

# Estimación Tobit en gret1

## Microeconomía Cuantitativa

R. Mora

Departamento de Economía  
Universidad Carlos III de Madrid

# Esquema

- 1 Introducción
- 2 Tobit en gretl
- 3 ML de un modelo Interval Regression

# El modelo Tobit y la estimación ML

## El modelo Tobit

- $h^* = \beta x + \varepsilon$
- $\varepsilon \sim N(0, \sigma^2)$
- $\begin{cases} \text{if } h^* > 0 \Rightarrow h = \beta x + \varepsilon \\ \text{if } h^* \leq 0 \Rightarrow h = 0 \end{cases}$

$$\hat{\beta}^{ML} = \arg \max \sum_i \left\{ 1(h_i > 0) \log \left( \left( \frac{1}{\sigma} \right) \phi \left( \frac{h_i - \beta x_i}{\sigma} \right) \right) + 1(h_i = 0) \log \left( 1 - \Phi \left( \frac{\beta x_i}{\sigma} \right) \right) \right\}$$

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

## Comandos básicos en gretl para la estimación Tobit

- `tobit`: computa la estimación del modelo Tobit por ML
  - `omit/add`: contrasta la significatividad conjunta
  - `$yhat`: estima la variable dependiente
  - `$lnl`: computa la log-verosimilitud del último modelo estimado
  - `intreg`: computa la estimación ML del modelo de regresión con variable censurada en intervalos (interval regression model) y errores normales
- 
- en esta Sesión vamos a aprender a utilizar `tobit` y `intreg`

## `tobit depvar indvars --verbose`

- “censura”: la variable dependiente toma valores no-negativos, con el 0 reservado para las observaciones censuradas
- para otros casos (censura por arriba, o un punto de masa diferente a 0) se debe redefinir la variable dependiente
- para censura por dos lados, se puede utilizar `intreg`
- es posible ver todas las iteraciones con `--verbose`
- el output muestra el test  $\chi_q^2$  de la nula que todas las pendientes son iguales a 0
- por defecto, las desviaciones típicas se calculan con la inversa negativa del Hessiano

## Ejemplo: datos simulados


### El modelo Tobit

- $h^* = 10 + 0.5 * educ - 5 * kids + \varepsilon$
- $\varepsilon \sim N(0, 49)$

- la educación te hace querer trabajar más horas
- tener niños te hace querer trabajar menos horas
- $\beta x = 10 + 0.5 * educ - 5 * kids$
- $\sigma = 7$


# Horas Observadas vs. Horas Deseadas

$$h^* = 10 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$




# Distribución de Horas Deseadas

$$h^* = 10 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$



# Censura en el modelo Tobit

$$h^* = 5 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$



## ols con muestra completa

$$h^* = 5 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$

Model 1: OLS, using observations 1-1500

Dependent variable: h

	coefficient	std. error	t-ratio	p-value	
const	6.60589	0.757742	8.718	7.39e-18	***
educ	0.387944	0.0751737	5.161	2.79e-07	***
kids	-4.48766	0.382296	-11.74	1.68e-30	***
Mean dependent var	7.370101	S.D. dependent var	6.413578		
Sum squared resid	54501.48	S.E. of regression	6.033833		
R-squared	0.116094	Adjusted R-squared	0.114913		
F(2, 1497)	98.30967	P-value(F)	7.67e-41		
Log-likelihood	-4822.980	Akaike criterion	9651.960		
Schwarz criterion	9667.899	Hannan-Quinn	9657.898		

## ols con muestra restringida

$$h^* = 5 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$

Model 2: OLS, using observations 1-1223

Dependent variable: h

	coefficient	std. error	t-ratio	p-value
const	7.35385	0.773674	9.505	1.02e-20 ***
educ	0.333273	0.0764336	4.360	1.41e-05 ***
kids	-2.84425	0.389046	-7.311	4.79e-13 ***
Mean dependent var	9.134221	S.D. dependent var	5.678892	
Sum squared resid	37539.67	S.E. of regression	5.547091	
R-squared	0.047441	Adjusted R-squared	0.045879	
F(2, 1220)	30.38012	P-value(F)	1.33e-13	
Log-likelihood	-3829.194	Akaike criterion	7664.387	
Schwarz criterion	7679.715	Hannan-Quinn	7670.156	

## La salida de tobit

$$h^* = 5 + 0.5 * educ - 5 * kids + \varepsilon, \varepsilon \sim N(0, 49)$$

Function evaluations: 48  
Evaluations of gradient: 9

Model 3: Tobit, using observations 1-1500  
Dependent variable: h

	coefficient	std. error	z	p-value
const	4.89145	0.893211	5.476	4.34e-08 ***
educ	0.461985	0.0891748	5.181	2.21e-07 ***
kids	-4.44067	0.470267	-9.443	3.63e-21 ***
Mean dependent var	7.447435	S.D. dependent var	6.233858	
Censored obs	277	sigma	7.089319	
Log-likelihood	-4412.070	Akaike criterion	8832.141	
Schwarz criterion	8853.394	Hannan-Quinn	8840.058	

Test for normality of residual -

Null hypothesis: error is normally distributed  
Test statistic: Chi-square(2) = 3.57203  
with p-value = 0.167627

# Prediciendo las horas de trabajo entre los que trabajan


computando  $\hat{h}_i^*$  y  $\hat{h}_i$

- $\hat{h}_i^*$ : genr h\_star\_hat=\$yhat
- para cada  $i$ ,  $\hat{h}_i = \max \{0, \hat{\beta}x_i\}$

$E[h | h > 0, x]$

- $E[h | h > 0, x] = \beta x + E[\varepsilon | \beta x + \varepsilon > 0, x]$
- se puede demostrar que:  $E[h | h > 0, x] = \beta x + \sigma \frac{\phi(\frac{\beta x}{\sigma})}{\Phi(\frac{\beta x}{\sigma})}$
- $\frac{\phi(\frac{\beta x}{\sigma})}{\Phi(\frac{\beta x}{\sigma})}$  es la inversa del ratio de Mills (John Mills en realidad usó  $\frac{1 - \Phi(\frac{\beta x}{\sigma})}{\phi(\frac{\beta x}{\sigma})}$ )

# La inversa del ratio de Mills



a mayor  $\frac{\beta x}{\sigma}$ , menor necesidad de corrección (menor probabilidad de censura)

# Prediciendo las horas observadas de trabajo

$E[h|x]$

- $E[h|x] = \Pr(h > 0) E[h|h > 0, x]$
- se puede demostrar que:  $E[h|x] = \Phi\left(\frac{\beta x}{\sigma}\right) \left[\beta x + \sigma \frac{\phi(\beta x)}{\Phi(\beta x)}\right]$

# Entendiendo las pendientes

- las estimaciones de las pendientes,  $\hat{\beta}$ , nos dan los efectos marginales del número deseado de horas
- a veces, queremos estimar el efecto sobre la probabilidad de trabajar y sobre el número real de horas trabajadas

# Efectos marginales algebraicos

## Probabilidad de participar

- $$\frac{\partial \Pr(h_i > 0)}{\partial x_j} = \phi\left(\frac{\beta x}{\sigma}\right) \left(\frac{\beta_j}{\sigma}\right)$$

## Horas realmente trabajadas

- $$\frac{\partial E(h_i|x)}{\partial x_j} = \beta_j \Phi\left(\frac{\beta x}{\sigma}\right)$$
- se pueden obtener aproximaciones con OLS con la muestra completa

## Efectos marginales individuales: un cambio discreto

- a veces queremos computar los efectos individuales

### Cambio discreto

- almacene los coeficientes estimados en un vector
- genere la matriz con los controles bajo el escenario 0,  $x_0$ , y la matriz del escenario 1,  $x_1$
- prediga  $\hat{\beta}^{ML}_{x_0}$  y  $\hat{\beta}^{ML}_{x_1}$
- simule la censura
- genere los efectos marginal individuales

# Ejemplo: el efecto de tener un niño adicional

```
# numerical individual marginal effects: having an extra kid
genr beta=$coeff
genr kids1=kids+1
matrix x0={const,educ,kids}
matrix x1={const,educ,kids1}
series h0 = (x0*beta>0)*x0*beta
series h1 = (x1*beta>0)*x1*beta
series Mg_kid=h1-h0
summary Mg_kid --by=educ --simple
```

summary Mg\_kid --by=educ --simple

también el efecto es menor con mayor educación

	Mean	Minimum	Maximum	Std. Dev.
educ = 8	-9.4738	-9.4738	-9.4738	0.0000
educ = 12	-7.1477	-11.164	-5.9182	2.2237
educ = 16	-5.0951	-7.6081	-2.3627	2.6231
educ = 21	-4.4750	-4.4750	-4.4750	0.0000

# El modelo Interval Regression

$$m_i \leq x_i\beta + \varepsilon_i \leq M_i$$

- de la variable dependiente solo se observa que pertenece a un intervalo
- en la práctica, cada observación pertenece a uno de los siguientes casos:
  - acotada por la izquierda
  - acotada por la derecha
  - acotada
  - observación puntual

## El modelo Interval Regression en gret1

```
intreg minvar maxvar X
```

- `minvar` contiene  $m_i$ , con NAs para observaciones no-acotadas por la izquierda
- `maxvar` contiene  $M_i$ , con NAs para observaciones no-acotadas por la derecha
- puede que  $m_i$  sea igual a  $M_i$  para algunas observaciones
- los errores estándar se computan usando la inversa negativa del Hessiano
- si la flag `--robust` está activada, estimadores sandwich de los errores estándar
- es fácil computar el ratio de verosimilitudes

## Un ejemplo

```
nulldata 100
# generate artificial data
set seed 201449
x = normal()
epsilon = 0.2*normal()
ystar = 1 + x + epsilon
lo_bound = floor(ystar)
hi_bound = ceil(ystar)
# run the interval model
intreg lo_bound hi_bound const x
```

# La salida intreg

```
Model 1: Interval estimates, using observations 1-100
Lower limit: lo_bound, Upper limit: hi_bound
```

	coefficient	std. error	z	p-value
const	0.977619	0.0360159	27.14	2.97e-162 ***
x	0.993708	0.0375009	26.50	1.02e-154 ***

Chi-square(1)	702.1575	p-value	1.0e-154
Log-likelihood	-40.45572	Akaike criterion	86.91144
Schwarz criterion	94.72695	Hannan-Quinn	90.07452

```
sigma = 0.225354
Left-unbounded observations: 0
Right-unbounded observations: 0
Bounded observations: 100
Point observations: 0
```

```
Test for normality of residual -
Null hypothesis: error is normally distributed
Test statistic: Chi-square(2) = 27.391
with p-value = 1.1275e-06
```

## Resumen

- gretl permite estimación ML para el modelo Tobit
- el modelo Tobit identifica cómo afecta cada control la probabilidad de participar y, si participa, el efecto marginal sobre la variable dependiente
- el modelo interval regression por ML también se puede estimar en gretl