

Modelos multinomiales para variables categóricas

Gabriel V. Montes-Rojas

Modelo logit multinomial

Supongamos que la variable dependiente toma muchos valores, ej. $y = 0, 1, 2, \dots, J$, aunque los valores de y no representan **ningún orden en particular**, $J + 1$ potenciales categorías. Éste es el modelo multinomial.

Ejemplo: Modelos de elección dicreta (discrete choice models). y podría ser la marca de un producto que el consumidor compra:

$y = 0$ A

$y = 1$ B

$y = 2$ C

$y = 3$ D

$y = 4$ E

Ejemplo: Participación en la fuerza laboral. y podría ser el status laboral de la persona:

$y = 0$ empleado

$y = 1$ desempleado

$y = 2$ fuera de la fuerza laboral

Modelo logit multinomial

- Seleccionemos sin pérdida de generalidad un **grupo base**. Por convención corresponde a $j = 0$.
- Cada valor de y contiene los parámetros β_j , $j = 1, 2, \dots, J$, vectores $K_j \times 1$. (Si $J = 1$ tenemos el modelo logit.)
- En un modelo logit multinomial para modelar cada probabilidad tenemos

$$P[y = j|\mathbf{x}] = \frac{\exp(\mathbf{x}\beta_j)}{1 + \sum_{h=1}^J \exp(\mathbf{x}\beta_h)}, \quad j = 1, 2, \dots, J$$

- Notemos que la suma debe ser 1 (o sea $\sum_{h=0}^J P[y = h|\mathbf{x}] = 1$), entonces

$$P[y = 0|\mathbf{x}] = \frac{1}{1 + \sum_{h=1}^J \exp(\mathbf{x}\beta_h)}, \quad j = 1, 2, \dots, J$$

- Construir el logaritmo de la función de verosimilitud:
 $\ell_i(\boldsymbol{\beta}) = \sum_{j=0}^J 1[y_i = j] \log(P[y = j|\mathbf{x}])$. McFadden (1984) muestra que esta función es cóncava global, entonces tiene un único máximo.

Modelo logit multinomial

- Los efectos parciales son

$$\frac{\partial P(y = j | \mathbf{x})}{\partial x_k} = P(y = j | \mathbf{x}) \left\{ \beta_{jk} - \left[\sum_{h=1}^J \beta_{hk} \exp(\mathbf{x}\beta_h) \right] / g(\mathbf{x}, \beta) \right\},$$

donde β_{hk} es el elemento k de β_h y $g(\mathbf{x}, \beta) = 1 + \sum_{h=1}^J \exp(\mathbf{x}\beta_h)$. Notemos que un cambio en x_k afecta todas las probabilidades simultáneamente.

- Una interpretación de β_j está dada por

$$p_j(\mathbf{x}, \beta) / p_0(\mathbf{x}, \beta) = \exp(\mathbf{x}\beta_j), j = 1, 2, \dots, J.$$

- Entonces, el cambio en $p_j(\mathbf{x}, \beta) / p_0(\mathbf{x}, \beta)$ ante un cambio en x_k (asumiendo es continua) es $\beta_{jk} \exp(\mathbf{x}\beta_j) \Delta x_k$. O lo que es lo mismo, el log odds-ratio es lineal en \mathbf{x} : $\log(p_j(\mathbf{x}, \beta) / p_0(\mathbf{x}, \beta)) = \mathbf{x}\beta_j$.
- Este resultado se extiende a comparaciones entre j y h : $\log(p_j(\mathbf{x}, \beta) / p_h(\mathbf{x}, \beta)) = \mathbf{x}(\beta_j - \beta_h)$
- ¿Cómo se interpretaría el caso de x_k dummy? Hacer.

Modelo logit multinomial

- Una vez estimado podemos construir las probabilidades estimadas, $p_j(\mathbf{x}, \hat{\beta}), j = 0, 1, \dots, J$.
- Para cada i podemos predecir el resultado usando la mayor probabilidad. O sea, $\hat{y}_i = \max\{j = 0, 1, \dots, J : p_j(\mathbf{x}_i, \hat{\beta})\}$.
- Podríamos construir una medida de bondad del ajuste:
 $\text{pseudo-R}^2 = \frac{\sum_{i=1}^N 1[\hat{y}_i = y_i]}{N}$.
- McFadden (1974) propone usar el likelihood ratio index:

$$LRI = 1 - \frac{\mathcal{L}(\hat{\beta})}{\mathcal{L}(\beta = 0)}$$

Modelo logit multinomial

- Una de las características de este modelo es que las **mismas** variables x se usan para todas las alternativas j .
- En este caso los controles afectan al individuo, pero no son específicas de las características $j = 0, 1, 2, \dots, J$.
- El logit condicional (ver más abajo) permite que las variables de control sean específicas de cada opción.

Modelo logit multinomial: STATA

- <http://www.stata.com/manuals13/rmlogit.pdf>
- `mlogit y x1 x2 x3`
- `margins, dydx(*) predict(outcome(1))` (efectos marginales en el promedio de las densidades)
- `margins, dydx(*) predict(outcome(1)) atmeans` (efectos marginales para $y = 1$ sobre \bar{x})

Modelo de elección probabilística: logit condicional

(McFadden, 1974, Wooldridge, 2012, cap.16)

- Supongamos que hay $j = 0, 1, \dots, J$ variables latentes que representan la utilidad del individuo i

$$y_{ij}^* = \mathbf{x}_{ij}\beta_j + a_{ij},$$

donde a_{ij} son variables no observadas que afectan los “gustos” de las personas. \mathbf{x}_{ij} es un vector de $1 \times K$ que puede diferir entre alternativas e individuos (notar que depende de j , no sólo de i).

- Ejemplo: alternativas de transporte, \mathbf{x}_{ij} puede contener el tiempo de viaje, o el costo del viaje.
- Ejemplo: alternativas de prepagas, \mathbf{x}_{ij} puede contener el costo o las características del plan.
- Definamos $y_i = \max\{y_{i0}^*, y_{i1}^*, \dots, y_{iJ}^*\}$. Si $a_{ij}, j = 0, 1, \dots, J$ son variables aleatorias independientes con distribución $F(a) = \exp[-\exp(-a)]$ (distribución de valores extremos de tipo I), entonces

$$P(y_i = j | \mathbf{x}_i) = \frac{\exp(\mathbf{x}_{ij}\beta_j)}{\sum_{h=0}^J \exp(\mathbf{x}_{ih}\beta_h)}, j = 0, 1, \dots, J.$$

Modelo de elección probabilística: logit condicional

(McFadden, 1974, Wooldridge, 2012, cap.16)

- Los efectos marginales son

$$\partial p_j(\mathbf{x}) / \partial x_{jk} = p_j(\mathbf{x}) [1 - p_j(\mathbf{x})] \beta_{jk}, j = 0, 1, \dots, J, k = 1, \dots, K$$

$$\partial p_j(\mathbf{x}) / \partial x_{hk} = p_j(\mathbf{x}) p_h(\mathbf{x}) \beta_{hk}, j = 0, 1, \dots, J, k = 1, \dots, K$$

Independencia de alternativas irrelevantes

- Un gran problema de estos modelos (mlogit o clogit) es que la elección entre dos alternativas dadas no depende de una tercera. O sea, son comparaciones de a pares.

$$\log(p_j(\mathbf{x}, \boldsymbol{\beta}) / p_h(\mathbf{x}, \boldsymbol{\beta})) = \mathbf{x}(\boldsymbol{\beta}_j - \boldsymbol{\beta}_h)$$

Esto recibe el nombre de supuesto de la independencia de alternativas irrelevantes.

- Este supuesto viene del supuesto de independencia de los errores y homocedásticos.
- Se puede proponer un contraste de Hausman para ver la validez del modelo (Hausman y McFadden, 1984). Supongamos que la alternativa $j = h$ es irrelevante, entonces excluirla no afecta los resultados entre las restantes. Si es relevante, excluirla debería generar inconsistencias. Sin embargo el modelo con $j = 0, 1, \dots, h-1, h+1, \dots, J$ es más eficiente que el modelo con $j = 0, 1, \dots, J$ (¿Por qué?)
Así,

$$(\hat{\boldsymbol{\beta}}_{all} - \hat{\boldsymbol{\beta}}_{-h})' [\hat{\mathbf{V}}_{-h} - \hat{\mathbf{V}}_{all}]^{-1} (\hat{\boldsymbol{\beta}}_{all} - \hat{\boldsymbol{\beta}}_{-h}) \xrightarrow{d} \chi_K^2$$

bajo la nula de alternativas irrelevantes.

Independencia de alternativas irrelevantes

- Existen otras alternativas que no tienen este supuesto.
- En este modelo \mathbf{a}_i sigue una distribución multivariada normal con correlaciones arbitrarias entre a_{ij} y a_{ih} , para todo $j \neq h$.
- Sin embargo el modelo es mucho más complejo para estimar (problemas de convergencia).
- Ver en STATA: <http://www.stata.com/manuals13/rmprobit.pdf>

Modelo probit de orden (ordered probit model)

Supongamos que la variable dependiente toma muchos valores, ej. $y = 0, 1, 2, \dots, J$, y los valores de y representan un orden en particular. Éste es el modelo de orden.

Ejemplo: y podría ser satisfacción con una compra de un bien; o evaluación de un candidato. En general aplica a evaluaciones subjetivas.

$y = 0$ "No me gusta"

$y = 1$ "Me es indiferente"

$y = 2$ "Me agrada"

$y = 3$ "Me gusta mucho"

¿Tiene sentido usar una regresión MCO?

Modelo probit de orden (ordered probit model)

- Asumamos una variable latente y^* dada por

$$y^* = \mathbf{x}\boldsymbol{\beta} + e, \quad e|\mathbf{x} \sim N(0, 1)$$

- Consideremos un modelo con $J + 1$ categorías indexadas por $j = 0, 1, 2, \dots, J$ supongamos J umbrales o puntos de corte desconocidos $\alpha_1 < \alpha_2 < \dots < \alpha_J$ que satisfacen

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

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

$$\vdots$$

$$y = J \text{ si } y^* \geq \alpha_J$$

- Entonces la distribución condicional es

$$P(y = 0|\mathbf{x}) = P(y^* \leq \alpha_1|\mathbf{x}) = P(\mathbf{x}\boldsymbol{\beta} + e \leq \alpha_1|\mathbf{x}) = \Phi(\alpha_1 - \mathbf{x}\boldsymbol{\beta})$$

$$P(y = 1|\mathbf{x}) = P(\alpha_1 < y^* \leq \alpha_2|\mathbf{x}) = \Phi(\alpha_2 - \mathbf{x}\boldsymbol{\beta}) - \Phi(\alpha_1 - \mathbf{x}\boldsymbol{\beta})$$

$$\vdots$$

$$P(y = J - 1|\mathbf{x}) = P(\alpha_{J-1} < y^* \leq \alpha_J|\mathbf{x}) = \Phi(\alpha_J - \mathbf{x}\boldsymbol{\beta}) - \Phi(\alpha_{J-1} - \mathbf{x}\boldsymbol{\beta})$$

$$P(y = J|\mathbf{x}) = P(y^* > \alpha_J|\mathbf{x}) = 1 - \Phi(\alpha_J - \mathbf{x}\boldsymbol{\beta})$$

Modelo probit de orden (ordered probit model)

- El modelo se puede estimar por MLE:
$$\ell_i(\boldsymbol{\beta}) = 1[y_i = 0] \log[\Phi(\alpha_1 - \mathbf{x}\boldsymbol{\beta})] + 1[y_i = 1] \log[\Phi(\alpha_2 - \mathbf{x}\boldsymbol{\beta}) - \Phi(\alpha_1 - \mathbf{x}\boldsymbol{\beta})] + \dots + 1[y_i = J] \log[1 - \Phi(\alpha_J - \mathbf{x}\boldsymbol{\beta})].$$
- Los efectos marginales se pueden calcular como:

$$\partial p_0(\mathbf{x}) / \partial x_k = -\beta_k \phi(\alpha_1 - \mathbf{x}\boldsymbol{\beta}),$$

$$\partial p_J(\mathbf{x}) / \partial x_k = \beta_k \phi(\alpha_J - \mathbf{x}\boldsymbol{\beta}),$$

$$\partial p_j(\mathbf{x}) / \partial x_k = \beta_k [\phi(\alpha_{j-1} - \mathbf{x}\boldsymbol{\beta}) - \phi(\alpha_j - \mathbf{x}\boldsymbol{\beta})], 0 < j < J$$

Modelo probit de orden (ordered probit model)

- Un supuesto que sale del modelo es el **supuesto de regresiones paralelas**. Es decir, todas las alternativas se basan en el mismo coeficiente β y sólo cambia la constante.
- Por ejemplo, notemos que $P(y \leq j|\mathbf{x}) = \sum_{h=0}^j P(y = h|\mathbf{x}) = \Phi(\alpha_1 - \mathbf{x}\beta) + (\Phi(\alpha_2 - \mathbf{x}\beta) - \Phi(\alpha_1 - \mathbf{x}\beta)) + \dots + (\Phi(\alpha_j - \mathbf{x}\beta) - \Phi(\alpha_{j-1} - \mathbf{x}\beta)) = \Phi(\alpha_j - \mathbf{x}\beta)$, (sólo cambia la constante).
- Podríamos armar el modelo de orden usando una serie de modelos probit. Por ejemplo, construir $w_{ij} = 1$ si $y_{ij} \leq j$, $w_{ij} = 0$ si $y_{ij} > j$ para $j = 0, 1, \dots, J - 1$.
- Entonces tenemos,

$$P(y \leq j|\mathbf{x}) = P(y^* \leq \alpha_j|\mathbf{x}) = \Phi(\alpha_j - \mathbf{x}\beta_j)$$

- El modelo de orden asume que los parámetros β son los mismos en todos los probit bivariados, excepto por la constante (α). Si estimamos cada probit por separado entonces los betas son específicos de cada modelo y tenemos más flexibilidad.
- Un subproducto de este análisis es obtener

$$\frac{P(y \leq j|\mathbf{x})}{\partial x_h} = -\beta_{hj}g(\alpha_j - \mathbf{x}\beta_j)$$

Modelo probit de orden (ordered probit model): STATA

- `oprobit y x1 x2 x3`
- `mfx, predict(p outcome(1))` (efectos marginales para $y = 1$)
- `mfx, predict(p outcome(2))` (efectos marginales para $y = 2$)
- <http://www.stata.com/manuals13/rologit.pdf>
- <http://www.stata.com/manuals13/roprobit.pdf>

Interval regression

En el modelo anterior se asumía que no se conocían los puntos de corte. Si estos se conocieran podemos armar un modelo con más información.

Ejemplo: y podría ser niveles de ingreso

$y = 0$ "Ingreso 0"

$y = 1$ " $0 < \text{Ingreso} \leq \1000 "

$y = 2$ " $\$1000 < \text{Ingreso} \leq \2000 "

$y = 3$ " $\$2000 < \text{Ingreso}$ "

¿Tiene sentido usar una regresión MCO?