

Nota de Clase 8

Introducción a modelos de Data Panel: Aplicación

Se dispone de la base de datos “ejemplo_panel.dta” que contiene data sobre el logaritmo del ingreso mínimo subjetivo: IMS (¿cuál es el ingreso mínimo que ud. considera necesario para satisfacer sus necesidades?). Se presume que el IMS aumenta en la medida que aumenta el ingreso observado. La hipótesis detrás es que personas que tienen más ingreso consideran que para satisfacer sus necesidades es necesario contar con mas recursos. Es decir, las necesidades del ser humano (o su valor) aumentan en la medida en que los ingresos (o riqueza) aumenta. Asimismo, se presume que el IMS aumenta con el tamaño de la familia. Es decir, a mayor número de miembros las presiones económicas aumentan por lo que es necesario contar con mayores ingresos para satisfacerlas. Sin embargo, en este tipo de aplicaciones existe la influencia de efectos no observables. Por ejemplo, hay gente que por naturaleza (o efectos sicológicos no observables) sentirá que necesita mas dinero para satisfacer sus necesidades. Tales efectos pueden no existir (lo que justifica una aplicación MCOC), pueden ser variables transversalmente y fijos en el tiempo (modelo MEF) o pueden ser aleatorios (MEA).

El objetivo del estudio es verificar estas dos hipótesis en un modelo de panel data para el periodo 2001 al 2006 para los hogares peruanos bajo los diferentes supuestos de los efectos no observables. Se disponen de 2,205 datos transversales para 6 años, lo que significa que en total la aplicación contiene 2,205x6=13,230 datos. Se estimará un panel corto (T>N), lineal (la variable dependiente es continua) y balanceado (no existen missing). Para empezar el análisis calculamos algunas variables descriptivas de las variables

```
. sum ly_s ly ln d_01 d_02 d_03 d_04 d_05 d_06
```

variable	Obs	Mean	Std. Dev.	Min	Max
ly_s	13230	6.53944	.7369081	2.302585	9.615806
ly	13230	8.715806	1.084943	4.465908	12.87422
ln	13230	1.383731	.5673864	0	2.772589
d_01	13230	.1666667	.3726921	0	1
d_02	13230	.1666667	.3726921	0	1
d_03	13230	.1666667	.3726921	0	1
d_04	13230	.1666667	.3726921	0	1
d_05	13230	.1666667	.3726921	0	1
d_06	13230	.1666667	.3726921	0	1

Ahora procedemos a testear las hipótesis bajo diferentes supuestos sobre los efectos no observables.

A. MCO combinado

Se estima el modelo

$$\log(y_{it}) = \alpha + \beta \log(y_{it}) + \theta \log(n_{it}) + \sum d_t D_t + e_{it}$$

donde las D_t corresponde a dicotómicas para cada uno de los años bajo análisis. Se propone estimar este modelo mediante MCOC. Para ello, utilice el siguiente comando

```
reg ly_s ly ln d_02 d_03 d_04 d_05 d_06
```

Source	SS	df	MS	Number of obs = 13230		
Model	2363.3372	7	337.619599	F(7, 13222) = 926.06		
Residual	4820.45432	13222	.364578303	Prob > F = 0.0000		
Total	7183.79151	13229	.543033601	R-squared = 0.3290		
				Adj R-squared = 0.3286		
				Root MSE = .6038		

ly_s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ly	.4987152	.0068869	72.41	0.000	.4852159	.5122146
ln	.0409898	.0099222	4.13	0.000	.0215409	.0604386
d_02	.2397933	.0181863	13.19	0.000	.2041455	.2754411
d_03	-.572642	.020884	-27.42	0.000	-.6135777	-.5317063
d_04	-.6353162	.0209953	-30.26	0.000	-.67647	-.5941623
d_05	-.6231284	.0210922	-29.54	0.000	-.6644722	-.5817847
d_06	-.6720618	.0214067	-31.39	0.000	-.714022	-.6301017
_cons	2.513242	.0513564	48.94	0.000	2.412576	2.613908

Los regresores incluidos y las dummies de tiempo incluidas explican alrededor del 33% de la varianza del IMS. Este R2 se podía también interpretar como el coeficiente de correlación ajustado entre los valores reales y los valores predichos de este modelo (esta interpretación será útil después). Antes de interpretar los coeficientes, sin embargo, resulta útil explorar si es que existe un proceso heterocedástico (lo que influirá en la significancia) para ello desarrollamos un test Breusch-Pagan con el comando “hettest” y obtenemos los siguientes resultados

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
Ho: Constant variance
Variables: fitted values of ly_s

chi2(1)      = 126.64
Prob > chi2   = 0.0000
```

Concluimos que el modelo estimado es caracterizado por heterocedasticidad. El valor Breusch-Pagan es 126.64 y la hipótesis nula de un proceso homocedástico del error es rechazada decisivamente por los datos para este modelo. Por ello, interpretar la significancia de los regresores estimados induciría a error. Se plantea por ello ajustar la matriz de la varianza-covarianza mediante el procedimiento de White / Huber (heteroscedasticity de forma desconocida). Para ello, estimamos el modelo usando el comando

```
. reg ly_s ly ln d_02 d_03 d_04 d_05 d_06, robust
```

```
Linear regression                               Number of obs = 13230
                                                F( 7, 13222) = 751.29
                                                Prob > F      = 0.0000
                                                R-squared    = 0.3290
                                                Root MSE    = .6038
```

ly_s	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
ly	.4987152	.0076289	65.37	0.000	.4837615	.513669
ln	.0409898	.0106629	3.84	0.000	.020089	.0618905
d_02	.2397933	.019581	12.25	0.000	.2014118	.2781748
d_03	-.572642	.0213132	-26.87	0.000	-.6144189	-.5308651
d_04	-.6353162	.0220717	-28.78	0.000	-.6785798	-.5920526

d_05		-.6231284	.022681	-27.47	0.000	-.6675865	-.5786703
d_06		-.6720618	.0227905	-29.49	0.000	-.7167345	-.6273892
_cons		2.513242	.0577557	43.52	0.000	2.400032	2.626451

Los coeficientes no cambian, pero se ajustan sus desviaciones estándar. Ahora sí, procedemos a interpretar los resultados.

- El coeficiente del ingreso está bien determinado y la estimación puntual es 0.5. El resultado es el esperado (en signo) y sugiere que una subida del 10% en el ingreso observado genera un aumento del IMS en 5%, manteniendo el resto de condiciones constante.
- El coeficiente del tamaño del hogar es también positivo y bien determinado. Así si el tamaño de la familia aumenta en 10%, el IMS aumenta en 0.4%, ceteris paribus.
- El efecto de las dummies temporales (efectos temporales) también son bien determinados aunque difíciles de interpretar. En general indican que el IMS ha caído con los años.

Es importante testear la significancia conjunta de estos regresores (dummies temporales) en la medida que es la forma en la que hemos introducido la heterogeneidad temporal no observada. Así testeamos

$H_0: d_2 = d_3 = d_4 = d_5 = d_6$

$H_a: H_0$ no es correcto

```
. test d_02 d_03 d_04 d_05 d_06
( 1) d_02 = 0
( 2) d_03 = 0
( 3) d_04 = 0
( 4) d_05 = 0
( 5) d_06 = 0
F( 5, 13222) = 466.01
Prob > F = 0.0000
```

Con lo que se concluye que existen efectos temporales no observados.

B. Estimador inter-grupo

Conviene estudiar la misma hipótesis utilizando el estimador inter-grupo. Así regresionamos

$$\log(y_s)_{it} = \alpha + \beta \log(y)_{it} + \theta \log(n)_{it} + e_{it}$$

Notese que las variables dicotómicas temporales se eliminan porque este es un estimador que analiza “solo” la variabilidad que existe entre los grupos. Así, se estima

```
. xtreg ly_s ly ln ,be i(hogar)

Between regression (regression on group means)   Number of obs   =   13230
Group variable: hogar                             Number of groups =   2205

R-sq:  within = 0.0056                               Obs per group: min =    6
        between = 0.5983                               avg =               6.0
        overall = 0.1808                               max =               6
```

sd(u_i + avg(e_i.))= .3667557 F(2,2202) = 1640.00
 Prob > F = 0.0000

ly_s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ly	.6455503	.0120323	53.65	0.000	.6219545	.6691461
ln	-.024466	.0163331	-1.50	0.134	-.0564959	.007564
_cons	.9468025	.0989728	9.57	0.000	.7527127	1.140892

Los resultados ahora arrojan que la variable ingresos sigue siendo significativa y en la dirección correcta, pero el tamaño de la familia ya no es significativo. En alguna medida el estimador inter-grupo revela los efectos de largo plazo, por lo que la no significancia del tamaño del hogar puede ser atribuido a que en el largo plazo esta variable no es importante. Sin embargo, hay que ser cuidadoso con esta conclusión debido a que solo se usan seis años (difícilmente revelen una relación de largo plazo) y además el modelo es sumamente austero (podrían haber otros determinantes). En todo caso, el unico regresos susceptible de ser interpretado es el ingreso cuyo estimador puntual es 0.7. Es decir, ante un aumento del 10% en el ingreso observado el IMS aumenta en 7%.

En contraste con el MCOC la interpretación del R² es menos evidente. Es decir, no necesariamente revela que % de la varianza de la dependiente es se puede explicar con las dependientes, más bien revela el cuadrado del coeficiente de correlación entre los valores predichos y los actuales (tal como se indicó previamente). Se tienen tres tipos de estimadores

$$R^2_{\text{overall}} = \text{cuadrado de la correlación}[\hat{y}_{it}, y_{it}] = 0.1808$$

$$\text{donde } \hat{y}_{it} = x_{it}'\beta_{\text{between}}$$

Es decir, la correlación ajustada entre el IMS predicho y el actual tomando en cuenta (para los valores actuales) toda la base datos. Para ello, el predicho se construye a partir de las estimaciones MCO – intergrupo y se comprara con toda la base de datos observados. Luego,

$$R^2_{\text{between}} = \text{cuadrado de la correlación}[\hat{y}_{i_B}, \bar{y}_i] = 0.5983$$

$$\text{donde } \hat{y}_{i_B} = \bar{x}_i'\beta_{\text{between}}$$

Es decir, la correlación ajustada entre el IMS predicho y el actual tomando en cuenta unicamente los promedios grupales (a lo largo del tiempo). Para ello, el predicho se construye a partir de las estimaciones MCO – intergrupo y se comprara con los promedios grupales observados. Este es el R² relevante por analizar en un contexto intergrupo. Luego,

$$R^2_{\text{within}} = \text{cuadrado de la correlación}[\hat{y}_{it_B} - \hat{y}_{i_B}, y_{it} - \bar{y}_i] = 0.0056$$

$$\text{donde } \hat{y}_{it_B} - \hat{y}_{i_B} = (x_{it} - \bar{x}_i)' \beta_{\text{between}}$$

Es decir, la correlación ajustada entre el IMS predicho y el actual tomando en cuenta la variación temporal de la data. Es decir, se tratan de predecir las desviaciones respecto al promedio temporal utilizando el estimador MCO – intergrupo.

Al momento de comprar los R2 se puede concluir que el estimador inter-grupo tiene un menor poder explicativo sobre la data total que el modelo MCOC (19% vs. 33%), lo cual es de suponer dada la significancia de las dummies temporales (que no aparecen en el segundo modelo). Luego, se observa que tiene un buen ajuste para explicar la variación intergrupo (60%). Esta es la medida relevante (se utiliza un modelo intergrupo para explicar variabilidad intergrupo). Asimismo, se observa que el estimador inter-grupo tiene poco poder para explicar la variabilidad intra-grupo. Esto es lógico suponer en la medida que el modelo correcto para estos efectos es el estimador inter-grupo.

C. Estimador intra-grupo

Conviene estudiar la misma hipótesis utilizando el estimador intra-grupo. Así regresionamos

$$\log(y_s)_{it} = \alpha_i + \beta \log(y)_{it} + \theta \log(n)_{it} + \sum d_t D_t + e_{it}$$

Se estima

```
. xtreg ly_s ly ln d_02 d_03 d_04 d_05 d_06, fe i(hogar)
```

Fixed-effects (within) regression	Number of obs	=	13230
Group variable: hogar	Number of groups	=	2205
R-sq: within = 0.0559	Obs per group: min	=	6
between = 0.3304	avg	=	6.0
overall = 0.2067	max	=	6
corr(u_i, xb) = 0.2865	F(7,11018)	=	93.21
	Prob > F	=	0.0000

ly_s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ly	.1116671	.0105843	10.55	0.000	.09092	.1324142
ln	.2130612	.0189224	11.26	0.000	.1759699	.2501524
d_02	.2507999	.0146505	17.12	0.000	.2220822	.2795175
d_03	.0037092	.0215397	0.17	0.863	-.0385124	.0459309
d_04	-.0470062	.0218016	-2.16	0.031	-.0897413	-.0042711
d_05	-.0250637	.0220343	-1.14	0.255	-.0682549	.0181274
d_06	-.0406546	.0227511	-1.79	0.074	-.0852508	.0039417
_cons	5.24772	.0780878	67.20	0.000	5.094654	5.400786
sigma_u	.50482081					
sigma_e	.4862629					
rho	.51871831	(fraction of variance due to u_i)				

F test that all u_i=0: F(2204, 11018) = 4.25 Prob > F = 0.0000

Nótese que las variables dummy temporales ahora si se pueden incorporar. Conviene especular un poco acerca de los resultados. Así, se observa que luego de corregir por heterogeneidad (transversal) no observada, la elasticidad del ingreso ha disminuido respecto al estimado de MCOC (0.1 vs 0.6) y el efecto del tamaño de la familia ha

aumentado (0.2 vs. 0.4). Del mismo modo, algunos de los efectos temporales son ahora no significativos. Sin embargo, en conjunto se observa que todavía son significativos

```
. test d_02 d_03 d_04 d_05 d_06
( 1) d_02 = 0
( 2) d_03 = 0
( 3) d_04 = 0
( 4) d_05 = 0
( 5) d_06 = 0

F( 5, 11018) = 75.51
Prob > F = 0.0000
```

Las medidas de ajuste R^2 revelan que el R_{within} (el relevante para este caso) es de apenas 0.06. Este mal resultado puede ser atribuido a la poca variabilidad temporal de la data incluida (el ingreso y el numero de miembros de la familia) lo que sugiere que necesitamos algunos regresores adicionales. Este problema de especificación puede generar efectos al momento de decidir entre los diferentes modelos (como se verá mas adelante). De momento interesa comparar los R^2 para el modelo inter-grupo e intra-grupo. Nótese que en este caso los calculos se realizan de la misma forma pero considerando parámetros MEF. Así, se puede observar que tanto el modelo intra-grupo como la alternativa inter-grupo tienen similares poderes explicativos sobre la variabilidad total de la data (0.2 vs. 0.18) y el poder de ambos es menor que el modelo MCOC. Luego, cada uno de ellos lo hace mejor sobre el tipo de variabilidad que intentan explicar y se observa que el estimador MEF es mejor para explicar la variabilidad inter-grupo que el modelo inter-grupo para explicar la variabilidad intra-grupo (0.33 vs. 0.006).

Luego, la correlación entre los efectos fijos y las variables explicativas es baja (0.287), esta correlación que sea baja o alta no tiene efectos sobre las propiedades de consistencia de los estimadores MEF, pero una elevada correlación hubiera tenido un impacto mayor sobre los valores puntuales de los resultados (los cambios hubieran sido mas dramáticos). La interpretación de una correlación baja es que la heterogeneidad no observada tiene una baja correlación con las variables incluidas en el modelo. Sin embargo, el % de la varianza que proviene de los efectos no observados es alta ($\rho=0.52$) por lo que no es de sorprender que el test F de significancia sobre estos efectos (4.25) acepte su inclusión (se favorece el uso de MEF sobre MCOC).

Los efectos fijos no son interpretables en sí, pero pueden ser estimados utilizando

```
. predict fe_est, u
. list fe_est
```

No se muestran dado que son 2,205 parámetros estimados

D. Estimador MEA

Ya se concluyo a favor del MEF sobre el MCOC, a pesar que el MCOC tenía un mayor poder explicativo. Asimismo se nota que la correlación con las explicativas incluida era bajo. Esto sugiere que tal vez un mejor supuesto sea efectos aleatorios. Para ello, se regresiona un modelo como

$$\log(y_s)_{it} = \alpha + \beta \log(y)_{it} + \theta \log(n)_{it} + \sum d_t D_t + e_{it}$$

```
. xtreg ly_s ly ln d_02 d_03 d_04 d_05 d_06, re i(hogar)
```

```
Random-effects GLS regression              Number of obs   =    13230
Group variable: hogar                     Number of groups  =     2205

R-sq:  within = 0.0428                    Obs per group:  min =      6
        between = 0.5689                      avg   =     6.0
        overall = 0.3220                      max   =      6

Random effects u_i ~ Gaussian              wald chi2(7)     =    2600.19
corr(u_i, x)      = 0 (assumed)            Prob > chi2      =     0.0000
```

ly_s	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ly	.3443076	.0082733	41.62	0.000	.3280923	.3605229
ln	.1097441	.0128291	8.55	0.000	.0845995	.1348887
d_02	.2441858	.0152509	16.01	0.000	.2142945	.2740771
d_03	-.3427119	.0196154	-17.47	0.000	-.3811574	-.3042664
d_04	-.4006136	.0197876	-20.25	0.000	-.4393967	-.3618305
d_05	-.384532	.0199383	-19.29	0.000	-.4236104	-.3454537
d_06	-.4201622	.0204186	-20.58	0.000	-.460182	-.3801424
_cons	3.603971	.0613006	58.79	0.000	3.483824	3.724117
sigma_u	.30838472					
sigma_e	.4862629					
rho	.28683562	(fraction of variance due to u_i)				

Al comprar los R2 se observa que el poder explicativo mejora. Luego, los coeficientes estimados están bien determinados (significativos y con el signo esperado). Se observa que este modelo arroja una elasticidad del ingreso observado sobre el IMS de 0.34 (entre el 0.5 y el 0.11 estimados previamente) y una elasticidad del tamaño de familia de 0.11 (más cercano al estimado MEF). Luego, las dummies temporales son significativas

Nótese que el supuesto implícito de la aplicación es que la correlación entre los efectos no observados y las explicativas es cero. Sin embargo, es necesario testear la presencia de efectos aleatorios. Se procede con el comando

```
. xttest0
```

Breusch and Pagan Lagrangian multiplier test for random effects

```
ly_s[hogar,t] = xb + u[hogar] + e[hogar,t]
```

Estimated results:

	Var	sd = sqrt(Var)
ly_s	.5430336	.7369081
e	.2364516	.4862629
u	.0951011	.3083847

Test: Var(u) = 0

```
chi2(1) = 2454.11
Prob > chi2 = 0.0000
```

La hipótesis nula de que no existen efectos aleatorios se rechaza, por lo que vale la pena su inclusión (esto favorece el uso de MEA frente al MCOC).

De este modo, tenemos dos posibles modelos MEA y MEF, para testear cual es el favorito se utiliza el test de Hausman. Se procede de la siguiente manera

. xtreg ly_s ly ln d_02 d_03 d_04 d_05 d_06, fe i(hogar)

Fixed-effects (within) regression
 Group variable: hogar
 Number of obs = 13230
 Number of groups = 2205
 R-sq: within = 0.0559
 between = 0.3304
 overall = 0.2067
 Obs per group: min = 6
 avg = 6.0
 max = 6
 F(7,11018) = 93.21
 Prob > F = 0.0000
 corr(u_i, xb) = 0.2865

ly_s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ly	.1116671	.0105843	10.55	0.000	.09092	.1324142
ln	.2130612	.0189224	11.26	0.000	.1759699	.2501524
d_02	.2507999	.0146505	17.12	0.000	.2220822	.2795175
d_03	.0037092	.0215397	0.17	0.863	-.0385124	.0459309
d_04	-.0470062	.0218016	-2.16	0.031	-.0897413	-.0042711
d_05	-.0250637	.0220343	-1.14	0.255	-.0682549	.0181274
d_06	-.0406546	.0227511	-1.79	0.074	-.0852508	.0039417
_cons	5.24772	.0780878	67.20	0.000	5.094654	5.400786
sigma_u	.50482081					
sigma_e	.4862629					
rho	.51871831	(fraction of variance due to u_i)				

F test that all u_i=0: F(2204, 11018) = 4.25 Prob > F = 0.0000

. est store fixed

. xtreg ly_s ly ln d_02 d_03 d_04 d_05 d_06, re i(hogar)

Random-effects GLS regression
 Group variable: hogar
 Number of obs = 13230
 Number of groups = 2205
 R-sq: within = 0.0428
 between = 0.5689
 overall = 0.3220
 Obs per group: min = 6
 avg = 6.0
 max = 6
 Random effects u_i ~ Gaussian
 corr(u_i, x) = 0 (assumed)
 wald chi2(7) = 2600.19
 Prob > chi2 = 0.0000

ly_s	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ly	.3443076	.0082733	41.62	0.000	.3280923	.3605229
ln	.1097441	.0128291	8.55	0.000	.0845995	.1348887
d_02	.2441858	.0152509	16.01	0.000	.2142945	.2740771
d_03	-.3427119	.0196154	-17.47	0.000	-.3811574	-.3042664
d_04	-.4006136	.0197876	-20.25	0.000	-.4393967	-.3618305
d_05	-.384532	.0199383	-19.29	0.000	-.4236104	-.3454537
d_06	-.4201622	.0204186	-20.58	0.000	-.460182	-.3801424
_cons	3.603971	.0613006	58.79	0.000	3.483824	3.724117
sigma_u	.30838472					
sigma_e	.4862629					
rho	.28683562	(fraction of variance due to u_i)				

. hausman fixed

---- Coefficients ----				
	(b) fixed	(B) .	(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
ly	.1116671	.3443076	-.2326405	.0066015
ln	.2130612	.1097441	.1033171	.0139094
d_02	.2507999	.2441858	.0066141	.
d_03	.0037092	-.3427119	.3464211	.0088991
d_04	-.0470062	-.4006136	.3536074	.009152
d_05	-.0250637	-.384532	.3594683	.0093794
d_06	-.0406546	-.4201622	.3795076	.0100346

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

```
chi2(7) = (b-B)'[(V_b-V_B)^(-1)](b-B)
        = 1249.69
Prob>chi2 = 0.0000
(V_b-V_B is not positive definite)
```

Así, se rechaza el modelo MEA a favor del MEF y esta pasaría a ser nuestra especificación central. Sin embargo, la matriz varianza covarianza no es semidefinida positiva, por lo que el resultado de Hausman no se puede interpretar correctamente (una de las propiedades asintóticas del test ha sido violada). Por ello, cuando salga este resultado se recomienda interpretar los resultados con cuidado (quizas sea necesario dotar de mayor estructura a los modelos). Sin embargo, si obviamos este resultado en nuestra aplicación el MEF sería el modelo favorito y el MEA nuestro resultado para proveer robustez. Ojo que el test de Breusch and Pagan para determinar la existencia de efectos aleatorios (que se acepta) no contradice los resultados del Hausman. El primer test indica que estos efectos existen y el segundo que tales efectos están correlacionados con las independientes del modelo.

Un correcto reporte de resultados sería utilizar los resultados MEF como estimación central y analizar desviaciones respecto al resultado MEA (no existen en términos de signo) aunque sí en valor (sobre todo para el ingreso observado). La estimación MCOC es útil simplemente a nivel exploratorio.