

Estimación Probit en gret1

Microeconomía Cuantitativa

R. Mora

Departamento de Economía
Universidad Carlos III de Madrid

Esquema

- 1 Introducción
- 2 Probit en gret1
- 3 El modelo Logit

El modelo Probit y su estimación MV

El modelo Probit

- $U_m = \beta_m x_m + \varepsilon_m$
- $U_h = \beta_h x_h + \varepsilon_h$
- $\varepsilon_h, \varepsilon_m \sim N(0, \Sigma)$ tal que $\varepsilon \sim N(0, 1)$
- $Pr(y = 1) = \Phi(\beta x)$ donde Φ es la fda de la normal estándar

$$\hat{\beta}^{ML} = \arg \max \sum_i \{y_i \log(\Phi(\beta x_i)) + (1 - y_i) \log(1 - \Phi(\beta x_i))\}$$

- en gret1, se utiliza un algoritmo quasi-Newton (el algoritmo BFGS)

Comandos básicos en gretl para la estimación Probit

- `probit`: computa Máxima Verosimilitud para el modelo Probit
 - `omit/add`: contrastes de exclusión
 - `$yhat`: estima la probabilidad del evento
 - `$lnl`: proporciona la log-verosimilitud del último modelo estimado
 - `logit`: computa Máxima Verosimilitud para el modelo alternativo logit
-
- in esta Sesión, aprenderemos a usar `probit`, `$yhat` y `logit`

probit *depuar* *indvars* --robust --verbose --p-values

- *depuar* debe ser binaria $\{0,1\}$ (de lo contrario, o aparece un error o se estima otro modelo)
- las pendientes (“slopes”) se computan en las medias muestrales
- las desviaciones típicas se obtienen con la inversa del hessiano
- el output muestra el estadístico χ_q^2 de la nula de que todos los coeficientes son cero salvo la constante
- opciones:
 - 1 --robust: matriz de covarianzas robusta a error de especificación
 - 2 --p-values: muestra los p-valores en vez de las “slopes”
 - 3 --verbose: muestra información sobre todas las iteraciones

Ejemplo: Datos Simulados

El Modelo Probit

- $U_m = 0.3 + 0.05 * educ + 0.5 * kids + \varepsilon_m$
- $U_h = 0.8 - 0.02 * educ + 2 * kids + \varepsilon_h$
- $\varepsilon_h, \varepsilon_m \sim N(0, \Sigma)$ such that $\varepsilon \sim N(0, 1)$

- la educación proporciona utilidad si trabajas y desutilidad si no
- tener un niño proporciona más utilidad si no trabajas
- $\beta_x = -0.5 + 0.07 * educ - 1.5 * kids$

La salida del comando probit

```
probit work const educ kids
```

Convergence achieved after 6 iterations

Model 1: Probit, using observations 1-5000

Dependent variable: work

	coefficient	std. error	t-ratio	slope
const	-0.434462	0.0812490	-5.347	
educ	0.0659247	0.00576068	11.44	0.0240325
kids	-1.47598	0.0407604	-36.21	-0.521270

Mean dependent var	0.366800	S.D. dependent var	0.364545
McFadden R-squared	0.233290	Adjusted R-squared	0.232378
Log-likelihood	-2519.525	Akaike criterion	5045.049
Schwarz criterion	5064.601	Hannan-Quinn	5051.902

Number of cases 'correctly predicted' = 3859 (77.2%)

$f(\beta'x)$ at mean of independent vars = 0.365

Likelihood ratio test: Chi-square(2) = 1533.26 [0.0000]

		Predicted	
		0	1
Actual	0	2495	671
	1	470	1364

Prediciendo probabilidades

Computando $\hat{\Pr}(y_i = 1 | x_i)$

```
genr p_hat = $yhat
```

- para cada observación, si $\hat{\Pr}(y_i = 1 | x_i) > 0.5$ entonces $\hat{y}_i = 1$
- “percent correctly predicted” es el % para el que \hat{y}_i iguala y_i
- es posible obtener altos % en modelos inservibles
 - supón que $\Pr(y_i = 0) = 0.9$
 - predecir siempre $\hat{y}_i = 0$ conllevará $\approx 90\%$ de predicciones correctas!

Entendiendo los coeficientes y las pendientes

- la columna “coefficient” incluye las estimaciones ML $\hat{\beta}^{ML}$
- a diferencia del modelo lineal, en el modelo Probit los coeficientes no capturan el efecto marginal sobre el output de una variación del control
 - si el control x_j es continuo, $\frac{\partial Pr(y=1)}{\partial x_j} = \phi(\beta x) \beta_j$
 - si el control x_j es discreto, $\Delta Pr(work = 1) = \Phi(\beta x_1) - \Phi(\beta x_0)$
- puesto que el modelo no es lineal, los efectos marginales dependen de los valores de otros controles
- la columna “slopes” incluye los efectos marginales computados en las medias muestrales de los controles

Efectos marginales individuales: cambios discretos

queremos estimar el cambio de la probabilidad cuando x pasa de valer x_0 a x_1

Cambio discreto

- tras estimar el modelo, guarda el vector $\hat{\beta}^{ML}$ en un vector
- genera una matriz con los controles bajo el escenario 0, x_0 , y otra con los controles bajo el escenario 1, x_1
- computa las funciones índices $\hat{\beta}^{ML}_{x_0}$ y $\hat{\beta}^{ML}_{x_1}$
- genera los efectos individuales

$$\Phi\left(\hat{\beta}^{ML}_{x_1}\right) - \Phi\left(\hat{\beta}^{ML}_{x_0}\right)$$

Ejemplo: el efecto de tener un niño

```
# marginal effects of having a kid
genr beta=$coeff
series kids0=0
matrix x0={const,educ,kids0}
series kids1=1
matrix x1={const,educ,kids1}
series x1b = x1*beta
series x0b = x0*beta
series Mg_kid = cdf(N,x1b)-cdf(N,x0b)
summary Mg_kid --by=educ --simple
summary Mg_kid --simple
```

```
summary Mg_kid --by=educ --simple
```

```
educ = 8 (n = 759) : -0.45370  
educ = 12 (n = 2279): -0.50782  
educ = 16 (n = 1499): -0.53638  
educ = 21 (n = 463) : -0.52950
```

- aunque la función índice es lineal, el efecto de tener un niño cambia con la educación
- mayor educación hace que los individuos tiendan a tener índices βx más cercanos a 0.5 (la pendiente probit es máxima en 0.5)
- tal y como está, el modelo no hace que tener un niño afecte más a las mujeres con menor educación
- ¿cómo podríamos crear tal efecto?

Efectos marginales individuales: cambios infinitesimales

Aproximación por cálculo infinitesimal

- guarda las estimaciones $\hat{\beta}^{ML}$ en un vector
- genera una matriz con los valores de todos los controles, x
- computa la función índice $\hat{\beta}^{ML}x$
- genera la aproximación: $\phi\left(\hat{\beta}^{ML}x\right)\hat{\beta}_j^{ML}$

Ejemplo de cálculo infinitesimal

```
genr beta=$coeff
matrix x={const,educ,kids}
series xb=x*beta
genr meanXb=mean(xb)
series Mg_educ_slope=pdf(N,meanXb)*$coeff(educ)      # this is the slope in gretl output
series Mg_educ_cal=pdf(N,xb)*$coeff(educ)           # this is the individual's marginal effect
summary Mg_educ_slope Mg_educ_cal --by=kids --simple
```

kids = 0 (n = 2035):

	Mean	Minimum	Maximum	Std. Dev.
Mg_educ_slope	0.025214	0.025214	0.025214	0.0000
Mg_educ_cal	0.024004	0.016797	0.027284	0.0028914

kids = 1 (n = 2965):

	Mean	Minimum	Maximum	Std. Dev.
Mg_educ_slope	0.025214	0.025214	0.025214	0.0000
Mg_educ_cal	0.016362	0.010516	0.024298	0.0038762

El supuesto Logit

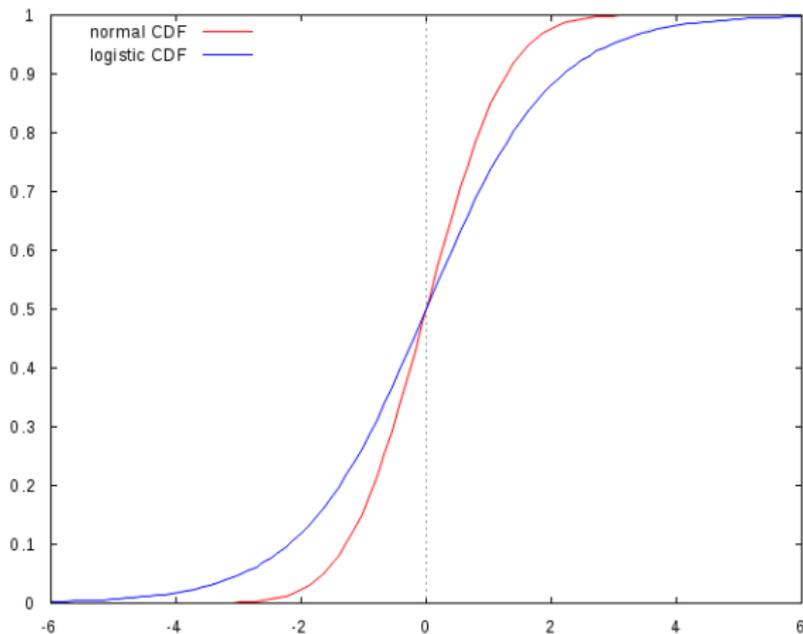
- $U_m = \beta_m^0 + \beta_m^e educ + \beta_m^k kids + \varepsilon_m$
- $U_h = \beta_h^0 + \beta_h^e educ + \beta_h^k kids + \varepsilon_h$

Supuesto Logit: $\varepsilon_h - \varepsilon_m = \varepsilon \sim \text{Logistic}$

- $Pr(\text{work} = 1) = \frac{\exp(\beta_0 + \beta_e educ + \beta_k kids)}{1 + \exp(\beta_0 + \beta_e educ + \beta_k kids)}$
- Esta probabilidad es muy fácil de computar

Logit vs. Probit

Las colas del Logit son más gruesas



Las estimaciones de Logit & Probit no son comparables directamente...

probit const educ kids

Convergence achieved after 6 iterations

Model 1: Probit, using observations 1-5000
 Dependent variable: work

	coefficient	std. error	t-ratio	slope
const	-0.434462	0.0812490	-5.347	
educ	0.0659247	0.00576068	11.44	0.0240325
kids	-1.47598	0.0407604	-36.21	-0.521270

Mean dependent var 0.366800 S.D. dependent var 0.364545
 McFadden R-squared 0.233290 Adjusted R-squared 0.232378
 Log-likelihood -2519.525 Akaike criterion 5045.049
 Schwarz criterion 5064.601 Hannan-Quinn 5051.902

Number of cases 'correctly predicted' = 3859 (77.2%)
 f(beta'x) at mean of independent vars = 0.365
 Likelihood ratio test: Chi-square(2) = 1533.26 [0.0000]

	Predicted	
	0	1
Actual 0	2495	671
1	470	1364

logit const educ kids

Convergence achieved after 5 iterations

Model 3: Logit, using observations 1-5000
 Dependent variable: work

	coefficient	std. error	t-ratio	slope
const	-0.785736	0.137875	-5.699	
educ	0.113003	0.00995293	11.35	0.0248565
kids	-2.45293	0.0712432	-34.43	-0.523436

Mean dependent var 0.366800 S.D. dependent var 0.219963
 McFadden R-squared 0.233181 Adjusted R-squared 0.232268
 Log-likelihood -2519.884 Akaike criterion 5045.768
 Schwarz criterion 5065.319 Hannan-Quinn 5052.620

Number of cases 'correctly predicted' = 3859 (77.2%)
 f(beta'x) at mean of independent vars = 0.220
 Likelihood ratio test: Chi-square(2) = 1532.54 [0.0000]

	Predicted	
	0	1
Actual 0	2495	671
1	470	1364

pero los efectos marginales, las columnas "slope", lo son

Resumen

- `gretl` permite la estimación del modelo Probit de la utilidad aleatoria por MV
- no todos los parámetros del modelo de utilidad aleatoria pueden ser estimados
- el modelo Probit identifica cómo cada control afecta la probabilidad de $y = 1$
- la estimación MV del modelo Logit también es posible en `gretl`