

Modelos ordinales en gret1

Microeconomía Cuantitativa

R. Mora

Departamento of Economía
Universidad Carlos III de Madrid

Esquema

- 1 Introducción
- 2 Probit ordinal en gretl
- 3 Efectos marginales
- 4 Efectos sobre la variable ordinal

Introduction

El Probit ordenado y la estimación MV

- Considera m resultados observados: $y = 0, 1, \dots, m$.
- Considera un modelo de variable latente sin constante:

$$y^* = x'\beta + \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, 1)$$

- Define $m - 1$ puntos de corte: $\alpha_1 < \dots < \alpha_{m-1}$
- No observamos y^* , pero observamos elecciones según la siguiente regla

$$y = 0 \text{ if } y^* \leq \alpha_1$$

$$y = 1 \text{ if } \alpha_1 < y^* \leq \alpha_2$$

⋮

$$y = m \text{ if } \alpha_{m-1} < y^*$$

Estimación por MV

- Puesto que:

$$\Pr(y = 0|x) = \Pr(x'\beta + \varepsilon \leq \alpha_1) = 1 - \Phi(x'\beta - \alpha_1)$$

$$\Pr(y = 1|x) = \Phi(x'\beta - \alpha_1) - \Phi(x'\beta - \alpha_2)$$

⋮

$$\Pr(y = m|x) = \Phi(x'\beta - \alpha_{m-1})$$

- Entonces, para una muestra de N observaciones, la verosimilitud es:

$$L(b) = \prod_{i=1}^N \left\{ (1 - \Phi(x_i'b - \alpha_1))^{1(y_i=0)} \times \right. \\
\left. (\Phi(x_i'b - \alpha_1) - \Phi(x_i'b - \alpha_2))^{1(y_i=1)} \times \dots \times \right. \\
\left. (\Phi(x_i'b - \alpha_{m-1}))^{1(y_i=m)} \right\}$$

Comandos básicos en gretl para la estimación del probit Ordinal

- `probit`: estima por MV el modelo probit ordinal si la variable dependiente no es binaria pero es discreta
 - `omit/add`: contrasta tests de significatividad
 - `$yhat`: proporciona estimaciones de la variable latente
 - `$lnl`: proporciona la log-verosimilitud del último modelo estimado
 - `logit`: estima por MV el modelo logit ordinal si la variable dependiente no es binaria pero es discreta
-
- en esta Sesión vamos a aprender a utilizar el comando `probit` para estimar modelos probit ordinales

Probit ordinal en gret1

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

- *depuar* debe tomar valores enteros no negativos, o estar explícitamente marcada como discreta.
 - Caso de que tenga valores no enteros, es recodificada.
- por defecto, los errores estándar se obtienen con la inversa del opuesto del hesiano
- opciones:
 - 1 --robust: matriz de covarianzas robusta
 - 2 --verbose: muestra todos los pasos del algoritmo de maximización

Estimaciones

- Se obtienen estimaciones MV para los coeficientes β y para los valores o puntos de corte α_m .
 - éstos se representan en gretl como cut1, cut2, etc.
- $\$uhat$ da los residuos generalizados; $\$yhat$ da $x'\hat{\beta}$.
 - It is thus possible to compute an unbiased estimate of the latent variable U simply by adding the two together.
- el output muestra el test χ_q^2 para la nula de que todas las pendientes son iguales a cero

Ejemplo: Datos simulados

Actividad

- $y^* = 0.07 \times educ - 1.0 \times kids + \varepsilon$, donde $\varepsilon \sim \mathcal{N}(0, 1)$

$y = 0$ if $y^* \leq 0.5$ (inactiva)

$y = 1$ if $0.5 < y^* \leq 2.5$ (tiempo parcial)

$y = 2$ if $2.5 < y^*$ (tiempo completo)

- la educación da más utilidad cuanto más trabajas
- tener un niño da más utilidad cuanto menos trabajas

probit *work educ kids*

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

	coefficient	std. error	z	p-value	
educ	0.0795682	0.00402396	19.77	5.03e-87	***
kids	-0.955750	0.0366670	-26.07	8.94e-150	***
cut1	0.656064	0.0677545	9.683	3.56e-22	***
cut2	2.63981	0.0764705	34.52	3.93e-261	***
Mean dependent var	0.657000	S.D. dependent var	0.599852		
Log-likelihood	-3903.096	Akaike criterion	7814.193		
Schwarz criterion	7840.262	Hannan-Quinn	7823.330		

Number of cases 'correctly predicted' = 3107 (62.1%)
Likelihood ratio test: Chi-square(2) = 1054.95 [0.0000]

Test for normality of residual -
Null hypothesis: error is normally distributed
Test statistic: Chi-square(2) = 0.108987
with p-value = 0.946965

El MLP puede dar malos resultados

Model 2: OLS, using observations 1-5000
Dependent variable: work
Heteroskedasticity-robust standard errors, variant HCl

	coefficient	std. error	t-ratio	p-value	
const	0.251884	0.0292683	8.606	1.00e-17	***
educ	0.0354561	0.00169676	20.90	4.97e-93	***
kids	-0.431542	0.0152135	-28.37	3.02e-164	***
Mean dependent var	0.657000	S.D. dependent var	0.599852		
Sum squared resid	1457.253	S.E. of regression	0.540024		
R-squared	0.189855	Adjusted R-squared	0.189531		
F(2, 4997)	651.6896	P-value(F)	3.2e-252		
Log-likelihood	-4012.480	Akaike criterion	8030.960		
Schwarz criterion	8050.512	Hannan-Quinn	8037.813		

omit no funciona para la significatividad conjunta

- no podemos usar omit para contrastar la significatividad conjunta de todos las pendientes con el test de Wald

```
omit educ kids -wald
```

```
No independent variables left after omissions
```

```
Error executing script: halting  
> omit educ kids --wald
```

- el resultado del test LR aparece en el output, y además podemos calcularlo “a mano”

Test LR para la significatividad de las pendientes

```
# estimating unrestricted model and storing loglikelihood
probit work educ kids --quiet
scalar lur= $lnl

# estimating restricted model and storing loglikelihood
probit work const --quiet
scalar lr= $lnl

# computing the LR statistic and p-value
scalar LR=2*(lur-lr)
scalar pval = pvalue(X, 1, LR)
```

- el resultado coincide con el output en probit:

```
? printf " LR = %.8g\n p-value = %.8g\n", LR,pval
LR = 1054.9521
p-value = 2.0415848e-231
```

Efectos marginales

Efectos parciales sobre las probabilidades

- Como interpretar los resultados?

- interpretar la ecuación de la variable latente

- $$\frac{\partial E(y|x)}{\partial x_j} = \frac{\partial \Pr(y=0|x)}{\partial x_j} \times 0 + \frac{\partial \Pr(y=1|x)}{\partial x_j} \times 1 + \dots + \frac{\partial \Pr(y=m|x)}{\partial x_j} \times m$$

- Alternativamente, podríamos computar los efectos sobre las probabilidades de los diferentes categorías ordenadas
 - si x_j es discreta computamos como en el caso binario de un cambio discreto en x_j .
 - en general, los efectos parciales para las probabilidades intermedias son pequeños y no significativos.

Efectos Marginales: Cambio discreto

Cambio discreto de x_0 a x_1

- estima el modelo y guarda $\hat{\beta}$ y $\hat{\alpha}$
- predice la función índice en los dos puntos $x'_0\hat{\beta}$ y $x'_1\hat{\beta}$
- genera los efectos marginales individuales

$$\Delta\widehat{\text{Pr}}(y = 0|x) = \Phi(x'_0\hat{\beta} - \hat{\alpha}_1) - \Phi(x'_1\hat{\beta} - \hat{\alpha}_1) = -\Delta\Phi(x'\hat{\beta} - \hat{\alpha}_1)$$

$$\Delta\widehat{\text{Pr}}(y = 1|x) = \Delta\Phi(x'\hat{\beta} - \hat{\alpha}_1) - \Delta\Phi(x'\hat{\beta} - \hat{\alpha}_2)$$

⋮

$$\Delta\widehat{\text{Pr}}(y = m|x) = \Delta\Phi(x'\hat{\beta} - \hat{\alpha}_{m-1})$$

- calcula las medias

Ejemplo: tener un niño *adicional*

```
# marginal effects of having an additional kid
probit work educ kids --quiet
genr beta=$coeff[1:2]
genr alpha=$coeff[3:4]
series kids0=kids
matrix x0={educ,kids0}
series kids1=kids0+1
matrix x1={educ,kids1}
series x1b = x1*beta
series x0b = x0*beta

series Mg_kid0 = (cdf(N,x0b-alpha[1])-cdf(N,x1b-alpha[1]))
series Mg_kid1 = (cdf(N,x1b-alpha[1])-cdf(N,x0b-alpha[1])) \
                 -(cdf(N,x1b-alpha[2])-cdf(N,x0b-alpha[2]))
series Mg_kid2 = (cdf(N,x1b-alpha[2])-cdf(N,x0b-alpha[2]))
```

summary *Mg_kid** --simple

```
summary Mg_kid* --simple
Summary statistics, using the observations 1 - 5000
```

	Mean	Minimum	Maximum	Std. Dev.
Mg_kid0	0.31409	0.13797	0.36398	0.057924
Mg_kid1	-0.25621	-0.31999	-0.13648	0.058980
Mg_kid2	-0.057872	-0.13917	-0.0014979	0.050060

- tener un niño adicional aumenta la probabilidad de no trabajar en más de 30 puntos porcentuales
- este incremento se produce a costa de reducciones de 25.6 puntos porcentuales en la probabilidad de trabajar a tiempo parcial y de 5.8 puntos porcentuales en la probabilidad de trabajar a tiempo completo

Efectos marginales: Cambios infinitesimales

Aproximación con cálculo

- estima el modelo y guarda $\widehat{\beta}$ y $\widehat{\alpha}$
- predice la función $x'\widehat{\beta}$ y calcula su media $\overline{x'\widehat{\beta}}$
- genera la aproximación:

$$\frac{\partial \widehat{\text{Pr}}(y = 0|x)}{\partial x_j} = -\phi(\overline{x'\widehat{\beta}} - \widehat{\alpha}_1) \widehat{\beta}_j$$

$$\frac{\partial \widehat{\text{Pr}}(y = 1|x)}{\partial x_j} = (\phi(\overline{x'\widehat{\beta}} - \widehat{\alpha}_1) - \phi(\overline{x'\widehat{\beta}} - \widehat{\alpha}_2)) \widehat{\beta}_j$$

$$\frac{\partial \widehat{\text{Pr}}(y = 2|x)}{\partial x_j} = \phi(\overline{x'\widehat{\beta}} - \widehat{\alpha}_2) \widehat{\beta}_j$$

Ejemplo de la aproximación

```
# one extra year of education: calculus approximation
genr beta=$coeff[1:2]
genr alpha=$coeff[3:4]
matrix X={educ,kids}
series Xb=X*beta
scalar meanXb=mean(Xb)
scalar Mg_educ0=-pdf(N,meanXb-alpha[1])*$coeff(educ)
scalar Mg_educ1= (pdf(N,meanXb-alpha[1]) \
                -pdf(N,meanXb-alpha[2]))*$coeff(educ)
scalar Mg_educ2= pdf(N,meanXb-alpha[2])*$coeff(educ)
```

```
? printf " Mg_educ0 = %.8g\n Mg_educ1 = %.8g\n Mg_educ2 = %.8g\n", \
        Mg_educ0, Mg_educ1, Mg_educ2
```

```
Mg_educ0 = -0.030702828
Mg_educ1 = 0.023540482
Mg_educ2 = 0.0071623465
```

Efectos sobre la variable ordinal

Efectos sobre y

- una vez hemos obtenido los efectos marginales sobre las probabilidades, el efecto esperado sobre la variable ordinal y es fácil de obtener
- para regresor continuo:

$$\frac{\partial \hat{E}(y|x)}{\partial x_j} = \frac{\partial \hat{\Pr}(y = 1|x)}{\partial x_j} \times 1 + \frac{\partial \hat{\Pr}(y = 2|x)}{\partial x_j} \times 2$$

- para regresor discreto:

$$\Delta \hat{E}(y|x) = \Delta \hat{\Pr}(y = 1|x) + 2 \times \Delta \hat{\Pr}(y = 2|x)$$

```
# marginal effects on work  
scalar EMg_kid=mean(Mg_kid1)+2*mean(Mg_kid2)  
scalar EMg_educ=Mg_educ1+2*Mg_educ2
```

```
.. .
```

```
? printf " EMg_kid = %.8g\n EMg_educ = %.8g\n", EMg_kid, EMg_educ  
EMg_kid = -0.371958  
EMg_educ = 0.037865175
```


Resumen

- gretl permite la estimación por MV del probit ordinal y del logit ordinal
- los efectos marginales son fáciles de computar