

***Modelos de elección simple y múltiple. Regresión logit y probit. Modelos multilogit y multiprobit.***

Siga

# Modelos de elección discreta.

- Modelos de elección simple.
  - Modelos de elección múltiple.
- 
- Final

*Modelos de elección discreta.*  
(Alternativas binarias)

Siga

# Modelos de elección simple.

- Introducción.
- Planteamiento.
- Modelos probit y logit.

• Atrás

# Introducción.

- Referencias.
- Análisis aplicado.
- Relevancia.

- Atrás

# Referencias.

- Goldberger, A. S. (2001), *Introducción a la Econometría*. Ariel. Capítulo 17, págs. 175-190.
  - Maddala, G. S. (1996), *Introducción a la Econometría*, 2<sup>a</sup> ed. Prentice Hall. Capítulo 8.
- [Atrás](#)

# Análisis aplicado

- Muro, J. e I. Senra (2002), *Ensayo 3*.  
*¿Influye el tamaño de una empresa sobre la probabilidad de acceder a la financiación bancaria? ¿Cambia el sentido de la influencia a partir de un tamaño determinado?*

- [Atrás](#)

# Relevancia.

- Tablas multidimensionales con condición *ceteris paribus*.
- Mecanismos de selección muestral.
- Modelos no lineales para datos de panel.
- Métodos discretos para modelos de duración.

• [Atrás](#)



# Planteamiento.

- Construcción del modelo a partir de una forma reducida.
- Modelización de la probabilidad asociada a la variable dicotómica a través de las expresiones derivadas de una formulación estructural.
  - Función índice (forma estructural de v. latente).
  - Utilidad aleatoria.

• Atrás

# Modelo en forma reducida.

- Analogía con el modelo de regresión (v. objetivo con 0 y 1).
  - Probabilidad es una función de la matriz de características  $\mathbf{X}$  y de los parámetros a estimar  $\beta$ .
  - Hipótesis de linealidad: el argumento de la función anterior es una combinación lineal de las características y de los parámetros.
- Siga

# Modelo en forma reducida.

- Probabilidad de que ocurra un suceso (se tome una decisión)

$$P_i = \text{Prob}[y_i = 1 | X_i, \beta] = G(X_i, \beta) = G(X'_i \beta).$$

- Probabilidad de que no ocurra un suceso (no se tome la decisión)

$$\text{Prob}[y_i = 0 | X_i, \beta] = 1 - G(.).$$

Siga

## Modelo en forma reducida.

- El valor esperado de la variable a estudio,  $y_i$ , es

$$E(y_i) = 1 * P_i + 0 * (1 - P_i) = P_i = G(.).$$

- *¿Cuáles pueden ser las candidatas para la función  $G(.)$ ?*
  - modelo lineal de probabilidad.
  - modelo probit.
  - modelo logit.

Atrás

# Modelo lineal de probabilidad.

- La función identidad, es decir  $G(.) = 1$ .
- Expresión formal es

$$y_i = X'_i \beta + \varepsilon_i \quad \forall i = 1, 2, \dots, N.$$

$$P_i = \text{Prob}(y_i = 1) = X'_i \beta.$$

Atrás

# Modelo probit.

- La función de distribución normal, es decir  $G(.) = F(.)$ .
- Expresión formal es

$$P_i = \text{Prob}(y_i = 1) = F(X'_i \beta).$$

Atrás

# Modelo logit.

- La función de distribución logística, es decir  $G(.) = \Lambda(.)$ .
- Expresión formal es

$$P_i = \text{Prob}(y_i = 1) = \frac{1}{1 + \exp(-X'_i \beta)}.$$

[Atrás](#)

# Planteamiento de función índice.

- La variable observada toma unos valores que responden al comportamiento de una variable índice (latente o inobservable).
  - Si el índice supera un determinado nivel la variable discreta toma el valor uno y, si no lo supera, toma el valor cero.
- La variable latente está relacionada con las características a través de un modelo estructural.

$$y_i^* = X_i \beta + \varepsilon_i \quad \forall i = 1, 2, \dots, N.$$

Siga



# Planteamiento de función índice.

- Según establezcamos el supuesto de que la perturbación aleatoria se distribuya como una Normal o una Logística, el modelo generado será un probit o un logit, respectivamente.
- Los valores de la variable a estudio, observados, se relacionan con los de la variable latente en la forma

$$y_i = \mathbf{1}(y_i^* > \mathbf{0}) = \mathbf{1}(X_i' \beta + \varepsilon_i > \mathbf{0}).$$

Siga

# Planteamiento de función índice.

- La probabilidad asociada a la realización del suceso tiene la expresión

$$\begin{aligned} P_i &= \text{Prob}[y_i = 1 \mid X_i, \beta] = \text{Prob}[y_i^* > 0] = \\ &= \text{Prob}[X_i\beta + \varepsilon_i > 0] = \text{Prob}[\varepsilon_i < X_i\beta] = \\ &= G(X_i' \beta). \end{aligned}$$

Siga

# Planteamiento de función índice.

- El hacer la varianza del modelo igual a uno es el resultado de un mero proceso de normalización, ya que el modelo no se altera porque se multiplique por cualquier cantidad.
- El umbral considerado a superar por el índice puede ser cero o cualquier otro valor.

[Atrás](#)

# Modelos probit y logit.

- Expresión de la función de verosimilitud.
  - Ecuaciones de verosimilitud.
  - Hessiano.
  - Presentación e interpretación de resultados.
  - Contrastes.
  - Bondad del ajuste.
- Atrás

La función de verosimilitud de los modelos probit y logit es:

$$L(\beta | y_i, X_i) = \prod_{i=1}^N G(X'_i \beta)^{y_i} [1 - G(X'_i \beta)]^{1-y_i}.$$

$$\ln L = \sum_i \{y_i \ln G(X'_i \beta) + (1 - y_i) \ln [1 - G(X'_i \beta)]\}.$$

[Atrás](#)

Las ecuaciones de verosimilitud de los modelos probit y logit son:

$$\frac{\partial \ln L(\beta)}{\partial \beta} = \mathbf{0}.$$

$$\sum_i \left\{ y_i \frac{g(\cdot)}{G(\cdot)} X_i + (y_i - 1) \frac{g(\cdot)}{1 - G(\cdot)} X_i \right\} = \mathbf{0}.$$

$$\sum_i \left\{ \frac{y_i - G(\cdot)}{G(\cdot)[1 - G(\cdot)]} g(\cdot) X_i \right\} = \mathbf{0}.$$

Siga

Que se concretan en

$$\sum_i \frac{f(\cdot)}{[1-F(\cdot)]} X_i = \mathbf{0}.$$

Modelo probit

$$\sum_i [y_i - \Lambda(\cdot)] X_i = \mathbf{0}.$$

Modelo logit

[Atrás](#)

El hessiano es definido negativo en ambos modelos y tiene la forma:

$$H = - \sum_i \lambda_i (\lambda_i + X_i' \beta) X_i X_i'$$

Modelo probit

$$H = - \sum_i \Lambda(.) [1 - \Lambda(.)] X_i X_i'$$

Modelo logit

[Atrás](#)



El hessiano es definido negativo en ambos modelos y tiene la forma:

$$\frac{\partial \ln L(\beta)}{\partial \beta} = \mathbf{0}.$$

$$\sum_i \left\{ y_i \frac{g(\cdot)}{G(\cdot)} X_i + (y_i - 1) \frac{g(\cdot)}{1 - G(\cdot)} X_i \right\} = \mathbf{0}.$$

$$\sum_i \left\{ \frac{y_i - G(\cdot)}{G(\cdot)[1 - G(\cdot)]} g(\cdot) X_i \right\} = \mathbf{0}.$$

[Atrás](#)

# Presentación e interpretación de resultados.

- Presentación:
  - Habitual (estimaciones parámetros).
  - Razón de probabilidades (odds ratio).
- Efectos marginales.
- Predicciones.

• [Atrás](#)

# Contrastes.

- Especificación.
- Especificación errónea.

- Atrás

# Contrastes de especificación errónea.

- Análisis de residuos generalizados.
- Contrastes de momentos condicionales. Pagan-Vella (1989).
- Contraste de heteroscedasticidad. Davidson y McKinnon (1993).

• Atrás

Pagan, A.R. y F. Vella (1989), “Diagnostic Tests for Models Based on Individual Data: A Survey”.  
*Journal of Applied Econometrics*, 4, S29-59.

# Davidson, R. y J. MacKinnon (1993), *Estimation and Inference in Econometrics*. Oxford University Press.

Contraste de heteroscedasticidad. Harvey (1976). Modelo probit.

Hipótesis nula.  $H_0: \text{Var}(u_i) = \text{cte}$ ;  $H_1: \text{Var}(u_i) = \exp(2\gamma \cdot \text{var})$ .

Regresión auxiliar. La suma de los cuadrados explicada de dicha regresión se distribuye asintóticamente bajo la hipótesis nula como una  $\chi^2$  con 1 grado de libertad (situación particular debida a que sólo hay una variable que cause la heteroscedasticidad, si hubiera más variables los grados de libertad serían iguales a su número).

La regresión auxiliar tiene la forma:

$$\frac{y_i - \hat{p}_i}{\sqrt{\hat{p}_i(1-\hat{p}_i)}} = \frac{f(-X_i' \theta)}{\sqrt{\hat{p}_i(1-\hat{p}_i)}} X_i' \phi_1 + \frac{f(-X_i' \theta) * (-X_i' \theta)}{\sqrt{\hat{p}_i(1-\hat{p}_i)}} \text{var}^* \phi_2 + v_i.$$

Las  $\hat{p}$  son predicciones, la  $X$  es la matriz de variables del lado derecho (que incluye la variable  $\text{var}$ ) y, finalmente,  $f(\cdot)$  es la función de densidad de probabilidad de una variable  $N(0,1)$ .

# Bondad del ajuste.

- Contraste de la razón de verosimilitud.
- Seudo  $R^2$ .
- Tabla de predicciones.

• Atrás

# Contraste de la razón de verosimilitud.

Compara de la forma habitual el modelo estimado con el modelo ingenuo (modelo que contiene sólo una constante).

Hipótesis nula.  $H_0: \beta=0$ .

$$LR = -2(\ln L - \ln L_0) \underset{H_0}{\sim} \chi^2(r)$$

$$\ln L_0 = N[P \ln P + (1-P) \ln(1-P)].$$



## Seudo $R^2$ .

Dificultades en crear un consenso sobre cuál es el modelo de comparación.

$$1 - \frac{\ln L}{\ln L_0}.$$

$$\ln L_0 = N[P \ln P + (1 - P) \ln(1 - P)].$$

## Tabla de predicciones.

Compara los resultados muestrales con los predichos para cada observación y suministra el número de aciertos y fallos.

Características de equilibrio de la muestra analizada.

Regla de construcción habitual.

**$\hat{P}_i > 0.5$  implica que  $\hat{y}_i = 1$ ;**

**$P_i \leq 0.5$  implica que  $\hat{y}_i = 0$ .**

*Modelos de elección discreta.*  
(Múltiples alternativas)

Siga

# Modelos de elección discreta con múltiples alternativas.

- Introducción.
- Los temas.
  - Características comunes.
  - ¿Cuáles son las causas de la aleatoriedad?
  - Problemas que nacen del diseño muestral.
- Los modelos.

# Introducción.

- Referencias.
- Thurstone, L. (1927), “A Law of Comparative Judgement”. *Psychological Review*, 34, págs. 273-286.
- Luce, D. (1959), *Individual Choice Behaviour*. Wiley.

• Atrás

# Referencias

- Greene, W. H. (1997), *Econometric Analysis*. 3<sup>a</sup> ed. Macmillan. Capítulo 19, págs. 871-931.
  - Wooldridge, J. M. (2002), *Econometric Analysis of Cross Section and Panel Data*, The MIT Press. Capítulo 15, págs. 453-509.
- [Atrás](#)

# Modelos de elección discreta con múltiples alternativas.

- Introducción.
- Los temas.
  - Características comunes.
  - ¿Cuáles son las causas de la aleatoriedad?
  - Problemas que nacen del diseño muestral.
- Los modelos.

Final

# Los temas.

1. Compras de bienes duraderos (bienes indivisibles).
  - ✓ Automóviles. Cragg y Uhler (1970).
  - ✓ Fecundidad. Becker (1960).
2. Demanda de características (bien heterogéneo).
  - ✓ Transporte. McFadden (1974.....1984).
  - ✓ Vivienda; educación; ocupación.....
3. Elección discreta como abstracción de demanda de un bien continuo.
  - ✓ Oferta de trabajo. Muro et al. (1986).
4. Otros temas.
  - ✓ Sentido del voto; construcción de autopistas. [Atrás](#)



# Características comunes.

- Comparación de utilidades.
- Hipótesis RUM (random utility maximization).
- IIA (Supuesto de independencia de las alternativas irrelevantes).

• [Atrás](#)

# Causas de la aleatoriedad

- Heterogeneidad.
- Deficiencias de información.

• [Atrás](#)

# Diseño muestral

- Exogeneidad.
- Endogeneidad.
  - Referencia útil: Pudney (1989).

• [Atrás](#)

# Los modelos.

1. La información disponible.
2. Planteamiento general.
3. Modelos para datos no ordenados.
4. Modelos para datos ordenados.
5. Líneas de investigación.

[Atrás](#)

# La información disponible.

➤ Individuos y alternativas.

- $n$  individuos;  $i = 1, 2, 3, \dots, n$ .
- $J$  alternativas;  $j = 0, 1, 2, 3, \dots, J-1$ .

➤ Características de los individuos.

- $W_i$  es un vector ( $K \times 1$ ).

➤ Atributos de las alternativas.

- $X_{ij}$  es un vector ( $L \times 1$ ).

➤ En suma:  $Z_{ij} = (X_{ij} \ W_i)$ .

- [Atrás](#)

- Utilidad estocástica  $U_{ij} = S_{ij} + \varepsilon_{ij}$ .
  - Donde  $S_{ij} = Z'_{ij}\gamma$ .  $\gamma = (\beta' \alpha')'$ .
- El individuo  $i$  escoge la alternativa que maximiza su utilidad.
  - $\text{Prob}(y_i = j) = P_{ij} = \text{prob}(U_{ij} > U_{ik}) \quad \forall k \neq j$ .
- Si la distribución del término de error es
  - Normal  $\rightarrow$  modelo probit;
  - Weibull  $\rightarrow$  modelo logit.

[Atrás](#)

# Modelos para un conjunto no ordenado de alternativas.

1. Modelo logit multinomial.
  2. Modelo logit condicional.
  3. Modelos anidados.
  4. ¿Por qué especificaciones logit?
- Atrás

# Modelo logit multinomial.

- McFadden (1973).
- Datos de características de los individuos (pero no de atributos de las alternativas).
- Planteamiento del modelo.
- Identificación.
- Razón de probabilidades (odds ratio).
- Estimación.
- Contrastes.
- Ejemplo 1; ejemplo 2.

[Atrás](#)



$$\text{Prob}(y_i = j) = P_{ij} = \frac{e^{W'_i \alpha_j}}{\sum_k e^{W'_i \alpha_k}}.$$

**Donde i representa individuos y k corre para las alternativas (J).**

[Atrás](#)

- Si  $\alpha^*_j = \alpha_j + \alpha_0$ .

$$\text{Prob}(y_i = j) = P_{ij} = \frac{e^{W'_i(\alpha^*_j - \alpha_0)}}{\sum_k e^{W'_i(\alpha^*_k - \alpha_0)}} = \frac{e^{W'_i\alpha^*_j}}{\sum_k e^{W'_i\alpha^*_k}}.$$

- Una mera traslación no altera el valor de las probabilidades (indeterminación).
- Manifestación de la propiedad de suma unitaria del conjunto de probabilidades.

Siga

**La expresión normalizada queda (se hace la medida relativa a la alternativa cero, por lo que los coeficientes  $\alpha_0$  de la alternativa cero se hacen nulos):**

$$\text{Prob}(y_i = j) = P_{ij} = \frac{e^{W'_i \alpha_j}}{1 + \sum_{k \neq 0} e^{W'_i \alpha_k}}.$$

[Atrás](#)

$$\frac{P_{ij}}{P_{i0}} = e^{W'_i \alpha_j}; \quad \frac{P_{ij}}{P_{ik}} = \frac{e^{W'_i \alpha_j}}{e^{W'_i \alpha_k}}.$$

**Si calculamos la relación en logaritmos (log odds ratio).**

$$\ln\left(\frac{P_{ij}}{P_{i0}}\right) = W'_i \alpha_j; \quad \ln\left(\frac{P_{ij}}{P_{ik}}\right) = W'_i (\alpha_j - \alpha_k).$$

[Atrás](#)

Hacemos :

$$d_{ij} = 1 \quad \text{si} \quad y_i = j ;$$

$$d_{ij} = 0 \quad \text{si} \quad y_i \neq j .$$

**La función de verosimilitud del modelo será:**

$$L(\alpha_j, j = 1, 2, \dots, J \mid W_i \dots) = \prod_{i=1}^n \prod_{j=0}^J [\text{prob}(d_{ij} = 1)]^{d_{ij}} .$$

$$\ln L = \sum_i \sum_j d_{ij} \ln \left\{ \frac{e^{W'_i \alpha_j}}{1 + \sum_{k \neq 0} e^{W'_i \alpha_k}} \right\} .$$

[Atrás](#)

**Las ecuaciones de verosimilitud del modelo son:**

$$\frac{\partial \ln L}{\partial \alpha_j} = \sum_i [d_{ij} - P_{ij}] W_i = 0.$$

**El término entre corchetes se puede utilizar para realizar contrastes oportunos por el método de los contrastes de momentos condicionales.**

[Atrás](#)

# Modelo logit condicional.

- McFadden (1974).
- Datos de atributos de las alternativas y/o características de los individuos.
- Planteamiento.
- Identificación.
- Razón de probabilidades (odds ratio). IIA.
- Estimación. ¿ Logit para datos de panel con efectos fijos?
- Contrastes de especificación (IIA).
- Ejemplo 1; ejemplo 2.

[Atrás](#)

**El calificativo condicional se deriva de que elegimos una alternativa concreta condicionada al hecho de que alguna de las alternativas se elige.**

$$\text{Prob}(y_i = j) = P_{ij} = \frac{e^{Z'_{ij}\gamma_j}}{\sum_k e^{Z'_{ik}\gamma_k}}$$

**Donde i representa individuos y k corre para las alternativas (J).**

**La mayor parte de los ejemplos de logit condicional se construyen con solo atributos de las alternativas.**

**Es conveniente observar que la misma expresión se obtiene de considerar nuestra muestra como el resultado de un logit para datos de panel con efectos fijos, Chamberlain (1980).**

[Atrás](#)



- Supongamos que  $\gamma_j = \gamma = \beta + \alpha$ . Entonces,

$$\text{Prob}(y_i = j) = P_{ij} = \frac{e^{X'_{ij}\beta + W'_i\alpha}}{\sum_k e^{X'_{ik}\beta + W'_i\alpha}} = \frac{e^{X'_{ij}\beta}}{\sum_k e^{X'_{ik}\beta}}.$$

- Los parámetros de las características de los individuos desaparecen.
- La identificación se produce por medio de términos de interacción que permiten recuperar los parámetros asociados con las características.
- Lo mismo ocurre con el término independiente del modelo.

[Atrás](#)

$$\frac{P_{ij}}{P_{ik}} = \frac{e^{X'_{ij}\beta}}{e^{X'_{ik}\beta}}$$

**Si calculamos la relación en logaritmos (log odds ratio).**

$$\ln\left(\frac{P_{ij}}{P_{ik}}\right) = \left(X'_{ij} - X'_{ik}\right)\beta.$$

**Se cumple el supuesto IIA (restricción implícita en el modelo).**

[Atrás](#)

Hacemos :

$$d_{ij} = 1 \quad \text{si} \quad y_i = j ;$$

$$d_{ij} = 0 \quad \text{si} \quad y_i \neq j .$$

**La función de verosimilitud del modelo será:**

$$L(\beta | X_{ij} \dots) = \prod_{i=1}^n \prod_{j=1}^J [\text{prob}(d_{ij} = 1)]^{d_{ij}} .$$

$$\ln L = \sum_i \sum_j d_{ij} \ln \left\{ \frac{e^{X'_{ij}\beta}}{\sum_k e^{X'_{ik}\beta}} \right\} .$$

[Atrás](#)

**El contraste del supuesto IIA, Hausman y McFadden (1984), es un contraste de tipo Hausman. El modelo sin restricciones es el que contiene todas las alternativas y el restringido el mismo modelo estimado sin una de las alternativas.**

**Bajo IIA ambos estimadores son consistentes y el del modelo restringido eficiente. Bajo la alternativa sólo el del modelo sin restricciones es consistente.**

$$\chi^2 = \left( \hat{\beta}_r - \hat{\beta}_{sr} \right)' \left[ V_r - V_{sr} \right]^{-1} \left( \hat{\beta}_r - \hat{\beta}_{sr} \right) \underset{H_0}{\sim} \chi^2_{rest..}$$

**Donde:**

**r significa modelo restringido; sr modelo sin restricciones; V matriz de varianzas y covarianzas de los modelos respectivos; rest. = número de restricciones implícitas en el supuesto IIA (ambos modelos proporcionan los mismos resultados; n° parámetros del modelo restringido).**

[Atrás](#)

# Modelo logit anidado.


- McFadden (1984).
- Relajación del supuesto IIA.
- Modelo jerárquico. Construcción de un árbol de decisiones.
- Planteamiento del modelo.
- Estimación.
- Contrastes de especificación (logit condicional).
- Ejemplo 1; ejemplo 2.

[Atrás](#)

**Supongamos que la elección se produce entre  $J$  alternativas, donde  $J = 3$ .**

**Ej. Mercado de trabajo: inactividad, paro y empleo.**

**Suponemos que la jerarquía (árbol de decisiones) se establece de la forma siguiente:**



**Llamamos ramas a cada una de las alternativas del primer nivel. Alternativas de cada rama a las que cuelgan de cada una de ellas.**

**Se admite que las ramas del árbol sean heteroscedásticas.**

[Atrás](#)

**Como información disponemos de los atributos de las ramas  $Z_l$  y de los atributos de las alternativas incluidas en cada rama  $X_{jl}$ .**

**Para el caso de un modelo para dos niveles, con  $L$  ramas en el primer nivel y con  $J_l$  alternativas en cada rama del segundo nivel, la probabilidad no condicionada de elegir la alternativa  $j$  que pertenece a la rama  $l$  es**

$$P_{jl} = \frac{e^{X'_{jl}\beta + Z'_l\gamma}}{\sum_l \sum_j e^{X'_{jl}\beta + Z'_l\gamma}} \cdot$$

**Esta probabilidad puede descomponerse en el producto de la condicional por la marginal. Es decir,**

$$P_{jl} = P_{j|l}P_l = \frac{e^{X'_{jl}\beta + Z'_l\gamma}}{\sum_l \sum_j e^{X'_{jl}\beta + Z'_l\gamma}} \frac{\sum_j e^{X'_{jl}\beta}}{\sum_j e^{X'_{jl}\beta}} \frac{\sum_l e^{Z'_l\gamma}}{\sum_l e^{Z'_l\gamma}} \cdot$$

Siga

**Se define el valor inclusivo, o de dentro de la rama, como**

$$I_l = \ln \sum_j e^{X'_{jl}\beta}.$$

**Y también la probabilidad de la alternativa j condicionada a encontrarse en la rama l como**

$$P_{j|l} = \frac{e^{X'_{jl}\beta}}{\sum_j e^{X'_{jl}\beta}}.$$

**Y la probabilidad marginal de la rama l como**

$$P_l = \frac{e^{Z'_l\gamma + \pi_l I_l}}{\sum_l e^{Z'_l\gamma + \pi_l I_l}}.$$

Siga



**En definitiva, de las definiciones anteriores se deriva que un modelo logit anidado tiene un doble comportamiento:**

**1. Modelo logit condicional interno para la elección de las alternativas de la rama correspondiente.**

**2. Modelo logit condicional para el conjunto de las ramas. En este logit condicional se consideran como atributos de las ramas no sólo las  $Z_i$  sino también los valores inclusivos  $I_i$ .**

## **1. Procedimiento maximoverosímil.**

- **Aplicación directa de la maximización de la función de verosimilitud (producto de la contribución de cada observación de la muestra).**

## **2. Procedimiento en dos etapas.**

- **Estimación del modelo logit condicional intrarrama.**
- **Cálculo del (o de los) valor inclusivo.**
- **Estimación del modelo logit condicional de las ramas.**

[Atrás](#)

**Cabe realizar un contraste de especificación que es equivalente al contraste del supuesto IIA.**

**En efecto, si en un modelo anidado la probabilidad condicional de elegir una alternativa dentro de una rama coincide con la no condicional el modelo se reduce a un modelo logit condicional de todas las alternativas contempladas (al margen de su pertenencia o no a una rama concreta)**

**Matemáticamente se reduce al contraste de que el parámetro, o parámetros, que afectan a los valores inclusivos son iguales a 1.**

[Atrás](#)

# Otras especificaciones distintas a las logísticas.

- Facilidad de cálculo.
- Imposibilidad de calcular integrales multidimensionales implícitas en modelos probit. Máximo  $J=3$ .
- Probit multinomial.
- Simulación. Nuevas investigaciones.

Atrás

# Probit multinomial

- Debería llamarse probit condicional.
- Alternativa al logit condicional que evita la IIA.
- Las  $J$  perturbaciones aleatorias se distribuyen como una distribución normal  $J$ -variante, que admite correlaciones para  $i \neq j$ .
  - Atrás.

# Modelos para un conjunto ordenado de alternativas.

- Planteamiento general.
- No se conocen los límites de los intervalos.
- Se conocen los límites de los intervalos:  
Variable dependiente agrupada.

Atrás

# Planteamiento general.

- Los datos dan información de dos cuestiones:
  - de la alternativa escogida;
  - y de la ordenación de las alternativas posibles .
- Modelización de la información discreta y ordenada a través de una función índice inobservable.

$$y_i^* = X'_i \beta + \varepsilon_i.$$

Siga

- La conversión de los valores de la función índice en los valores discretos ordenados sigue la regla siguiente:

$$\begin{aligned}y &= 0 \quad \text{si} \quad y^* \leq 0, \\y &= 1 \quad \text{si} \quad 0 < y^* \leq \mu_1, \\y &= 2 \quad \text{si} \quad \mu_1 < y^* \leq \mu_2, \\y &= J \quad \text{si} \quad \mu_{J-1} < y^* .\end{aligned}$$

- La conversión puede considerarse una censura de los datos. Sólo se conoce el intervalo en el que está una observación concreta.

Siga



- En general, el modelo se representa como:

$$\mathbf{Prob}(y=0) = \mathbf{Prob}(y^* \leq 0) = \mathbf{G}(-X\beta),$$

$$\mathbf{Prob}(y=1) = \mathbf{Prob}(0 < y^* \leq \mu_1) =$$

$$\mathbf{G}(\mu_1 - X\beta) - \mathbf{G}(-X\beta),$$

.....

- Cuando G(.) es la función de distribución de una normal el modelo será un probit; cuando es la logística será un logit.

Atrás

• **Si los parámetros  $\mu_j$  son desconocidos, los modelos probit y logit ordenados son los oportunos.**

• *Modelo probit (logit) ordenado.*

• **Dado que los límites del intervalo son desconocidos podemos hacer estándar el modelo y suponer que las perturbaciones aleatorias del modelo son  $N(0,1)$ .**

• *Expresión formal del modelo.*

• **Para la estimación empleamos el método de la máxima verosimilitud. La función de verosimilitud es**

$$L(\beta, \mu_j) = \prod_{i=1}^N \prod_{j=1}^J [G(\mu_j - X'_i \beta) - G(\mu_{j-1} - X'_i \beta)]^{d_{ij}}.$$

$$\ln L = \sum_i \sum_j d_{ij} \ln [G(\mu_j - X'_i \beta) - G(\mu_{j-1} - X'_i \beta)]$$

• **Donde,**

$$d_{ij} = 1 \quad \text{si} \quad \mu_{j-1} < y_i^* \leq \mu_j,$$

$$d_{ij} = 0 \quad \text{en el resto de los casos.}$$

[Atrás](#)

• **Si los parámetros  $\mu_j$  son conocidos, el modelo apropiado es el de variables dependientes agrupadas.**

• *Modelo de variable dependiente agrupada.*

• **Al conocer los límites del intervalo, el modelo no se puede hacer estándar y los parámetros a estimar serán  $\beta$  y  $\sigma^2$ .**

• *Expresión formal del modelo.*

• **La función de verosimilitud del modelo es**

$$\ln L = \sum_i \sum_j d_{ij} \ln \left[ G\left(\frac{\mu_j - X'_i \beta}{\sigma}\right) - G\left(\frac{\mu_{j-1} - X'_i \beta}{\sigma}\right) \right].$$

• **Donde las equivalencias con la expresión anterior son inmediatas.**

[Atrás](#)