 1 & p & p^2 & \cdots & p^{T-1} \\ p & 1 & p & & \vdots \\ \vdots & & \ddots & & \vdots \\ p^{T-1} & & & \ddots & p \\ & & & & 1 \end{pmatrix}$$

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

$$X = \begin{pmatrix} 1 & 1 \\ \vdots & 2 \\ 1 & 1 \end{pmatrix}$$

$$\text{Var}(\hat{\alpha}) = \sigma^2 (X' X)^{-1} X' \Omega X (X' X)^{-1}$$

$$(X' X)^{-1} X' y$$

$$\Rightarrow \text{eff} = \frac{\text{Var}(\hat{\beta})}{\text{Var}(\hat{\alpha})} = \frac{[(X' X)^{-1} X' \Omega X (X' X)^{-1}]}{[(X' \Omega^{-1} X)^{-1}]}_{22}$$

Maximize $\lambda_2 \lambda_3 \lambda_4$

```

interface(rtablesize=infinity):
with(LinearAlgebra):

X:=Transpose(Matrix(2,10,[seq(1,i=1..10),seq(t,t=1..10)]));
Omega:=rho->1/(1-rho^2)*ToeplitzMatrix([seq(rho^i,i=0..9)]);
symmetric);

Omega:=rho->LinearAlgebra-ToeplitzMatrix([seq(rho^i,i=0..9)],symmetric)
(1)

eff:=rho->((Transpose(X).X)^(-1).Transpose(X).Omega(rho).X.
(Transpose(X).X)^(-1))[2,2]/((Transpose(X).Omega(rho)^(-1).X)^
(-1))[2,2];
(2)

= rho->((1/LinearAlgebra-Transpose(X).X)LinearAlgebra-Transpose(X).Omega(p).X
(1/LinearAlgebra-Transpose(X).X))/_2,2
(3)

c:=Vector([seq(i/10,i=-9..9)]):
eff_c:=map(eff,c):
evalf(Matrix([c,eff_c]));
evalf(Matrix([c,eff_c]));

```

-0.9000000000	3.614197177
-0.8000000000	1.883037090
-0.7000000000	1.431728807
-0.6000000000	1.241970322
-0.5000000000	1.140228564
-0.4000000000	1.078756489
-0.3000000000	1.040143027
-0.2000000000	1.016542343
-0.1000000000	1.003902558
0.	1.
0.1000000000	1.003608253
0.2000000000	1.014041676
0.3000000000	1.030798167
0.4000000000	1.055144609
0.5000000000	1.079558224
0.6000000000	1.107040685
0.7000000000	1.130493695
0.8000000000	1.142597222
0.9000000000	1.134969941

$$8.3) \quad y = (\nu, X) \begin{pmatrix} \alpha \\ \beta \end{pmatrix} + u, \quad \mathbb{E}u=0, \quad \text{Var } u = \sigma^2 \Omega \quad \text{mit} \\ \Omega = (1-p) I_T + p \nu \nu' \quad (p \in [0,1])$$

OLS- u. GLS-Schätzter stimmen überein, falls $(\nu, X)^T \Omega = \Omega (\nu, X)^T$

$$(\nu, X)^T \Omega = \cancel{\Omega \nu} (1-p) (\nu, X)^T + p \underbrace{(\nu, X)^T \nu}_{\nu'} = (1-p) (\nu, X)^T + p \nu \nu'$$

$$\Omega (\nu, X)^T = (1-p) (\nu, X)^T + p \underbrace{\nu \nu^T (\nu, X)^T}_{[\Delta (\nu, X)^T]} = (1-p) (\nu, X)^T + p \nu \nu'$$

$$\nu [\Delta (\nu, X)^T] = \nu'$$

8.4

$$\Rightarrow x_n \xrightarrow{d} x_0 \text{ d.h. } \lim_{n \rightarrow \infty} P[|x_n - x_0| > \varepsilon] = 0 \quad \forall \varepsilon > 0.$$

Sei $x \in \mathbb{R}$.

$$\underbrace{[x_0 \leq x - \varepsilon] \setminus [x_0 \leq x - \varepsilon \wedge |x_n - x_0| > \varepsilon]}_{\downarrow} \subseteq [x_n \leq x] \subseteq [x_0 \leq x + \varepsilon] \cup [|x_n - x_0| > \varepsilon]$$

$$\Rightarrow F_0(x - \varepsilon) - P[|x_n - x_0| > \varepsilon] \leq P(\quad) \leq F_n(x) \leq F_0(x + \varepsilon) + P[|x_n - x_0| > \varepsilon]$$

$$\Rightarrow F_0(x - \varepsilon) \leq \liminf_n F_n(x) \leq F_0(x + \varepsilon) \quad \forall \varepsilon > 0$$

$$\Rightarrow F_0(x) = \lim_n F_n(x) \quad \text{falls } F_0 \text{ stetig in } x$$

$$\text{else } x_n \xrightarrow{d} x_0$$

$$\Leftrightarrow x_n \xrightarrow{d} x_0 \text{ d.h. } \lim_n F_n(x) = F_0(x) = \mathbb{1}_{[x_0, \infty)}(x) \quad \forall x \in S_{F_0} \\ (x_n \sim F_n, x_0 \sim F_0) \quad \text{d.h. } x \neq x_0.$$

$$\text{Bsp: } P[|x_n - x_0| > \varepsilon] = P[x_n > x_0 + \varepsilon] + P[x_n < x_0 - \varepsilon]$$

$$[|x_n - x_0| > \varepsilon] = [x_n > x_0 + \varepsilon] \cup [x_n < x_0 - \varepsilon]$$

$$= 1 - F_n(x_0 + \varepsilon) + \underbrace{F_n(x_0 - \varepsilon)}_{\text{1}}$$

$$\leq F_n(x_0 - \varepsilon)$$

$$\Rightarrow \lim_n P[|x_n - x_0| > \varepsilon] \leq 1 - \underbrace{F_0(x_0 + \varepsilon)}_1 + \underbrace{F_0(x_0 - \varepsilon)}_0 = 0. \quad \forall \varepsilon > 0.$$