

Základy ekonometrie

VI. Uvolnění klasických předpokladů – autokorelace náhodných složek

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 GLS estimátor
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

- Předpoklad: chyby regrese pro různá pozorování vzájemně nekorelovaná.
- Rozumné pro průřezová data.
- Časové řady: korelace sousedních pozorování.
- Příklad: vývoj makroekonomických agregátů.
- Korelace mezi pozorováními \rightarrow korelaci mezi různými náhodnými členy.

- Značení: $t = 1, \dots, T$.
- Pro časové řady i lepší metody a modely než LRM.
- Pro naše potřeby:

$$Y_t = \alpha + \beta_1 X_{1t} + \dots + \beta_k X_{kt} + \epsilon_t.$$

- Splněny všechny klasické předpoklady, jen $\text{cov}(\epsilon_t, \epsilon_{t-s}) \neq 0$ pro některá $s \neq 0$.

- Při splnění všech klasických předpokladů → Gaussův-Markovův teorém říká, že OLS je BLUE.
- Při nesplnění předpokladu o nekorelovanosti: OLS estimátor není BLUE.
- OLS nestranný, ale ne nejlepší.
- Využití GLS estimátoru → vhodná transformace (a OLS).

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 GLS estimátor
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

AR(1) proces

- Náhodné chyby: *autoregresní proces řádu 1 (AR(1))*:

$$\epsilon_t = \rho\epsilon_{t-1} + u_t.$$

- u_t : $E(u_t) = 0$, $\text{var}(u_t) = \sigma_u^2$ a $\text{cov}(u_t, u_{t-s}) = 0$ (pro $s \neq 0$).
- Předpokládáme $-1 < \rho < 1 \rightarrow$ *stacionarita*.
- Obecný $AR(p)$ procesu náhodných chyb:

$$\epsilon_t = \rho_1\epsilon_{t-1} + \rho_2\epsilon_{t-2} + \dots + \rho_p\epsilon_{t-p} + u_t.$$

Vlastnosti ϵ_t – střední hodnota

- Klasické předpoklady pro ϵ_t .
- $AR(1)$ model pro všechny časové okamžiky (od $-\infty$ do ∞).
- Pozorujeme $t = 1, \dots, T$ a platí $\epsilon_{t-s} = \rho\epsilon_{t-s-1} + u_{t-s}$ pro jakékoli t a s .
- Postupné substituce \rightarrow jen u_t, u_{t-1}, \dots

$$\epsilon_t = \sum_{i=0}^{\infty} \rho^i u_{t-i}.$$

- Chyby regrese mají nulovou střední hodnotu:

$$E(\epsilon_t) = E\left(\sum_{i=0}^{\infty} \rho^i u_{t-i}\right) = 0.$$

Vlastnosti ϵ_t – rozptyl

- Využijeme pro c menší než 1 v absolutní hodnotě:

$$\sum_{i=0}^{\infty} c^i = \frac{1}{1-c}.$$

- Vlastnosti operátoru rozptylu a u_t splňuje klasické předpoklady:

$$\begin{aligned} \text{var}(\epsilon_t) &= \text{var}\left(\sum_{i=0}^{\infty} \rho^i u_{t-i}\right) \\ &= \sum_{i=0}^{\infty} \rho^{2i} \text{var}(u_{t-i}) = \sigma_u^2 \sum_{i=0}^{\infty} \rho^{2i} \\ &= \frac{\sigma_u^2}{1-\rho^2}, \end{aligned}$$

- Autokorelované náhodné chyby jsou homoskedastické.

Vlastnosti ϵ_t – kovariance

- S využitím definice operátoru kovariance a $E(\epsilon_t) = 0$:

$$\begin{aligned} \text{cov}(\epsilon_t, \epsilon_{t-s}) &= E(\epsilon_t \epsilon_{t-s}) - E(\epsilon_t)E(\epsilon_{t-s}) = E(\epsilon_t \epsilon_{t-s}) \\ &= E \left[\left(\sum_{i=0}^{\infty} \rho^i u_{t-i} \right) \left(\sum_{i=0}^{\infty} \rho^i u_{t-s-i} \right) \right]. \end{aligned}$$

- $\text{cov}(u_t, u_{t-s}) = E(u_t u_{t-s}) = 0$ (pro $s \neq 0$) \rightarrow eliminace většiny členů:

$$\begin{aligned} \text{cov}(\epsilon_t, \epsilon_{t-s}) &= E(\rho^s u_{t-s}^2 + \rho^{s+2} u_{t-s-1}^2 + \dots) \\ &= E \left(\sum_{i=0}^{\infty} \rho^{s+2i} u_{t-s-i}^2 \right) = \sum_{i=0}^{\infty} \rho^{s+2i} E(u_{t-s-i}^2) \\ &= \sigma_u^2 \sum_{i=0}^{\infty} \rho^{s+2i} = \sigma_u^2 \rho^s \sum_{i=0}^{\infty} \rho^{2i} \\ &= \frac{\sigma_u^2 \rho^s}{1 - \rho^2} = \rho^s \text{var}(\epsilon_t). \end{aligned}$$

Příklad

- Gujarati a Porter (2009) – příklad 12.5.
- Datový soubor Table_12.4 na záložce Gujarati.
- Level-level i log-log specifikace.
- Vztah mezi mzdami a produktivitou v sektoru obchodu v USA (1960–2005), datový soubor obsahuje data období 1959-1998 .
- Y – reálná kompenzace za hodinu (index).
- X – výstup za hodinu (index).

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 **GLS estimátor**
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

Transformace modelu

- „Kvazi diferencování“.

$$Y_t = \alpha + \beta_1 X_{1t} + \dots + \beta_k X_{kt} + \epsilon_t.$$

- Platí v každém časovém okamžiku \rightarrow čas $t - 1$ a násobení parametrem ρ :

$$\rho Y_{t-1} = \rho\alpha + \rho\beta_1 X_{1t-1} + \dots + \rho\beta_k X_{kt-1} + \rho\epsilon_{t-1}.$$

- Odečtení od původní regrese:

$$Y_t - \rho Y_{t-1} = \alpha - \rho\alpha + \beta_1 (X_{1t} - \rho X_{1t-1}) + \dots + \beta_k (X_{kt} - \rho X_{kt-1}) + \epsilon_t - \rho\epsilon_{t-1}$$

- Nové značení:

$$Y_t^* = \alpha^* + \beta_1 X_{1t}^* + \dots + \beta_k X_{kt}^* + u_t.$$

- u_t splňuje klasické předpoklady \rightarrow metoda OLS je BLUE (GLS estimátor pro model s $AR(1)$ náhodnými složkami).

Problém

- GLS estimátor zahrnuje regresi Y^* na X_1^*, \dots, X_k^* , kdy proměnné „kvazi-diferencované“:

$$Y_t^* = Y_t - \rho Y_{t-1},$$

$$X_{1t}^* = X_{1t} - \rho X_{1t-1},$$

atd.

- Problém: data od $t = 1, \dots, T \Rightarrow Y_1^* = Y_1 - \rho Y_0$ zahrnuje Y_0 (totéž pro vysvětlující proměnné).
- Nejsme schopni pozorovat *počáteční podmínku* jako je Y_0 .
- Řešení: data od $t = 2, \dots, T$ (data pro $t = 1$ jako počáteční podmínky) \rightarrow ztráta pozorování.
- Mnohem sofistikovanější metody jako je odhad metodou maximální věrohodnosti.

Praisova-Winstenova transformace

- Model: $Y_t = \beta_1 + \beta_2 X_t + \epsilon_t$.
- Náhodné $AR(1)$ složky: $\epsilon_t = \rho\epsilon_{t-1} + u_t$.
- Kvazi-diferencování:

$$(Y_t - \rho Y_{t-1}) = \beta_1(1 - \rho) + \beta_2(X_t - \rho X_{t-1}) + \epsilon_t - \rho\epsilon_{t-1}.$$

- Ztráta jednoho pozorování.
- Vyhnutí se ztráty = transformace prvních pozorování:

$$Y_1 \sqrt{1 - \rho^2} \quad X_1 \sqrt{1 - \rho^2}.$$

- Pokud necháme první pozorování netransformované \rightarrow problém s homoskedasticitou!

Metoda prvních diferencí

- Pokud je ρ blízké jedné: silná pozitivní autokorelace (> 0.8).
- Model již bez autokorelace: $\Delta Y_t = \beta_2 \Delta X_t + u_t$.
- Co když do regrese dáme úroňovou konstantu?

$$\Delta Y_t = \beta_1 + \beta_2 \Delta X_t + u_t.$$

- Možnost testování trendu v původní časové řadě.
- První diference i pro stacionarizaci časových řad.

$$\epsilon_t = \epsilon_{t-1} + u_t \rightarrow \epsilon_t - \epsilon_{t-1} = \Delta \epsilon_t = u_t).$$

- Berenbluttův-Webbův test: $H_0 : \rho = 1 \rightarrow g$ statistika

$$g = \frac{\sum_{t=2}^N \hat{u}_t^2}{\sum_{t=1}^N \hat{\epsilon}_t^2}.$$

- Tabulky DW testu \times nulová hypotéze $\rho = 1$ (ne $\rho = 0$).

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 GLS estimátor**
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

Motivace

- Pokud známe $\rho \rightarrow$ transformace.
- Jinak odhad, $\hat{\rho}$.
- Využití OLS metody (nestranné odhady) + získání reziduí k odhadu parametru ρ .

$$\epsilon_t = \rho\epsilon_{t-1} + u_t.$$

- Další zobecnění pro $AR(p)$ procesy: odhady koeficientů $\rho_1, \dots, \rho_p +$ vynechání p pozorování (počáteční podmínky).
- Použití $\hat{\rho} \rightarrow$ feasible GLS (FGLS) resp. estimated GLS (EGLS).
- Dobré u velkých vzorků, u malých vzorků potřeba opatrnosti při interpretaci (plus ponechání prvních pozorování – á la Praisova-Winstonova transformace = tzv. full EGLS resp FEGLS).

Postup

- 1 Regrese Y_t na úrovnovou konstantu, X_1, \dots, X_k s využitím OLS a získání reziduí, $\hat{\epsilon}_t$.
- 2 Regrese $\hat{\epsilon}_t$ na $\hat{\epsilon}_{t-1}$ využitím OLS \rightarrow získání $\hat{\rho}$.
- 3 Kvazi-diferencování všech proměnných:

$$Y_t^* = Y_t - \hat{\rho}Y_{t-1},$$
$$X_{1t}^* = X_{1t} - \hat{\rho}X_{1t-1},$$

atd.

- 4 Regrese Y_t^* na úrovnovou konstantu, X_1^*, \dots, X_k^* metodou OLS \rightarrow GLS odhady koeficientů.

Iterační varianta

- 1 Regrese Y_t na úrovnovou konstantu, X_1, \dots, X_k pomocí OLS a získání reziduí, $\hat{\epsilon}_t$.
- 2 Regrese $\hat{\epsilon}_t$ na $\hat{\epsilon}_{t-1}$ využitím OLS a získání $\hat{\rho}$.
- 3 Kvazi-diferencování všech proměnných k získání:

$$Y_t^* = Y_t - \hat{\rho}Y_{t-1},$$

$$X_{1t}^* = X_{1t} - \hat{\rho}X_{1t-1},$$

atd.

- 4 Regrese Y_t^* na úrovnovou konstantu, X_1^*, \dots, X_k^* metodou OLS a získání GLS odhadů koeficientů $\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_k$.
- 5 Vytvoření nových reziduí použitím GLS odhadu z kroku 4,

$$\hat{\epsilon}_t = Y_t - \hat{\alpha} - \hat{\beta}_1 X_{1t} - \dots - \hat{\beta}_k X_{kt}.$$
- 6 Návrat ke kroku 2 opakování postupu stále dokola dokud se odhad, $\hat{\rho}$ nepřestane měnit (s danou tolerancí).

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 **GLS estimátor**
 - Cochranova-Orcuttova procedura
 - **HAC estimátor**
- 3 Testování autokorelace
- 4 Doporučení pro praxi

Motivace

- Podobně jako u heteroskedasticity (HCE).
- Korektní vztah pro $\text{var}(\hat{\beta})$ = korektní použití OLS metody.
- Druhé nejlepší řešení.
- Obvykle tzv. *heteroskedasticitě a autokorelaci konzistentními estimátory (HAC)*, např. *Neweyho-Westův estimátor*.
- Problém malých vzorků!

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 GLS estimátor
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

Motivace

- Pokud je $\rho = 0 \rightarrow$ korektní OLS metoda.
- Test nulové hypotézy: $H_0 : \rho = 0$ oproti alternativní hypotéze $H_1 \neq 0$.
- Řada testů (i obecnější než jen $AR(1)$).
- Proč tolik testů? \rightarrow jako u heteroskedasticity není prokázáno, který je nejlepší.
- Jednoduchý test – vykreslení (standardizovaných) reziduí.

Testy věrohodnostního poměru

- $H_0 : \rho = 0$ oproti alternativě $H_1 : \rho \neq 0$.
- Potřeba maximálně věrohodného odhadu jak omezeného, tak i neomezeného modelu.
- Software udělá práci za nás – nelineární optimalizace.
- Z důvodu potřeby odhadu obou modelů není preferován.

Breuschův-Godfreyho test

- Test Lagrangeových multiplikátorů (odhad pouze omezeného modelu).
- Omezený model = model vícenásobné regrese splňující klasické předpoklady.
- Pro obecný případ $AR(p)$ procesu:

$$\epsilon_t = \rho_1\epsilon_{t-1} + \rho_2\epsilon_{t-2} + \dots + \rho_p\epsilon_{t-p} + u_t.$$

- Test sdružené hypotézy $H_0 : \rho_1 = 0, \rho_2 = 0, \dots, \rho_p = 0$:
 - 1 Regrese Y_t na úroňovou konstantu a X_1, \dots, X_k použitím OLS a získání reziduí, $\hat{\epsilon}_t$.
 - 2 Regrese $\hat{\epsilon}_t$ na úroňovou konstantu a $X_1, \dots, X_k, \hat{\epsilon}_{t-1}, \dots, \hat{\epsilon}_{t-p}$ metodou OLS a získání koeficientu determinace, R^2 .
 - 3 Spočítání testové statistiky $LM = TR^2$
- Při platnosti nulové hypotézy, H_0 , má LM statistika (aproximativně) $\chi^2(p)$ rozdělení.

Boxův-Pierceův test

- Myšlenka: pokud nejsou náhodné složky autokorelovány, potom by korelace mezi různými náhodnými složkami měla být nulová.
- Odhady v podobě reziduí, $\hat{\epsilon}_t$, pro $t = 1, \dots, T$, na základě OLS regrese Y na úrovněovou konstantu a X_1, \dots, X_k .
- Odhad korelace mezi ϵ_t a ϵ_{t-s} :

$$r_s = \frac{\sum_{t=s+1}^T \hat{\epsilon}_t \hat{\epsilon}_{t-s}}{\sum_{t=s+1}^T \hat{\epsilon}_t^2}.$$

- *Boxova-Pierceova testová statistika (Q-statistika):*

$$Q = T \sum_{j=1}^p r_j^2,$$

- Výběr p označuje test existence $AR(p)$.

Ljungův test

- Stejný postup jako Boxův-Pierceův test.
- *Ljungova testová statistika (Ljungovo Q)*:

$$Q^* = T(T + 2) \sum_{j=1}^p \frac{r_j^2}{T - j}.$$

- Obě statistiky mají (aproximativně) $\chi^2(p)$ (při platnosti $H_0 : \rho_1 = 0, \rho_2 = 0, \dots, \rho_p = 0$).
- Úskalí: mezi regresory zpožděná vysvětlovaná proměnná \Rightarrow oba testy nejsou vhodné.

Durbinův-Watsonův test

- Pro $AR(1)$ proces.
- OLS regrese vysvětlované veličin, Y , na úrovnovou konstantu a vysvětlující proměnné, $X_1, \dots, X_k \rightarrow$ OLS rezidua, $\hat{\epsilon}_t$.

- Testová statistika:

$$DW = \frac{\sum_{t=2}^T (\hat{\epsilon}_t - \hat{\epsilon}_{t-1})^2}{\sum_{t=1}^T \hat{\epsilon}_t^2}.$$

- Platí: $0 \leq DW \leq 4$.
- DW aproximativně rovna $2(1 - \hat{\rho}) \iff \hat{\rho} = 1 - DW/2$.
- Nestandardní rozdělení (hodnoty tabelovány); z programů i p -hodnoty (H_0 : nekorelovanost).

Vyhodnocení DW testu

- Z tabulek hodnoty dolní meze (d_L) a horní meze (d_U).
- Závisí na počtu pozorování, T , a počtu vysvětlujících proměnných, k .

Hodnota testu	Vyhodnocení
$4 - d_L < DW < 4$	Zamítáme H_0 ; závěr $\rho < 0$
$4 - d_U < DW < 4 - d_L$	Výsledek neurčitý
$2 < DW < 4 - d_U$	Nezamítáme H_0 ; závěr $\rho = 0$
$d_U < DW < 2$	Nezamítáme H_0 ; závěr $\rho = 0$
$d_L < DW < d_U$	Výsledek neurčitý
$0 < DW < d_L$	Zamítáme H_0 ; závěr $\rho > 0$

- Není zaručeno jednoznačné zamítnutí $H_0 : \rho = 0$.
- Nevhodný v případě zpožděné závisle proměnné jako vysvětlující proměnné a při náhodných regresorech (i pro velké vzorky).

Durbinova h -statistika

- Pro případ, kdy jedna z vysvětlujících proměnných je zpožděná vysvětlovaná proměnná:

$$Y_t = \alpha + \beta Y_{t-1} + \gamma X_t + \epsilon_t.$$

- Postup:

- 1 Provedení OLS regrese Y na úrovnovou konstantu, zpožděnou závisle proměnnou a X (případně další vysvětlující proměnné v regresi).
- 2 Získání DW statistiky a rozptylu odhadu parametru β (tj. $\text{var}(\hat{\beta})$).
- 3 Výpočet testové statistiky (*Durbinovo h*):

$$h = \left(1 - \frac{DW}{2}\right) \sqrt{\frac{T}{1 - T\text{var}(\hat{\beta})}}.$$

- 4 Platí: $h \sim N(0, 1)$.
- Test nebude fungovat pro $T\text{var}(\hat{\beta}) > 1$.

Obsah tématu

- 1 Vlastnosti autokorelovaných náhodných složek
- 2 GLS estimátor
 - Cochranova-Orcuttova procedura
 - HAC estimátor
- 3 Testování autokorelace
- 4 Doporučení pro praxi

Praktická doporučení

- Jestliže testy indikují přítomnost autokorelace: zkusit model transformovat či jinak specifikovat.
- Hrubé pravidlo: práce s prvními diferencemi pokud $DW < R^2$.
- Možné použití Cochranovy-Orcuttovy procedury (případ $AR(1)$ náhodných složek) × část ekonometrů proti tomuto postupu (zavádějící výsledky pokud jiný než $AR(1)$ proces).
- Lze zobecnit i pro $AR(p)$ procesy.
- Po každé transformaci vhodné testovat vyřešení problému.
- Pokud nedokážeme nalézt transformaci → raději HAC estimátor.

Problém malých vzorků

- FGLS a HAC oproti OLS efektivní \times vlastnosti u malých vzorků málo zdokumentované.
- Malé vzorky: studie (Monte Carlo simulace) $\rightarrow \rho < 0.3 \Rightarrow$ raději OLS.
- Co je velké? \rightarrow relativní \rightarrow 15 pozorování asi ne \times 50+ už rozumně velké.

Další otázky a metody

- Durbinova dvou kroková procedura.
 - 1 $Y_t = \beta_1(1 - \rho) + \beta_2 X_t - \beta_2 \rho X_{t-1} + \rho Y_{t-1} + u_t$.
 - 2 Odhad $\hat{\rho}$ (u Y_{t-1}) \rightarrow standardní transformace původního modelu a odhad parametrů.
- Theilův-Nagarův odhad ρ založený na DW statistice (pro malé vzorky):

$$\hat{\rho} = \frac{N^2(1 - DW/2) + k^2}{N^2 - k^2}.$$

- Hildrethova-Luova procedura skenování resp. hledání (odhad ρ pro $AR(1)$ metodou hledání pro $\rho \in (-1, 1)$).
- Rozlišení čisté autokorelace a chybné specifikace!

Shrnutí přednášky na závěr

