

Cechy prób panelowych

- Dane panelowe są to dane, w które mają charakter zarówno próby przekrojowej jak i szeregu czasowego.

Czas	Obiekty			
1	1	2	...	N
	↓	↓		↓
2	1	2	...	N
⋮	↓	↓		↓
T	1	2	...	N

przy czym i oznacza obiekt badany o numerze i ten sam dla wszystkich okresów badania.

- Dane panelowe należy odróżnić od prób przekrojowo-czasowych, dla których dysponujemy szeregiem *różnych* prób przekrojowych dla kolejnych momentów czasu.

Przykład Próba Badania Ekonomicznej Aktywności Ludności jest w istocie rotacyjnym panelem. Każde gospodarstwo domowe wylosowane do próby jest badane czterokrotnie: w 1 i 2 kwartale badania, oraz w 5 i 6 kwartale badania. Przy każdym nowym badaniu jedna czwarta próby jest na nowo losowana. W rezultacie na podstawie *BAEL* można skonstruować panele dla gospodarstw z ilością przekrojów równą 4. Podobna sytuacja istnieje w przypadku badań budżetów gospodarstw.

1995				1996				1997			
1	2	3	4	1	2	3	4	1	2	3	4
X	-	-	X	X							
X	X	-	-	X	X						
	X	X	-	-	X	X					
		X	X	-	-	X	X				
			X	X	-	-	X	X			
				X	X	-	-	X	X		
					X	X	-	-	X	X	
						X	X	-	-	X	X
							X	X	-	-	X

Table 1: The sample structure of Polish LFS

Liniowy model efektów nieobserwowalnych

- Model efektów nieobserwowalnych (indeks i dla jednostki, t dla czasu):

$$y_{it} = \mathbf{x}_{it} \boldsymbol{\beta} + u_i + \varepsilon_{it}$$

- u_i jest nieobserwowalny i stały w czasie
- u_i jest nazywany *charakterystyką (efektem) nieobserwowalną (indywidualną)* bądź *nieobserwowalnym (indywidualnym) zróżnicowaniem*
- ε_{it} jest nazywany *błędem czysto losowym*
- **Panele zbilansowane i niezbilansowane**

- Wszystkie (po czasie) obserwacje dostępne dla wszystkich jednostek
- Forma estymatorów dla paneli niezbilansowanych jest nieco bardziej skomplikowana niż dla paneli zbilansowanych niemniej np. w STAT'cie poprawki konieczne przy braku zbilansowania stosowane są automatyczne.

Przykład Struktura panelu BAEL, fala 13, 1995 kw.1, 1995 kw.2, 1996 kw.1, 1996 kw. 2.

ID: 1300007, 1300015, ..., 1372365 n = 5137
DATE: 140, 141, ..., 145 T = 4
Delta(DATE) = 1; (145-140)+1 = 6
(ID*DATE uniquely identifies each observation)

Distribution of T_i: min 5% 25% 50% 75% 95% max
 1 1 2 4 4 4 4

Freq.	Percent	Cum.	Pattern
3082	60.00	60.00	11..11
404	7.86	67.8611
371	7.22	75.08	11....
281	5.47	80.55	.1..11
224	4.36	84.911
181	3.52	88.44	1.....
146	2.84	91.28	11..1.
126	2.45	93.73	.1....
102	1.99	95.721.
220	4.28	100.00	(other patterns)
5137	100.00		XX..XX

- **Analiza asymptotyczna w panelach**

- Zwykle liczba obserwacji w przekrojach N jest znacznie większa niż liczba przekrojów T
- Z tego powodu jest bardzo ważne udowodnienie, że estymator jest zgodny dla $N \rightarrow \infty$ nawet jeśli T jest skończone (małe)

- **Korzyści związane z używaniem paneli**

- **Efektywność:** panelowa struktura danych może być użyta do efektywniejszego szacowania parametrów dzięki uwzględnieniu korelacji między nieobserwowalnymi efektami indywidualnymi (estymacja z efektami losowymi)
- **Zgodność:** jeśli efekty indywidualne są skorelowane ze zmiennymi objaśniającymi, to struktura danych panelowych może posłużyć do

uzyskania zgodnego estymatora dzięki uwzględnieniu faktu, że nieobserwowalny efekt indywidualny jest stały w czasie (estymacja z efektami stałymi)

Estymacja w próbach panelowych z pomocą estymatora *MNK*

- **Regresja liniowa na pełnej próbie (Pooled Ordinary Least Squares - *POLS*)**
- Policz *MNK* na wszystkich obserwacjach (wszystkich przekrojach)
- u_i jest nieobserwowalny, łączny błąd losowy równy $v_{it} = u_i + \varepsilon_{it}$
- Estymator *MNK* będzie zgodny jeśli:

$$E(u_i | \mathbf{x}_{it}) = 0$$

- Estymator MNK będzie więc zgodny tylko wtedy, gdy efekty indywidualne nie będą skorelowane ze zmiennymi objaśniającymi ($\text{Cov}(u_i, \mathbf{x}_{it}) = 0$) ponieważ tylko wtedy łączny błąd losowy będzie nieskorelowany z \mathbf{x}_{it} ($\text{Cov}(v_{it}, \mathbf{x}_{it}) = 0$)
 - **Intuicja:** indywidualne nieobserwowalne charakterystyki reprezentują zazwyczaj pominięte (nieobserwowalne) zmienne. Estymator MNK jest zgodny tylko wtedy, gdy pominięte zmienne są nieskorelowane z błędem losowym.
- Jeśli spełniony jest ten warunek, to estymator MNK daje zgodne choć nieefektywne oszacowanie parametrów.
- Problem: v_{it} będzie wykazywała autokorelację z racji na występowanie u_i w każdym z okresów

$$(\text{Cov}(v_{it}, v_{it-1}) = \sigma_u^2)$$

- Z tego powodu powinniśmy zastosować w tym przypadku odporną macierz wariancji. W tym przypadku korelacja występuje tylko między obserwacjami.
- Dla tego przypadku macierz wariancji kowariancji można uzyskać definiując jednostki jako tak zwane warstwy (*clusters*) - grupy obserwacji o powiązanych niezerowych kowariancjach między błędami losowymi.

Przykład Determinanty płacy. Szacunek na podstawie panelu dla BAEL rozpoczętej w 1995.1. Estymator *MNK*.

Regression with robust standard errors

Number of obs = 16178

F(18, 5053) = 325.53

Prob > F = 0.0000

R-squared = 0.3465

Root MSE = .33666

Number of clusters (ID) = 5054

	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
LNTPAY						
AGE	.023474	.0029087	8.07	0.000	.0177716	.0291764
AGE2	-.0002125	.0000386	-5.51	0.000	-.0002881	-.0001369
_ISEX_2	-.2944018	.0094636	-31.11	0.000	-.3129546	-.2758491
_IEDUCAT_2	-.2471495	.0231851	-10.66	0.000	-.2926024	-.2016966
_IEDUCAT_3	-.2508185	.017512	-14.32	0.000	-.2851495	-.2164874
_IEDUCAT_4	-.2017467	.0220539	-9.15	0.000	-.2449818	-.1585115
_IEDUCAT_5	-.3873151	.0171888	-22.53	0.000	-.4210127	-.3536176
_IEDUCAT_7	-.4826221	.0191834	-25.16	0.000	-.5202299	-.4450144
_IEDUCAT_8	-.4696502	.1126117	-4.17	0.000	-.690418	-.2488824
_ITOWN2_1	-.014375	.0201918	-0.71	0.477	-.0539596	.0252096

_ITOWN2_2		.0238628	.0223628	1.07	0.286	-.019978	.0677035
_ITOWN2_3		-.0180127	.0208025	-0.87	0.387	-.0587947	.0227693
_ITOWN2_4		-.0663333	.019641	-3.38	0.001	-.1048381	-.0278285
_ITOWN2_5		-.0432959	.022122	-1.96	0.050	-.0866646	.0000727
_ITOWN2_6		-.1104966	.0276596	-3.99	0.000	-.1647214	-.0562718
_ITOWN2_7		-.1238275	.0286291	-4.33	0.000	-.1799529	-.067702
_ITOWN2_9		-.139221	.017152	-8.12	0.000	-.1728464	-.1055955
OBSNUM		.1080488	.0017707	61.02	0.000	.1045776	.1115201
_cons		5.70988	.0565267	101.01	0.000	5.599064	5.820697

Efekty stałe i efekty losowe

- W zastosowaniach ekonomicznych prawie zawsze efekty indywidualne u_i są losowe
- Różnica między efektami stałymi i losowymi wiąże się z założeniami dotyczącymi korelacji między efektami indywidualnymi a zmiennymi objaśniającymi:
 - jeśli u_i jest nieskorelowany z x_i używamy *estymatora efektów losowych (random effects)*
 - jeśli u_i jest skorelowany z x_i używamy *estymatora efektów stałych (fixed effects)*

Estymator efektów losowych

- Warunki, przy których estymator efektów losowych (random effects) jest zgodny:
 1. Dokładna egzogeniczność: $E(\varepsilon_{it} | \mathbf{x}_{it}, u_i) = 0$ dla $t = 1, \dots, T$
 - brak korelacji między \mathbf{x}_{it} , u_i oraz obecnymi, przyszłymi i zaszłymi ε_{it}
 2. Brak korelacji między u_i i \mathbf{x}_i , $E(u_i | \mathbf{x}_i) = 0$, gdzie $\mathbf{x}_i = (\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{iT})$

- Model

$$y_{it} = \mathbf{x}_{it}\beta + v_{it}$$

- $v_{it} = u_i + \varepsilon_{it}$, gdzie v_{it} jest łącznym błędem losowym
- W zapisie macierzowym

$$\mathbf{y}_i = \mathbf{X}_i \beta + \mathbf{v}_i$$

- O błędzie czysto losowym ε_{it} zakładamy, że jest homoskedastyczny i nieskorelowany:
 - $E(\varepsilon_{it}^2) = \sigma_\varepsilon^2$
 - $E(\varepsilon_{it}\varepsilon_{js}) = 0, (i, t) \neq (j, s)$ (próba losowa)
- O u_i także zakładamy, że jest homoskedastyczny i nieskorelowany:
 - $E(u_i^2) = \sigma_u^2$
 - $E(u_i u_j) = 0, i \neq j$ (próba losowa)
- Przy tych założeniach wariancja błędu łącznego wynosi:

$$E(v_{it}^2) = E(u_i^2) + 2E(u_i \varepsilon_{it}) + E(\varepsilon_{it}^2) = \sigma_u^2 + \sigma_\varepsilon^2$$

gdzie σ_u^2 jest wariancją u_i

- Dla $t = s$, kowariancja między v_{it} i v_{is} jest równa

$$E(v_{it}v_{is}) = E[(u_i + \varepsilon_{it})(u_i + \varepsilon_{is})] = E(u_i^2) = \sigma_u^2$$

- W rezultacie

$$\Omega = E(\mathbf{v}_i \mathbf{v}_i') = \begin{bmatrix} \sigma_u^2 + \sigma_\varepsilon^2 & \sigma_u^2 & \dots & \sigma_u^2 \\ \sigma_u^2 & \sigma_u^2 + \sigma_\varepsilon^2 & & \vdots \\ \vdots & & \ddots & \sigma_u^2 \\ \sigma_u^2 & & & \sigma_u^2 + \sigma_\varepsilon^2 \end{bmatrix}$$

- Jeśli powyższe założenia są prawdziwe to estymator efektów losowych jest estymatorem efektywny

Estymator UMNK dla efektów losowych

- Uogólniona Metoda Najmniejszych Kwadratów (*UMNK*) - przypadek ogólny

$$\hat{\beta} = \left(\mathbf{X}'\bar{\Omega}^{-1}\mathbf{X} \right)^{-1} \mathbf{X}'\bar{\Omega}^{-1}\mathbf{y}$$

gdzie $\bar{\Omega} = Var(\mathbf{v}) = E(\mathbf{v}\mathbf{v}')$, i $\mathbf{v} = (\mathbf{v}_1, \dots, \mathbf{v}_N)$

- Dla paneli skorelowane są jedynie v_{it} and v_{is} dla $t \neq s$ ale v_{it} i v_{js} dla $i \neq j$ są nieskorelowane

- W związku z tym macierz $\bar{\Omega}$ będzie miała postać blokowo diagonalną

$$\bar{\Omega} = \begin{bmatrix} \Omega & & 0 \\ & \dots & \\ 0 & & \Omega \end{bmatrix}$$

a estymator *UMNK* będzie miał specjalną postać:

$$\hat{\beta}_{RE} = \left(\sum_{i=1}^N \mathbf{X}'_i \Omega^{-1} \mathbf{X}_i \right)^{-1} \left(\sum_{i=1}^N \mathbf{X}'_i \Omega^{-1} \mathbf{y}_i \right)$$

- Ω jest nieznana ale jako macierz $T \times T$ może być wyestymowana (T jest zazwyczaj małe)
- Załóżmy, że dysponujemy zgodnymi estymatorami σ_u^2 and σ_v^2

- Stosowalny estymator Uogólnionej Metody Najmniejszych Kwadratów (*SUMNK*) ma więc postać

$$\hat{\beta}_{RE} = \left(\sum_{i=1}^N \mathbf{X}'_i \hat{\Omega}^{-1} \mathbf{X}_i \right)^{-1} \left(\sum_{i=1}^N \mathbf{X}'_i \hat{\Omega}^{-1} \mathbf{y}_i \right)$$

- Aby użyć tego wzoru musimy znaleźć zgodne estymatory dla σ_u^2 and σ_ε^2
- Ponieważ *MNK* jest zgodnym estymatorem w przypadku prawdziwości założeń koniecznych do zgodności estymatora efektów losowych więc estymator *MNK* dla błędu losowego regresji (s^2) będzie estymatorem zgodnym $\hat{\sigma}_v^2$, gdzie $\sigma_v^2 = \sigma_u^2 + \sigma_\varepsilon^2$
- Z drugiej strony kowariancja między v_{it}, v_{is} jest równa σ_u^2 . Kowariancję tę

można oszacować na podstawie kowariancji reszt uzyskanych w *MNK*:

$$\hat{\sigma}_u^2 = \frac{1}{[NT(T-1)/2 - K]} \sum_{i=1}^N \sum_{t=1}^{T-1} \sum_{s=t+1}^T \hat{v}_{it} \hat{v}_{is}$$

- Ponieważ $\sigma_v^2 = \sigma_u^2 + \sigma_\varepsilon^2$, więc estymator $\hat{\sigma}_\varepsilon^2$ można policzyć jako $\hat{\sigma}_\varepsilon^2 = \hat{\sigma}_v^2 - \hat{\sigma}_u^2$

Uwaga Niekiedy oszacowana w ten sposób wariancja $\hat{\sigma}_\varepsilon^2$ może wyjść ujemna. Jednym z proponowanych rozwiązań jest przyjęcie, że $\sigma_\varepsilon^2 = 0$

- Można także znaleźć oszacowanie dla metody efektów zmiennych za pomocą *MNW*. W tym przypadku nie ma problemu z ujemnymi oszacowaniami σ_ε^2 .

- Przy założeniu, że $E(v_i v_i' | x_i, u_i) = \sigma_\varepsilon^2 \mathbf{I}_T$ i $E(u_i^2 | x_i) = \sigma_u^2$, to estymator efektów losowych jest najbardziej efektywny
- Najważniejszą hipotezą jaką testuje się w kontekście metody efektów losowych jest hipoteza o istnieniu efektów indywidualnych.
- W kontekście tej metody testowanie istnienia efektów indywidualnych sprowadza się do testowania zerowości wariancji u_i .
 - jeśli $\text{Var}(u_i) = \sigma_u^2 \neq 0$, efekty indywidualne istnieją, estymator efektów losowych efektywniejszy od estymatora *MNK*
 - jeśli $\text{Var}(u_i) = \sigma_u^2 = 0$, efekty indywidualne nie są istotne, estymator *MNK* równie efektywny jak estymator efektów losowych

Przykład Determinanty płacy. Estymator *SUMNK*.

```

Random-effects GLS regression                Number of obs      =      16178
Group variable (i): ID                      Number of groups   =       5054

R-sq:  within  = 0.4063                    Obs per group: min =          1
       between = 0.3262                    avg      =          3.2
       overall  = 0.3457                    max      =          4

Random effects u_i ~Gaussian                Wald chi2(18)      =   10088.51
corr(u_i, X)      = 0 (assumed)             Prob > chi2        =    0.0000
    
```

LNTPAY	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
AGE	.0249031	.0028113	8.86	0.000	.0193929	.0304132
AGE2	-.0002209	.0000372	-5.94	0.000	-.0002938	-.0001479
_ISEX_2	-.2843309	.0096685	-29.41	0.000	-.3032807	-.2653811
_IEDUCAT_2	-.2404923	.0256165	-9.39	0.000	-.2906996	-.1902849
_IEDUCAT_3	-.2506126	.0157783	-15.88	0.000	-.2815374	-.2196877
_IEDUCAT_4	-.2144521	.0202829	-10.57	0.000	-.2542059	-.1746983
_IEDUCAT_5	-.3898099	.0156276	-24.94	0.000	-.4204395	-.3591803
_IEDUCAT_7	-.4959456	.0181669	-27.30	0.000	-.5315522	-.4603391

_IEDUCAT_8		-.4941375	.1234323	-4.00	0.000	-.7360604	-.2522147
_ITOWN2_1		-.0182726	.0191882	-0.95	0.341	-.0558807	.0193355
_ITOWN2_2		.0095936	.0207216	0.46	0.643	-.03102	.0502071
_ITOWN2_3		-.0315726	.0200406	-1.58	0.115	-.0708515	.0077063
_ITOWN2_4		-.07844	.0190514	-4.12	0.000	-.1157801	-.0410999
_ITOWN2_5		-.0593752	.0218263	-2.72	0.007	-.102154	-.0165965
_ITOWN2_6		-.1322534	.0278677	-4.75	0.000	-.1868731	-.0776336
_ITOWN2_7		-.1465557	.0323892	-4.52	0.000	-.2100374	-.0830741
_ITOWN2_9		-.1460398	.01687	-8.66	0.000	-.1791044	-.1129752
OBSNUM		.1082641	.0012704	85.22	0.000	.1057742	.110754
_cons		5.666961	.0542192	104.52	0.000	5.560694	5.773229

sigma_u		.30293482					
sigma_e		.1662991					
rho		.76842858	(fraction of variance due to u_i)				

- R^2_{within} jest procentem zróżnicowania wewnątrzgrupowego (a więc zróżnicowania dotyczącego poszczególnych jednostek), które udało nam się wytłumaczyć zmianami w czasie charakterystyk tych jednostek

- $R_{between}^2$ jest procentem zróżnicowania międzygrupowego (a więc zróżnicowania między jednostkami), które udało nam się wytłumaczyć różnicami w średnich wielkościach charakterystyk dla tych jednostek
- $R_{overall}^2$ jest procentem całkowitego zróżnicowania zmiennej zależnej, które udało nam się wytłumaczyć
- $\rho = \frac{\text{Cov}(v_{it}, v_{is})}{\text{Var}(v_{it})} = \frac{\sigma_u^2}{\sigma_v^2} = \frac{\sigma_u^2}{\sigma_u^2 + \sigma_\varepsilon^2} = \frac{.30303724^2}{.30303724^2 + .16615063^2} = .76887$ jest częścią łącznego błędu losowego, który jest związana z efektami indywidualnymi.
- W tym analizowanym przypadku, 77% błędu losowego można wytłumaczyć, niezmiennymi w czasie charakterystykami indywidualnymi.
- Wielkości współczynników interpretujemy identycznie jak w zwykłej regresji.

- W analizowanym przez nas przypadku różnice w wielkościach oszacowanych współczynników i błędach standardowych wyszły bardzo niewielkie.

Przykład Determinanty płacy. Wynik testu na istnienie efektów losowych

Breusch and Pagan Lagrangian multiplier test for random effects:

$$\text{LNETPAY}[id,t] = Xb + u[id] + e[id,t]$$

Estimated results:

	Var	sd = sqrt(Var)
LNETPAY	.1732811	.4162705
e	.027606	.1661506
u	.0918316	.3030372

Test: Var(u) = 0

chi2(1) = 10552.09
 Prob > chi2 = 0.0000

- Hipotezę zerową o braku efektów losowych odrzucamy!

Estymator efektów stałych

- Model

$$y_{it} = \mathbf{x}_{it}\beta + u_i + \varepsilon_{it}$$

- Zakładamy, że błąd losowy nie zależy od przeszłych, obecnych i przyszłych wartości \mathbf{x}_i

$$E(\varepsilon_{it} | \mathbf{x}_i, u_i) = 0 \text{ for } t = 1, \dots, T$$

- Efekt indywidualny u_i może być skorelowany z \mathbf{x}_{it}
- Można pokazać, że estymator efektów, jest zgodny nawet jeśli $E(u_i | \mathbf{x}_i) \neq 0$, to jest nawet w sytuacji kiedy estymatory efektów zmiennych i *MNK* nie są zgodne

- W tym sensie estymator efektów stałych jest bardziej odporny
- **Przekształcenie efektów stałych** (przekształcenie wewnątrz obiektowe):
- Uśredniamy po czasie równanie

$$y_{it} = \mathbf{x}_{it}\boldsymbol{\beta} + u_i + \varepsilon_{it}$$

i otrzymujemy

$$\bar{y}_i = \bar{\mathbf{x}}_i\boldsymbol{\beta} + u_i + \bar{\varepsilon}_i$$

gdzie $\bar{y}_i = \frac{\sum_{t=1}^T y_{it}}{T}$, $\bar{\mathbf{x}}_i = \frac{\sum_{t=1}^T \mathbf{x}_{it}}{T}$, $\bar{\varepsilon}_i = \frac{\sum_{t=1}^T \varepsilon_{it}}{T}$

- Odejmując od siebie stronami model i uśredniając po czasie otrzymujemy:

$$y_{it} - \bar{y}_i = (\mathbf{x}_{it} - \bar{\mathbf{x}}_i)\boldsymbol{\beta} + (\varepsilon_{it} - \bar{\varepsilon}_i)$$

lub

$$\ddot{y}_{it} = \ddot{x}_{it} \beta + \ddot{\varepsilon}_{it}$$

- Zauważmy, że stosując te przekształcenie eliminujemy efekt indywidualny!
- Do przekształconego równania możemy zastosować zwykłe *MNK*, ponieważ

$$E(\varepsilon_{it} | \mathbf{x}_i, u_i) = 0 \implies E(\bar{\varepsilon}_{it} | \bar{\mathbf{x}}_i, u_i) = 0$$

a więc

$$E(\varepsilon_{it} | \mathbf{x}_i, u_i) = 0 \implies E(\ddot{\varepsilon}_{it} | \ddot{\mathbf{x}}_{it}, u_i) = 0$$

co wystarcza, aby *MNK* zastosowane do przekształconego modelu dało zgodny estymator.

- Zauważmy, że w przypadku estymatora efektów stałych nie musimy robić żadnych założeń na temat relacji między tym efektami indywidualnymi a czystym błędem losowym.

- Z drugiej strony, tak samo jak w modelu efektów losowych musimy założyć, że ε_{it} jest nieskorelowane z przeszłymi, obecnymi i przyszłymi wartościami x_i .
- **Podstawowy problem:** jeśli wśród zmiennych pojawia się zmienna, która nie zmienia się w czasie, to jej wpływu nie da się oszacować, ponieważ eliminuje ją przekształcenie efektów stałych.

Przykład Załóżmy, że chcemy oszacować wpływ płci i wieku na płacę.

$$wage_{it} = \beta_0 + \beta_1 sex_i + \beta_2 age_{it} + u_i + \varepsilon_{it}$$

Przy zmiennej sex_i jest tylko jeden indeks ponieważ nie zmienia się ona w czasie. Zastosujmy przekształcenie efektów stałych. Otrzymamy

$$wage_{it} - \overline{wage}_i = \beta_2 (age_{it} - \overline{age}_i) + \ddot{\varepsilon}_{it}$$

Stała i zmienna sex_i całkowicie znikły z modelu po jego przekształceniu!

- Estymator efektów stałych (FE - **F**ixed **E**ffect) liczymy za pomocą MNK przeprowadzając regresję \ddot{y}_{it} on \ddot{x}_{it}
- Jedyną korektą jaką należy zastosować jest korekta liczby stopni swobody we wzorze na $\hat{\sigma}_u^2$.
- Aby uzyskać niobciążony estymator σ_u^2 należy zastosować wzór $\hat{\sigma}_u^2 = \frac{RSS}{[N(T-1)-K]}$
- Estymator efektów stałych nazywany jest także estymatorem wewnątrzobiektywnym (*within estimator*), ponieważ wykorzystuje on do estymacji parametrów jedynie zróżnicowanie wewnątrzobiektywne (odchylenia obserwacji dla jednostki od średniej dla tej jednostki)

- Przy założeniu, że $E(\mathbf{u}_i \mathbf{u}_i' | \mathbf{x}_i) = \sigma_u^2 \mathbf{I}_T$ estymator efektów stałych jest estymatorem efektywnym.
- Testowanie występowania efektów indywidualnych w przypadku stosowania estymatora efektów stałych polega na testowaniu parametrycznej hipotezy, że wszystkie efekty indywidualne równe są zeru.
- Test taki można przeprowadzić porównując sumy kwadratów reszt w modelu wyestymowanym za pomocą MNK zastosowanego do próby wymieszanej i sumy kwadratów reszt w modelu wyestymowanym za pomocą estymatora efektów stałych.
- Uzyskana statystyka będzie miała postać

$$\frac{(RSS_{MNK} - RSS_{FE}) / (N - 1)}{(RSS_{MNK}) / (N - K - 1)} \sim F(N - 1, N - K - 1)$$

Przykład Płaca netto a charakterystyki respondenta - kontynuacja.

```

Fixed-effects (within) regression
Group variable (i): ID

R-sq:  within = 0.4254
       between = 0.0502
       overall = 0.0495

Number of obs      = 16178
Number of groups   = 5054

Obs per group: min = 1
               avg  = 3.2
               max  = 4

F(8,11116)        = 1028.50
Prob > F          = 0.0000

corr(u_i, Xb)    = -0.9457
    
```

LNTPAY	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
AGE	.1408278	.012854	10.96	0.000	.1156316	.166024
AGE2	-.0002616	.0001496	-1.75	0.080	-.0005548	.0000316
_ISEX_2	(dropped)					
_IEDUCAT_2	-.1363578	.1326115	-1.03	0.304	-.3962998	.1235843
_IEDUCAT_3	-.1170238	.0845124	-1.38	0.166	-.282683	.0486355
_IEDUCAT_4	-.1765529	.0737762	-2.39	0.017	-.3211673	-.0319385
_IEDUCAT_5	-.1683508	.0990707	-1.70	0.089	-.362547	.0258455
_IEDUCAT_7	-.1236027	.1132831	-1.09	0.275	-.3456577	.0984522

```

_IEDUCAT_8 | (dropped)
_ITOWN2_1 | (dropped)
_ITOWN2_2 | (dropped)
_ITOWN2_3 | (dropped)
_ITOWN2_4 | (dropped)
_ITOWN2_5 | (dropped)
_ITOWN2_6 | (dropped)
_ITOWN2_7 | (dropped)
_ITOWN2_9 | (dropped)
OBSNUM | .0638621 .0026914 23.73 0.000 .0585866 .0691377
_cons | 1.133222 .3066956 3.69 0.000 .5320439 1.7344
-----+-----
sigma_u | 1.2139867
sigma_e | .1662991
rho | .9815805 (fraction of variance due to u_i)
-----+-----
F test that all u_i=0: F(5053, 11116) = 10.91 Prob > F = 0.0000

```

- Zauważmy, że wszystkie zmienne, SEX (płeć) i TOWN2 (wielkość miasta w którym zamieszkuje respondent) wypadły z regresji. Płeć nie zmienia się w czasie zaś wielkość miasta, w którym mieszka respondent nie może

się zmienić z racji na konstrukcję badania - jeśli respondent zmieni miejsce zamieszkania to wypada z próby

- Oszacowania przy zmiennej EDUCAT (wykształcenie) są bardzo nieprecyzyjne - prawdopodobnym powodem jest mały udział zaobserwowanych w próbie osób, które w trakcie trwania badania (1,5 roku) podniosły swój poziom wykształcenia.
- Wynik testu na istnienie efektów indywidualnych $F(5053, 11116) = 10.91$, sugeruje udrzucenie hipotezy o nieistotności efektów losowych

- Estymator efektów stałych można policzyć także przeprowadzając regresję y_{it} na x_{it} oraz na zmiennych $d_{1it}, d_{2it}, \dots, d_{Nit}$, gdzie zmienne d_{kit} jest zmienną zerojedynekową przyjmującą wartość 1 jeśli $i = k$ i 0 w przeciwnym przypadku.
- Ta forma estymatora efektów stałych określana jest w literaturze *LSDV* (**L**east **S**quares **D**ummy **V**ariables)
- W praktyce stosowanie tego estymatora ma sens tylko wtedy, gdy liczba jednostek jest mała, w przeciwnym razie powstają problemy z odwracaniem macierzy X - ponieważ zawiera ona bardzo dużo $((K + N) \times (K + N))$ elementów.
- Jedyną zaletą estymatora *LSDV* jest to, że uzyskujemy za jego pomocą bezpośrednio oszacowania efektów indywidualnych dla poszczególnych jednostek jako oszacowania parametrów stojących przed zmiennymi zerojedynekowymi odnoszącymi się do tych jednostek.

- Oszacowania te, choć nieobciążone, nie są jednak zgodne, chyba że $T \rightarrow \infty$ (ale jako powiedziano zazwyczaj T jest małe)
- Aby oszacować efekty indywidualne dla poszczególnych jednostek w przypadku, kiedy stosujemy standardową formę estymatora efektów stałych możemy zastosować następujący wzór:

$$\hat{u}_i = \bar{y}_i - \bar{x}_i \hat{\beta}_{FE}$$

Porównanie estymatorów i test na nieobciążoność estymatora efektów losowych

- Estymator MNK (*POLS*) i estymator efektów losowych wykorzystują zróżnicowanie wewnątrzobiektywne

$$y_{it} - \bar{y}_i = (\mathbf{x}_{it} - \bar{\mathbf{x}}_i) \boldsymbol{\beta} + (\varepsilon_{it} - \bar{\varepsilon}_i)$$

gdzie $\bar{y}_i = \frac{\sum_{t=1}^T y_{it}}{T}$, $\bar{\mathbf{x}}_i = \frac{\sum_{t=1}^T \mathbf{x}_{it}}{T}$, $\bar{\varepsilon}_i = \frac{\sum_{t=1}^T \varepsilon_{it}}{T}$

oraz zróżnicowanie międzyobiektywne

$$y_{it} - \bar{y}_t = (\mathbf{x}_{it} - \bar{\mathbf{x}}_t) \boldsymbol{\beta} + (\varepsilon_{it} - \bar{\varepsilon}_t)$$

gdzie $\bar{y}_t = \frac{\sum_{i=1}^N y_{it}}{N}$, $\bar{\mathbf{x}}_t = \frac{\sum_{i=1}^N \mathbf{x}_{it}}{N}$, $\bar{\varepsilon}_t = \frac{\sum_{i=1}^N \varepsilon_{it}}{N}$

- Estymator efektów stałych wykorzystuje jedynie różnicowanie wewnątrzobiektowe
- Estymator efektów losowych jest efektywny i zgodny jeśli u_i i x_i są nieskorelowane
- Estymator efektów stałych jest nieefektywny ale zgodny jeśli u_i i x_i są nieskorelowane
- Estymator efektów losowych jest nie jest zgodny jeśli u_i i x_i są skorelowane
- Estymator efektów stałych jest efektywny i zgodny jeśli u_i i x_i są skorelowane
- Za pomocą estymatora efektów stałych nie da się oszacować wpływu zmiennych stałych w czasie na zmienną zależną

Test Hausmana

- Testowanie poprawności założeń modelu efektów losowych
 - H_0 : założenie o braku skorelowania efektów indywidualnych ze zmiennymi objaśniającymi jest prawdziwe
 - * estymatory efektów losowych i stałych są zgodne - różnica między szacowaniami nie powinna być statystycznie istotna
 - H_1 : założenie o braku korelacji między efektami indywidualnymi i zmiennymi objaśniającymi jest fałszywe
 - * estymator efektów losowych nie jest zgodny, estymator efektów stałych zgodny - różnica między oszacowaniami może być statystycznie istotna
- Wniosek: jeśli różnica między oszacowaniami wektora parametrów β

uzyskanymi za pomocą estymatora efektów losowych i zmiennych jest statystycznie istotna powinniśmy odrzucić H_0

- Istotne uproszczenie postaci statystyki można uzyskać dzięki temu, że przy H_0 estymator RE jest efektywny, ponieważ w takiej sytuacji $\text{Cov}(\tilde{\beta}_{FE}, \tilde{\beta}_{RE}) \xrightarrow{p} \tilde{\Sigma}_{\beta_{RE}}$
- Test (nazywany testem Hausmana) przyjmuje w tej sytuacji typową postać formy kwadratowej z udziałem odwrotności macierzy wariancji

$$\left(\tilde{\beta}_{FE} - \tilde{\beta}_{RE}\right) \left(\tilde{\Sigma}_{\beta_{FE}} - \tilde{\Sigma}_{\beta_{RE}}\right)^{-1} \left(\tilde{\beta}_{FE} - \tilde{\beta}_{RE}\right) \xrightarrow{D} \chi_{K^*+1}^2,$$

- Uwagi: w przypadku, kiedy w modelu występują zmienne stałe w czasie, zarówno estymatory jak i macierz wariancji kowariancji powinny dotyczyć jedynie oszacowań przy parametrach zmieniających się w czasie.

Przykład Wynik testu Hausmana na poprawność modelu efektów losowych

	---- Coefficients ----			
	(b)	(B)	(b-B)	sqrt (diag (V_b-V_B))
	fe	re	Difference	S.E.
AGE	.1408278	.0249031	.1159247	.0125428
AGE2	-.0002616	-.0002209	-.0000407	.0001449
_IEDUCAT_2	-.1363578	-.2404923	.1041345	.1301138
_IEDUCAT_3	-.1170238	-.2506126	.1335888	.0830264
_IEDUCAT_4	-.1765529	-.2144521	.0378992	.0709333
_IEDUCAT_5	-.1683508	-.3898099	.2214591	.0978304
_IEDUCAT_7	-.1236027	-.4959456	.3723429	.1118169
OBSNUM	.0638621	.1082641	-.044402	.0023727

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

Test: Ho: difference in coefficients not systematic

$$\begin{aligned} \text{chi2}(7) &= (b-B)' [(V_b-V_B)^{-1}] (b-B) \\ &= 369.23 \end{aligned}$$

Prob>chi2 = 0.0000

- Wielkość statystyki testu Hausmana $\text{chi2}(7) = 369.23$ bardzo silnie sugeruje odrzucenie H_0 o prawidłowości założeń modelu efektów losowych
- Powinniśmy więc stosować model efektów stałych
- Z racji na wspomniane wady modelu efektów stałych opracowano inne estymatory, nie będziemy ich jednak tutaj bliżej opisywać.

Inne zastosowania paneli

- Jednym z bardzo ważnych zastosowań paneli jest możliwość obserwacji zmiany stanów jednostek
- Powiedzmy, że jesteśmy zainteresowani problemem bezrobocia
- Bardzo często w literaturze pojawia się opinia, że szczególnie trudny społecznie problemem jest bezrobocie długotrwałe
- Jeśli chcemy zbadać problem występowania bezrobocia długotrwałego możemy albo oprzeć się na:
 - ankietach retrospektywnych: pytania dotyczące przeszłości zawodowej

- panelu: obserwujemy wtedy także zmiany w czasie charakterystyk respondenta
- Na podstawie próby przekrojowej bez pytań retrospektywnych nie da się prześledzić dynamiki zmian
- Na podstawie panelu można między innymi oszacować prawdopodobieństwa zmiany stanów np. z bezrobotnego na emeryta, lub pracującego na bezrobotnego.

Przykład Główne źródło utrzymania. Podział w ramach całej populacji badanej.

- 1 praca najemna
- 2 gosp.rolne
- 3 praca na r-k własny
- 4 renta, emeryt
- 5 zasilek
- 6 inne niezarobkowe

zrodlo utrzymania	Freq.	Percent	Cum.
praca najemna	37,964	52.76	52.76
gosp.rolne	8,373	11.64	64.39
praca na r-k własny	4,654	6.47	70.86
renta, emeryt	17,919	24.90	95.76
zasilek	1,950	2.71	98.47
inne niezarobkowe	1,099	1.53	100.00
Total	71,959	100.00	

- Na podstawie tego rodzaju tabeli możemy ustalić udziały poszczególnych

grup w ogóle populacji nie możemy jednak powiedzieć nic na temat przepływów między grupami.

- Pytanie - na ile prawdopodobna jest zmiana głównego źródła utrzymania i w jakim kierunku zachodzą te zmian?
- Oszacowanie prawdopodobieństw zmian stanów między okresem t i $t + 1$

zrodlo utrzymania	zrodlo utrzymania						Total
	1	2	3	4	5	6	
1	96.11	0.23	0.85	1.15	1.42	0.24	100.00
2	0.86	97.87	0.47	0.74	0.06	0.00	100.00
3	3.46	0.27	93.25	1.30	1.14	0.57	100.00
4	1.47	0.16	0.30	97.74	0.23	0.10	100.00
5	24.36	0.49	2.75	1.62	66.38	4.38	100.00
6	22.30	1.30	2.97	3.32	4.27	65.84	100.00
Total	52.63	11.69	6.57	25.03	2.74	1.35	100.00

- Najbardziej stabilnymi stanami jest osiągnięcie głównego źródła dochodów

z rolnictwa lub z emerytury lub renty - blisko 98% osób zaobserwowanych w tym stanie znajdowało się w tym samym stanie w następnym badaniu

- Mniej stabilnymi stanami jest utrzymywanie się z zasiłku i źródeł niezarobkowych.
- 66% osób, dla których głównym źródłem był zasiłek, w następnym okresie było także na zasiłku, 24% udało się zdobyć pracę
- Szerszej analizie przejść między stanami dokonuje się w ramach analizy łańcuchów Markowa.