

## Regressão não linear

Considere um modelo geral:

$$Y_t = f(X_t, \beta) + \varepsilon_t \quad T \text{ observações}$$

onde

$X_t$  é um vetor de variáveis exógenas ( $N \times 1$ )

$\beta$  é um vetor de parâmetros ( $K \times 1$ )

$Y_t$  é a variável dependente

$\varepsilon_t$  é o erro aleatório

$K$  e  $N$  não são necessariamente iguais nesse caso.

Exemplo:

Considere a função de produção Cobb-Douglas  $Q_t = \alpha L_t^{\beta_1} K_t^{\beta_2} + \varepsilon_t$

$$f(X_t, \beta) = \alpha L_t^{\beta_1} K_t^{\beta_2} \quad X_t = \begin{bmatrix} L_t \\ K_t \end{bmatrix} \quad \beta = \begin{bmatrix} \alpha \\ \beta_1 \\ \beta_2 \end{bmatrix}$$

Considere um modelo simples com um só parâmetro.

$$Y_t = f(X_t, \beta) + \varepsilon_t = \beta X_{t1} + \beta^2 X_{t2} + \varepsilon_t$$

A estimativa de mínimos quadrados não linear de  $\beta$  é definida como o valor de  $\beta$  que minimiza a soma de quadrados dos erros.

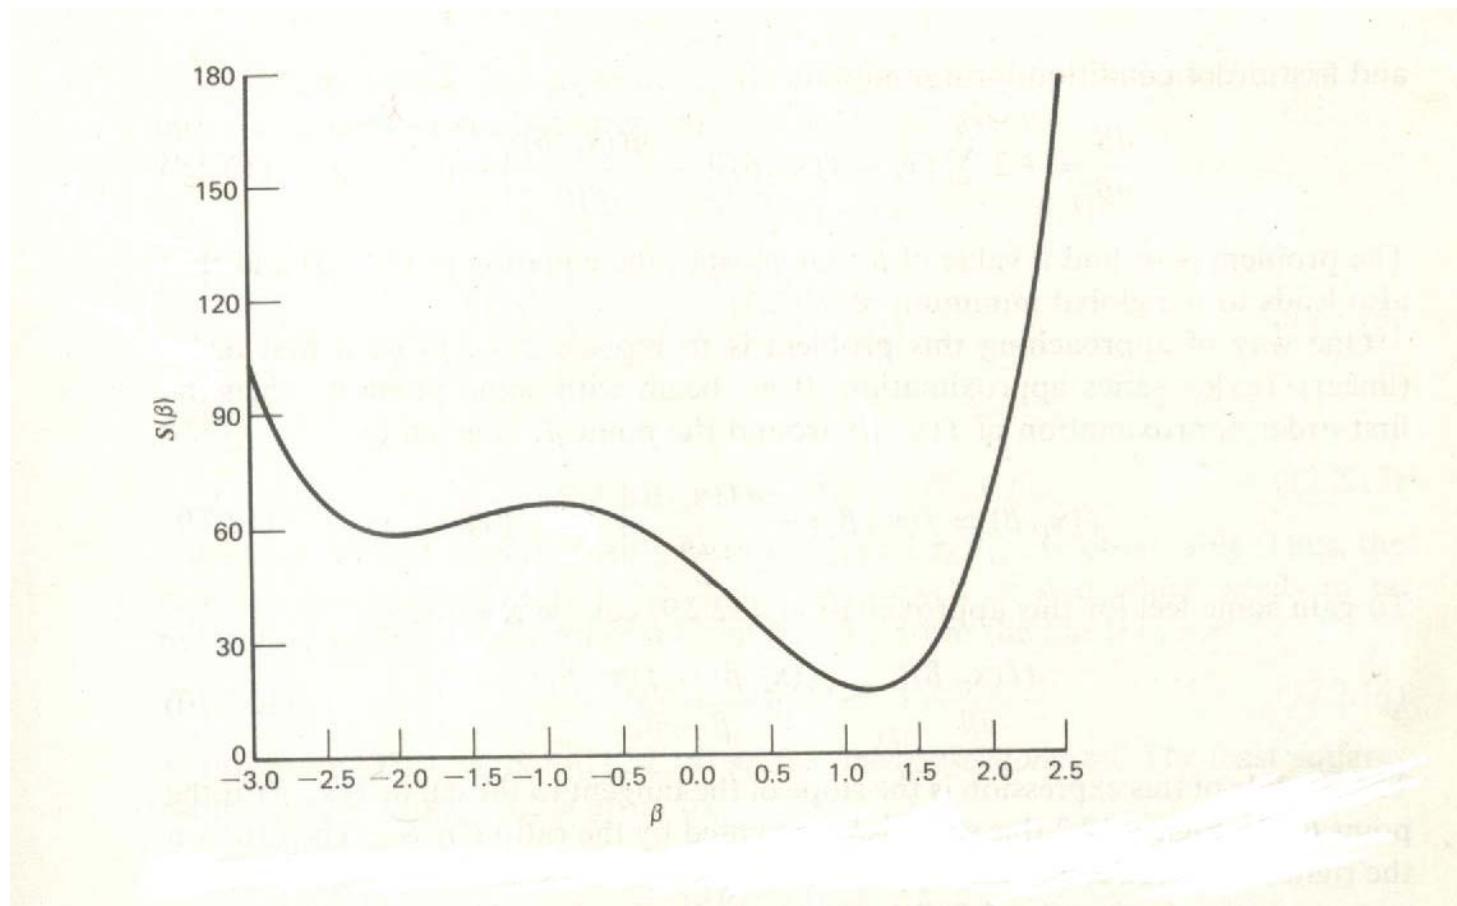
$$S(\beta) = \sum_{t=1}^T \varepsilon_t^2 = \sum_{t=1}^T [Y_t - f(X_t, \beta)]^2 = \sum_{t=1}^T (Y_t - \beta X_{t1} - \beta^2 X_{t2})^2$$

Condição de 1<sup>a</sup>. ordem

$$\frac{\partial S}{\partial \beta} = 2 \sum_{t=1}^T (Y_t - f(X_t, \beta)) \left( -\frac{\partial f(X_t, \beta)}{\partial \beta} \right) = 2 \sum_{t=1}^T (Y_t - \beta X_{t1} - \beta^2 X_{t2}) \cdot (-X_{t1} - 2\beta X_{t2}) = 0$$

Rearranjando,

$$2\beta^3 \sum X_{t2}^2 + 3\beta^2 \sum X_{t1}X_{t2} + \beta \left( \sum X_{t1}^2 - 2 \sum X_{t2}Y_t \right) - \sum X_{t1}Y_t = 0$$



Para achar o valor de  $\beta$  que satisfaça a equação

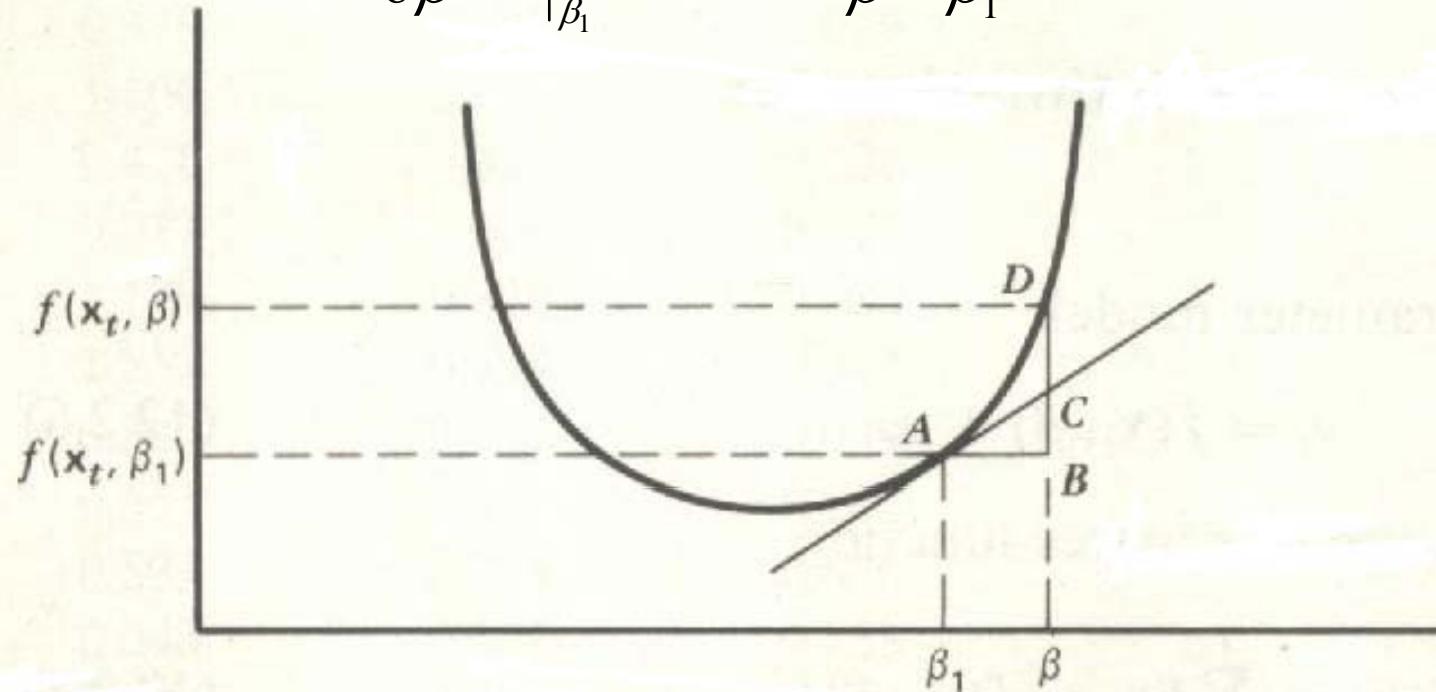
$$\frac{\partial S}{\partial \beta} = 2 \sum (y_t - f(X_t, \beta)) \left( -\frac{\partial f(X_t, \beta)}{\partial \beta} \right) = 0$$

e forneça um mínimo global, vamos substituir  $f(X_t, \beta)$  pela aproximação da série de Taylor de 1ª. ordem. Começando com um ponto inicial  $\beta_1$ , a aproximação de 1ª. ordem de  $f(X_t, \beta)$  em torno do ponto  $\beta_1$  é:

$$f(X_t, \beta) \cong f(X_t, \beta_1) + \left. \frac{\partial f(X_t, \beta)}{\partial \beta} \right|_{\beta_1} (\beta - \beta_1)$$

O que significa esta aproximação?

$$\left. \frac{\partial f(X_t, \beta)}{\partial \beta} \right|_{\beta_1} \simeq \frac{f(X_t, \beta) - f(X_t, \beta_1)}{\beta - \beta_1}$$



O lado esquerdo da expressão é a inclinação da reta tangente à curva  $f(X_t, \beta)$  no ponto  $\beta_1 = CB/BA$ . O lado direito,  $DB/BA$ , pode ser visto como a inclinação da reta unindo os pontos D e A, e esta inclinação sendo usada para aproximar a inclinação CA.

Considere,

$$Z_t(\beta) = \frac{\partial f(X_t, \beta)}{\partial \beta} \quad \text{e} \quad Z_t(\beta_1) = \left. \frac{\partial f(X_t, \beta)}{\partial \beta} \right|_{\beta_1}$$

$$S(\beta) = \sum (Y_t - f(X_t, \beta))^2$$

Substituindo

$$f(X_t, \beta) \cong f(X_t, \beta_1) + Z_t(\beta_1)(\beta - \beta_1)$$

em  $S(\beta)$  fica:

$$\begin{aligned} S(\beta) &= \sum (Y_t - f(X_t, \beta_1) - Z_t(\beta_1)(\beta - \beta_1))^2 \\ &= \sum (Y_t - f(X_t, \beta_1) + Z_t(\beta_1) \cdot \beta_1 - Z_t(\beta_1) \cdot \beta)^2 \\ &= \sum (\bar{Y}_t(\beta_1) - Z_t(\beta_1) \cdot \beta)^2 \end{aligned}$$

onde

$$\bar{Y}_t(\beta_1) = Y_t - f(X_t, \beta_1) + Z_t(\beta_1) \cdot \beta_1$$

Observe que para um dado valor de  $\beta_1$ ,  $\bar{Y}_t(\beta_1)$  e  $Z_t(\beta_1)$  são conhecidos. Portanto, a soma de quadrado dos resíduos  $S(\beta)$  acima, pode ser vista como aquela que precisa ser minimizada para achar a estimativa de mínimos quadrados para  $\beta$  do modelo linear.

$$\bar{Y}_t(\beta_1) = Z_t(\beta_1) \cdot \beta + \varepsilon_t$$

que é conhecido como pseudo-modelo.

A estimativa de mínimos quadrados é:

$$\beta_2 = \frac{\sum \bar{Y}_t(\beta_1) Z_t(\beta_1)}{\sum Z_t(\beta_1)^2} = [Z(\beta_1)' Z(\beta_1)]^{-1} Z(\beta_1)' \bar{Y}(\beta_1)$$

Este processo pode ser repetido.

$$\bar{Y}(\beta_2) = Z(\beta_2) \cdot \beta + \varepsilon$$

$$\beta_3 = \left[ Z(\beta_2)' Z(\beta_2) \right]^{-1} Z(\beta_2)' \bar{Y}(\beta_2)$$

...

$$\begin{aligned}\beta_{n+1} &= \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} Z(\beta_n)' \bar{Y}(\beta_n) = \\ &\quad \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} Z(\beta_n)' (Y - f(X, \beta_n) + Z(\beta_n) \beta_n)\end{aligned}$$

$$\beta_{n+1} = \beta_n + \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} Z(\beta_n)' [Y - f(X, \beta_n)]$$

O processo caminha em direção a um mínimo.

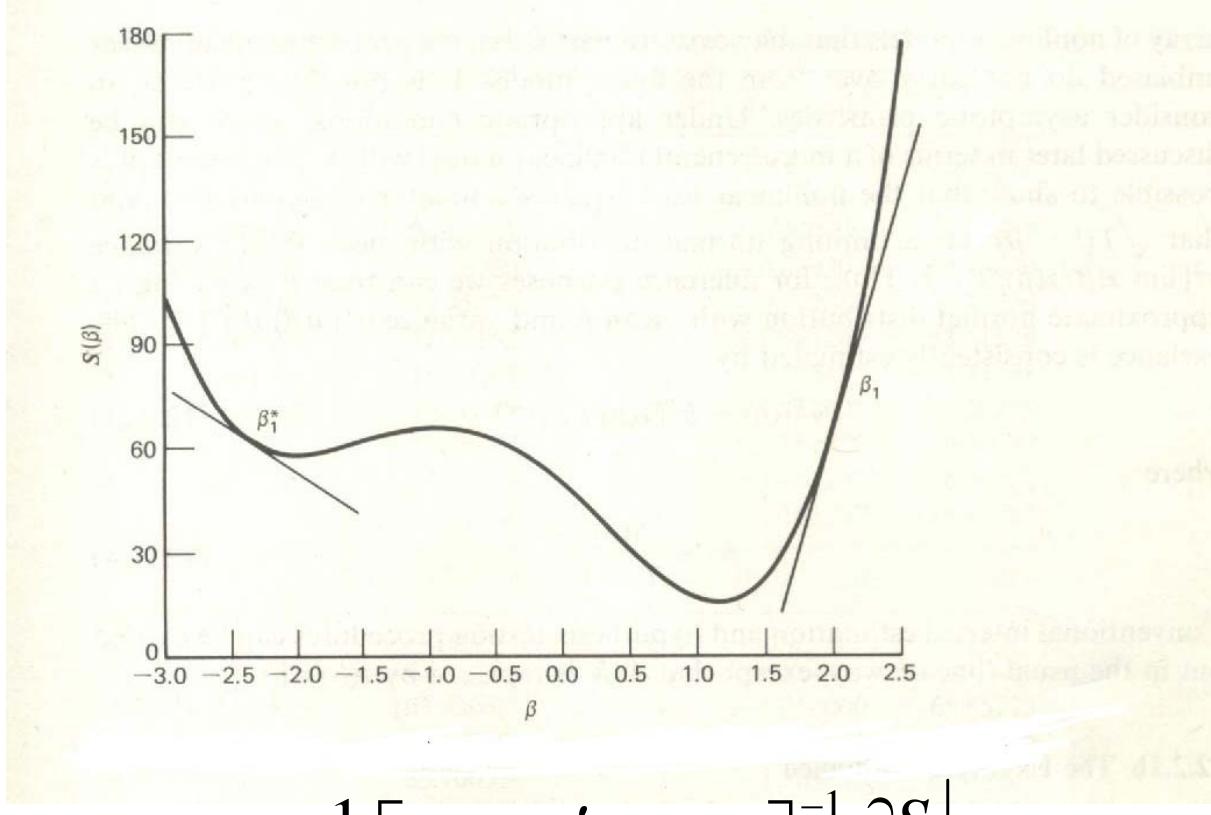
Lembre-se que

$$\frac{\partial S}{\partial \beta} = -2Z(\beta)' [Y - f(X_t, \beta)]$$

então

$$\beta_{n+1} = \beta_n - \frac{1}{2} \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n}$$

Se  $\beta_{n+1} = \beta_n$ , então  $\partial S / \partial \beta = 0$  e, portanto,  $\beta_n$  satisfaz a condição necessária para mínimo.



$$\beta_{n+1} = \beta_n - \frac{1}{2} \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n}$$

No ponto  $\beta_1$ ,  $\partial S / \partial \beta$  é positivo. Como  $Z(\beta)'Z(\beta)$  é uma soma de quadrados,  $[Z(\beta)'Z(\beta)]^{-1}$  será sempre positivo. Portanto, o 2º. valor de  $\beta$  será menor do que o 1º.

No ponto  $\beta_1^*$ ,  $\partial S / \partial \beta$  é negativo e mudança em  $\beta$  será em direção ao mínimo.

## Convergência em probabilidade.

Seja  $\hat{\theta}_T$  o estimador de  $\theta$  baseado em uma amostra de tamanho  $T$ .

Então  $\hat{\theta}_T$  converge em probabilidade para  $\theta$  se:

$$\lim_{T \rightarrow \infty} \left( \text{Prob} \left| \hat{\theta}_T - \theta \right| < \varepsilon \right) = 1 \quad \Rightarrow \quad \lim_{T \rightarrow \infty} \left( \text{Prob} (\theta - \varepsilon < \hat{\theta}_T < \theta + \varepsilon) \right) = 1$$

Se  $\hat{\theta}_T$  converge em probabilidade para  $\theta \Rightarrow \text{plim } \hat{\theta}_T = \theta$

Um estimador  $\hat{\theta}_T$  do parâmetro  $\theta$  é consistente se e somente se  $\text{plim } \hat{\theta}_T = \theta$

Propriedades assintóticas do estimador:

$b$  é um estimador consistente com distribuição aproximadamente normal com média  $\beta$  e variância

$$\sigma^2 \left[ Z(\beta)' Z(\beta) \right]^{-1}$$

$$Var(b) = s^2 \left[ Z(b)' Z(b) \right]^{-1}$$

$$s^2 = \frac{s(b)}{T - K}$$

Voltando ao exemplo:

$$Y_t = \beta X_{t1} + \beta^2 X_{t2} + \varepsilon_t$$

$$Z(\beta) = \frac{\partial f(X, \beta)}{\partial \beta} = X_1 + 2\beta X_2$$

$$Z(\beta)' Z(\beta) = \sum_{t=1}^T (X_{1t} + 2\beta X_{2t})^2$$

$$Z(\beta)' [Y - f(X, \beta)] = \sum (X_{1t} + 2\beta X_{2t})(Y_t - \beta X_{1t} - \beta^2 X_{2t})$$

$$\beta_{n+1} = \beta_n + \frac{\sum (X_1 + 2\beta_n X_2)(Y - \beta_n X_1 - \beta_n^2 X_2)}{\sum (X_1 + 2\beta_n X_2)^2}$$

Se  $\beta_0 = 1$ , então

$$\beta_1 = 1 + \frac{\sum X_1 Y - \beta \sum X_1^2 - \beta^2 \sum X_1 X_2 + 2\beta \sum X_2 Y - 2\beta^2 \sum X_1 X_2 - 2\beta^3 \sum X_2^2}{\sum X_1^2 + 4\beta \sum X_1 X_2 + 4\beta^2 \sum X_2^2}$$

## Considere os dados

$X_1$	$X_2$	$Y$	$X_1Y$	$X_1^2$	$X_2Y$	$X_2^2$	$X_1X_2$
0	3	11	0	0	33	9	0
1	0	3	3	1	0	0	0
2	3	17	34	4	51	9	6
3	0	5	15	9	0	0	0
4	1	12	48	16	12	1	4
total			100	30	96	19	10

$$\hat{\beta}_1 = 1 + \frac{100 - 30 - 10 + 2 \cdot 96 - 2 \cdot 10 - 2 \cdot 19}{30 + 4 \cdot 10 + 4 \cdot 19} = 1 + \frac{194}{146} = 1 + 1,33$$

$$\hat{\beta}_1 = 2,33$$

$$\hat{\beta}_2 = 2,33 + \dots$$

converge para  $\hat{\beta} = 2$

$$\hat{Y} = \hat{\beta}X_1 + \hat{\beta}^2 X_2 = 2X_1 + 4X_2$$

$$e = Y - \underbrace{(2X_1 + 4X_2)}_{\hat{Y}}$$

$Y$	$\hat{Y}$	$e$
11	12	-1
3	2	1
17	16	1
5	6	-1
12	12	0

$$s^2 = \frac{\sum e^2}{4} = \frac{4}{4} = 1$$

$$Var(b) = \left( Z(\beta)' Z(\beta) \right)^{-1} s^2 = \left[ \sum (X_1 + 4X_2)^2 \right]^{-1} \cdot 1 = [414]^{-1} \cdot 1 = 0,00242$$

## Forma Matricial

O modelo

$$Y_t = f(X_t, \beta) + \varepsilon_t$$

onde  $\beta$  é um vetor( $K \times 1$ ), na forma matricial fica,

$$Y = f(X, \beta) + \varepsilon$$

Pressupondo que  $E(\varepsilon)=0$  e  $E(\varepsilon\varepsilon')=\sigma^2 I$ , a estimativa de mínimos quadrados não linear do vetor  $\beta$  é o valor de  $\beta$  que minimiza a soma de quadrado dos erros.

$$S(\beta) = \varepsilon' \varepsilon = [Y - f(X, \beta)]' [Y - f(X, \beta)] = \sum_{t=1}^T [Y_t - f(X_t, \beta)]^2$$

Neste caso, existem  $K$  condições de primeira ordem para o mínimo, definidas a partir de  $K$  derivadas,

$$\frac{\partial S}{\partial \beta} = -2 \frac{\partial f(X, \beta)}{\partial \beta}' [Y - f(X, \beta)] = 0$$

onde  $\partial f(X, \beta)' / \partial \beta$  é uma matriz  $(K \times T)$  de derivadas onde o  $(K, t)$  ésmo elemento é  $\partial f(X_t, \beta)' / \partial \beta_K$ .

Sendo  $Z(\beta)$  o transposto da matriz  $\frac{\partial f(X, \beta)'}{\partial \beta}$ , tem-se

$$Z(\beta) = \frac{\partial f(X, \beta)}{\partial \beta'} = \begin{bmatrix} \frac{\partial f(X_1, \beta)}{\partial \beta_1} & \dots & \frac{\partial f(X_1, \beta)}{\partial \beta_K} \\ \vdots & & \\ \frac{\partial f(X_T, \beta)}{\partial \beta_1} & \dots & \frac{\partial f(X_T, \beta)}{\partial \beta_K} \end{bmatrix}_{T \times K}$$

A condição de 1<sup>a</sup>. ordem para mínimo será.

$$Z(\beta)' [Y - f(X, \beta)] = 0$$

Aproximação de Taylor para a t-ésima observação é,

$$f(X_t, \beta) \approx f(X_t, \beta_1) + \left[ \frac{\partial f(X_t, \beta)}{\partial \beta_1} \Big|_{\beta_1} \dots \frac{\partial f(X_t, \beta)}{\partial \beta_K} \Big|_{\beta_1} \right] (\beta - \beta_1)$$

Incluindo-se todas as  $T$  observações tem-se,

$$f(X, \beta) \approx f(X, \beta_1) + Z(\beta_1)(\beta - \beta_1)$$

então,

$$Y \cong f(X_t, \beta_1) + Z(\beta_1)(\beta - \beta_1) + \varepsilon$$

$$Y \cong f(X, \beta_1) + Z(\beta_1)\beta - Z(\beta_1)\beta_1 + \varepsilon$$

$$Y - f(X, \beta_1) + Z(\beta_1)\beta_1 \cong Z(\beta_1)\beta + \varepsilon$$

ou

$$\tilde{Y}(\beta_1) \cong Z(\beta_1)\beta + \varepsilon$$

é um pseudo-modelo, então

$$\beta_2 = \left[ Z(\beta_1)' Z(\beta_1) \right]^{-1} \left[ Z(\beta_1)' \tilde{Y}(\beta_1) \right]$$

$$\beta_2 = \left[ Z(\beta_1)' Z(\beta_1) \right]^{-1} Z(\beta_1)' [Y - f(X, \beta_1) + Z(\beta_1)\beta_1]$$

$$\beta_2 = \beta_1 + \left[ Z(\beta_1)' Z(\beta_1) \right]^{-1} Z(\beta_1)' [Y - f(X, \beta_1)]$$

Continuando o processo, a  $n$ -ésima iteração do algoritmo de Gauss-Newton é dada por:

$$\beta_{n+1} = \beta_n + \underbrace{\left[ Z(\beta_n)' Z(\beta_n) \right]^{-1}}_A Z(\beta_n)' [Y - f(X, \beta_n)]^B$$

Quando a iteração pára é porque  $\hat{\beta}_{n+1} = \hat{\beta}_n$ , isto é,  $A=0$ . Como  $B\neq 0$ , então  $Z(\beta_n)' [Y - f(X, \beta_n)] = 0$  e esta é exatamente a condição de 1ª. ordem para o mínimo.

$$\sum_b = \hat{\sigma}^2 \left[ Z(b)' Z(b) \right]^{-1}$$

$$\hat{\sigma}^2 = \frac{\hat{\varepsilon} \hat{\varepsilon}'}{T - K}$$

## Algorítimo de Newton-Raphson

$$Y = f(X, \beta) + \varepsilon$$

$$E(\varepsilon) = 0$$

$$E(\varepsilon \varepsilon') = \sigma^2 I$$

queremos encontrar o valor de  $\beta$  que minimiza,

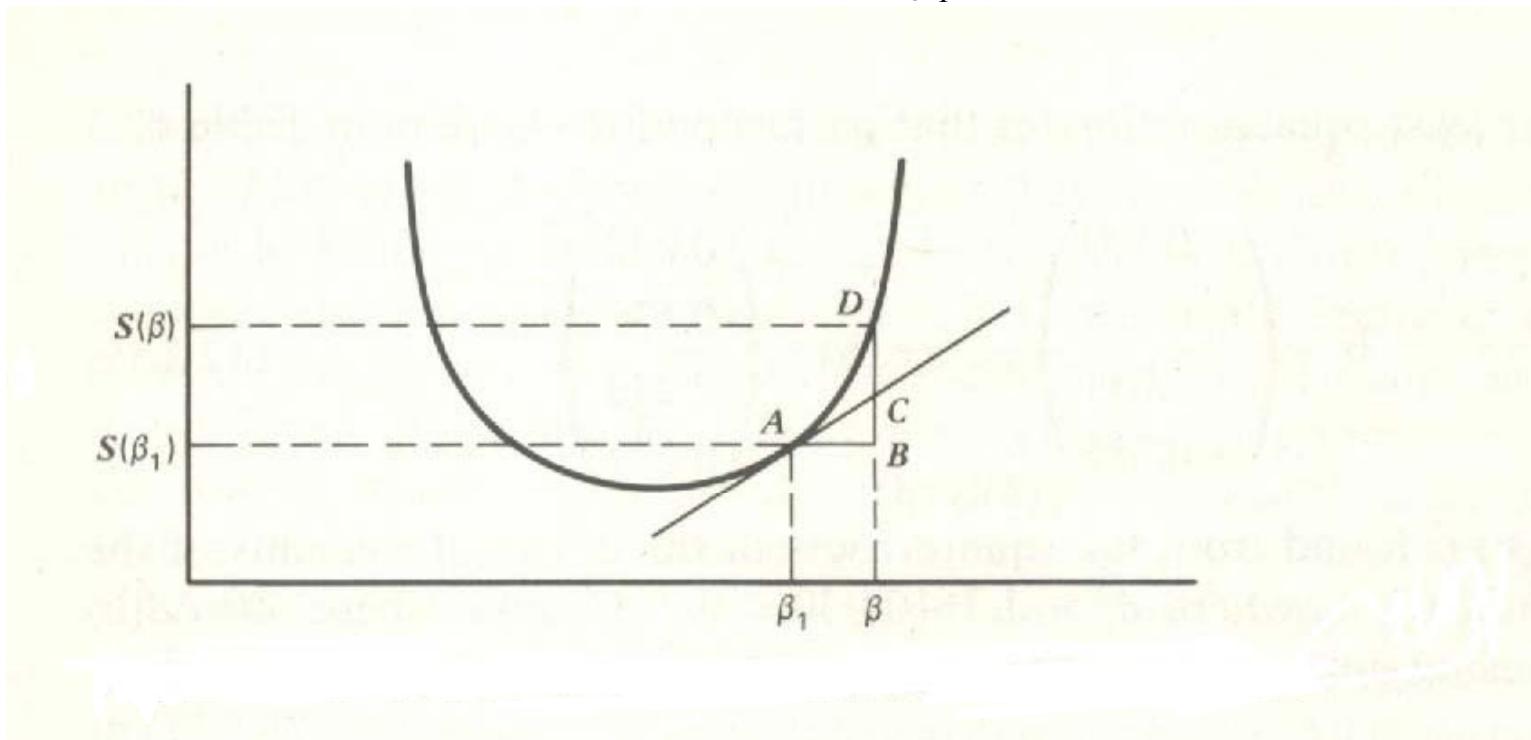
$$S(\beta) = [Y - f(X, \beta)]' [Y - f(X, \beta)] = \sum_{t=1}^T [Y_t - f(X_t, \beta)]^2$$

Iniciamos substituindo  $S(\beta)$  pela aproximação de Taylor de 2<sup>a</sup>. ordem.

$$S(\beta) \approx S(\beta_1) + \frac{\partial S}{\partial \beta} \Big|_{\beta_1} (\beta - \beta_1) + \frac{1}{2} \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} (\beta - \beta_1)^2$$

O que significa esta aproximação?

$$\left. \frac{\partial S}{\partial \beta} \right|_{\beta_1} \cong \frac{S(\beta) - S(\beta_1)}{\beta - \beta_1} - \left. \frac{1}{2} \frac{\partial^2 S}{\partial \beta^2} \right|_{\beta_1} (\beta - \beta_1)$$



A equação aproxima a tangente no ponto  $A$  pela inclinação da reta unindo  $DA$  menos  $\left. \frac{1}{2} \frac{\partial^2 S}{\partial \beta^2} \right|_{\beta_1} (\beta - \beta_1)$ . A magnitude do termo que é subtraído de  $DA$  depende de quão longe  $\beta$  está de  $\beta_1$  e da taxa na qual a inclinação da função  $S(\beta)$  está mudando.

Para achar o valor de  $\beta$  que minimiza  $S(\beta)$ , dado  $\beta_1$  inicial, diferenciamos

$$S(\beta) \approx S(\beta_1) + \frac{\partial S}{\partial \beta} \Big|_{\beta_1} (\beta - \beta_1) + \frac{1}{2} \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} (\beta - \beta_1)^2$$

com relação à  $\beta$ .

$$\frac{\partial S}{\partial \beta} \approx \frac{\partial S}{\partial \beta} \Big|_{\beta_1} + \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} (\beta - \beta_1)$$

Igualando a zero e resolvendo para  $\beta$  obtém-se

$$\frac{\partial S}{\partial \beta} \Big|_{\beta_1} + \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} \beta - \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} \beta_1 = 0$$

$$\beta_2 = \beta_1 - \left( \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_1} \right)^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_1}$$

Continuando o processo obtém-se,

$$\beta_{n+1} = \beta_n - \left( \frac{\partial^2 S}{\partial \beta^2} \Big|_{\beta_n} \right)^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n}$$

O processo converge se  $\beta_{n+1} = \beta_n$ , então  $\partial S / \partial \beta$  deve ser zero, que é a condição de primeira ordem.

Relação entre o algoritmo de Gauss-Newton e Newton-Raphson

Algoritmo de Gauss-Newton:

$$\beta_{n+1} = \beta_n - \frac{1}{2} \left[ Z(\beta_n)' Z(\beta_n) \right]^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n}$$

$$\frac{\partial S}{\partial \beta} = 2 \sum (Y - f(X_t, \beta)) \left( -\frac{\partial f(X_t, \beta)}{\partial \beta} \right)$$

$$\frac{\partial^2 S}{\partial \beta^2} = 2 \sum \left[ \left( \frac{\partial f(X_t, \beta)}{\partial \beta} \right)^2 - (Y - f(X_t, \beta)) \frac{\partial^2 f(X_t, \beta)}{\partial \beta^2} \right]$$

ou na forma matricial,

$$\frac{\partial^2 S}{\partial \beta^2} = 2Z(\beta)'Z(\beta) - 2 \sum (Y - f(X_t, \beta)) \frac{\partial^2 f(X_t, \beta)}{\partial \beta^2}$$

então, a diferença entre o estimador de Gauss-Newton e Newton-Raphson é o termo  $-2 \sum (Y - f(X_t, \beta)) \frac{\partial^2 f(X_t, \beta)}{\partial \beta^2}$ , o qual tem esperança zero, uma vez que a  $E(Y) = f(X, \beta)$ .

A matriz de covariância é:

$$\hat{\Sigma}_b = 2\hat{\sigma}^2 \left[ \frac{\partial^2 S}{\partial \beta^2} \right]^{-1}_b$$

Como  $E(Y) = f(X, \beta)$  então a

$$E\left(\frac{\partial^2 S}{\partial \beta^2}\right) = 2[Z(\beta)'Z(\beta)]$$

$$E(\hat{\Sigma}_b) = 2\hat{\sigma}^2 [2Z(\beta)'Z(\beta)]^{-1} = \hat{\sigma}^2 [Z(\beta)'Z(\beta)]^{-1}$$

Exemplo:

Queremos achar  $\beta$  que minimize

$$S(\beta) = \sum (Y - \beta X_1 - \beta^2 X_2)^2$$

$$\frac{\partial S}{\partial \beta} = -2 \sum (X_{1t} + 2\beta X_{2t})(Y_t - \beta X_{1t} - \beta^2 X_{2t})$$

$$\frac{\partial^2 S}{\partial \beta^2} = -2 \sum [-(X_1 + 2\beta X_2)(X_1 + 2\beta X_2) + (Y - \beta X_1 - \beta^2 X_2)(2X_2)]$$

$$\frac{\partial^2 S}{\partial \beta^2} = 2 \sum [(X_1 + 2\beta X_2)^2 - (Y - \beta X_1 - \beta^2 X_2)(2X_2)]$$

$$\beta_2 = \beta_1 + \frac{2 \sum (Y - \beta_1 X_1 - \beta_1^2 X_2)(X_1 + 2\beta_1 X_2)}{2 \sum [(X_1 + 2\beta_1 X_2)^2 - (Y - \beta_1 X_1 - \beta_1^2 X_2)(2X_2)]}$$

sendo  $\beta_1=1$

$$\beta_2 = 1 + \frac{\sum (YX_1 + 2X_2Y - X_1^2 - 2X_1X_2 - X_1X_2 - 2X_2^2)}{\sum [X_1^2 + 2 \cdot 2X_1X_2 + 4X_2^2 - 2YX_2 + 2X_1X_2 + 2X_2^2]}$$

$$\beta_2 = 1 + \frac{100 + 2 \cdot 96 - 30 - 3 \cdot 10 - 2 \cdot 19}{30 + 4 \cdot 10 + 4 \cdot 19 - 2 \cdot 96 + 2 \cdot 10 + 2 \cdot 19}$$

Generalizando o modelo para  $K$  parâmetros.

$$Y = f(X, \beta) + \varepsilon$$

$$E(\varepsilon) = 0$$

$$E(\varepsilon \varepsilon') = \sigma^2 I$$

queremos encontrar o valor de  $\beta$  que minimiza,

$$S(\beta) = [Y - f(X, \beta)]' [Y - f(X, \beta)] = \sum_{t=1}^T [Y_t - f(X_t, \beta)]^2$$

Iniciamos substituindo  $S(\beta)$  pela aproximação de Taylor de 2ª. ordem.

$$S(\beta) \approx S(\beta_1) + \frac{\partial S}{\partial \beta'} \Big|_{\beta_1} (\beta - \beta_1) + \frac{1}{2} (\beta - \beta_1) \frac{\partial^2 S}{\partial \beta \partial \beta'} \Big|_{\beta_1} (\beta - \beta_1)' = Q(\beta)$$

$$\frac{\partial Q(\beta)}{\partial \beta} = \left. \frac{\partial S}{\partial \beta} \right|_{\beta_1} + \left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} (\beta - \beta_1) = 0$$

$$\left. \frac{\partial S}{\partial \beta} \right|_{\beta_1} + \left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} \beta - \left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} \beta_1 = 0$$

$$\left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} \beta = \left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} \beta_1 - \left. \frac{\partial S}{\partial \beta} \right|_{\beta_1} = 0$$

$$\beta_2 = \beta_1 - \left[ \left. \frac{\partial^2 S}{\partial \beta \partial \beta'} \right|_{\beta_1} \right]^{-1} \left. \frac{\partial S}{\partial \beta} \right|_{\beta_1}$$

Generalizando,

$$\beta_{n+1} = \beta_n - \left[ \frac{\partial^2 S}{\partial \beta \partial \beta'} \Big|_{\beta_n} \right]^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n} = \beta_n - H_n^{-1} \frac{\partial S}{\partial \beta} \Big|_{\beta_n}$$

onde

$$\frac{\partial S}{\partial \beta} \Big|_{\beta_n} = \left( \frac{\partial S}{\partial \beta_1}, \frac{\partial S}{\partial \beta_2}, \dots, \frac{\partial S}{\partial \beta_K} \right)' \Big|_{\beta_n}$$

e

$$H_{K \times K} = \frac{\partial^2 S}{\partial \beta \partial \beta'} = \begin{bmatrix} \frac{\partial^2 S}{\partial \beta_1^2} & \cdots & \frac{\partial^2 S}{\partial \beta_1 \partial \beta_K} \\ \vdots & & \\ \frac{\partial^2 S}{\partial \beta_K \partial \beta_1} & & \frac{\partial^2 S}{\partial \beta_K^2} \end{bmatrix} \Big|_{\beta_n}$$