

Problem równoczesności w *MNK*

- O problemie równoczesności mówimy, gdy występuje korelacja między wartością oczekiwaną ε_i i równoczesnym x_i
- Model liniowy

$$\begin{aligned} \mathbf{y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \\ E(\mathbf{u}) &= \mathbf{0} \end{aligned}$$

- Powiedzmy, że występuje w nim zależność między wartością oczekiwaną błędu losowego a zmiennymi objaśniającymi:

$$E(\boldsymbol{\varepsilon} | \mathbf{X}) \neq \mathbf{0}$$

- W takiej sytuacji

$$\begin{aligned} E(\mathbf{b}) &= E\left[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \mid \mathbf{X}\right] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E[\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \mid \mathbf{X}] \\ &= \boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E[\boldsymbol{\varepsilon} \mid \mathbf{X}] \neq \boldsymbol{\beta} \end{aligned}$$

- Estymator *MNK* jest więc obciążony!

Wynik Aby estymator nie był obciążony, nie może być związku między wartością oczekiwaną błędu losowego ε_i a wszystkimi x_1, \dots, x_n

- Jednak jeśli $E(\mathbf{x}'_i \varepsilon_i) = 0$ estymator obciążony może być estymatorem zgodnym

- W dużych próbach

$$\text{plim} \frac{1}{n} \mathbf{X}' \mathbf{X} = \text{plim} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i' = \mathbb{E}(\mathbf{x}_i \mathbf{x}_i')$$

$$\text{plim} \frac{1}{n} \mathbf{X}' \boldsymbol{\varepsilon} = \text{plim} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i' \varepsilon_i = \mathbb{E}(\mathbf{x}_i' \varepsilon_i)$$

- Estymator *MNK* ma granicę według prawdopodobieństwa równą

$$\begin{aligned} \text{plim} \mathbf{b} &= \text{plim} \left[(\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{y} \right] = \text{plim} \left[(\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' (\mathbf{X} \boldsymbol{\beta} + \mathbf{u}) \right] \\ &= \boldsymbol{\beta} + \text{plim} \left(\frac{1}{n} \mathbf{X}' \mathbf{X} \right)^{-1} \left(\frac{1}{n} \mathbf{X}' \boldsymbol{\varepsilon} \right) \\ &= \boldsymbol{\beta} + [\mathbb{E}(\mathbf{x}_i \mathbf{x}_i')]^{-1} \mathbb{E}(\mathbf{x}_i' \varepsilon_i) \neq \boldsymbol{\beta} \end{aligned}$$

Wynik Estymator *MNK* parametru β jest estymatorem zgodnym jeśli $E(\mathbf{x}'_i \varepsilon_i) = \text{Cov}(\mathbf{x}_i, \varepsilon_i) = 0$.

- Zauważmy, że wymóg ten jest znacznie słabszy niż warunek konieczny do nieobciążoności - wystarczy jedynie brak korelacji między ε_i i równoczesnym \mathbf{x}_i .

Przykład Chcemy wyestymować wpływ edukacji na poziom zarobków. Jednak w badaniach nie jesteśmy w stanie uchwycić zdolności danej osoby. Zwykle zdolności wpływają zarówno na poziom edukacji jak i na poziom zarobków. Jeśli zamiast modelu (dane PGSS *lrincome* - logarytm dochodu z pracy)

$$\log(lrincome) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{sex} + \beta_3 \text{age} + \beta_4 \text{age}^2 + \beta_5 \text{zdolności} + \varepsilon$$

wyestymujemy model

$$\log(wage) = \beta_0 + \beta_1 educ + \beta_2 sex + \beta_3 age + \beta_4 age^2 + u$$

to przy założeniu, że osiągnięty poziom wykształcenia zależy od zdolności uzyskujemy:

$$\text{Cov}(educ, u) = \text{Cov}(educ, \beta_5 \text{zdolności} + \varepsilon) = \beta_5 \text{Cov}(educ, \text{zdolności}) \neq 0$$

Ponieważ zmienna pominięta jest dodatnio zdolności są dodano skorelowane z edukacją i wpływają dodatnio na zarobki więc oczekujemy, że obciążenie oszacowania współczynnika β_4 jest dodatnie.

Source	SS	df	MS			
Model	192.55502	4	48.1387549	Number of obs =	4227	
Residual	4815.96513	4222	1.14068336	F(4, 4222) =	42.20	
Total	5008.52015	4226	1.18516804	Prob > F =	0.0000	
				R-squared =	0.0384	
				Adj R-squared =	0.0375	
				Root MSE =	1.068	

lrincome	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
educ	.0415494	.0052952	7.85	0.000	.0311681	.0519307
sex	-.3073812	.033083	-9.29	0.000	-.3722412	-.2425211
age	.052235	.0096668	5.40	0.000	.0332831	.071187
age2	-.0005858	.0001157	-5.06	0.000	-.0008127	-.0003589
_cons	4.788569	.2033733	23.55	0.000	4.389851	5.187288

Metoda Zmiennych Instrumentalnych

- Załóżmy, że jesteśmy w stanie znaleźć takie zmienne, od których nie zależy równoczesny błąd losowy:

$$E(\varepsilon_i | z_i) = 0$$

- Zgodnie z terminologią stosowaną w *GMM*, zmienne z_i nazywać będziemy instrumentami.
- Instrumentami mogą być również elementy x_i
- Zgodnie z tym co powiedziano na temat *GMM* warunek $E(\varepsilon_i | z_i) = 0$ implikuje, że

$$E(z_i' \varepsilon_i) = 0$$

- Spróbujmy teraz wyprowadzić estymator *GMM* dla tego przypadku

$$\varepsilon_i = y_i - \mathbf{x}_i\boldsymbol{\beta}$$

- A więc ograniczenie narzucone na momenty teoretyczne ma postać:

$$E[\mathbf{z}'_i (y_i - \mathbf{x}_i\boldsymbol{\beta})] = 0$$

- Analogiczne ograniczenie narzucone na momenty empiryczne następujące:

$$\begin{aligned} \sum_{i=1}^n \frac{1}{n} \mathbf{z}'_i (y_i - \mathbf{x}_i\hat{\boldsymbol{\beta}}) &= \sum_{i=1}^n \frac{1}{n} \mathbf{z}'_i y_i - \sum_{i=1}^n \frac{1}{n} \mathbf{z}'_i \mathbf{x}_i \hat{\boldsymbol{\beta}} \\ &= \mathbf{Z}'\mathbf{y} - \mathbf{Z}'\mathbf{X}\hat{\boldsymbol{\beta}} = 0 \end{aligned}$$

- Jeśli liczba elementów \mathbf{z}_i będzie równa liczbie elementów \mathbf{x}_i

- liczba równań będzie równa liczbie niewiadomych zawartych w $\hat{\beta}$
 - $\hat{\beta}$ będzie dokładnie zidentyfikowana
 - macierz $Z'X$ będzie $K \times K$
-
- W takim przypadku można będzie policzyć odwrotność $Z'X$ i uzyskać wzór na $\hat{\beta}$
-
- Estymator *MZI* (*IV* - **I**nstrumental **V**ariable) jest wtedy dany wzorem:

$$\hat{\beta} = (Z'X)^{-1} Z'y$$

- **Zgodność** estymatora *MZI*

$$\begin{aligned}
 \text{plim}(\hat{\beta}) &= \text{plim} \left[(\mathbf{Z}'\mathbf{X})^{-1} \mathbf{Z}'\mathbf{y} \right] = \text{plim} \left[(\mathbf{Z}'\mathbf{X})^{-1} \mathbf{Z}'(\mathbf{X}\beta + \varepsilon) \right] \\
 &= \beta + \text{plim} \left[(\mathbf{Z}'\mathbf{X})^{-1} \mathbf{Z}'\varepsilon \right] \\
 &= \beta + \left(\text{plim} \frac{1}{n} \mathbf{Z}'\mathbf{X} \right)^{-1} \left(\text{plim} \frac{1}{n} \mathbf{Z}'\varepsilon \right) \\
 &= \beta + [\mathbf{E}(z_i x_i)]^{-1} \underbrace{\mathbf{E}(z_i' \varepsilon_i)}_0 = \beta
 \end{aligned}$$

Uwaga Wyprowadzenie to jest prawidłowe jedynie, gdy $\mathbf{E}(z_i x_i)$ jest macierzą nieosobliwą: estymator *MZI* jest zgodny jeśli nie ma korelacji między instrumentami i równoczesnymi błędami losowymi, ale *jest* korelacja między instrumentami i zmiennymi objaśnianymi.

Uogólniony estymator estymator *MZI*

- Uogólniony estymator *MZI* (*GIV* - **G**eneralized **I**nstrumental **V**ariable) używamy wtedy, gdy liczba instrumentów jest większa od liczby zmiennych w modelu
- W tym przypadku w układzie równań

$$Z'y - Z'X\hat{\beta} = 0$$

- liczba równań będzie większa niż liczba niewiadomych zawartych w $\hat{\beta}$
- to $\hat{\beta}$ będzie przeidentyfikowana
- macierz $Z'X$ będzie $G \times K$ gdzie G liczba instrumentów $G > K$

- W tym przypadku nie da się policzyć odwrotności $Z'X$ - macierz ta nie jest kwadratowa
- Załóżmy, że

$$\mathbf{x}_i = \mathbf{z}_i \mathbf{B} + \mathbf{u}_i$$

$$E(\mathbf{u}_i | \mathbf{z}_i) = 0$$

- Wynika z tego, że
 - $E(\mathbf{x}_i | \mathbf{z}_i) = \mathbf{z}_i \mathbf{B}$
- Przypomnijmy sobie, że

$$E(\boldsymbol{\varepsilon}_i | \mathbf{z}_i) = E[f_i(\boldsymbol{\beta}) | \mathbf{z}_i] = 0$$

gdzie $f_i(\boldsymbol{\beta}) = y_i - \mathbf{x}_i \boldsymbol{\beta}$

- Dla tego problemu optymalne instrumenty będą można prosto policzyć ze wzoru:

$$\begin{aligned} \mathbf{J}_i &= \mathbb{E} \left(\frac{\partial f_i(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}'} \middle| \mathbf{z}_i \right) = \mathbb{E} \left(\frac{\partial (y_i - \mathbf{x}_i \boldsymbol{\beta})}{\partial \boldsymbol{\beta}'} \middle| \mathbf{z}_i \right) \\ &= \mathbb{E} (-\mathbf{x}_i | \mathbf{z}_i) = \mathbb{E} (-\mathbf{z}_i \mathbf{B} - \mathbf{u}_i | \mathbf{z}_i) = -\mathbf{z}_i \mathbf{B}. \end{aligned}$$

- Wektorem optymalnych instrumentów jest

$$\mathbf{W}_i = \mathbf{z}_i \mathbf{B}.$$

- Ponieważ w praktyce \mathbf{B} jest nieznane, więc zastępujemy je przez estymator *MNK* postaci $\hat{\mathbf{B}} = (\mathbf{Z}' \mathbf{Z})^{-1} \mathbf{Z}' \mathbf{X}$.

- Uzyskany w ten sposób optymalne instrumenty mają postać

$$\widehat{W} = Z (Z'Z)^{-1} Z'X$$

- Postać estymatora można parametru $\widehat{\beta}$ ma teraz postać:

$$m(\widehat{\beta}) = \frac{1}{n} \widehat{W}' e(\widehat{\beta}) = \frac{1}{n} \widehat{W}' (y - X\widehat{\beta}) = 0$$

$$\begin{aligned} b_{MZI} &= \left(\widehat{W}' X \right)^{-1} \widehat{W}' y = \left(X' Z (Z'Z)^{-1} Z' X \right)^{-1} X' Z (Z'Z)^{-1} Z' y \\ &= \left(X' P_Z X \right)^{-1} X' P_Z y \end{aligned}$$

gdzie

$$P_Z = Z (Z'Z)^{-1} Z'$$

- Pokazanie zgodności i postaci macierzy wariancji przebiega tak samo jak dla zwykłego estymatora MZI

Testowanie w *MZI*

- Test egzogeniczności jest wariantem testu Hausmana
- Test Hausmana można przeprowadzić, jeśli mamy dwa estymatory o następujących właściwościach
 1. jeśli H_0 jest prawdziwa to $\hat{\theta}$ jest zgodny a $\tilde{\theta}$ jest asymptotycznie efektywny
 2. jeśli H_0 jest fałszywa jest to $\hat{\theta}$ jest dalej zgodny, ale $\tilde{\theta}$ jest asymptotycznie obciążony
- Test Hausmana polega na sprawdzeniu, czy oszacowania parametrów uzyskanych za pomocą estymatora $\hat{\theta}$ i $\tilde{\theta}$ są do siebie zbliżone.

- W naszym przypadku H_0 brzmi, że X jest egzogeniczne.
- W takim przypadku rolę estymatora $\hat{\theta}$ pełni estymator MZI a estymatora $\tilde{\theta}$ estymator MNK .
- Jeśli H_0 jest prawdziwe i X jest egzogeniczne to łatwo pokazać, że

$$\sqrt{n} (\mathbf{b}_{MZI} - \mathbf{b}_{MNK}) \xrightarrow{D} N(0, \Sigma_{\mathbf{b}_{MZI} - \mathbf{b}_{MNK}})$$

co oznacza, że statystyka

$$(\mathbf{b}_{MZI} - \mathbf{b}_{MNK})' \left(\tilde{\Sigma}_{\mathbf{b}_{MZI} - \mathbf{b}_{MNK}} \right)^{-1} (\mathbf{b}_{MZI} - \mathbf{b}_{MNK}) \xrightarrow{D} \chi_g^2$$

gdzie g jest ilością zmiennych, których egzogeniczność badamy.

- Test na poprawność instrumentów Sargana

- Jest to test na prawdziwość ograniczeń preidentyfikujących
- Przeprowadzamy go badając

$$\frac{\tilde{\mathbf{e}}' \mathbf{P}_W \tilde{\mathbf{e}}}{\tilde{\sigma}^2} \xrightarrow{D} \chi_{p-K}^2$$

gdzie $\tilde{\mathbf{e}} = \mathbf{y} - \mathbf{X}\mathbf{b}_{MZI}$, $\tilde{\sigma}^2 = \frac{\tilde{\mathbf{e}}'\tilde{\mathbf{e}}}{n}$

- Statystyka ta służy do badania prawidłowości doboru instrumentów.
- Jeśli H_0 jest odrzucone to znaczy, że założenie o braku skorelowania zmiennych instrumentalnych i zaburzeń losowych jest fałszywe.

Przykład kontynuacja. Za instrumenty dla edukacji osiągnięty poziom przez matkę i ojca poziom wykształcenia. Zakładamy, że edukacja rodziców

nie mają znaczenia dla poziomu płac (jest nieskorelowana z u) Uzyskane za pomocą *MZI* oszacowania mają postać:

Instrumental variables (2SLS) regression

Source	SS	df	MS	Number of obs =	3862
Model	36.0635538	4	9.01588846	F(4, 3857) =	37.77
Residual	4503.18032	3857	1.16753444	Prob > F =	0.0000
Total	4539.24387	3861	1.17566534	R-squared =	0.0079
				Adj R-squared =	0.0069
				Root MSE =	1.0805

lrincome	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
educ	.1005262	.0131433	7.65	0.000	.0747576	.1262948
sex	-.3317927	.0358404	-9.26	0.000	-.4020608	-.2615247
age	.0496855	.0103803	4.79	0.000	.0293342	.0700369
age2	-.0005467	.0001253	-4.36	0.000	-.0007924	-.0003011
_cons	4.200114	.2384509	17.61	0.000	3.732612	4.667616

Instrumented: educ

Instruments: sex age age2 _Ipadeg_1 _Ipadeg_2 _Ipadeg_3 _Ipadeg_4 _Ipadeg_5
 _Ipadeg_6 _Ipadeg_7 _Ipadeg_8 _Ipadeg_9 _Ipadeg_98 _Imadeg_1
 _Imadeg_2 _Imadeg_3 _Imadeg_4 _Imadeg_5 _Imadeg_6 _Imadeg_7
 _Imadeg_8 _Imadeg_9 _Imadeg_98

- Zauważmy, że oszacowany współczynnik dla edukacji jest teraz znacznie wyższy!
- Wynik testu sargana

Tests of overidentifying restrictions:

Sargan N*R-sq test	12.918	Chi-sq(19)	P-value = 0.8427
Basman test	12.881	Chi-sq(19)	P-value = 0.8446

- Instrumenty wydają się być poprawne.

- Wynik testu Hausmana:

	---- Coefficients ----			
	(b)	(B)	(b-B)	sqrt(diag(V_b-V_B))
	MZI	MNK	Difference	S.E.
educ	.1005262	.0415494	.0589768	.0118632
sex	-.3317927	-.3073812	-.0244116	.0126693
age	.0496855	.052235	-.0025495	.0034388
age2	-.0005467	-.0005858	.0000391	.0000441

b = consistent under Ho and Ha; obtained from ivreg
 B = inconsistent under Ha, efficient under Ho; obtained from regress

Test: Ho: difference in coefficients not systematic

$$\begin{aligned} \text{chi2}(4) &= (b-B)' [(V_b-V_B)^{-1}] (b-B) \\ &= 28.59 \\ \text{Prob>chi2} &= 0.0000 \end{aligned}$$

- Wyniki uzyskane dla *MZI* i *MNK* istotnie się różnią - odrzucamy H_0 , że w modelu nie występuje równoczesność

- Uwaga: uzyskany wynik nie jest zgodny z intuicją - obciążenie oszacowania MNK współczynnika przy edukacji powinno być dodatnie. Zgodny estymator MZI dał jednak jeszcze wyższe oszacowanie tego współczynnika.