

Modelos não lineares

Tópicos:

- Estimação e inferência em modelos não lineares
- Modelos para dados binários
- Modelos para excesso de zeros

Motivação para o uso de modelos não lineares:

- Frequentemente a variável dependente é discreta e/ou limitada, não sendo o modelo linear o mais apropriado

Modelos não lineares

Quantidades de interesse:

- Modelos lineares:
 - $E(Y|X)$
- Modelos não lineares:
 - $E(Y|X)$
 - $Pr(Y|X)$
 - Em alguns casos, também outras quantidades:
 - Exemplo: quando $Y \geq 0$, com muitos zeros, pode ser interessante estimar:
 - » $Pr(Y = 0|X)$
 - » $E(Y|X, Y > 0)$

Modelos não lineares

Efeitos parciais:

- Modelos lineares:

- Modelo: $E(Y|X) = X\beta$
- Efeitos: $\Delta X_j = 1 \Rightarrow \Delta E(Y|X) = \beta_j$

- Modelos não lineares:

- Modelo:

- $E(Y|X) = G(X\beta)$
- $Pr(Y|X) = F(X\beta)$

- Efeitos: $\Delta X_j = 1 \Rightarrow$

- $\Delta E(Y|X) = \frac{\partial E(Y|X)}{\partial X_j} = \frac{\partial G(X\beta)}{\partial X_j} = \beta_j \frac{\partial G(X\beta)}{\partial X\beta} = \beta_j g(x_i'\beta)$
- $\Delta Pr(Y|X) = \frac{\partial Pr(Y|X)}{\partial X_j} = \frac{\partial F(X\beta)}{\partial X_j} = \beta_j \frac{\partial F(X\beta)}{\partial X\beta} = \beta_j f(x_i'\beta)$

Modelos não lineares

- Os efeitos parciais podem-se comparar para diferentes modelos mas os β não
- Contudo, como $\frac{\partial G(X\beta)}{\partial X\beta} > 0$ e $\frac{\partial F(X\beta)}{\partial X\beta} > 0$:
 - β_j informa sobre o sinal do efeito parcial
 - A significância individual do efeito pode ser testada com $H_0: \beta_j = 0$
- Para calcular a magnitude dos efeitos parciais:
 - Calcular o efeito para cada individuo e fazer a média no final: efeito parcial médio
 - Substituir x pela sua média: efeito parcial avaliado na média
 - *Substituir x por valores específicos*

Stata
(after estimating the model)
margins, dydx(*varlist*)
margins, dydx(*varlist*) atmeans
margins, dydx(*varlist*) at(...)

Modelos não lineares

Estimação por máxima verosimilhança:

Especifica-se:

- $E(Y|X) = G(X\beta)$
- $Pr(Y|X) = F(X\beta)$

Problema de otimização

$$\max_{\beta} LL(X\beta) = \sum_{i=1}^N \ln[f(y_i|x_i; \beta)]$$

Propriedades assintóticas dos estimadores MV:

- Consistencia
- Eficiencia
- Normalidade

Modelos não lineares

Cálculo das variância dos parâmetros:

- Standard
- Cluster-robust → dados de painel
- Bootstrap

Testes clássicos:

- Rácio de verossimilhanças, “Likelihood Ratio” (LR)
- Wald
- Score/LM

Modelos não lineares

Teste para a significância conjunta:

- Modelos:

- Restrito: $L_R(\beta_0 + \beta_1 x_1 + \dots + \beta_g x_g)$
- Não restrito $L_F(\beta_0 + \beta_1 x_1 + \dots + \beta_g x_g + \beta_{g+1} x_{g+1} + \dots + \beta_k x_k)$

- Hipoteses:

$H_0: \beta_{g+1} = \dots = \beta_k = 0$ (escolha do modelo restrito)

$H_1: \text{No } H_0$ (escolha do modelo não restrito)

Modelos não lineares

- Teste LR test:

$$LR = 2[LL_F(X\beta_F) - LL_R(X\beta_R)] \sim \chi_{k-g}^2$$

- Disponível na maioria dos packages
- Há que estimar dois modelos

```
Stata
(estimate one model)
estimates store Model1
(estimate the other model)
estimates store Model2
lrtest Model1 Model2
```

- Teste de Wald :

$$W = \hat{\beta}'_D [\text{Var}(\hat{\beta}_D)]^{-1} \hat{\beta}_D \sim \chi_{k-g}^2$$

onde $\hat{\beta}_D = (\hat{\beta}_{g+1}, \dots, \hat{\beta}_k)$ se baseia em $LL_F(X\beta_F)$

- Se $H_0: \beta_j = 0$, W simplifica-se:

$$t = \frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim \mathcal{N}(0,1)$$

- Disponível na maioria dos packages
- Apenas o modelo não restrito é estimado

```
Stata
(after estimating the full model)
test X_{g+1} \dots X_k
```


Modelos não lineares

Testes de especificação

1. Teste RESET:

- Estimar o modelo em teste:

$$Pr(Y|X) = F(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)$$

- Gerar $(X\hat{\beta})^2, (X\hat{\beta})^3, (X\hat{\beta})^4, \dots$

- Estimar o modelo auxiliar

$$Pr(Y|X)$$

$$= F \left[\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \gamma_1 (X\hat{\beta})^2 + \gamma_2 (X\hat{\beta})^3 + \gamma_3 (X\hat{\beta})^4 + \dots \right]$$

- Aplicar um teste LR / Wald para:

$$H_0: \gamma_1 = \gamma_2 = \gamma_3 = \dots = 0 \text{ (forma funcional correcta)}$$

$$H_1: \text{Não } H_0 \text{ (forma funcional incorrecta)}$$

Modelos não lineares

2. Teste de Chow:

- Considerando a dummy $D = \begin{cases} 1 & \text{se o individuo pertence a } G_A \\ 0 & \text{se o individuo pertence a } G_B \end{cases}$

- Estimar o modelo 'duplicado':

$$Pr(Y|X) = F(\theta_0 + \theta_1 X_1 + \dots + \theta_k X_k + \gamma_0 D + \gamma_1 D X_1 + \dots + \gamma_k D X_k)$$

- Aplicar um teste LR / Wald para:

$$H_0: \gamma_0 = \gamma_1 = \dots = \gamma_k = 0 \text{ (não existe quebra estrutural)}$$

$$H_1: \text{Não } H_0$$

Modelos binários

- $Y \in \{0,1\}$
- Exemplos:
 - $Y=1$ se obteve crédito bancário
 - $Y=1$ se comprou o produto A
 - $Y=1$ se incorreu em incumprimento

- $E(Y_i|x_i) = Pr(Y_i = 1|x_i)$:

$$\begin{aligned} E(Y_i|x_i) &= 1 \times Pr(Y_i = 1|x_i) + 0 \times Pr(Y_i = 0|x_i) \\ &= Pr(Y_i = 1|x_i); \end{aligned}$$

- Função de densidade nos estimadores MV:

$$f(y_i|x_i) = G(x_i'\beta)^{y_i} (1 - G(x_i'\beta))^{1-y_i},$$

onde $G(x_i'\beta) = E(Y_i|x_i) = Pr(Y_i = 1|x_i)$ e $0 < G(\cdot) < 1$, já que $Pr(Y_i = 1|x_i)$ está limitada entre 0 e 1

Modelos binários

- Estimação por MV baseada em :


$$LL = \sum_{i=1}^N \{y_i \ln[G(x'_i \beta)] + (1 - y_i) \ln[1 - G(x'_i \beta)]\}$$

- Modelos mais conhecidos:

- Probit: $G(x'_i \beta) = \Phi(x'_i \beta) = \int_{-\infty}^{x'_i \beta} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x'_i \beta)^2}{2}} dx \beta$
- Logit: $G(x'_i \beta) = \Lambda(x'_i \beta) = \frac{e^{x'_i \beta}}{1 + e^{x'_i \beta}}$
- Cloglog: $G(x'_i \beta) = 1 - e^{-e^{x'_i \beta}}$

Stata
logit $Y X_1 \dots X_k$
probit $Y X_1 \dots X_k$
cloglog $Y X_1 \dots X_k$

Modelos binários




Modelos binários

Efeitos parciais:

- $\Delta X_j = 1 \implies \Delta E(Y|X) = \Delta Pr(Y = 1|X) = \frac{\partial G(X\beta)}{\partial X_j} = \beta_j \frac{\partial G(X\beta)}{\partial (X\beta)} = \beta_j g(x'_i\beta)$, com $g(x'_i\beta)$ dado por:
 - Logit: $g(x'_i\beta) = \lambda(x'_i\beta) = \Lambda(x'_i\beta)[1 - \Lambda(x'_i\beta)]$
 - Probit: $g(x'_i\beta) = \phi(x'_i\beta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x'_i\beta)^2}{2}}$
 - Cloglog: $g(x'_i\beta) = [1 - G(x'_i\beta)]e^{x'_i\beta}$

Modelos binários



Modelos binários

Critérios de selecção:

Para “desempatar” modelos não rejeitados pelo RESET , é comum obter a percentagem de previsões correctas:

	$Y_i = 1$	$Y_i = 0$	Total
$\hat{Y}_i = 1$	n_{11}		
$\hat{Y}_i = 0$		n_{00}	
Total	n_1	n_0	n

- $\hat{Y}_i = \begin{cases} 1 & \text{if } Pr(\widehat{Y}_i = 1|x_i) \geq 0.5 \\ 0 & \text{if } Pr(\widehat{Y}_i = 1|x_i) < 0.5 \end{cases}$
- % previsões correctas: $(n_{11} + n_{00})/n$
- % 1's correctamente previstos: n_{11}/n_1
- % 0's correctamente previstos: n_{00}/n_0

Stata
(depois de estimar o modelo)
estat classification

Modelos binários

. **Exemplo: Loan application**

- Variável dependente: *aprove* (=1 se obteve crédito à habitação)
- Variáveis explicativas: *hrat* (peso da prestação no rendimento mensal em %), *married* (=1 se casado), *dep* (número de dependentes do agregado familiar)

Modelos binários

Exemplo: Loan application

```
. logit approve married dep hrat
```

```
Logistic regression
```

```
Number of obs      =      1,986
```

```
LR chi2(3)         =      20.14
```

```
Prob > chi2        =      0.0002
```

```
Pseudo R2         =      0.0136
```

```
Log likelihood = -729.88535
```

```
-----+-----
```

approve	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
married	.4848471	.1534378	3.16	0.002	.1841145	.7855796
dep	-.1410653	.0642852	-2.19	0.028	-.267062	-.0150686
hrat	-.0267698	.0094215	-2.84	0.004	-.0452355	-.008304
_cons	2.453316	.2693916	9.11	0.000	1.925318	2.981314

```
-----+-----
```

```
. probit approve married dep hrat
```

```
Probit regression
```

```
Number of obs      =      1,986
```

```
LR chi2(3)         =      19.52
```

```
Prob > chi2        =      0.0002
```

```
Pseudo R2         =      0.0132
```

```
Log likelihood = -730.19351
```

```
-----+-----
```

approve	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
married	.255545	.0812719	3.14	0.002	.0962551	.414835
dep	-.0747856	.0345529	-2.16	0.030	-.1425081	-.0070632
hrat	-.0134307	.004899	-2.74	0.006	-.0230325	-.0038289
_cons	1.397252	.1395427	10.01	0.000	1.123753	1.670751

```
-----+-----
```

Modelos binários

Para o caso do logit:

$$Pr(\widehat{approve} = 1|X) = \Lambda(2.453 + 0.485married - 0.141dep - 0.027hrat)$$

Pode-se apenas afirmar que a probabilidade de ter um credito aprovado aumenta no caso do individuo ser casado e diminui quando o número de dependentes e a taxa de esforço para pagamento aumentam. Para se ter a magnitude do impacto sobre a probabilidade em estudo, será necessário calcular os efeitos parciais

Para o caso do probit:

$$Pr(\widehat{approve} = 1|X) = \Phi(1.397 + 0.256married - 0.075dep - 0.013hrat)$$

O comentário anterior aplica-se, apesar da diferença natural da magnitude dos coeficientes

Modelos binários

Restringindo o interesse ao logit, por exemplo:

Efeitos parciais

```
. margins, dydx ( married dep hrat )
Average marginal effects          Number of obs      =       1,986
Model VCE      : OIM
Expression    : Pr(approve), predict()
dy/dx w.r.t.  : married dep hrat
```

		Delta-method			[95% Conf. Interval]	
	dy/dx	Std. Err.	z	P> z		
married	.0516943	.0163988	3.15	0.002	.0195532	.0838354
dep	-.0150404	.0068616	-2.19	0.028	-.0284888	-.0015919
hrat	-.0028542	.0010057	-2.84	0.005	-.0048254	-.000883

Modelos binários

Teste LR para a significância conjunta

```
. logit approve
```

```
Logistic regression
```

```
Number of obs      =      1,986
```

```
LR chi2(0)         =      -0.00
```

```
Prob > chi2        =          .
```

```
Pseudo R2         =     -0.0000
```

```
Log likelihood = -739.95364
```

```
-----+-----
```

approve	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
_cons	1.965621	.0683551	28.76	0.000	1.831647	2.099594

```
-----+-----
```

• $LR = 2(-729.885 + 739.954) = 20.14$, a 5% $\chi^2_3 = 7.814$

Modelos binários

Teste LR para a significância conjunta de *dep* e *hrat*

```
. logit approve married
```

```
Logistic regression
```

```
Number of obs      =      1,986
```

```
LR chi2(1)         =         7.08
```

```
Prob > chi2        =         0.0078
```

```
Pseudo R2         =         0.0048
```

```
Log likelihood = -736.41424
```

approve	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
married	.3743725	.1394271	2.69	0.007	.1011004	.6476446
_cons	1.731135	.1074245	16.11	0.000	1.520587	1.941683

- $LR = 2(-729.885 + 736.414) = 13.30$, a 5% $\chi_2^2 = 5.99$

Modelos binários

Teste RESET

```
. quietly logit approve married dep hrat
. predict xb ,xb
. gen xb2=xb^2
. gen xb3=xb^3
. quietly logit approve married dep hrat xb2 xb3

. test xb2 xb3
( 1) [approve]xb2 = 0
( 2) [approve]xb3 = 0

           chi2( 2) =    11.57
       Prob > chi2 =    0.0031
```

Obtenção de probabilidade de sucesso para cada individuo

```
. quietly logit approve married dep hrat

. predict P1, pr
```

Modelos para excesso de zeros

Objectivo: descrever casos onde a variável dependente assume

- O mesmo valor para muitos indivíduos: $Y_i = 0$
- Um valor positivo para os restante indivíduos

Exemplos:

- Gastos em bens duradouros, álcool, ...
- Horas de trabalho
- % de dívida de longo prazo em PME's

Modelos estudados:

- Tobit: um modelo único descreve os 0's e os valores positivos
- Modelos a 2 partes: envolvem dois modelos independentes para explicar os 0's e os valores positivos

Modelos para excesso de zeros

Tobit

Especificação:

- Modelo latente: $Y_i^* = x_i' \beta + u_i$

- Em lugar de Y_i^* observa-se:

$$Y_i = \begin{cases} 0 & \text{if } Y_i^* \leq 0 \\ Y_i^* & \text{if } Y_i^* > 0 \end{cases}$$

com $u_i \sim N(0, \sigma^2)$

$$\begin{aligned} - \Pr(Y_i = 0 | x_i) &= \Pr(Y_i^* \leq 0 | x_i) = \Pr(x_i' \beta + u_i \leq 0 | x_i) = \Pr(u_i \leq \\ &-x_i' \beta | x_i) = \Pr\left(\frac{u_i}{\sigma} \leq -\frac{x_i' \beta}{\sigma} \mid x_i\right) = \Phi\left(-\frac{x_i' \beta}{\sigma}\right) = 1 - \Phi\left(\frac{x_i' \beta}{\sigma}\right) \end{aligned}$$

- Descrição dos dados: $f(y_i | x_i) = \begin{cases} 1 - \Phi\left(\frac{x_i' \beta}{\sigma}\right) & \text{if } Y = 0 \\ \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_i - x_i' \beta)^2}{2\sigma^2}} & \text{if } Y > 0 \end{cases}$

Modelos para excesso de zeros

Tobit

Estimação:

- Metodo: MV
- Parametros a estimar: β and σ
- Função de log-verosimilhança:

```
Stata  
tobit YX1 ... Xk, ll(0)
```

$$LL = \sum_i \left\{ (1 - d_i) \log \left[1 - \Phi \left(\frac{x_i' \beta}{\sigma} \right) \right] + d_i \log \left[\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_i - x_i' \beta)^2}{2\sigma^2}} \right] \right\}$$

$$\text{onde } d_i = \begin{cases} 0 & \text{if } Y_i = 0 \\ 1 & \text{if } Y_i > 0 \end{cases}$$

Modelos para excesso de zeros

Tobit

Quantidades de interesse:

- Média condicional dado que Y_i é positivo:

$$E(Y_i|x_i, Y_i > 0) = x_i'\beta + \sigma\lambda\left(\frac{x_i'\beta}{\sigma}\right)$$

onde $\lambda\left(\frac{x_i'\beta}{\sigma}\right) = \frac{\phi\left(\frac{x_i'\beta}{\sigma}\right)}{\Phi\left(\frac{x_i'\beta}{\sigma}\right)}$ é designado de rácio de Mills

- Probabilidade de observar valores positivos de Y_i :

$$\Pr(Y_i > 0|x_i) = \Phi\left(\frac{x_i'\beta}{\sigma}\right)$$

- Média condicional global:

$$\begin{aligned} E(Y_i|x_i) &= \Pr(Y_i = 0|x_i)E(Y_i|x_i, Y_i = 0) + \Pr(Y_i > 0|x_i)E(Y_i|x_i, Y_i > 0) \\ &= \Phi\left(\frac{x_i'\beta}{\sigma}\right)x_i'\beta + \sigma\phi\left(\frac{x_i'\beta}{\sigma}\right) \end{aligned}$$

Modelos para excesso de zeros

Tobit

Efeitos parciais:

- $\Delta X_j = 1 \Rightarrow$
 - $\Delta E(Y_i|x_i, Y_i > 0) = \beta_j \left\{ 1 - \lambda \left(\frac{x_i' \beta}{\sigma} \right) \left[\frac{x_i' \beta}{\sigma} + \lambda \left(\frac{x_i' \beta}{\sigma} \right) \right] \right\}$
 - $\Delta Pr(Y_i > 0|x_i) = \frac{\beta_j}{\sigma} \phi \left(\frac{x_i' \beta}{\sigma} \right)$
 - $\Delta E(Y_i|x_i) = \beta_j \Phi \left(\frac{x_i' \beta}{\sigma} \right)$
- O sinal é igual para todos. Naturalmente, a magnitude difere

Modelos para excesso de zeros

2 partes (tópico extra)

Especificação:

- Parte 1– modelo binário:

$$\Pr(d_i = 1|x_i) = G_1(x_i'\beta)$$

- $d_i = \begin{cases} 0 & \text{se } Y_i = 0 \\ 1 & \text{se } Y_i > 0 \end{cases}$

- Parte 2– exponential, linear, ...

$$E(Y_i|x_i, d_i = 1) = G_2(x_i'\theta)$$

- Média condicional:

$$\begin{aligned} E(Y_i|x_i) &= \Pr(Y_i = 0|x_i)E(Y_i|x_i, Y_i = 0) + \Pr(Y_i > 0|x_i)E(Y_i|x_i, Y_i > 0) \\ &= G_1(x_i'\beta)G_2(x_i'\theta) \end{aligned}$$

Modelos para excesso de zeros

2 partes (tópico extra)

Estimação:

Cada parte é estimada separadamente:

- Na parte 1: usa-se a totalidade da amostra
- Na parte 2: usa-se a subamostra com $Y_i > 0$
- Podem ser usadas as mesmas ou diferentes variáveis explicativas em cada parte

Efeitos parciais:

- $\Delta Pr(d_i = 1|x_i) = \Delta Pr(Y_i > 0|x_i)$
- $\Delta E(Y_i|x_i, d_i = 1) = \Delta E(Y_i|x_i, Y_i > 0)$
- $\Delta E(Y_i|x_i) = \Delta Pr(d_i = 1|x_i)E(Y_i|x_i, d_i = 1) + Pr(d_i = 1|x_i)\Delta E(Y_i|x_i, d_i = 1)$