

# Estimación Probit

## Microeconomía Cuantitativa

R. Mora

Departamento de Economía  
Universidad Carlos III de Madrid

# Esquema

- 1 El Modelo de Utilidad Aleatoria
- 2 La log-verosimilitud
- 3 Estimación

## El modelo de utilidad aleatoria

- $U_m = \beta_m x_m + \varepsilon_m$
- $U_h = \beta_h x_h + \varepsilon_h$



$$\beta_m x_m + \varepsilon_m > \beta_h x_h + \varepsilon_h \Leftrightarrow \text{work} = 1$$



$$\beta x + \varepsilon > 0 \Leftrightarrow \text{work} = 1$$

donde  $\varepsilon = \varepsilon_m - \varepsilon_h$  (la utilidad neta de participación inobservada) y  
 $\beta x = \beta_m x_m - \beta_h x_h$  (la función índice)

## El supuesto Probit

- El econometra solo observa  $work$ ,  $x_m$ , y  $x_h$

### Supuesto Probit : $\varepsilon_h, \varepsilon_m \sim N(0, \Sigma)$

- $\varepsilon \equiv \varepsilon_m - \varepsilon_h | x \sim N(0, \sigma^2)$
- $Pr(work = 1) = Pr(\varepsilon > -\beta x) = Pr(\varepsilon \leq \beta x)$
- $Pr(work = 1) = Pr\left(\frac{\varepsilon}{\sigma} \leq \frac{\beta x}{\sigma}\right)$
- $Pr(work = 1) = \Phi\left(\frac{\beta}{\sigma} x\right)$

donde  $\Phi$  es la función de distribución acumulada de la normal estándar

## Observabilidad de $\sigma$

$\beta$  y  $\sigma$  son observacionalmente equivalentes a  $\beta^* = k\beta$  y  $\sigma^* = k\sigma$

$$\Phi\left(\frac{\beta^*}{\sigma^*}x\right) = \Phi\left(\frac{k\beta}{k\sigma}x\right) = \Phi\left(\frac{\beta}{\sigma}x\right), k \neq 0$$

- un número infinito de pares  $(\beta^*, \sigma^*)$  dan la misma verosimilitud
- las condiciones de identificación asintótica de MV no se cumplen

supuesto identificador:  $\sigma = 1$  (por tanto  $\varepsilon \sim N(0,1)$ )

- $Pr(\text{work} = 1) = \Phi(\beta x)$

## Interpretación de las pendientes y los efectos marginales

cuando el control  $x_j$  aparece en ambas utilidades  $U_m$  y  $U_h$ ...

- solo el efecto neto en la función índice,  $\beta_{mj} - \beta_{hj}$ , está identificado

el supuesto de normalidad (no-linealidad)

- la “pendiente neta”  $\beta_{mj} - \beta_{hj}$  captura el efecto marginal sobre la función índice  $\beta x$  de un aumento unitario de  $x_j$
- el efecto marginal sobre la probabilidad de participación es más complejo
- si  $x_j$  es continua,  $\frac{\partial Pr(work=1)}{\partial x_j} = \phi(\beta x) \beta_j$
- si  $x_j$  es discreta,  $\Delta Pr(work = 1) = \Phi(\beta x_1) - \Phi(\beta x_0)$   
donde  $x_1$  es el vector final de controles y  $x_0$  es el vector inicial de controles

## Un ejemplo simple


- $U_m = \beta_m^0 + \beta_m^e educ + \beta_m^k kids + \varepsilon_m$  con  $\varepsilon_m \sim N(0, \sigma_m^2)$
- $U_h = \beta_h^0 + \beta_h^e educ + \beta_h^k kids + \varepsilon_h$  con  $\varepsilon_h \sim N(0, \sigma_h^2)$
- $cov(\varepsilon_m, \varepsilon_h) = \sigma_{m,h}$

Supuesto Probit:  $\varepsilon_m - \varepsilon_h | x \sim N(0, 1)$

- $Pr(work = 1) = \Phi(\beta_0 + \beta_e educ + \beta_k kids)$
- $\beta_0 = \beta_m^0 - \beta_h^0$
- $\beta_e = \beta_m^e - \beta_h^e$
- $\beta_k = \beta_m^k - \beta_h^k$
- $var(\varepsilon_m - \varepsilon_h) = \sigma_m^2 + \sigma_h^2 - 2\sigma_{m,h} = 1$

## Una interpretación gráfica

La probabilidad de participar es una función no-lineal de la función índice  $\beta_0 + \beta_e educ + \beta_k kids$





## La densidad

Supuesto: muestra iid

- sea  $\beta_0$  el verdadero valor
- entonces, en el modelo Probit

$$Pr(work|x) = \begin{cases} \Phi(\beta_0 x) & \text{si } work = 1 \\ 1 - \Phi(\beta_0 x) & \text{si } work = 0 \end{cases}$$

## La verosimilitud de una observación

- la verosimilitud reemplaza en la densidad el verdadero vector  $\beta_0$  por un valor cualquiera  $\beta$
- entonces la verosimilitud para el individuo  $i$  es

$$L_i(\beta) = \begin{cases} \Phi(\beta x_i) & \text{si } work_i = 1 \\ 1 - \Phi(\beta x_i) & \text{si } work_i = 0 \end{cases}$$

- o, de forma más compacta,

$$L_i(\beta) = [\Phi(\beta x_i)]^{work_i} [1 - \Phi(\beta x_i)]^{1-work_i}$$

## La log-verosimilitud

- primero, tomamos logaritmos

$$l_i(\beta) = work_i \log(\Phi(\beta x_i)) + (1 - work_i) \log(1 - \Phi(\beta x_i))$$

- luego juntamos la muestra entera

$$l(\beta) = \sum_{i=1}^n l_i(\beta)$$

- por tanto

$$l(\beta) = \sum_i \{work_i \log(\Phi(\beta x_i)) + (1 - work_i) \log(1 - \Phi(\beta x_i))\}$$

## Estimación MV

### definición

- El estimador MV es el vector  $\hat{\beta}^{ML}$  tal que

$$\hat{\beta}^{ML} = \underset{\beta}{\operatorname{arg\,max}} l(\beta)$$

- debido a la naturaleza no-lineal de la maximización de la verosimilitud, no hay fórmulas explícitas para los estimadores MV del modelo Probit
- en vez de expresiones algebraicas, se utilizan algoritmos numéricos de maximización, necesitándose normalmente solo unas pocas iteraciones
- en `gretl`, se utiliza un algoritmo cuasi-Newton (el BFGS)

## Un Control que Clasifica Perfectamente

- supón que la dummy  $D_i$  predice perfectamente  $work_i$  en la muestra en el sentido que  $work_i = 1 \Leftrightarrow D_i = 1$
- si  $\beta_X = \beta_0 + \beta_D D$ , entonces  $\beta_X = \begin{cases} \beta_0 + \beta_D & \text{si } work = 1 \\ \beta_0 & \text{si } work = 0 \end{cases}$
- y la log-verosimilitud será creciente en  $\beta_D$ :

$$l(\beta) = \sum_i \{work_i \log(\Phi(\beta_0 + \beta_D)) + (1 - work_i) \log(1 - \Phi(\beta_0))\}$$

- por tanto, no puede haber un estimador MV

## El problema de predicción perfecta

- en general, supón que  $\tilde{\beta}$  predice perfectamente  $work_i$  en la muestra en el sentido de que para un escalar  $k$ ,  $\tilde{\beta}x_i > k$  si y solo si  $work_i = 1$
- entonces lo mismo ocurre para cualquier múltiplo de  $\tilde{\beta}$  y la log-verosimilitud no tendrá un máximo
- ésto se puede deber a varias razones
  - un control puede ser un clasificador perfecto: (hay que quitarlo)
  - el modelo puede estar trivialmente mal especificado (como predecir participación entre trabajadores)
  - la muestra puede simplemente no ser suficientemente grande

## Propiedades asintóticas y contrastes

bajo condiciones generales, el estimador MV es consistente, asintóticamente normal, y asintóticamente eficiente

- podemos construir contrastes asintóticos tipo  $t$  e intervalos de confianza (como hacemos en MCO, MC2E, y VI)
- restricciones de exclusión (por ejemplo,  $H_0 : \beta_j = 0$  and  $\beta_k = 0$ )
  - el multiplicador de Lagrange solo requiere la estimación del modelo bajo la nula
  - el test de Wald solo requiere la estimación del modelo sin restringir
  - la razón de verosimilitudes (LR) requiere la estimación de ambos modelos

## El contraste de razón de verosimilitudes

### Hipótesis anidadas

- se basa en la diferencia de las log-verosimilitudes bajo la hipótesis nula y la alternativa
- restringir un modelo no puede generar mayores log-verosimilitudes

$$LR = 2 \left( l_{ur} \left( \hat{\beta}_{ur}^{ML} \right) - l_r \left( \hat{\beta}_r^{ML} \right) \right) \xrightarrow{a} \chi_q$$

donde  $q$  es el número de restricciones



## Resumen

- no todos los parámetros del modelo de utilidad aleatoria pueden ser estimados
- el modelo Probit identifica cómo cada control afecta la probabilidad de participación
- la estimación MV del modelo Probit requiere el uso de algoritmos numéricos de maximización
- bajo condiciones generales los estimadores MV son consistentes y asintóticamente normales y eficientes
- contrastes de significatividad y contrastes de restricciones generales son fáciles de implementar en el modelo Probit