

MODELOS DE RESPOSTA BINÁRIA

Existe uma variedade de comportamentos econômicos onde as aproximações contínuas não são boas, por exemplo:

- (a) Indivíduos: escolha de emprego; número de filhos; se compra uma casa; se é inadimplente; se participa da escola; se opta casar.
- (b) Empresas: se construir uma planta, e se sim, qual localização; qual produto produzir; se para a dívida (se dá o default); adquirem-se outras empresas.

Para isso precisamos de modelos de probabilidade que aproximem o verdadeiro processo gerador dos dados. Nós nos concentraremos no caso em que a variável explicada, y , é uma resposta binária.

Por exemplo, $y=1$ se a pessoa é inadimplente, $y=0$ caso contrário.

Em econometria tratamos estas variáveis como dummy.

A variável dummy é um simples exemplo de variável aleatória (ξ), o qual é chamada de função indicadora de um conjunto A :

$$\xi = I_A(x)$$

onde,

$$I_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases}$$


São utilizadas para diversos fins:

- a) Reconhecer diferenças no intercepto
- b) Reconhecer diferenças na inclinação
- c) Sazonalidade
- d) Variáveis qualitativas: diferenças em idade, sexo, escolaridade,...
- e) Comprovam o teste de estabilidade
- f) Como variável dependente: Logit e Probit

Variável dummy dependente

Em geral trabalhamos com modelos em que as variáveis explicativas (x) são dummies, agora veremos modelos em que variáveis explicadas (y) são dummies.

A idéia de fazer uma estimativa por OLS, tentando aproximar uma linha de regressão linear, temos que os valores previstos podem ficar fora do intervalo $[0,1]$ e assim os erros de previsão serão grandes.



De forma a evitar estes problemas faremos as estimativas via modelos Probit e Logit, o qual chamarei de modelos de resposta binária.

$$\text{Assuma: } y_i^* = a + \sum_{j=1}^k b_j x_{ij} + e_i$$

onde, y^* é não observada (variável latente), isto é, poderia ser definida como a propensão de uma empresa entrar em default.

O que nós observamos é uma variável dummy y_i definida por:

$$y_i = \begin{cases} 1 & \text{se } y^* > 0 \\ 0 & \text{caso contrário} \end{cases}$$

Se multiplicarmos y^* por qualquer constante positiva não mudamos y_i com isso podemos assumir $V(\epsilon_t)=1$. Isto fixa a escala de y^* , então:

$$\begin{aligned} P_i &= \Pr(y_i = 1) = \Pr[a + \sum_{j=1}^k b_j x_{ij} + e_i > 0] \\ &= \Pr[e_i > -(a + \sum_{j=1}^k b_j x_{ij})] \\ &= 1 - F[-(a + \sum_{j=1}^k b_j x_{ij})] \end{aligned}$$

onde, F é a função distribuição cumulativa do erro (ϵ), contínua, estritamente crescente que toma valores reais e retorna a valores entre zero e um.

Se a distribuição de ϵ é simétrica, desde que $1 - F(-Z) = F(Z)$ podemos escrever:

$$P_i = F[a + \sum_{j=1}^k b_j x_{ij}] \quad (1)$$

A escolha da função F determina o tipo de modelo binário (Probit e Logit).

Para o modelo de probabilidade linear(OLS):

$$F(z)=z \text{ onde } z = a + \sum_{j=1}^k b_j x_{ij}$$

é a função identidade, no qual significa que a resposta probabilística não necessariamente estará entre 0 e 1 para todo x e β .

Nesta seção assumimos que $F(\cdot)$ toma valores no intervalo aberto unitário: $0 < F(z) < 1$ para todo $z \in \mathbb{R}$.

O modelo **Probit** é um caso especial da equação (1) com:

$$F(z) = \Phi(z) = \int_{-\infty}^z f(u) du$$


onde $\phi(z)$ é a densidade da normal padrão

$$f(z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2}{2}\right)$$

O modelo **Logit** é um caso especial da equação (1) com:

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

Simulação da probabilidade para o modelo probit e logit



Pela diferença dos dois métodos, temos os resultados podem ser diferentes exceto para amostras muito grandes. Entretanto, as estimativas dos parâmetros α e os β_i dos dois métodos não são comparáveis.

Dada tal especificação, podemos estimar os parâmetros deste modelo usando o **método da máxima verossimilhança**. Desde que os dados observados y_i são realizações de um processo binomial com probabilidade P_i a função de verossimilhança é dada por:

$$L = \prod_{y_i=1} P_i \prod_{y_i=0} (1 - P_i)$$

Transformando para a forma de log, temos:

$$\log L(\mathbf{a}, \mathbf{b}) = \sum_{i=0}^n y_i \log(F[\mathbf{a} + \sum_{j=1}^k \mathbf{b}_j x_{ij}]) + (1 - y_i) \log(1 - F[\mathbf{a} + \sum_{j=1}^k \mathbf{b}_j x_{ij}])$$

As condições de primeira ordem para esta função log da verossimilhança são não lineares, tal que para estimar os parâmetros é necessário um procedimento iterativo (otimização numérica).

Interpretação dos modelos de resposta binária

A interpretação dos parâmetros não é tão simples como o básico modelo de regressão OLS (onde podemos achar β como uma derivada parcial). Isto é por causa da não linearidade.

Para aplicar os modelos probit e logit, é importante saber como interpretar os β_j no caso de variáveis explicativas contínua e discreta.

Primeiro, se x_j é contínua

$$\frac{\partial p(x)}{\partial x_j} = f(x\mathbf{b}) \mathbf{b}_j$$

onde

$$f(z) = \frac{dF}{dz}(z)$$

Se $F(\cdot)$ é uma função distribuição cumulativa (cdf) estritamente crescente, como nos casos do probit e logit, $f(z) > 0$ para todo z . Então, o sinal do efeito é dado pelo sinal do β_j .

No caso probit

$$f(z) = \phi(z)$$

No caso logit

$$f(z) = \frac{\exp(z)}{(1 + \exp(z))^2}$$

Fazer o caso $z=0$

Se x_k é uma variável explicativa binária, então o efeito parcial da troca x_k de zero para um, mantendo todas as outras fixas, é simplesmente:

$$F(\mathbf{b}_1 + \mathbf{b}_2 x_2 + \dots + \mathbf{b}_{k-1} x_{k-1} + \mathbf{b}_k) - F(\mathbf{b}_1 + \mathbf{b}_2 x_2 + \dots + \mathbf{b}_{k-1} x_{k-1})$$

Ver o caso para outros tipos de variáveis discretas

É trivial incluir formas funcionais padrão nas variáveis explicativas. Por exemplo, no modelo:

$$P(y = 1 | z) = F(\mathbf{b}_0 + \mathbf{b}_1 z_1 + \mathbf{b}_2 z_1^2 + \mathbf{b}_3 \log(z_2) + \mathbf{b}_4 z_3)$$

Ver o efeito parcial de z_1 e z_2

Para fazer comparável as estimativas dos modelos Logit e Probit, podemos usar o fato que aproximações da trocas na probabilidade são:

$$\Delta \hat{P}(y = 1 | z) \approx [f(\hat{\mathbf{b}}_0 + \hat{\mathbf{b}}_z) \hat{\mathbf{b}}_j] \Delta z_j$$

para pequenas trocas em z , então, o fator f pode ser usado para ajustar cada beta.

Assim, podemos comparar as magnitudes das inclinações estimadas do probit e logit. Tomando para o probit $f(0) \approx 0.4$ e para o logit $f(0) \approx 0.25$. Então, para fazer comparável as estimativas da inclinação para logit e probit, podemos multiplicar as estimativas do probit por $0.4/0.25 = 1.6$ ou a do logit por 0.625 . No trabalho de Amemiya¹, sugere multiplicar as estimativas Logit por 0.625 e também sugere a comparação entre OLS e Probit.

Regra de bolso para tornar os modelos comparáveis:

- 1) α e β (Logit) $\times 0.625 = \alpha$ e β (Probit)
- 2) α e β (OLS) $\times 2.5$ e α (OLS) $- 1.25 = \alpha$ e β (Probit)

Exemplo 10: Medir o efeito de execuções do governo, com o seguinte modelo:

$$D_1 = \mathbf{a} + \mathbf{b}_1 T + \mathbf{b}_2 Y + \mathbf{b}_3 LF + \mathbf{b}_4 NW$$

onde, $D_1 = 1$ se o governo faz execuções e zero caso contrário

T = mediana de tempo em meses de o assassino ser condenado

Y = mediana da renda familiar

LF = taxa de participação na força de trabalho

NW = proporção da população não branca

Para comparar faremos três estimativas, por OLS, Logit e Probit.

```
>> ols1 = ols(ex10(:,1),[ones(44,1),ex10(:,2:5)]);
>> prt_reg(ols1)
```

¹ T. Amemiya, "Qualitative Response Model: A Survey", Journal of Economic Literature, 1981, p. 1488.

Ordinary Least-squares Estimates

R-squared = 0.2802

Rbar-squared = 0.2063

sigma^2 = 0.1321

Durbin-Watson = 2.0779

Nobs, Nvars = 44, 5

Variable	Coefficient	t-statistic	t-probability
variable 1	2.733391	2.105437	0.041744
variable 2	0.000834	0.866134	0.391714
variable 3	0.535329	2.254490	0.029857
variable 4	-0.061771	-2.145844	0.038167
variable 5	2.583121	3.664107	0.000737

>> log1 = logit(ex10(:,1),[ones(44,1),ex10(:,2:5)]);

>> prt_reg(log1)

Logit Maximum Likelihood Estimates

McFadden R-squared = 0.5914

Estrella R-squared = 0.5963

LR-ratio, 2*(Lu-Lr) = 26.3691

LR p-value = 0.0000

Log-Likelihood = -9.1076

of iterations = 11

Convergence criterion = 6.456733e-011

Nobs, Nvars = 44, 5

of 0's, # of 1's = 9, 35

Variable	Coefficient	t-statistic	t-probability
variable 1	16.566989	0.843565	0.404057
variable 2	0.016516	1.718467	0.093642
variable 3	9.131548	1.807101	0.078466
variable 4	-0.715389	-1.492673	0.143569
variable 5	85.361600	2.380780	0.022257

>> prob1 = probit(ex10(:,1),[ones(44,1),ex10(:,2:5)]);

>> prt_reg(prob1)

Probit Maximum Likelihood Estimates

McFadden R-squared = 0.5955

Estrella R-squared = 0.6004

LR-ratio, 2*(Lu-Lr) = 26.5509

LR p-value = 0.0000

Log-Likelihood = -9.0167

of iterations = 10

Convergence criterion = 1.6172748e-007

Nobs, Nvars = 44, 5

of 0's, # of 1's = 9, 35

Variable	Coefficient	t-statistic	t-probability
variable 1	10.267388	0.978093	0.334057
variable 2	0.009421	1.858119	0.070713
variable 3	5.551099	1.973971	0.055499
variable 4	-0.436545	-1.702430	0.096634
variable 5	50.248741	2.501305	0.016681

Para tornar os modelos comparáveis utilizaremos a regra de bolso de Amemiya.

```
>> ols_probit=[(ols1.beta(1,1)*2.5)-1.25;ols1.beta(2:5,1)*2.5];
>> logit_probit=log1.beta*0.625;
>> coef=[ols_probit, logit_probit, prob1.beta]
```

coef =

```
5.5835 10.3544 10.2674
0.0021 0.0103 0.0094
1.3383 5.7072 5.5511
-0.1544 -0.4471 -0.4365
6.4578 53.3510 50.2487
```

Como podemos perceber o modelo por OLS ficou com os coeficientes bastante diferentes dos modelos Logit e Probit, enquanto que estes dois últimos ficaram muito semelhantes.

Testes de especificação

a) Autocorrelação:

Pelo plote da função de autocorrelação (autocorr) dos três modelos não há evidência dos erros serem correlacionados, se os dados são em cross-section não precisamos fazer este teste.

b) Multicolinearidade:

Calculando os coeficientes de correlação simples das variáveis (corrcoef) também não evidenciamos problema de multicolinearidade, mas cabe ressaltar, que é importante fazer o teste com as correlações múltiplas R^2_i .

c) Heterocedasticidade:

Para testar heterocedasticidade quando a variável explicada é binária, como os resíduos tomam valores \hat{P} ou $1-\hat{P}$ para cada observação, não é suficiente apenas fazer um teste de White, em que testávamos a hipótese $H_0: V(e_i)=s^2$ (homocedasticidade) contra $H_1: V(e_i)=s^2 z_i^2$ (heterocedasticidade)

No modelo binário (Probit) temos:

$$y_i^* = a + \sum_{j=1}^k b_j x_{ij} + e_i \quad \text{sendo} \quad e_i \sim IN(0,1)$$

Mas como observamos apenas o y sendo 0 ou 1, podemos escrever o modelo como:

$$\text{Detonate, } Z_i = a + \sum_{j=1}^k b_j x_{ij}$$

Vimos que: $P_i = \Pr(y_i = 1 | Z_i) = 1 - F[-Z_i] = F(Z_i)$

$$E(y_i = 1 | Z_i) = 1 * \Pr(y_i = 1 | Z_i) + 0 * \Pr(y_i = 0 | Z_i) = \Pr(y_i = 1 | Z_i)$$

$y_i = F(Z_i) + u_i$ sendo F a distribuição cumulativa de ε e u é um resíduo representando o desvio da binária y de sua média condicional. Então:

$$E(u_i | Z_i) = E(y_i - F(Z_i)) = 0$$

$$V(u_i | Z_i) = E(u_i)^2 = F(Z_i)(1 - F(Z_i))$$

Uma especificação mais geral é que os erros sejam heterocedástico:

$$y_i^* = a + \sum_{j=1}^k b_j x_{ij} + e_i \quad \text{sendo} \quad e_i \sim N(0, \exp(2z_i'g))$$

onde z_i é uma das variáveis explicativas e γ um parâmetro não conhecido.

Se $\gamma=0$ temos que os erros são homocedásticos, assim o teste conforme Davidson e Mackinnon (1993) é feito por testar as seguintes hipóteses:

$H_0: \gamma=0$ (homocedástico)

$H_1: \gamma \neq 0$ (heterocedástico)

Para testar as hipóteses, montamos a seguinte regressão dos resíduos:

Como vimos que u_i tem variância $F(Z_i)(1 - F(Z_i))$ dividimos ambos os lados da

regressão por $(V(u_i | Z_i))^{-1/2} = (F(Z_i)(1 - F(Z_i)))^{-1/2} = (\hat{y}_i(1 - \hat{y}_i))^{-1/2}$.

$$\frac{y_i - \hat{y}_i}{\sqrt{\hat{y}_i(1 - \hat{y}_i)}} = a \frac{f(-Z_i)}{\sqrt{\hat{y}_i(1 - \hat{y}_i)}} + \sum_{j=1}^k b_j \frac{f(-Z_i)}{\sqrt{\hat{y}_i(1 - \hat{y}_i)}} x_{ij} + c \frac{f(-Z_i)(-Z_i)}{\sqrt{\hat{y}_i(1 - \hat{y}_i)}} z_i$$

onde \hat{y} é o y estimado para cada observação, $f(-Z_i)$ é a densidade da distribuição (pdf).

A estatística do teste é dada pela soma do quadrado dos valores estimados (resíduos padronizados). Este teste tem distribuição χ^2 com graus de liberdade igual ao número de variáveis z .

Uma outra boa referência é o Greene²

Exemplo 11: De acordo com Greene. Modelo para analisar a efetividade de um novo método de ensinar economia. O modelo é:

$$GRADE = a + b_1 GPA + b_2 TUCE + b_3 PSI$$

onde, GRADE = 1 se o estudante melhorou seu coeficiente 0 caso contrário.

GPA = coeficiente médio

TUCE = conhecimento do material

PSI = 1 se o estudante foi exposto ao novo método e 0 caso contrário.

```
>> prob1 = probit(ex11(:,1),[ones(32,1),ex11(:,2:4)]);
>> p_hat=prob1.yhat;
>> xb=[ones(32,1),ex11(:,2:4)]*prob1.beta;
>> brmr_y=prob1.resid./sqrt(p_hat.*(1-p_hat));
```

² Greene, W. Econometric Analysis. 3º ed. Prentice-Hall, 1997.


```
>> fac=normpdf(-xb)./sqrt(p_hat.*(1-p_hat));
>> brmr_x=[fac,ex11(:,2).*fac,ex11(:,3).*fac,ex11(:,4).*fac];
>> oslh=ols(brmr_y,[brmr_x,ex11(:,4).*(-xb).*fac]);
>> brmr_yf=oslh.yhat;
>> lm_test=sum((brmr_yf).^2);
lm_test =

    1.5480
>> p_val = 1-chi2cdf(lm_test,1);
p_val =

    0.2134
```

Acima temos que não rejeito H_0 (homocedástico) com probabilidade = 78.66%

Exercício: Testar heterocedasticidade para o exemplo 10.

d) Inclusão de variáveis irrelevantes:

Considere o modelo:

$$P(y = 1 | x, z) = G(x\mathbf{b} + z\mathbf{g})$$

onde x é $1 \times K$ e z é $1 \times Q$. Queremos testar na hipótese nula:

$H_0: \gamma=0$ (Q restrições de exclusões).

O elemento de z pode ser funções de x , tais como quadráticas – neste caso o teste é somente da forma funcional. Ou z pode ser variáveis explicativas adicionais.

Podemos fazer os teste padrão Wald, LR e LM. O teste LR pode ser facilmente computado, estimando o log-likelihood do modelo restrito e não restrito.

O teste LM é atrativo se o modelo não restrito é difícil de ser estimado. A estatística LM usando a hessiana esperada A é numericamente idêntica ao seguinte:

1) Defina $\hat{u}_i = y_i - G(x_i\hat{\mathbf{b}})$, $\hat{G}_i = G(x_i\hat{\mathbf{b}})$, $\hat{g}_i = g(x_i\hat{\mathbf{b}})$ todas são obtidas depois de estimar o modelo sem z .

2) Usar todas N observações para rodar regressão OLS

$$\frac{\hat{u}_i}{\sqrt{\hat{G}_i(1-\hat{G}_i)}} \text{ on } \frac{\hat{g}_i}{\sqrt{\hat{G}_i(1-\hat{G}_i)}} x_i, \frac{\hat{g}_i}{\sqrt{\hat{G}_i(1-\hat{G}_i)}} z_i$$

A estatística LM é igual a soma do quadrado dos valores estimados desta regressão, com distribuição χ^2 com Q graus de liberdade. Um teste que é assintoticamente (mas não numericamente) equivalente é NR^2 onde R^2 é o R -quadrado não centrado da regressão acima.

O teste LM é atrativo com relação ao LR se z tem uma dimensão grande, pois o modelo probit é difícil de estimar para muitas variáveis explicativas.

e) Testando não linearidade em β :

O teste de Wald é indicado, pois o estimador não restrito de β no qual é o modelo Logit e Probit, é fácil estimar.

$H_0: c(\beta)=0$ onde $c(\beta)$ é um vetor $Q \times 1$ de possíveis funções não lineares. A estatística é:

$$W = c(\hat{\beta})' [\nabla_b c(\hat{\beta}) \hat{V} \nabla_b c(\hat{\beta})']^{-1} c(\hat{\beta})$$

onde $\nabla_b c(\hat{\beta})$ é o Jacobiano $Q \times K$ de $c(\beta)$.

Teste de performance

As estimativas dos modelos nada nos diz sobre qual modelo utilizar ou qual modelo é melhor, então para avaliar o modelo com melhor ajuste, usaremos medidas tipo R^2 , que são as seguintes:

$$\text{McFadden } R^2 = 1 - \frac{\log L_{UR}}{\log L_R}$$

onde L_{UR} é o máxima da função de verossimilhança³ do modelo e L_R é o máximo da função de verossimilhança do modelo com as restrições dos $\beta_i=0$ para $i=1,2,\dots,k$, ou seja, é rodar a regressão com a constante apenas.

Uma outra medida é R^2 é dada por: $R^2 = 1 - \left(\frac{L_{UR}}{L_R} \right)^{2/n}$, onde $n=n^o$ observações.

Para os três modelos acima o R^2 de McFadden já é calculado no programa Probit e Logit, sendo que temos que calcular para o OLS.

No exemplo 10 temos:

```
>> L_OLS_UR = -44/2*((1+log(2*3.141593))+log(sum(ols1.resid.^2)/44))
L_OLS_UR = -15.2532
```

```
>> ols1_r = ols(ex10(:,1),ones(44,1));
>> L_OLS_R = -44/2*((1+log(2*3.141593))+log(sum(ols1_r.resid.^2)/44))
L_OLS_R = -22.4856
>> R2_MacFadden = 1-(L_OLS_UR/L_OLS_R)
R2_MacFadden = 0.3216
```

```
>> log1.r2mf
ans = 0.5914
```

```
>> prob1.r2mf
ans = 0.5955
```

³ A função log da máxima verossimilhança é definida por: $\log L = -\frac{n}{2} (1 + \log(2\pi) + \log(\sum e^2 / n))$

Pelo R^2 de MacFadden o melhor modelo é o Probit e o OLS apresenta uma performance pobre.

Além do teste de performance de McFadden R^2 podemos ver o poder de previsão do modelo. Neste caso temos que:

- 1) Reestimar o modelo com N-n observações
- 2) Prever as n observações, só que neste caso é preciso considerar se $G(x_i \hat{\mathbf{b}}) > 0.5$ prevemos y_i sendo a unidade e se $G(x_i \hat{\mathbf{b}}) \leq 0.5$ y_i sendo zero.
- 3) O percentual de vezes que o valor previsto de y foi o observado é o percentual previsto corretamente.

Bibliografia

MADDALA, G. S. *Introduction to Econometrics*. Prentice Hall, 2º ed, 1992.

DAVIDSON, R. and MACKINNON, J. *Estimation and inference in econometrics*. Oxford, 1993.

LESAGE, James P. Econometrics Toolbox. <http://www.spatial-econometrics.com/>.

WOOLDRIDGE, J. M. *Econometric Analysis of Cross-Section and Panel Data*. MIT Press, 2002.