



**LISBOA  
SCHOOL OF  
ECONOMICS &  
MANAGEMENT**

## Capítulo 5 – Modelos de escolha Binária

### Estimação, testes e efeitos parciais

Luís Silveira Santos

lsantos@iseg.ulisboa.pt

Mestrado em Econometria Aplicada e Previsão,  
Instituto Superior de Economia e Gestão – Universidade de Lisboa

10 de Abril de 2016

## Programa desta aula

- 1 Revisão
- 2 Estimação
- 3 Efeitos parciais
  - Efeito parcial na média
  - Efeito parcial médio
  - Cálculo dos erros-padrão
- 4 Testes de hipóteses
  - Testes de restrições de exclusão simples ou múltiplas
  - Testes de hipóteses não lineares
- 5 Interpretação dos resultados
  - Qualidade das previsões
  - $R^2$  de McFadden
  - Probit vs. Logit vs. MPL

## Revisão

- Recordemos que pretendemos estimar:

$$P(y = 1 | \mathbf{X}) = G(\mathbf{X}\beta) \equiv p(\mathbf{x})$$

onde se assume que  $G(\cdot) \in [0, 1]$

- Se  $\varepsilon | \mathbf{X} \sim N(0, 1)$  então,

$$G(z) \equiv \Phi(z) = \int_{-\infty}^z \phi(z) dz$$

- Se  $\varepsilon | \mathbf{X} \sim \text{Logistic}(0, 1)$  então,

$$G(z) \equiv \Lambda(z) = \frac{\exp(z)}{1 + \exp(z)}$$

- Como  $y \in \{0, 1\}$ , sabemos que, em geral,  $Y | \mathbf{X} \sim \text{Ber}(G(\mathbf{X}\beta))$

# Estimação

- A estimação de modelos não lineares pode ser feita por duas vias:
  - ① Mínimos quadrados não lineares (NLS)
  - ② Máxima Verosimilhança (ML)
- Do método NLS iremos obter:
  - Estimadores consistentes e  $\sqrt{N}$  assintoticamente Normais
  - Inferência robusta a heterocedasticidade com forma funcional genérica
- Do método ML iremos obter:
  - Estimadores consistentes e  $\sqrt{N}$  assintoticamente Normais
  - Variância assintótica que atinge o limite inferior de Fréchet-Cramer-Rao  $\Rightarrow$  estimador assintoticamente mais eficiente
  - **No entanto**, estes resultados são válidos apenas no caso em que a densidade de  $Y | \mathbf{X}$  esteja bem especificada

## Estimação (cont.)

- Como estamos a assumir que a densidade de  $Y \mid \mathbf{X}$  está bem especificada, iremos optar pelo estimador assintoticamente mais eficiente: o estimador ML
  - Assim sendo, em primeiro lugar, será necessário definir a densidade de  $Y \mid \mathbf{X}$  (em termos genéricos):

$$f(y_i \mid \mathbf{x}_i; \beta) = [G(\mathbf{x}_i\beta)]^{y_i} [1 - G(\mathbf{x}_i\beta)]^{1-y_i}$$

- Em seguida, iremos obter a função log-verosimilhança para o indivíduo  $i$ :

$$\ell_i(\beta) = y_i \log [G(\mathbf{x}_i\beta)] + (1 - y_i) \log [1 - G(\mathbf{x}_i\beta)]$$

- Note-se que a função log-verosimilhança para uma amostra i.i.d. de dimensão  $N$  é imediatamente obtida por via do somatório da função log-verosimilhança individual

## Funções Score e Hessiana

- Se derivarmos uma vez a função log-verosimilhança individual iremos obter a função score para o indivíduo  $i$ :

$$\begin{aligned}
 \mathbf{s}_i(\boldsymbol{\beta}) &= \nabla_{\boldsymbol{\beta}} \ell_i(\boldsymbol{\beta})' = \\
 &= y_i \left[ \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i'}{G(\mathbf{x}_i\boldsymbol{\beta})} \right] - (1 - y_i) \left[ \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i'}{1 - G(\mathbf{x}_i\boldsymbol{\beta})} \right] = \\
 &= \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i' \{y_i [1 - G(\mathbf{x}_i\boldsymbol{\beta})] - (1 - y_i) G(\mathbf{x}_i\boldsymbol{\beta})\}}{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]} = \\
 &= \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i'}{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]} [y_i - G(\mathbf{x}_i\boldsymbol{\beta})]
 \end{aligned}$$

onde  $g(\cdot)$  é a primeira derivada da função  $G(\cdot)$

## Funções Score e Hessiana (cont.)

- Derivando 2ª vez, iremos obter a hessiana para o indivíduo  $i$ :

$$\begin{aligned}
 \mathbf{H}_i(\boldsymbol{\beta}) &= \nabla_{\boldsymbol{\beta}}^2 \ell_i(\boldsymbol{\beta}) = \\
 &= \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}'_i \times [-g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i]}{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]} + [y_i - G(\mathbf{x}_i\boldsymbol{\beta})] \left( \frac{\nabla_{\boldsymbol{\beta}} g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}'_i \mathbf{x}_i G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]}{\{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]\}^2} - \right. \\
 &\quad \left. - \frac{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}'_i \{g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i [1 - G(\mathbf{x}_i\boldsymbol{\beta})] - g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}_i G(\mathbf{x}_i\boldsymbol{\beta})\}}{\{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]\}^2} \right) = \\
 &= -\frac{[g(\mathbf{x}_i\boldsymbol{\beta})]^2 \mathbf{x}'_i \mathbf{x}_i}{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]} + \\
 &\quad + [y_i - G(\mathbf{x}_i\boldsymbol{\beta})] \left( \frac{\nabla_{\boldsymbol{\beta}} g(\mathbf{x}_i\boldsymbol{\beta}) \mathbf{x}'_i \mathbf{x}_i}{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]} - \frac{[g(\mathbf{x}_i\boldsymbol{\beta})]^2 \mathbf{x}'_i \mathbf{x}_i [1 - 2G(\mathbf{x}_i\boldsymbol{\beta})]}{\{G(\mathbf{x}_i\boldsymbol{\beta}) [1 - G(\mathbf{x}_i\boldsymbol{\beta})]\}^2} \right)
 \end{aligned}$$

onde  $\nabla_{\boldsymbol{\beta}} g(\cdot)$  é a segunda derivada da função  $G(\cdot)$

## Funções Score e Hessiana (cont.)

Se aos resultados obtidos anteriormente aplicarmos o valor esperado condicionado verificamos que:

$$\rightarrow E[s_i(\beta) | \mathbf{X}_i] = \frac{g(\mathbf{x}_i\beta) \mathbf{x}_i'}{G(\mathbf{x}_i\beta) [1 - G(\mathbf{x}_i\beta)]} \underbrace{[E(Y_i | \mathbf{X}_i) - G(\mathbf{x}_i\beta)]}_{=0} = 0$$

$$\rightarrow E[\mathbf{H}_i(\beta) | \mathbf{X}_i] = -\frac{[g(\mathbf{x}_i\beta)]^2 \mathbf{x}_i' \mathbf{x}_i}{G(\mathbf{x}_i\beta) [1 - G(\mathbf{x}_i\beta)]} + \underbrace{[E(Y_i | \mathbf{X}_i) - G(\mathbf{x}_i\beta)]}_{=0} \Upsilon(\mathbf{x}_i\beta)$$

Ou seja,

- A propriedade do valor esperado condicionado da função Score verifica-se, para uma qualquer função  $G(\cdot)$
- A variância assintótica do estimador ML,

$$\widehat{\text{Avar}}(\hat{\beta}) = \left\{ \sum_{i=1}^N -E[\mathbf{H}_i(\beta) | \mathbf{X}_i] \right\}^{-1}$$

se a densidade de  $Y | \mathbf{X}$  estiver bem especificada

## Resumindo...

	Probit	Logit
$s_i(\beta)$	$\frac{\phi(\mathbf{x}_i\beta) \mathbf{x}'_i [y_i - \Phi(\mathbf{x}_i\beta)]}{\Phi(\mathbf{x}_i\beta) [1 - \Phi(\mathbf{x}_i\beta)]}$	$[y_i - \Lambda(\mathbf{x}_i\beta)] \mathbf{x}_i$
$H_i(\beta)$	$-\frac{[\phi(\mathbf{x}_i\beta)]^2 \mathbf{x}'_i \mathbf{x}_i}{\Phi(\mathbf{x}_i\beta) [1 - \Phi(\mathbf{x}_i\beta)]} + [y_i - G(\mathbf{x}_i\beta)] \varphi(\mathbf{x}_i\beta)$	$-\lambda(\mathbf{x}_i\beta) \mathbf{x}'_i \mathbf{x}_i$
$E[s_i(\beta)   \mathbf{X}_i]$	0	0
$E[H_i(\beta)   \mathbf{X}_i]$	$-\frac{[\phi(\mathbf{x}_i\beta)]^2 \mathbf{x}'_i \mathbf{x}_i}{\Phi(\mathbf{x}_i\beta) [1 - \Phi(\mathbf{x}_i\beta)]}$	$-\lambda(\mathbf{x}_i\beta) \mathbf{x}'_i \mathbf{x}_i$
$\widehat{Avar}(\hat{\beta})$	$\left\{ \sum_{i=1}^N \frac{[\phi(\mathbf{x}_i\beta)]^2 \mathbf{x}'_i \mathbf{x}_i}{\Phi(\mathbf{x}_i\beta) [1 - \Phi(\mathbf{x}_i\beta)]} \right\}^{-1}$	$\left\{ \sum_{i=1}^N \lambda(\mathbf{x}_i\beta) \mathbf{x}'_i \mathbf{x}_i \right\}^{-1}$

**NOTA:**  $\lambda(\cdot) = \Lambda(\cdot) [1 - \Lambda(\cdot)]$

## Efeitos parciais

- Recordemos da aula anterior que os efeitos parciais obtidos por via destes modelos não lineares são dados por:

$$\frac{\partial P(Y = 1 | \mathbf{X})}{\partial x_j} = \frac{\partial p(\mathbf{x})}{\partial x_j} = \beta_j \times g(\mathbf{X}\beta)$$

- No entanto a função  $g(\mathbf{X}\beta)$  depende dos valores que cada elemento da matriz  $\mathbf{X}$  pode assumir
- A solução passa por calcular dois tipos de efeitos parciais:
  - 1 Efeito parcial na média (PEA)
  - 2 Efeito parcial médio (APE)

## Efeito parcial na média

- Neste contexto, vamos calcular a função  $g(\mathbf{X}\beta)$  para valores “representativos” de cada elemento da matriz  $\mathbf{X}$ :
  - 1 Médias
  - 2 Máximos e Mínimos
- Desta forma podemos:
  - 1 Analisar os efeitos parciais no indivíduo “médio”
  - 2 Proceder a uma análise de sensibilidade dos efeitos parciais para valores extremos de  $x_j$ ,  $j = 1, 2, \dots, K$

## Efeitos parciais na média (cont.)

- Se  $x_j$  é variável contínua:

$$\widehat{PEA}_j = \frac{\partial P(Y = 1 \mid \mathbf{X} = \bar{\mathbf{X}})}{\partial x_j} = \hat{\beta}_j \times g(\bar{\mathbf{X}}\hat{\beta})$$

- Se  $x_j$  é variável discreta:

$$\widehat{PEA}_j = G \left[ \hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2 + \dots + \hat{\beta}_{j-1} \bar{x}_{j-1} + \hat{\beta}_j (c_j + 1) \right] - G \left( \hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2 + \dots + \hat{\beta}_{j-1} \bar{x}_{j-1} + \hat{\beta}_j c_j \right)$$

- Quando  $x_j$  é variável binária, podemos utilizar o  $PEA_j$  anterior, fixando  $c_j = 0$

## Efeito parcial médio

- Uma alternativa passa por calcular a média da função  $g(\mathbf{X}\beta)$ :

$$APE_j = \beta_j \times E[g(\mathbf{X}\beta)]$$

- Se  $x_j$  é variável contínua, um estimador consistente será:

$$\widehat{APE}_j = \hat{\beta}_j \left[ \frac{1}{N} \sum_{i=1}^N g(\mathbf{x}_i \hat{\beta}) \right]$$

- Se  $x_j$  é variável discreta, um estimador consistente será:

$$\widehat{APE}_j = \frac{1}{N} \sum_{i=1}^N \left\{ G \left[ \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_{j-1} x_{i,j-1} + \hat{\beta}_j (c_j + 1) \right] - G \left( \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_{j-1} x_{i,j-1} + \hat{\beta}_j c_j \right) \right\}$$

- Quando  $x_j$  é variável binária, fixamos  $c_j = 0$  no  $APE_j$  anterior

## Cálculo dos erros-padrão

- A maioria dos *softwares* econométricos permite-nos realizar inferência sobre para as estimativas dos *PEAs* e dos *APEs*, através do cálculo dos erros-padrão
- Estes erros-padrão são habitualmente calculados numericamente através de duas metodologias:
  - Método Delta
  - *Bootstrap*

## Testes de hipóteses

- Tal como acontece no caso dos modelos lineares, estamos interessados em realizar testes de hipóteses sobre os parâmetros do modelo estimado
- Iremos dar enfoque a dois tipos de testes:
  - 1 Testes de restrições de exclusão simples ou múltiplas
  - 2 Testes de hipóteses não lineares sobre os parâmetros  $\beta$
- As estatísticas de teste que seguidamente se irão apresentar são assintoticamente equivalentes, porém algumas delas poderão ser computacionalmente difíceis de obter

## Testes de restrições de exclusão simples ou múltiplas

- Considere-se o seguinte modelo:

$$P(Y = 1 | \mathbf{X}, \mathbf{Z}) = G(\mathbf{X}\beta + \mathbf{Z}\gamma)$$

onde  $\mathbf{Z}$  é matriz  $N \times Q$  e  $\gamma$  é vector de dimensão  $Q \times 1$

- Pretendemos testar a hipótese:

$$H_0 : \gamma = 0$$

- Existem três estatísticas de teste em opção:
  - 1 Estatística de Wald
  - 2 Rácio de verosimilhanças (ou teste LR)
  - 3 Teste de Score (ou teste LM)

## Testes de restrições de exclusão simples ou múltiplas (cont.)

### 1 ESTATÍSTICA DE WALD:

$$W = (R\hat{\gamma} - r)' (R\hat{V}R')^{-1} (R\hat{\gamma} - r) \xrightarrow{d} \chi^2_{(Q)}$$

onde  $\hat{V}$  é a matriz de variância assintótica do modelo com  $G(\mathbf{X}\beta + \mathbf{Z}\gamma)$

### 2 RÁCIO DE VEROSIMILHANÇAS:

$$LR = 2(\mathcal{L}_{ur} - \mathcal{L}_r) \xrightarrow{d} \chi^2_{(Q)}$$

onde  $\mathcal{L}_{ur}$  é a função log-verosimilhança para o modelo com  $G(\mathbf{X}\beta + \mathbf{Z}\gamma)$  e  $\mathcal{L}_r$  é a função log-verosimilhança para o modelo com  $G(\mathbf{X}\beta)$

## Testes de restrições de exclusão simples ou múltiplas (cont.)

### 3 TESTE DE SCORE:

$$LM = NR_u^2 \xrightarrow{d} \chi^2_{(Q)}$$

onde  $R_u^2$  é o  $R^2$  não centrado da regressão auxiliar, estimada por OLS, de:

$$\frac{\hat{u}_i}{\sqrt{\hat{G}_i (1 - \hat{G}_i)}} \text{ sobre } \frac{\hat{g}_i}{\sqrt{\hat{G}_i (1 - \hat{G}_i)}} \mathbf{x}_i \text{ e } \frac{\hat{g}_i}{\sqrt{\hat{G}_i (1 - \hat{G}_i)}} \mathbf{z}_i$$

com  $\hat{u}_i = y_i - G(\mathbf{x}_i \hat{\beta})$ ,  $\hat{G} = G(\mathbf{x}_i \hat{\beta})$  e  $\hat{g} = g(\mathbf{x}_i \hat{\beta})$

⇒ Note-se que se pondera por  $[\hat{G}_i (1 - \hat{G}_i)]^{-1/2}$  pois, sob  $H_0$ ,

$$\text{Var}(u_i | \mathbf{X}, \mathbf{Z}) = G(\mathbf{x}_i \beta) [1 - G(\mathbf{x}_i \beta)]$$

## Testes de hipóteses não lineares

- Relativamente aos testes de hipóteses não lineares, apesar de podermos considerar novamente as estatísticas anteriores, existem problemas computacionais relativamente ao seu cálculo
- Em concreto, impor-se restrições não lineares na estimação dos modelos Probit e Logit eleva substancialmente o nível de complexidade computacional de maximização da função de verosimilhança, com implicações directas no cálculo das estatísticas de teste  $LM$  e  $LR$
- Resta-nos, portanto, a estatística de Wald. No entanto, esta estatística não é invariante a reparameterizações (ao contrário das estatísticas de teste  $LM$  e  $LR$ ), traduzindo-se em fracas propriedades de amostras finitas

## Testes de hipóteses não lineares (cont.)

- Ainda assim, iremos optar por calcular a estatística de Wald, uma vez que os resultados assintóticos permanecem válidos
- Tendo por base o modelo com  $G(\mathbf{X}\beta)$ , vamos considerar que pretendemos testar uma restrição não linear genérica, i.e.,

$$H_0 : \mathbf{c}(\beta) = 0$$

onde  $\mathbf{c}(\beta)$  é vector de dimensão  $K_1 \times 1$ , com  $K_1 \leq K$

- Neste caso, a estatística de Wald é dada por:

$$W = \mathbf{c}(\hat{\beta})' \left( \nabla_{\beta} \mathbf{c}(\hat{\beta}) \hat{V} \nabla_{\beta} \mathbf{c}(\hat{\beta})' \right)^{-1} \mathbf{c}(\hat{\beta}) \xrightarrow{d} \chi^2_{(K_1)}$$

onde  $\nabla_{\beta} \mathbf{c}(\hat{\beta})$  é o jacobiano do vector  $\mathbf{c}(\beta)$  avaliado em  $\hat{\beta}$

## Qualidade do ajustamento

- Um outro aspecto importante da nossa análise será avaliar o potencial do modelo estimado
- Para tal, temos duas medidas da qualidade do ajustamento:
  - 1 Qualidade das previsões
  - 2  $R^2$  de McFadden (ou pseudo- $R^2$ )
- Note-se, porém, que não devemos esperar valores convincentes destas medidas

## Qualidade das previsões

- Sabe-se que:

$$\hat{y}_i = \begin{cases} 1 & \text{se } G(\mathbf{x}_i \hat{\beta}) \geq 0.5 \\ 0 & \text{se } G(\mathbf{x}_i \hat{\beta}) < 0.5 \end{cases}$$

- Vamos então definir:
  - $N_0 = \#(y_0)$ , número de “insucessos” na amostra
  - $N_1 = \#(y_1)$ , número de “sucessos” na amostra
  - $N_{00} = \#(\hat{y}_0)$ , número de “insucessos” bem previstos
  - $N_{11} = \#(\hat{y}_1)$ , número de “sucessos” bem previstos

## Qualidade das previsões (cont.)

- Uma medida da qualidade das previsões envolve a relação entre a proporção dos “sucessos” e dos “insucessos” bem previstas:

$$q_0 = \frac{N_{00}}{N_0} \text{ e } q_1 = \frac{N_{11}}{N_1}$$

- Se alguma das proporções acima apresentar um valor demasiado baixo, poderemos ajustar o *threshold* das probabilidades estimadas de 0.5 para  $\bar{y}$ , uma vez que este é um estimador consistente para a probabilidade de sucesso não condicionada
- A proporção total de previsões correctas é dada por:

$$q = \frac{N_{00} + N_{11}}{N} = \frac{N_0}{N} q_0 + \frac{N_1}{N} q_1$$

## $R^2$ de McFadden

- O  $R^2$  de McFadden é dado por

$$R_{P_{\text{seudo}}}^2 = 1 - \frac{\mathcal{L}_{ur}}{\mathcal{L}_0}$$

onde  $\mathcal{L}_{ur}$  é a função log-verosimilhança para o modelo estimado e  $\mathcal{L}_0$  é a função log-verosimilhança para o modelo apenas com a constante

## Probit vs. Logit vs. MPL

- A escolha entre o Probit e o Logit é, em geral, difícil
- Uma vez que ambos têm implícita uma função de distribuição, a decisão recai sobre a caracterização dos valores extremos dos nossos dados
- Nos casos em que exista uma grande densidade de valores extremos, deveremos optar pelo Logit, uma vez que a distribuição Logística estandarizada tem caudas mais pesadas

## Probit vs. Logit vs. MPL (cont.)

- No entanto, é possível comparar as magnitudes das estimativas entre os três modelos através de factores de escala:
  - MPL  $\rightarrow g(0) = 1$
  - Probit  $\rightarrow g(0) = \frac{1}{\sqrt{2\pi}} \approx 0.4$
  - Logit  $\rightarrow g(0) = \frac{\exp(0)}{1 + \exp(0)} \times \left[ 1 - \frac{\exp(0)}{1 + \exp(0)} \right] = 0.25$
- **EXEMPLO:** dividir as estimativas Logit por  $0.4/0.25 = 1.6$  para torná-las comparáveis com as estimativas Probit