



## Monitoria Econometria II

REC 2312 - 1º Semestre 2015

Monitor(a): Victória Mazás Martinez

4ª Lista de exercícios - modelos não lineares

\*Lembrando que a resolução é apenas uma síntese simplificada das respostas esperadas.

1. Suponha que você tenha que estimar um modelo no qual sua variável dependente seja uma *dummy* que assume o valor 1 se o indivíduo de 18 anos completou o Ensino Médio e zero caso contrário. Discorra sobre como seria a melhor forma de estimar o modelo, dado que queremos saber o efeito sobre a probabilidade de conclusão do E.M. aos 18 anos. Descreva detalhadamente as etapas necessárias para a estimação e as suposições sobre o modelo.

Como não se deseja obter probabilidade fora do intervalo  $[0,1]$ , devemos utilizar o modelo *Probit* ou *Logit*. A diferença entre eles encontra-se apenas na suposição sobre a distribuição do termo de erro; caso acredite-se que ele segue uma distribuição Normal, utiliza-se o modelo Probit, caso acredite-se que ele segue uma distribuição logística, utiliza-se o *Logit*. Em ambos os casos, assume-se que :  $P(y = 1|x) = G(X\beta)$ , onde  $G(z) = \Phi(z)$ , é uma distribuição acumulada de uma normal padrão no caso do *Probit* e  $G(z) = \exp(z)/[1 + \exp(z)]$  no caso do *Logit*. A estimação dos parâmetros é feita pela maximização da função de verossimilhança:

$$L = \prod_{i=1}^n f(y|x_i; \beta) = \prod_{i=1}^n [G(x_i\beta)]^{y_i} [1 - G(x_i\beta)]^{1-y_i}$$

Que é o mesmo que maximizar a função de log-verossimilhança:

$$L = \sum_{i=1}^n \ln f(y|x_i; \beta) = \sum_{i=1}^n y_i [G(x_i\beta)] + (1 - y_i) \ln[1 - G(x_i\beta)]$$

Efetutando-se a maximização ...

2. Discorra sobre a diferença na interpretação dos coeficientes nos modelos de probabilidade Linear e não Linear (Probit ou Logit )

No modelo de probabilidade linear o coeficiente estimado pode ser interpretado diretamente como a mudança marginal na probabilidade de um evento ocorrer dada uma mudança em  $x$ . Contudo, o mesmo não ocorre com os modelos *Logit* e *Probit*. Nestes modelos apenas o sinal do coeficiente pode ser considerado, ou seja, ele dará um indicativo da direção do efeito (observe a forma do efeito marginal para variáveis contínuas na questão abaixo, como  $g(\cdot)$  é sempre positivo,  $\beta$  determinará o sinal do efeito marginal. A magnitude do efeito marginal dependerá do valor do vetor  $x$ ).

3. Apresente a forma dos efeitos marginais nos modelos não lineares (obs: eles diferem nos casos contínuo, discreto e para dummies).

Efeitos Marginais :

- (a) Para o caso de variáveis contínuas:

$$Pr(y_i = 1|x) = G(\beta_0 + \beta X)$$

Derivando em  $x$ , temos:

$$\frac{\partial G(\cdot)}{\partial x_i} = g(\cdot)\beta_i$$

onde  $g(\cdot)$  é uma função de densidade de probabilidade ( que dependendo da hipótese sobre a distribuição do termo de erro pode ser logística ou normal).

- (b) para o caso de variável dummy:

$$G(\hat{\beta}_0 + \hat{\beta}_1) - G(\hat{\beta}_0)$$

(c) Se  $x_i$  é discreto :

$$G(\hat{\beta}_0 + \hat{\beta}_1(c + 1)) - G(\hat{\beta}_0 + \hat{\beta}_1(c))$$

4. Dado que o efeito marginal em regressões não lineares depende do valor do vetor  $\mathbf{x}$ , apresente duas formas de calcular uma medida sumarizada do impacto marginal de uma variável explicativa.

(a) Efeito Marginal na Média:

$$\frac{\partial Pr}{\partial x_j} = g(\hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2) \beta_j$$

Onde o  $\bar{x}_i$  representa o valor atribuído ao indivíduo representativo que neste caso é o indivíduo médio.

(b) Média do Efeito Marginal :

$$E[\partial Pr / \partial x_j]$$

Por analogia :

$$1/N \sum_{i=1}^N g_i \beta_j$$

5. O efeito parcial de  $x_j$  sobre  $Pr(\mathbf{x})$  depende de  $\mathbf{x}$ . Contudo o efeito relativo não depende de  $\mathbf{x}$ . Mostre que para variáveis contínuas  $x_j$  e  $x_h$ , a taxa dos efeitos parciais é constante.

$$\frac{\partial Pr / \partial x_j}{\partial Pr / \partial x_h} = g(\mathbf{x}\boldsymbol{\beta}) \beta_j / g(\mathbf{x}\boldsymbol{\beta}) \beta_h = \frac{\beta_j}{\beta_h}$$

6. Defina *grad* como uma variável *dummy* informando se um estudante- atleta de uma grande universidade se formará em cinco anos. Sejam *nmem* e *sat* a nota média do ensino médio e a nota no exame *SAT*, respectivamente. Defina *estudo* como o número de horas gastas por semana em uma sala de estudos organizada. Suponha que usando os dados de 420 estudantes- atletas, observa-se o seguinte modelo logit:

$$\hat{P}(\text{grad} = 1 | \text{nmem}, \text{sat}, \text{estudo}) = \Lambda(-1, 17 + 0, 24\text{nmem} + 0, 00058\text{sat} + 0, 073\text{estudo}),$$

onde  $\Lambda(z) = \exp(z)/[1 + \exp(z)]$  é a função logit. Mantendo fixos *nmem* e *sat* em 3,0 e 1.200, respectivamente, compute a diferença estimada na probabilidade de formatura de alguém que passou dez horas por semana em uma sala de estudos e de alguém que passou cinco horas por semana.

Como horas é uma variável discreta, pelo exercício acima, sabemos que seu efeito será calculado da seguinte maneira

$$G(\hat{\beta}_0 + \hat{\beta}_1(c + k)) - G(\hat{\beta}_0 + \hat{\beta}_1(c)),$$

portanto substituindo os valores dados e calculando, obteremos

$$\Lambda(7.24) - \Lambda(6.875) = 0.000315433$$

7. Apresente a justificativa para o uso de variável latente para estimar um modelo e a estrutura do modelo sob este enfoque.

O enfoque da variável latente trata o uso de variáveis dicotômicas basicamente como um problema de medida, ou seja, existe uma variável latente contínua ( $Y^*$ ) que não observamos diretamente de forma que não podemos mensurá-la. O que nós observamos é um indicador da variável latente.

O modelo sobre este enfoque é descrito da seguinte maneira:

$$Y^* = \beta_0 + \beta_1 X_i + \epsilon_i$$

$$Y_i = 0, \text{ se } Y_i^* \leq 0,$$

$$Y_i = 1, \text{ se } Y_i^* > 0,$$

$$P(Y_i = 1) = P(Y_i^* > 0) = P(X_i\beta + \epsilon_i > 0) = P(\epsilon_i \leq X_i\beta)$$