

Ekonometrinė panelinių duomenų analizė

Vaidotas Zemlys

Matematikos ir Informatikos Fakultetas, Ekonometrinės analizės katedra
Vaidotas.Zemlys@maf.vu.lt

2005 m. balandžio 5 d.

Individualieji efektai

- Mazodier ir Trognon (1978) apibendrina AE modelį, heteroskedastiškų individualių efektų atveju $\mu_i \sim \text{IID}(0, w_i^2)$, su homoskedastinėmis paklaidomis $\nu_{it} \sim \text{IID}(0, \sigma_\nu^2)$. Šiuo atveju atitinkamas kovariacijų matricos išskaidymas yra

$$\Omega = \text{diag}[Tw_i^2 + \sigma_\nu^2] \otimes \bar{J}_T + \text{diag}[\sigma_\nu^2] \otimes E_T$$

- Norint rasti GLS įverčius reikia įvertinti nežinomas dispersijas: σ_ν^2 ir w_i^2 , $i = 1, \dots, N$. Taigi reikia, kad $T \gg N$.
- σ_ν^2 galima įvertinti, kaip ir homoskedastiniu atveju, w_i^2 įverčius galima gauti naudojantis tuo, kad $\text{var}(u_{it}) = w_i^2 + \sigma_\nu^2$

Paklaidų heteroskedastiškumas

- Analogiškai galima nagrinėti atvejį, kai paklaidos yra heteroskedastiškos paklaidos $\nu_{it} \sim \text{IID}(0, w_i^2)$, o individualieji efektai homoskedastiniai – $\mu_i \sim \text{IID}(0, \sigma_\mu^2)$. Tada kovariacijų matricos išskaidymas yra

$$\Omega = \text{diag}[\sigma_\mu^2] \otimes \bar{J}_T + \text{diag}[w_i^2] \otimes E_T$$

- Randolph (1988) nagrinėjo bendresnius AE modelius, kai tiek paklaidos tiek individualūs efektai yra heteroskedastiški.

AR(1) paklaidų modelis

- Klasikiniam AE modelyje laike koreliuoja tik to pačio individo stebėjimai, ir ši koreliacija yra pastovi visiems laiko tarpams.
- Lillard ir Willis (1978) apibendrina AE modelį ($\mu_i \sim \text{IID}(0, \sigma_\mu^2)$) serijinės koreliacijos atvejui, tardami, kad ν_{it} yra AR(1) laiko eilutė:

$$\nu_{it} = \rho \nu_{i,t-1} + \epsilon_{it},$$

čia $|\rho| < 1$ ir $\epsilon_{it} \sim \text{IID}(0, \sigma_\epsilon^2)$. Individualūs efektai $\mu_i \sim \text{IID}(0, \sigma_\mu^2)$ nepriklauso nuo ν_{it} , ir $\nu_{i0} \sim \text{IID}(0, \sigma_\epsilon^2 / (1 - \rho^2))$

Koeficientų vertinimas AR(1) atveju

- Naudodami Prais-Wainsten transformaciją C pakeičiame AR(1) paklaidas į paklaidas be serijinės koreliacijos. Šią transformaciją reikia pritaikyti N individams. Modelio paklaidos tada yra

$$u^* = (I_N \otimes C v_T)\mu + (I_N \otimes C)\nu$$

- Šių paklaidų kovariacijų matricai Ω^* egzistuoja atitinkamas išskaidymas, kurio pagalba lengvai galime rasti $\Omega^{*-1/2}$. Turėdami $\Omega^{*-1/2}$ galime gauti GLS įverčius.
- AR(1) atveju matrica $\Omega^{*-1/2}$ priklausys nuo σ_μ^2 , σ_ϵ^2 ir ρ , taigi norint gauti GLS įverčius reikia gauti šių dydžių įverčius.

Kiti laiko eilučių paklaidų modeliai

- Tegu $\exists C$ tokia, kad $\text{var}((I_N \otimes C)\nu) = \sigma^2 I_N T$. Modelį $y_{it} = X'_{it}\beta + \mu_i + \nu_{it}$ transformuokime tokia dviejų žingsnių transformacija:

- 1 $y_i^* = Cy_i$, $y_i' = (y_{i1}, \dots, y_{iT})$. (Eliminuojama serijinė koreliacija).

- 2

$$y_{it}^{**} = y_{it}^* - \theta_\alpha \alpha_t \left(\sum_{i=1}^T \alpha_s y_{is}^* \right) / \left(\sum_{i=1}^T \alpha_s^2 \right),$$

čia $Cv_T = (\alpha_1, \dots, \alpha_T)$, $\theta_\alpha = 1 - (\sigma/\sigma_\alpha)$ ir
 $\sigma_\alpha^2 = \sigma_\mu^2 (\sum_{i=1}^T \alpha_T) + \sigma$.

OLS įverčiai taip transformuotam modeliui duos GLS įverčius pradiniam modeliui.

- Šis metodas pritaikomas AR(2), MA(1) paklaidų modeliams. Baltagi ir Li (1994) apibendrina atvejui MA(q), Galbraith ir Zinde-Walsh (1995) atvejui ARMA(p,q).

Testas serijinei koreliacijai ir individualiems efektams nustatyti

- Baltagi ir Li (1995) LM testas jungtinei hipotezei
 $H_0 : \sigma_\mu^2 = 0, \rho = 0$ tikrinti:

$$LM = \frac{NT^2}{2(T-1)(T-2)} [A^2 - 4AB + 2TB^2],$$

čia $A = [\hat{u}'(I_N \otimes J_T)\hat{u}/(\hat{u}'\hat{u})] - 1$, $B = \hat{u}'\hat{u}_{-1}/\hat{u}'\hat{u}$. Dideliems N šios statistikos pasiskirstymas yra χ_2^2 , jei teisinga nulinė hipotezė.

- Hipotezei $H_0 : \sigma_\mu^2 = 0, \lambda = 0$ tikrinti tinka ta pati statistika.
- Naudojant A ir B galime tikrinti hipotezes $H_0 : \sigma_\mu^2 = 0$ ir $H_0 : \rho = 0$ (arba $\lambda = 0$).

Testas serijinei koreliacijai, AE ir FE modeliuose

- Baltagi ir Li (1995) išvedė testą hipotezei $H_0 : \rho = 0$ (kai $\sigma_\mu^2 > 0$) tikrinti. Kadangi tariama, kad yra AE modelis, reikia naudoti GLS įverčius ir LM statistika pasidaro sudėtinga.
- Testas hipotezei $H_0 : \rho = 0$, kai μ_i – fiksuoti:

$$LM = \sqrt{NT^2/(T-1)(\tilde{v}'\tilde{v}_{-1}/\tilde{v}'\tilde{v})}$$

čia \tilde{v} – vidinės regresijos liekanos ir statistika dideliems T pasiskirsčius kaip $N(0, 1)$.

- Abiem atvejais statistika ta pati, nepriklausomai nuo to, kokį serijinės koreliacijos modelį testuosime, ar $AR(1)$ ar $MA(1)$.

Durbin-Watson statistika FE modeliui

- Bhargava, Franzini ir Narendranathan (1982) pasiūlė testą hipotezei $H_0 : \rho = 0$ su alternatyva $|\rho| < 1$:

$$d_\rho = \frac{\sum_{i=1}^N \sum_{t=2}^T (\tilde{v}_{it} - \tilde{v}_{i,t-1})^2}{\sum_{i=1}^N \sum_{t=1}^T (\tilde{v}_{it}^2)}$$

ir parodė, kad jis yra lokaliai galingiausias invariantiškas testas $\rho = 0$ aplinkoje, nepriklausomai nuo pasirinktų regresorių.

- Tie patys autoriai pasiūlė lokaliai galingiausių testą $\rho = 1$ aplinkoje, bei testą hipotezei $H_0 : \rho = 1$ tikrinti. Autoriai parodė, kad dideliems N visi šie trys testai nagrinėjami esant nulinei atsitiktinio klaidžiojamo hipotezei sutampa.

Testai serijinės koreliacijos pobūdžiui nustatyti

- Baltagi ir Li (1995) pasiūlė du apibendrinimus Burke, Godfrey ir Termayne (1990) testui atskirti $AR(1)$ nuo $MA(1)$ proceso.
- Esant nulinei $AR(1)$ hipotezei $\text{corr}(v_{it}, v_{i,t-\tau}) = \rho_\tau = \rho_1^\tau$. Taigi $AR(1)$ procesui $\rho_2 - (\rho_1)^2 = 0$. $MA(1)$ procesui $\rho_2 = 0$ ir $\rho_2 - (\rho_1)^2 < 0$.
- ρ_s , $s = 1, 2$ iverčius galime gauti kiekvienam individui naudojant vidinės regresijos liekanas:

$$(\tilde{\rho}_s)_i = \sum_{t=2}^T \tilde{u}_{it} \tilde{u}_{i,t-s} / \sum_{t=2}^T \tilde{u}_{it}^2.$$

Taikant tokius iverčius gauname $O(1/T)$ poslinkį, todėl šia idėja besiremianti statistika netiks tradiciniams panelinių duomenų modeliams, kuriems T mažas, o N - didelis.

Kitas testas

- Nulinė hipotezė $H_0 : \nu_{it} = \epsilon_{it} + \lambda\epsilon_{i,t-1}$
- Tegū $Q_s = \sum \sum u_{it} u_{i,t-s} / N(T-s)$. Kai $N \rightarrow \infty$
 - ① MA(1) modeliui

$$\text{plim } Q_0 = \sigma_\mu^2 + \sigma_\epsilon^2(1 + \lambda^2)$$

$$\text{plim } Q_1 = \sigma_\mu^2 + \lambda\sigma_\epsilon^2$$

$$\text{plim } Q_s = \sigma_\mu^2, \text{ kai } s \geq 2.$$

- ② AR(1) modeliui

$$\text{plim } Q_0 = \sigma_\mu^2 + \sigma_\nu^2$$

$$\text{plim } Q_1 = \sigma_\mu^2 + \rho^s \sigma_\nu^2, \text{ kai } s \geq 1.$$

Dideliems N , $\sqrt{N/V}(Q_2 - Q_3)$ turi normalų pasiskirstymą, čia V – tam tikras normuojantis dydis.

SUR su paklaidų komponentų modeliu

- Avery (1977) nagrinėjo M lygčių $y_j = Z_j\delta_j + u_j$ modelį su paklaidomis $u_j = Z_\mu\mu_j + \nu_j$. Lygčių tarpusavio priklausomybė išreiškiama taip:

$$E \begin{pmatrix} \mu_j \\ \nu_j \end{pmatrix} (\mu'_j, \nu'_j) = \begin{bmatrix} \sigma_{\mu_{jl}}^2 I_N & 0 \\ 0 & \sigma_{\nu_{jl}}^2 I_{NT} \end{bmatrix}$$

- Visų M lygčių kovariacijų matrica tada yra

$$\Omega = E(uu') = \Sigma_\mu \otimes (I_N \otimes J_T) + \Sigma_\nu \otimes (I_N \otimes I_T)$$

- Toliau vertiname panašiai kaip ir vienos regresijos atveju. Jei visoms lygtims regresorių matrica vienoda, tai visos sistemos įvertis nesutampa su atskirų lygčių iverčiais kaip modeliui be paklaidos komponentų.