

Ekonometrinė panelinių duomenų analizė

Vaidotas Zemlys

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

2005 m. kovo 15 d.

- Duomenys apie objektus (namų ūkius, firmas, šalis) surinkti keliems laiko periodams.
- Panel Study of Income Dynamics (PSID) - duomenys apie US namų ūkius. Pradėti rinkti nuo 1968 metų apie 4802 šeimas, apklausiant jas kiekvienais metais.
- Nuo 80-tųjų panašios apklausos buvo pradėtos atlikti kitose šalyse: Vokietijoje, Nyderlanduose, Belgijoje, Kanadoje, Prancūzijoje, Anglijoje.

- Atsižvelgiama į individualų heterogeniškumą.
- Daugiau informacijos, kintamumo, mažiau kolinearumo tarp kintamųjų, daugiau laisvės laipsnių ir efektyvumo.
- Labiau pritaikyti studijuoti prisitaikymo dinamiką.
- Galima nustatyti ir išmatuoti dydžius, kurių neįmanoma pastebėti turint grynai pjūvinius (cross-section) arba grynai laiko eilučių duomenis.
- Įmanoma kontstruoti ir testuoti labiau komplikuočius elgsenos modelius, nei turint pjūvinius arba laiko eilučių duomenis.
- Duomenys renkami mikro lygyje, todėl išvengiama paklaidų dėl agregavimo.

- Plano ir duomenų surinkimo problemos.
- Matavimo paklaidos turi didesnę įtaką.
- Pasirenkamumo problemos
- Trumpa laiko eilučių dimensija.

Vieno paklaidos komponento regresijos modelis

- Regresijos modelis paneliniams duomenims:

$$y_{it} = \alpha + X'_{it}\beta + u_{it} \quad i = 1, \dots, N; \quad t = 1, \dots, T$$

- Dažniausiai naudojamas vieno paklaidos komponento modelis

$$u_{it} = \mu_i + \nu_{it},$$

čia μ_i nestebimas individualus poveikis.

- Matricinis modelio pavidalas

$$y = \alpha \iota_{NT} + X\beta + Z_{\mu}\mu + \nu,$$

čia $Z_{\mu} = I_N \otimes \iota_T$.

- Vidinės regresijos β įvertis gaunamas iš regresijos

$$Qy = QX\beta + Q\nu,$$

čia $Q = I_{NT} - I_N \otimes \bar{J}_T$ - simetrinė idempotentinė matrica.
Tipiškas Qy elementas yra $y_{it} - \bar{y}_i$.

- Tarpinės regresijos įvertis gaunamas iš regresijos

$$Py = \alpha + PX\beta + P\nu,$$

čia $P = I_N \otimes \bar{J}_T$ - simetrinė idempotentinė matrica. Tipiškas Py elementas yra \bar{y}_i , pakartotas T kartų kiekvienam individui.

- $P + Q = I$, $PQ = 0$.

- μ_i - fiksuoti. Įverčius gauname taikydami LSDV.
- LSDV įverčių gavimą iliustruoja šios lygtys, atveju, kai turime tik vieną nepriklausomą kintamąjį:

$$\bar{y}_i = \alpha + \beta \bar{x}_i + \mu_i + \bar{v}_i.$$

$$y_{it} - \bar{y}_i = \beta(x_{it} - \bar{x}_i) + (v_{it} - \bar{v}_i.)$$

$$\bar{y}_{..} = \alpha + \beta \bar{x}_{..} + \bar{v}_{..}$$

- Imamas vidinės regresijos įvertis $\tilde{\beta}$, gaunamas iš antros lygties. α įvertinamas iš trečios lygties, taikant sąlygą $\sum \mu_i = 0$. μ_i įverčiai gaunami iš pirmos lygties. Jei $\sum \mu_i \neq 0$, galėsime įvertinti tik $\alpha + \mu_i$

- Tinka, jei nagrinėjame tam tikrą specifinę objektų grupę (pvz. N firmų, N šalių) ir ja remdamiesi norime daryti tam tikras išvadas.
- Jei tikrasis modelis yra FE, LSDV yra BLUE, jei $\nu_{it} \sim IID(0, \sigma_\nu^2)$.
- Jei $T \rightarrow \infty$, tai LSDV suderintas, jei T – fiksuotas, o $N \rightarrow \infty$, tai suderintas tik β įvertis.
- Jei tikrasis modelis FE, tai taikant įprastą MKM gausime paslinktus įverčius.
- Jei tarp nepriklausomų kintamųjų yra tokių, kurie nekinta laike, tai jų įtakos su LSDV neįvertinsime.

- Prielaidos: $\mu_i \sim IID(0, \sigma_\mu^2)$, $\nu_{it} \sim IID(0, \sigma_\nu^2)$
- Paklaidų kovariacijų matrica pasidaro nebeįstrižaininė:

$$\Omega = E(uu') = \sigma_\mu^2(I_N \otimes J_T) + \sigma_\nu^2(I_N \otimes I_T)$$

- Paklaidų variacija išlieka homoskedastinė, bet atsiranda serijinė koreliacija atskiriems individams:

$$\begin{aligned} \text{cov}(u_{it}, u_{js}) &= \sigma_\mu^2 + \sigma_\nu^2, & \text{kai } i = j, t = s \\ &= \sigma_\mu^2, & \text{kai } i = j, t \neq s \end{aligned}$$

- Reikia taikyti GLS, tam reikia Ω^{-1} .

Matricą Ω galima užrašyti taip sumą:

$$\Omega = \sigma_1^2 P + \sigma_\nu^2 Q,$$

čia $\sigma_1^2 = T\sigma_\mu^2 + \sigma_\nu^2$. Tada

$$\Omega^{-1} = \frac{1}{\sigma_1^2} P + \frac{1}{\sigma_\nu^2} Q$$
$$\Omega^{-1/2} = \frac{1}{\sigma_1} P + \frac{1}{\sigma_\nu} Q,$$

$y^* = \sigma_\nu \Omega^{-1/2} y$ tipinis elementas yra $y_{it} - (1 - \sigma_\nu/\sigma_1)\bar{y}_i$.

- Padauginę regresijos modelį iš $\sigma_\nu \Omega^{-1/2}$, GLS gausime taikydami svorinį OLS.
- GLS sprendinys yra

$$\hat{\beta}_{GLS} = W_1 \tilde{\beta}_{Within} + W_2 \hat{\beta}_{Between},$$

čia $W_1 + W_2 = I$.

- Matricos W_1 ir W_2 priklauso nuo $\phi = \sigma_\nu / \sigma_1$, taigi reikia rasti σ_1 ir σ_ν įverčius.
- Paprastai remiamasi tuo, kad $Pu \sim (0, \sigma_1^2 P)$ ir $Qu \sim (0, \sigma_\nu^2 Q)$.

- Naudojamas, kai atsitikusiai pasirenkame N individų.
- Kai $\sigma_{\mu} = 0$, GLS įvertis susiveda į OLS.
- Kai $T \rightarrow \infty$, $\hat{\beta}_{GLS}$ artėja į $\tilde{\beta}_{Within}$, $\text{var}(\tilde{\beta}_{Within}) - \text{var}(\hat{\beta}_{GLS})$ yra teigiamai apibrėžta matrica.
- Kai tikrasis modelis yra AE, GLS įverčiai su tikromis dispersijomis yra BLUE, o su įvertintomis yra asimptotiškai geriausi, kai $N \rightarrow \infty$ arba $T \rightarrow \infty$
- Nežinomom dispersijom surasti yra pasiūlyta daug metodų: Wallace ir Hussain(1969), Amemiya(1971), Swamy ir Arora (1972), Nerlove (1971). Metodai buvo palyginti Maddala ir Mount (1973), Taylor (1980). Buvo nustatyta, kad mažom imtims visi jie duoda panašius rezultatus.

- Įvedamas papildomas dėmuo:

$$u_{it} = \mu_i + \lambda_t + \nu_{it} \quad i = 1, \dots, N; \quad t = 1, \dots, T,$$

čia μ_i – nestebimas individualus efektas, λ_t – nestebimas laiko efektas.

- Vektorinis pavidalas:

$$u = Z_\mu \mu + Z_\lambda \lambda + \nu,$$

čia $Z_\mu = I_N \otimes \mathbf{1}_T$, $Z_\lambda = \mathbf{1}_N \otimes I_T$.

- Analogiškai nagrinėjami fiksuotų bei atsitiktinių efektų modeliai.

- FE atveju įverčiai gaunami taikant LSDV, tik vidinės regresijos transformacijos matrica eliminuoja tiek individualius, tiek laiko efektus. Taip gauname įvertį $\tilde{\beta}$. Individualius ir laiko efektus gauname atitinkamai iš tarpinės individų ir tarpinės laiko regresijų.
- RE atveju matricą Ω galima panašiai išskaidyti į tarpusavyje ortogonalų idempotentinių matricų sumą. GLS β įvertis yra trijų regresijų svorinis vidurkis:

$$\hat{\beta}_{GLS} = W_1\beta_W + W_2\beta_B + W_3\beta_C$$

- Matricos W_1 , W_2 ir W_3 taip pat priklauso nuo nežinomų dispersijų, kurias reikia įvertinti.

- Turime N regresijų

$$y_i = Z_i \delta_i + u_i$$

Nulinė hipotezė $H_0 : \delta_i = \delta$ visiems i .

- Esant prielaidai $u \sim N(0, s^2 I_{NT})$ taikomas Chow testas:

$$F = \frac{(e'e - e^*e^*) / (N - 1)K}{e^*e^* / N(T - K)},$$

čia e - nulinės hipotezės regresijos liekanos, e^* - alternatyvios hipotezės regresijos liekanos

- Esant prielaidai $u \sim N(0, \Omega)$, taikomas Roy-Zellner testas, gaunamas Chow teste liekanas pakeitus GLS liekanų įverčiais.

- Klausimas ar traktuoti duomenis, kaip panelinius ar ne susiveda į hipotezės testavimą. Pritaikius apribojimus bus sumažinta variacija, bet gali atsirasti poslinkis, jeigu apribojimai neteisingi.
- Baltagi(1981) atliko Chow ir Roy-Zellner Monte-Carlo palyginimą. Esant dviejų komponentų paklaidos modeliui, Chow testas pernelyg dažnai atmetė nulinę hipotezę, kai ji buvo teisinga.
- Ziemer ir Weitzstein (1983) pasiūlė lyginti panelinių duomenų ($\hat{\delta}_{OLS}$) įverčius su nepaneliniais įverčiais ($\hat{\delta}_{i,OLS}$) pagal prognozavimo riziką

- Breusch ir Pagan (1980) LM testas hipotezei

$$H_0 : \sigma_\mu^2 = \sigma_\lambda^2 = 0$$

$$LM_1 = \frac{NT}{2(T-1)} \left[1 - \frac{\tilde{u}'(I_N \otimes J_T)\tilde{u}}{\tilde{u}'\tilde{u}} \right]^2$$
$$LM_2 = \frac{NT}{2(N-1)} \left[1 - \frac{\tilde{u}'(J_N \otimes I_T)\tilde{u}}{\tilde{u}'\tilde{u}} \right]^2,$$

čia \tilde{u} – OLS liekanos.

- $LM = LM_1 + LM_2$ esant teisingai H_0 yra pasiskirstęs pagal χ_2^2 .
- Su LM_1 galima testuoti hipotezę $H_0 : \sigma_\mu^2 = 0$, su LM_2 – $H_0 : \sigma_\lambda^2 = 0$.

- Honda (1985) pasiūlė tolygiai galingiausius testus:

$$A = \sqrt{\frac{NT}{2(T-1)}} \left[\frac{\tilde{u}'(I_N \otimes J_T)\tilde{u}}{\tilde{u}'\tilde{u}} - 1 \right]$$
$$B = \sqrt{\frac{NT}{2(N-1)}} \left[\frac{\tilde{u}'(J_N \otimes I_T)\tilde{u}}{\tilde{u}'\tilde{u}} - 1 \right],$$

tikrinti atitinkamoms nulinėms hipotezėms $H_0 : \sigma_\mu^2 = 0$ ir $H_0 : \sigma_\lambda^2 = 0$. A ir B yra asimptotiškai normalūs.

- Testai su vienpuse alternatyva hipotezei $H_0 : \sigma_\mu^2 = \sigma_\lambda^2 = 0$ tikrinti yra gaunami įvairiai sudėjus A ir B . Honda (1985), Baltagi, Chang ir Li (1992), Gourieroux, Holy, Monfort (1982).

- Baltagi, Chang ir Li pasiūlė LM testus nulinėms hipotezėms $H_0 : \sigma_\mu^2 = 0$ (tariant $\sigma_\lambda^2 > 0$), bei $H_0 : \sigma_\lambda^2 = 0$ (tariant $\sigma_\mu^2 > 0$) tikrinti.
- Moulton ir Randolph (1989) parodė, kad FE modeliui naudojami F testai gali būti pritaikyti ir AE modeliui.
- Gourioux, Holy, Monfort išvedė LR statistikas ir parodė, kad jos turi tą patį asimptotinį pasiskirstymą kaip ir LM statistikos.

- Baltagi, Chang ir Li (1992) atliko įvairių testų Monte-Karlo palyginimą.
- Jei $H_0 : \sigma_\mu^2 = 0$ yra teisinga, bet $\sigma_\lambda^2 > 0$, visi testai į tai neatsižvelgiantys per dažnai atmeta nulinę hipotezę. Dideliems σ_μ^2 tai įtakos nedaro.
- Testai skirti $H_0 : \sigma_\mu^2 = 0$ (variant $\sigma_\lambda^2 > 0$) dideliems $\sigma_\mu^2 = 0$ turi didelę galią. Be to, net jei tikrajam modeliui $\sigma_\lambda^2 = 0$, testams tai įtakos nedaro.
- Palyginus su LM ir LR statistikomis F statistikos elgiasi šiek tiek geriau.

- Paklaidų komponentų modeliamas svarbi sąlyga yra $E(u_{it}|X_{it}) = 0$
- Jei ši sąlyga netenkinama, tai $\hat{\beta}_{GLS}$ yra paslinktas ir nesuderintas, bet $\tilde{\beta}_{Within}$ išlieka suderintas ir nepaslinktas.
- Hausman (1978) pasiūlė statistiką, besiremiančią šių įverčių skirtumu $\hat{q}_1 = \hat{\beta}_{GLS} - \tilde{\beta}_{Within}$:

$$m_1 = \hat{q}'_1[\text{var}(\hat{q}_1)]\hat{q}_1,$$

esant nulinei hipotezei m_1 pasiskirstęs kaip χ^2_K .

- Hausman ir Taylor (1981) parodė, kad nulinę hipotezę $E(u_{it}|X_{it}) = 0$ galima tikrinti naudojant bet kurį iš šių skirtumų: $\hat{q}_1 = \hat{\beta}_{GLS} - \tilde{\beta}_{Within}$, $\hat{q}_2 = \hat{\beta}_{GLS} - \tilde{\beta}_{Between}$ ir $\hat{q}_3 = \hat{\beta}_{Within} - \tilde{\beta}_{Between}$.
- Arellano (1993) sukonstravo testą, kuris nejautrus bet kokiai autokoreliacijos ir heteroskedastiškumo formai.
- Chamberlain (1982), Angrist ir Newey (1991) nagrinėjo specifikacijos testus FE modeliui. Chamberlain parodė, kad FE modelyje koeficientai iš tikrųjų yra apriboti.