

# *Técnicas Computacionais em Probabilidade e Estatística I*

## Aula VI

Chang Chiann  
MAE 5704- IME/USP  
1º Sem/2008

# Análise Exploratória

## Duas Variáveis Quantitativas

Lembre-se da construção destes gráficos para estudar relações entre variáveis:

**Gráficos de Dispersão**  
**Gráficos P-P (Q-Q)**

**Coeficiente de Correlação Robusto**

**Régressão Robusta**

**Suavização**

# Modelo Probabilístico

a) Variáveis quantitativas discretas

(x,y): caracterizada por uma função de probabilidade

i)  $P(x,y)=P(X=x, Y=y)$  : dist. Conjunta

ii)  $P(X=x)=\sum_y P(X=x, Y=y)$ : dist. Marginal de X;

iii)  $P(Y=y)=\sum_x P(X=x, Y=y)$ : dist. Marginal de Y.

X e Y independentes  $\rightarrow P(x,y)=P(x)*P(y)$

Propriedades:

- i)  $P(x,y) \geq 0$ ;
- ii)  $\sum_x \sum_y P(x,y) = 1$ ;
- iii)  $P(a \leq X \leq b, c \leq Y \leq d) = \sum_x \sum_y P(x,y)$ .

Transformação:

$$Z = h(x, y)$$

$$E(Z) = \sum_i \sum_j h(x_i, y_j) P(X=x_i, Y=y_j)$$

Distribuições condicionais:

$$P(Y = y/X = x) = P(X = x, Y = y)/P(X = x)$$

se  $P(X = x) > 0$ .

Média da distribuição condicional:

$$E(Y/X=x) = \sum_y y P(Y=y/X=x)$$

## b) Variáveis quantitativas contínuas

Uma função de densidade de probabilidade  $f(x,y)$ ,  
tal que:

i)  $f(x,y) \geq 0$ , para todos par(x,y);

ii)  $\iint f(x,y) dx dy = 1$ ;

iii)  $P(a \leq X \leq b, c \leq Y \leq d) = \int_a^b \int_c^d f(x,y) dx dy$

X e Y são independentes  $\rightarrow f(x,y) = f(x)f(y)$

Densidades marginais:

$$f_x(x) = \int f(x,y) dy$$

$$f_y(y) = \int f(x,y) dx$$

Distribuição condicional:

$$f_{y/x}(y/x) = f(x,y)/f_x(x), f_x(x) > 0.$$

Média condicional:

$$E(y/X=x) = \int y f_{y/x}(y/x) dy: \text{ função de } x, \text{ curva de regressão de } y \text{ sobre } x.$$

# Vizualizando Dados Bivariados

## DADOS

Obs	X1	Y1	Y2	Y3	X2	Y4
1	10	8.04	9.14	7.46	8	6.58
2	8	6.95	8.14	6.77	8	5.76
3	13	7.58	8.74	12.74	8	7.71
4	9	8.81	8.77	7.11	8	8.84
5	11	8.33	9.26	7.81	8	8.47
6	14	9.96	8.10	8.84	8	7.04
7	6	7.24	6.13	6.08	8	5.25
8	4	4.26	3.10	5.39	19	12.50
9	12	10.84	9.13	8.15	8	5.56
10	7	4.82	7.26	6.42	8	7.91
11	5	5.68	4.74	5.73	8	6.89

Considere os dados apresentados por Frank Anscombe

11 observações de 6 variáveis

# Vizualizando Dados Bivariados

## DADOS

Obs	X1	Y1	Y2	Y3	X2	Y4
1	10	8.04	9.14	7.46	8	6.58
2	8	6.95	8.14	6.77	8	5.76
3	13	7.58	8.74	12.74	8	7.71
4	9	8.81	8.77	7.11	8	8.84
5	11	8.33	9.26	7.81	8	8.47
6	14	9.96	8.10	8.84	8	7.04
7	6	7.24	6.13	6.08	8	5.25
8	4	4.26	3.10	5.39	19	12.50
9	12	10.84	9.13	8.15	8	5.56
10	7	4.82	7.26	6.42	8	7.91
11	5	5.68	4.74	5.73	8	6.89

Considerando os dados apresentados por Frank Anscombe

## CORRELAÇÕES (Pearson)

Correlation of X1 and Y1 = 0.816

Correlation of X1 and Y2 = 0.816

Correlation of X1 and Y3 = 0.816

Correlation of X2 and Y4 = 0.817

$$\hat{Y}_j = 3 + 0.5 X_j$$

Mesmos valores de correlação

Mesma equação de ajuste

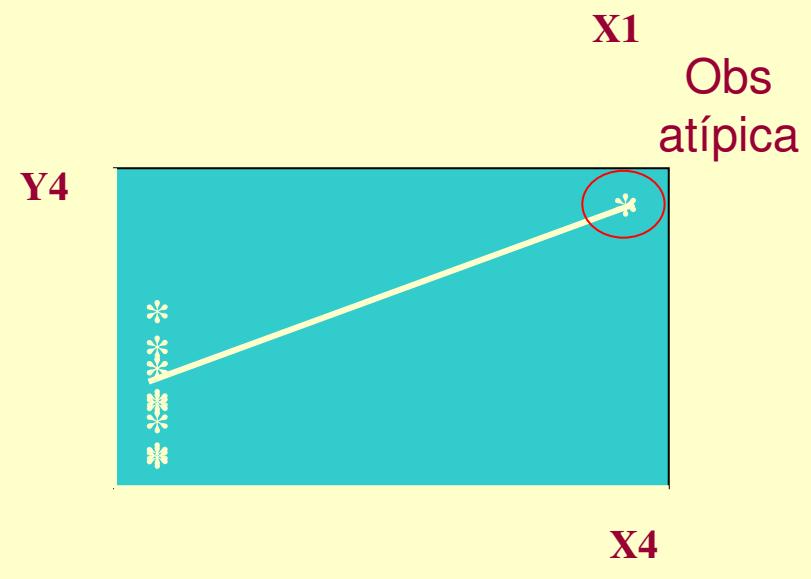
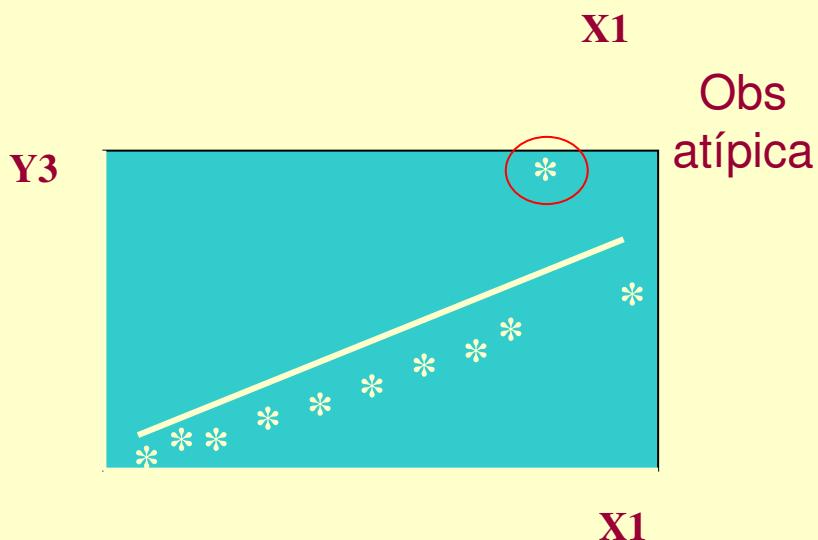
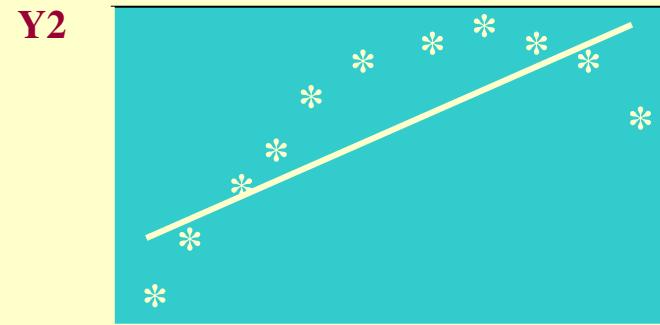
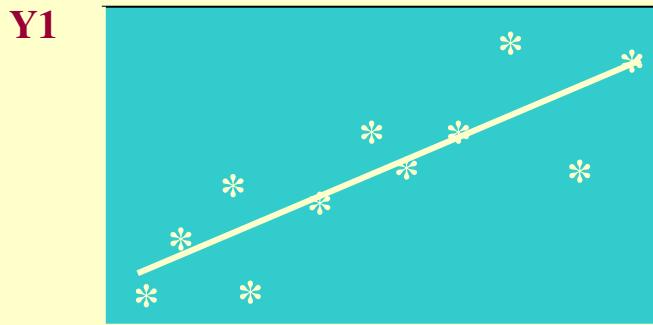
?

# Vizualizando Dados

Arquivo F. Anscombe

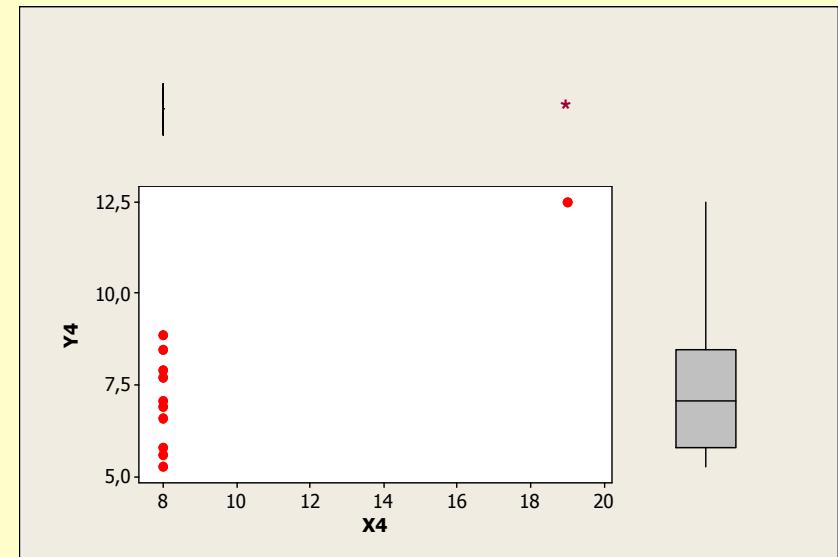
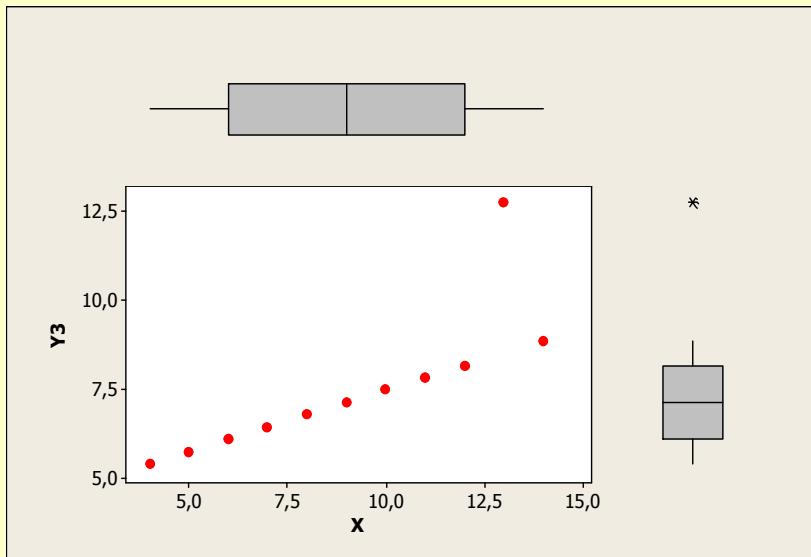
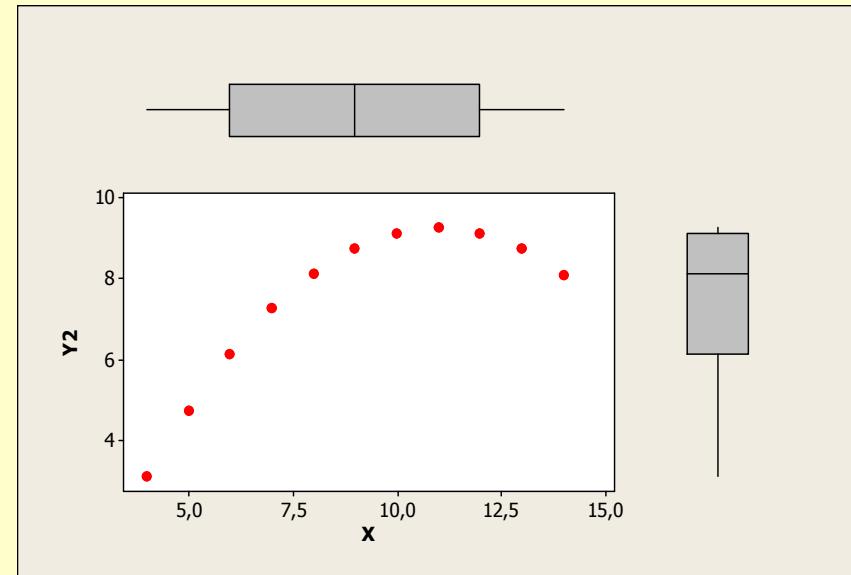
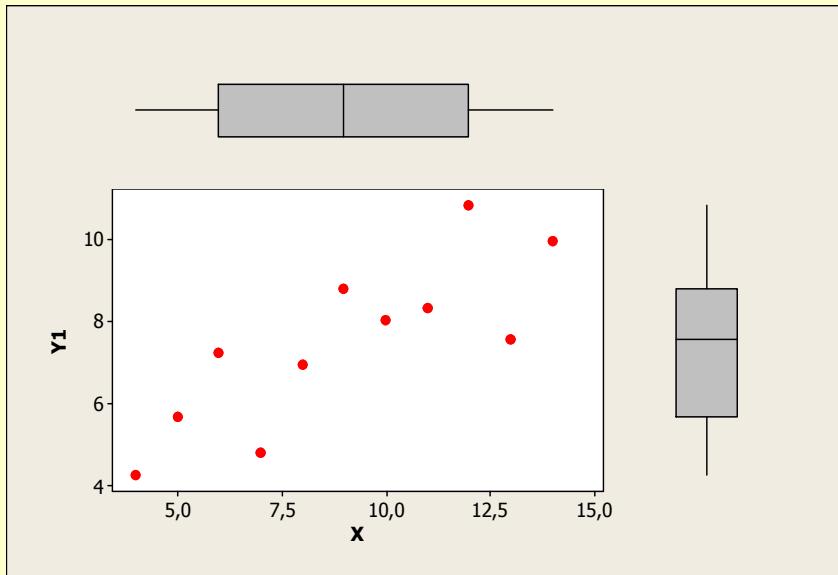
$$\hat{Y}_j = 3 + 0.5 X_j$$

Tendência não linear



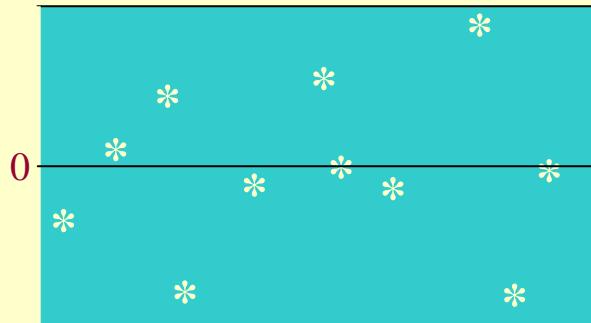
# Vizualizando Dados

Arquivo F. Anscombe

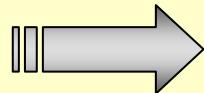


# Vizualizando Resíduos

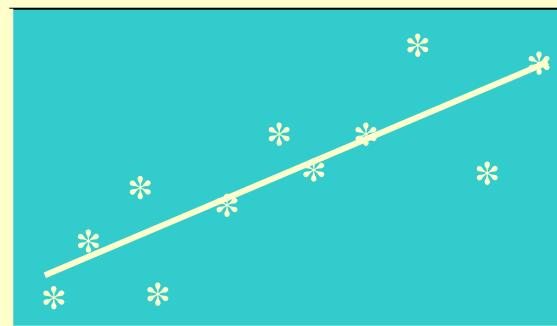
$$R = 66,7\% \ ??$$



*O que se espera da Dispersão dos resíduos em função dos valores ajustados ??*



$$Y1 = 3 + 0,5 X1$$



<u>Obs</u>	X1	Y1	$\hat{Y}_1$	RESÍDUO
1	10	8,04	8,0010	0,03900
2	8	6,95	7,0008	-0,05082
3	13	7,58	9,5013	-1,92127
4	9	8,81	7,5009	1,30909
5	11	8,33	8,5011	-0,17109
6	14	9,96	10,0014	-0,04136
7	6	7,24	6,0006	1,23936
8	4	4,26	5,0005	-0,74045
9	12	10,84	9,0012	1,83882
10	7	4,82	6,5007	-1,68073
11	5	5,68	5,5005	0,17945

Total -5,41789E-14

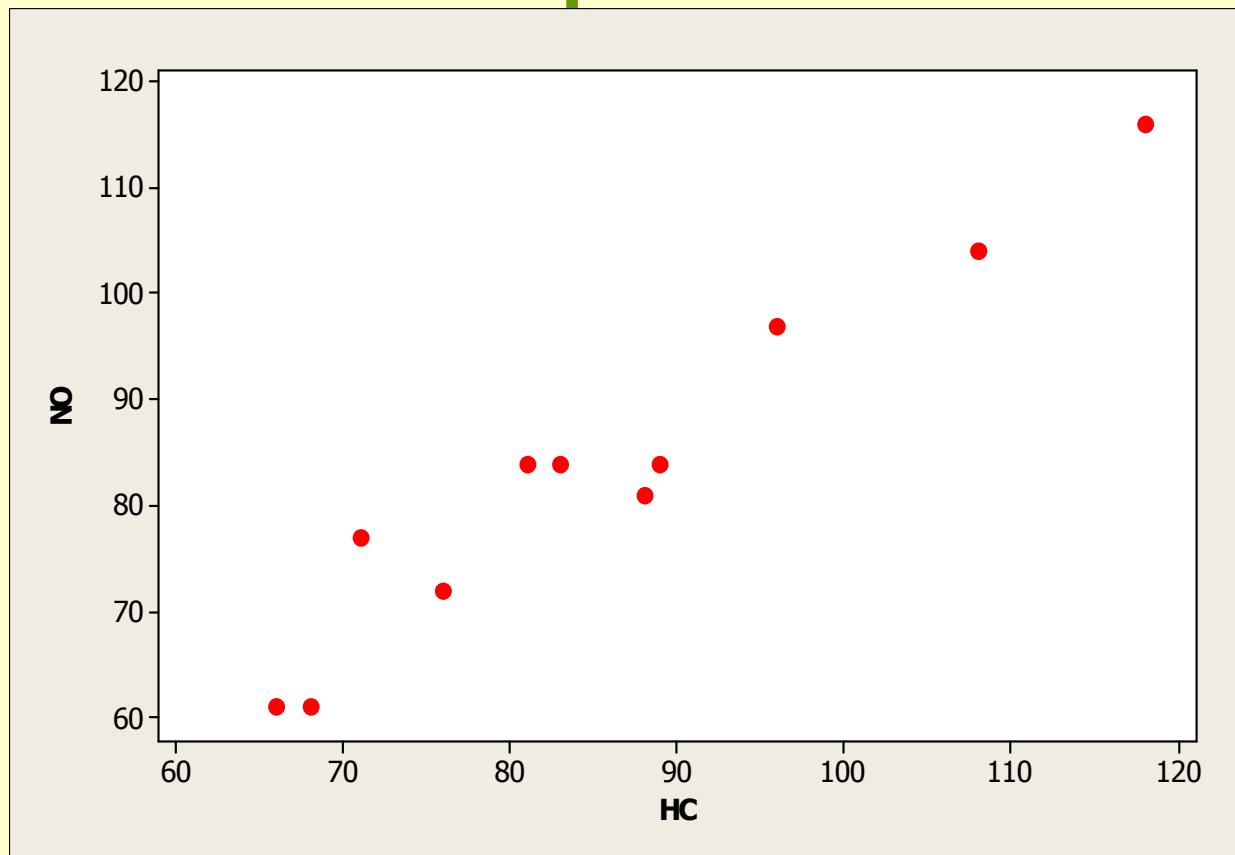
# Análise Exploratória

## Dados Bidimensionais

### Dados de poluentes ambientais

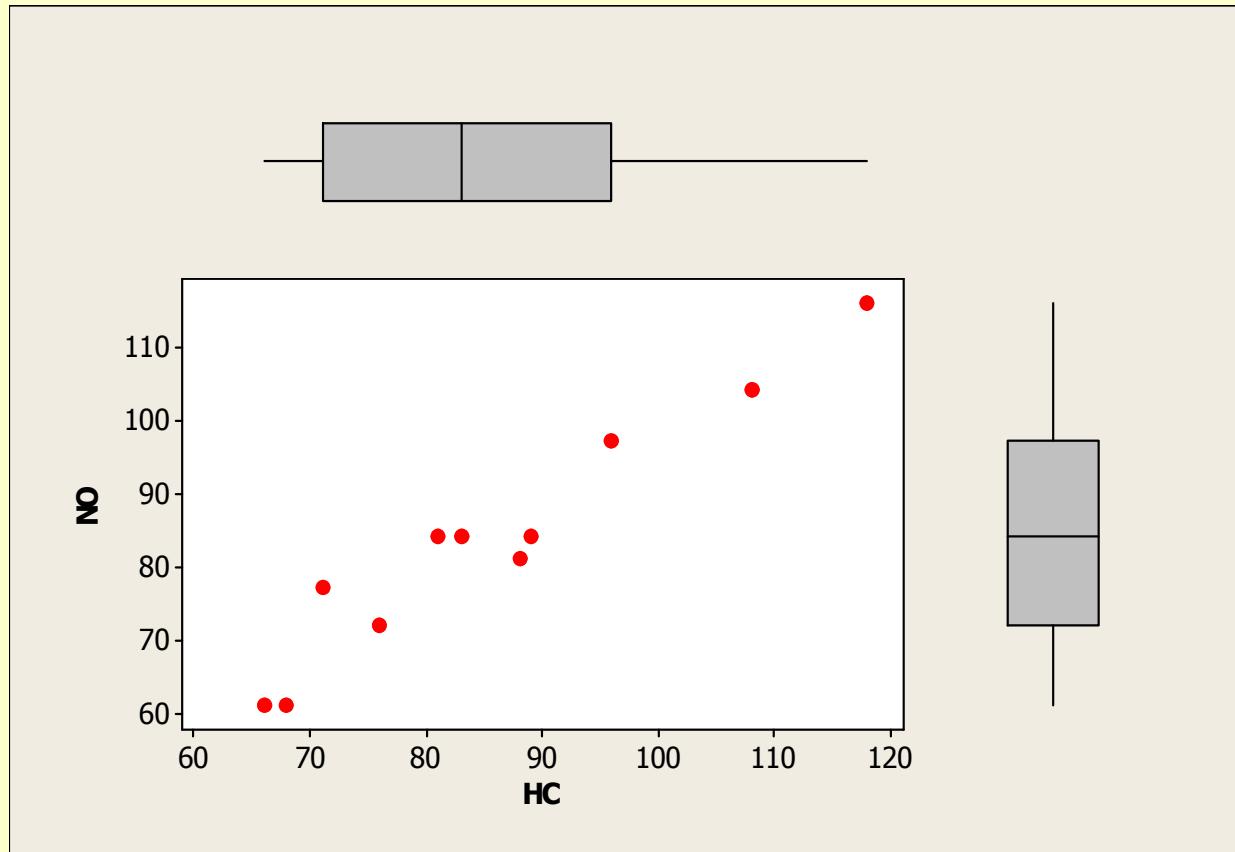
Day	Nitrogen Oxides	Hydrocarbons
1	104	108
2	116	118
3	84	89
4	77	71
5	61	66
6	84	83
7	81	88
8	72	76
9	61	68
10	97	96
11	84	81

# Análise Exploratória - Gráfico de Dispersão

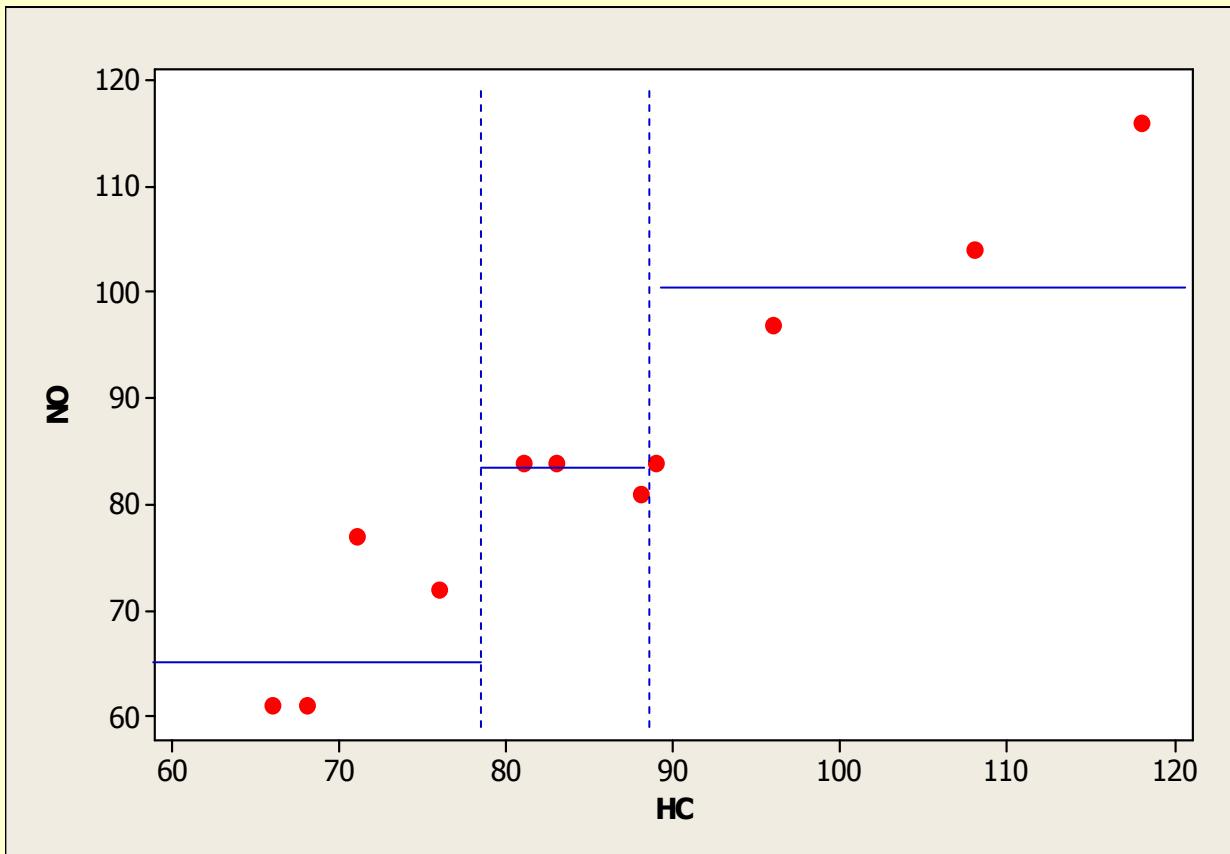


- Gráficos: *antes* que qualquer modelo seja ajustado
- Gráficos: *durante* o processo de ajuste de modelos
- Gráficos: *depois* que o modelo foi ajustado    (*Chambers et al., 1992*)  
15

# Vizualizando Dados Bivariados

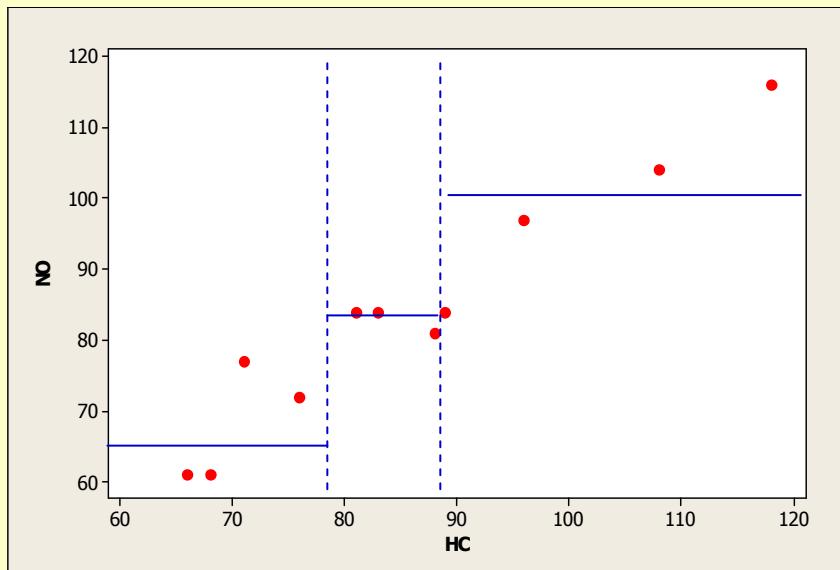


# Análise Exploratória - Gráfico de Dispersão



- Faixas verticais com igual número de obs (tanto quanto possível)
- Medianas (de Y) de cada faixa

# Análise Exploratória - Gráfico de Dispersão

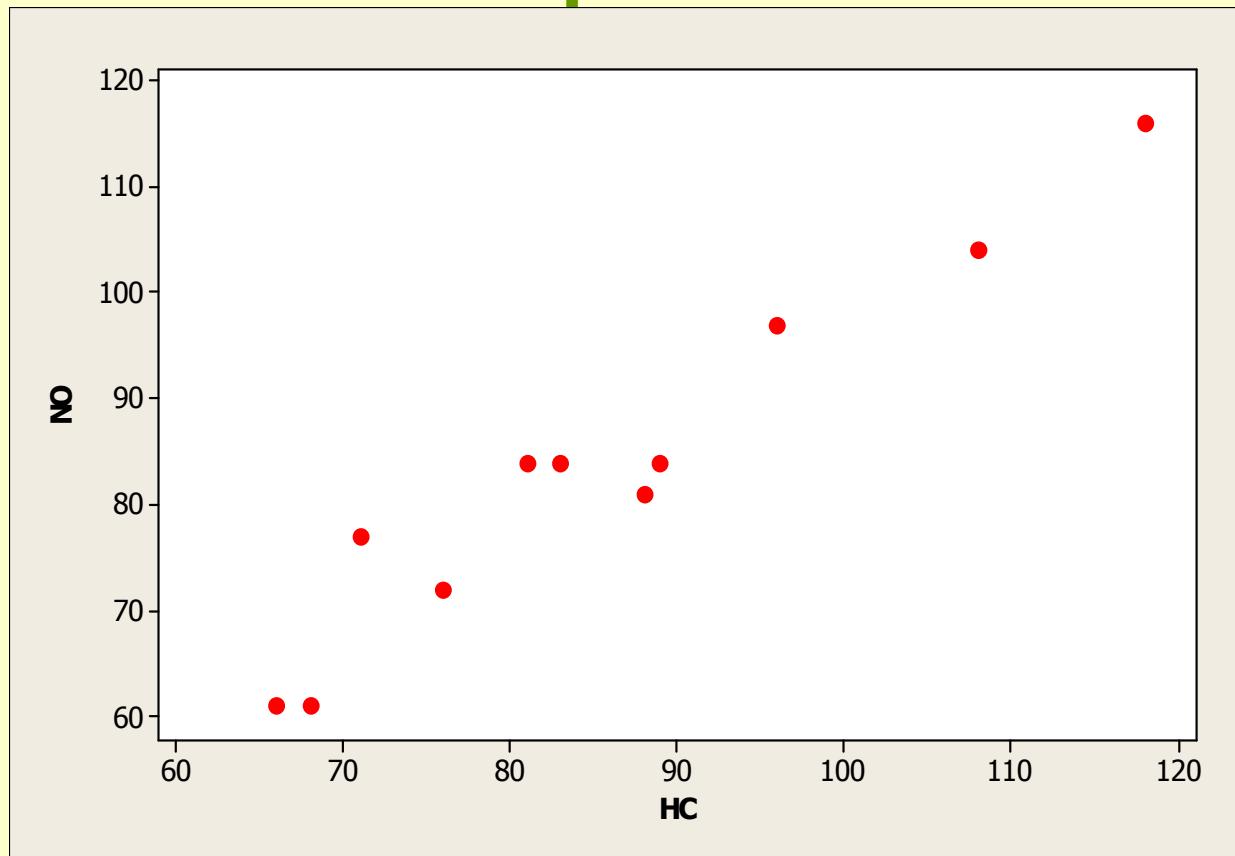


Medidas resumo para o poluente NO (“Y”)

	Faixas do poluente HC (“X”)		
	66+ 79	79+ 89	89+ 119
<i>n</i>	4	3	4
<i>Mediana</i>	66,5	84	100,5
<i>Média</i>	67,8	83	100,3

- Categorizando uma das variáveis  $\Rightarrow$  análise exploratória da variável quantitativa em cada nível da variável categorizada
- Medidas resumo e gráficos da variável quantitativa em cada nível da variável categorizada (depende de  $n$  em cada faixa)

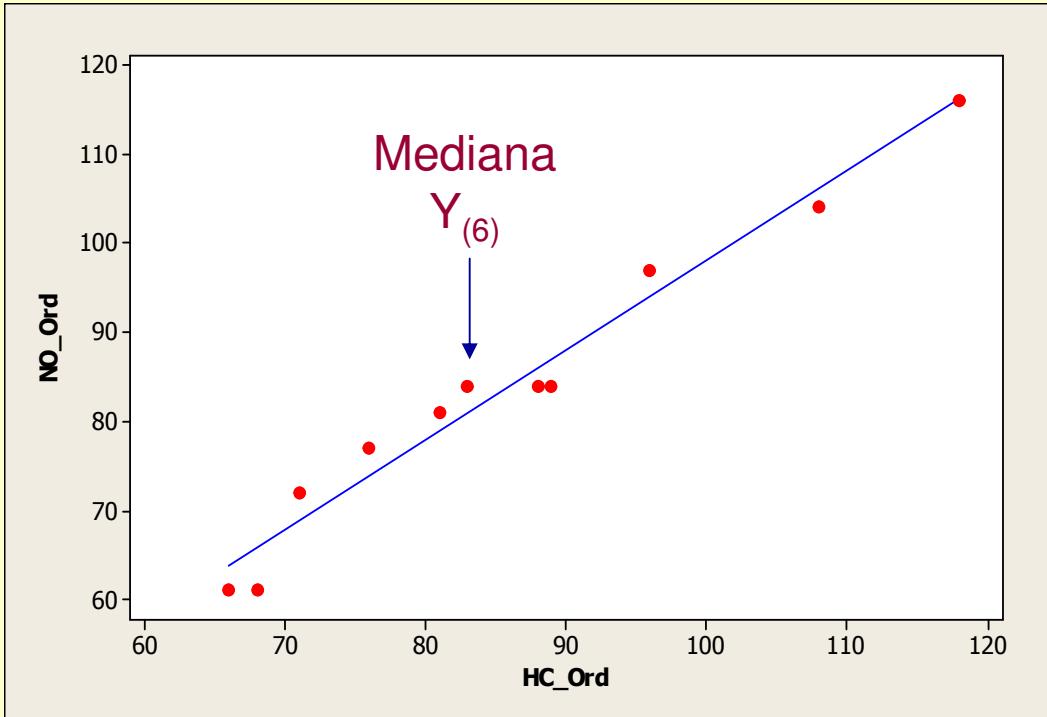
# Análise Exploratória - Gráfico de Dispersão



- Gráficos de dispersão: relação sistemática global entre  $Y$  e  $X \Rightarrow$  não permitem comparar diretamente os valores pequenos, medianos e grandes dos dois conjuntos de dados
- ⇒ Gráficos Q-Q (P-P)

# Gráfico Quantis-Quantis

## Dados de Poluentes



$n=11$ : pares de obs

⇒ Gráfico P-P:  $Y_{(j)}$  x  $X_{(j)}$   
das observações ordenadas

- os menores níveis do poluente HC foram superiores àqueles do poluente NO
- a magnitude dos valores dos dois poluentes, ao longo dos dias, não difere muito

Gráfico de Dispersão: pareamento das observações é pela variável que define a ocorrência dos dados (var. Day, neste caso)

Gráfico P-P: pareamento é pela ordem das observações  
(percentil/quantil)

P-P plot:

$$P_x(q) = P(X \leq q) = F_x(q)$$

$$P_y(q) = P(Y \leq q) = F_y(q)$$

Pares  $(P_x(q), P_y(q))$ , para qq  $q$  real  $\rightarrow$  P-P plot: gráfico de probabilidades.

Q-Q plot:

Os pares  $(Q_x(p), Q_y(p))$ , p/  $0 < p < 1$   $\rightarrow$  Q-Q plot: gráfico de quantis vs quantis.

$Q_x(p)$ : um valor que deixa  $100p\%$  das obs. à sua esquerda.

Se as distribuições de X e Y são iguais, então  $F_x = F_y$  e as gráficos P-P e Q-Q resultam em retas  $y=x$ .

Em geral, os gráficos Q-Q são mais sensíveis a diferenças nas caudas das distribuições, se estas forem aproximadamente simétricas e com a aparência de uma normal.

Considere:

$x_1, x_2, \dots, x_n$  e  $y_1, y_2, \dots, y_m$

a) Caso  $n=m$ :

cada par  $(x_{(i)}, y_{(i)})$  é calculado p/

$$p=p_i=(i-0,5)/n, i = 1, \dots, n.$$

Supondo que  $y=aX+b \rightarrow$  distribuições são as mesmas, exceto por uma transformação linear.

$$P = P(X \leq Q_x(p)) = P(aX + b \leq aQ_x(p) + b) = P(Y \leq Q_y(p))$$



$$Q_y(p) = aQ_x(p) + b$$



$$\text{posição}(y_i) = a * \text{posição}(x_i) + b$$

$$\text{escala}(y_i) = |a| \text{ escala}(x_i)$$

O gráfico Q-Q mostrará uma reta com inclinação **a** e intercepto **b**.

Essa propriedade não vale para gráficos P-P

## b) Caso $m \neq n$

$x_{(1)}, \dots, x_{(n)}$  e  $y_{(1)}, \dots, y_{(m)}$

- i) Consideramos os valores ordenados  $y_{(i)}$  calculados para  $p_i = (i-0,5)/m$ ,  $i=1, \dots, m$
- ii) Interpolamos um conjunto correspondente de quantis para  $x_i$ . Queremos um valor  $j$  tal que:

$$(j-0,5)/n = (i-0,5)/m \rightarrow j = (i-0,5)n/m + 0,5$$

Se  $j$  for inteiro:

Colocamos no gráfico Q-Q os pontos  $(x_{(j)}, y_{(i)})$

Se não:

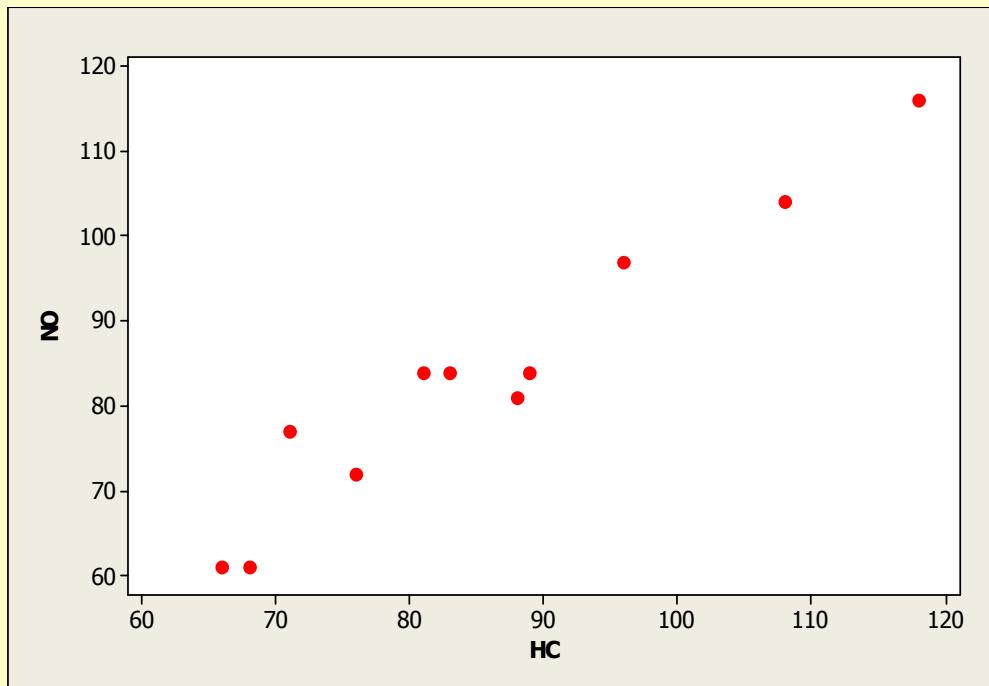
Considere  $j=k+r$ , com  $k$  inteiro e  $0 < r < 1$ .

O quantil correspondente a  $y_{(i)}$  é

$$Q_x((i-0,5)/m) = (1-r)x_{(k)} + r x_{(k+1)}$$

# Análise Exploratória - Gráfico de Dispersão

Dados de Poluentes

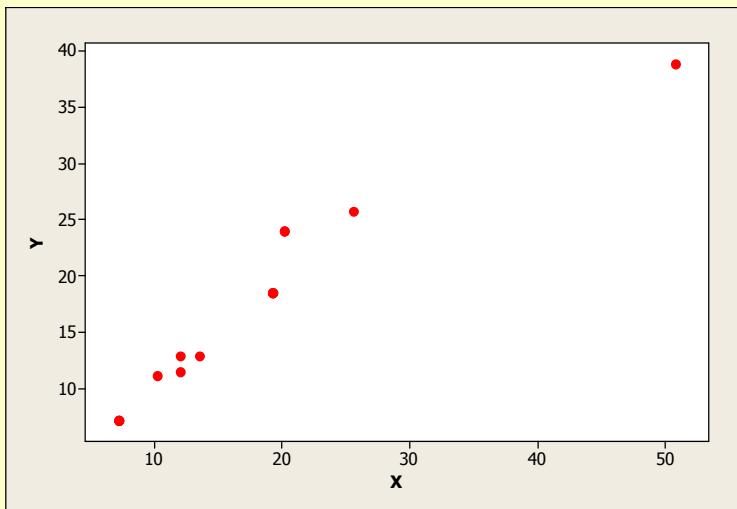


$$r = \frac{\sum_{j=1}^n (X_j - \bar{X})(Y_j - \bar{Y})}{\left[ \sum_{j=1}^n (X_j - \bar{X})^2 \sum_{j=1}^n (Y_j - \bar{Y})^2 \right]^{1/2}} \Rightarrow r = 0,967$$

O coeficiente de correlação de Pearson é uma medida não resistente  
⇒ Como obter uma medida robusta de relação entre variáveis ? 27

# Coeficiente de Correlação Robusto

$$\Rightarrow r = 0,961$$



- Padronizar as variáveis pela variância aparada  $\Rightarrow$  Obter somas e diferenças padronizadas

$$\tilde{X}_j = \frac{X_j}{s_X(\alpha)} \quad \tilde{Y}_j = \frac{Y_j}{s_Y(\alpha)} \quad j = 1, \dots, n$$

$$\Rightarrow r(\alpha) = \frac{s_{\tilde{X}+\tilde{Y}}^2(\alpha) - s_{\tilde{X}-\tilde{Y}}^2(\alpha)}{s_{\tilde{X}+\tilde{Y}}^2(\alpha) + s_{\tilde{X}-\tilde{Y}}^2(\alpha)}$$

X	Y
20,2	24
50,8	38,8
12	11,5
25,6	25,8
20,2	24
7,2	7,2
7,2	7,2
7,2	7,2
19,3	18,5
19,3	18,5
19,3	18,5
10,2	11,1
12	12,9
7,2	7,2
13,5	12,9

$$\bar{X}(\alpha=0,05) = 14,86 \quad \bar{Y}(\alpha=0,05) = 15,33$$

$$s_X(\alpha=0,05) = 5,87$$

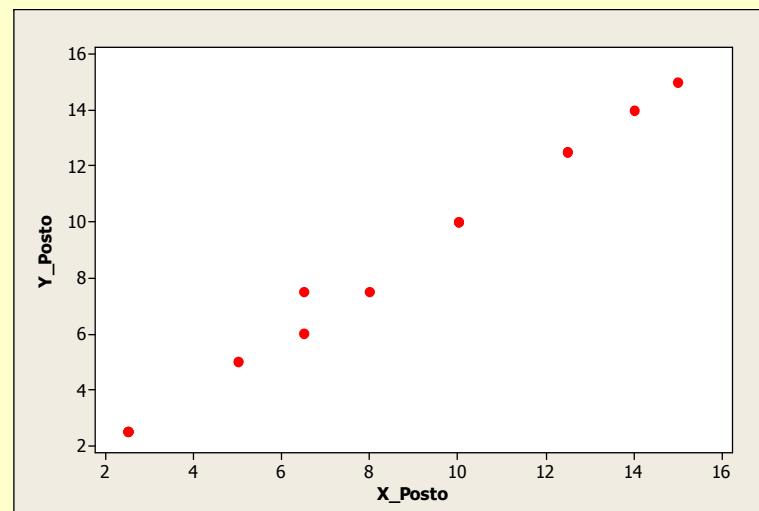
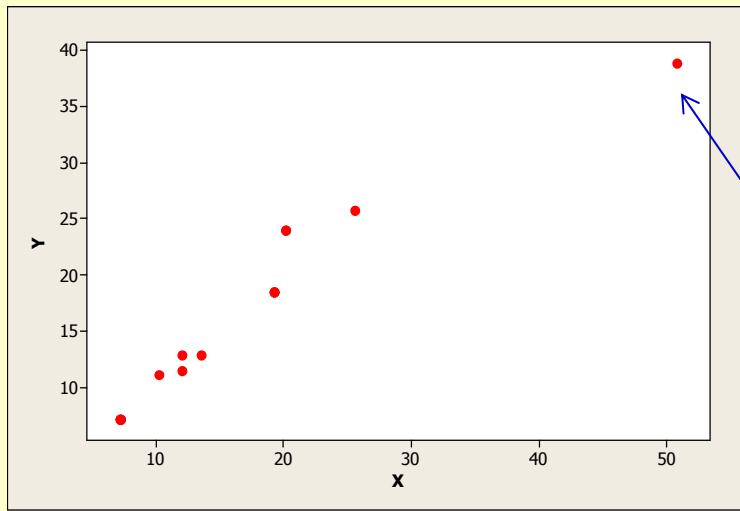
$$s_Y(\alpha=0,05) = 6,40$$

$$\Rightarrow r(\alpha=0,05) = 0,973$$

$$(\tilde{X} + \tilde{Y})(\alpha) = 4,93 \quad (\tilde{X} - \tilde{Y})(\alpha) = 0,14$$

$$s_{\tilde{X}+\tilde{Y}}^2(\alpha) = 3,93 \quad s_{\tilde{X}-\tilde{Y}}^2(\alpha) = 0,054$$

# Outros Coeficientes de Correlação Robustos



$$\Rightarrow r = 0,961$$

$$\Rightarrow r(\alpha = 0,05) = 0,973$$

**Coeficiente de Correlação de Spearman:**

**“atribuição de postos às obs em Y e em X, independentemente”**

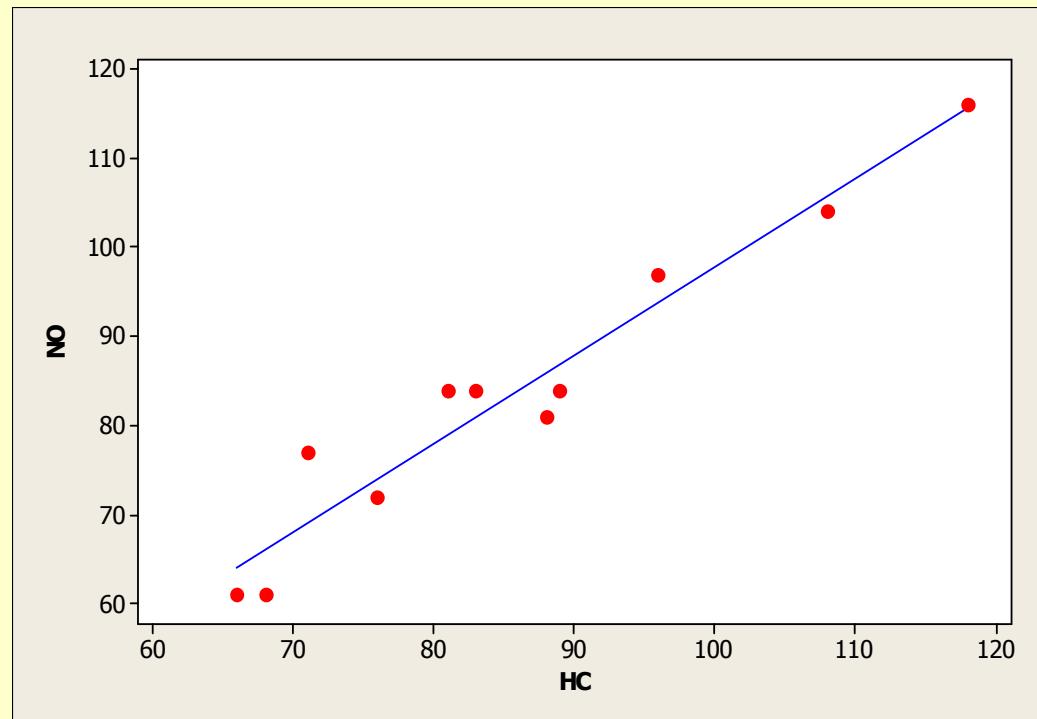
$$\Rightarrow r_{Posto} = 0,997$$

X	Y	X_Posto	Y_Posto
20,2	24	12,5	12,5
50,8	38,8	15	15
12	11,5	6,5	6
25,6	25,8	14	14
20,2	24	12,5	12,5
7,2	7,2	2,5	2,5
7,2	7,2	2,5	2,5
7,2	7,2	2,5	2,5
19,3	18,5	10	10
19,3	18,5	10	10
19,3	18,5	10	10
10,2	11,1	5	5
12	12,9	6,5	7,5
7,2	7,2	2,5	2,5
13,5	12,9	8	7,5

# Análise Exploratória

## Regressão Linear

Dados de Poluentes



Propriedades do ajuste por Mínimos Quadrados ?

# Modelos de Regressão



Revisando

$$Y_j = \beta_0 + \beta_1 X_j + \varepsilon_j \quad j = 1, \dots, n$$

$$Y_j = \beta_0 + e^{\beta_1 X_j} + \varepsilon_j \quad j = 1, \dots, n \Rightarrow \text{Modelo não-linear}$$

$$Y_j = \beta_0 + \sum_{k=1}^K \beta_k X_{kj} + \varepsilon_j \quad j = 1, \dots, n \Rightarrow \text{Modelo linear aditivo}$$

$$Y_j = \beta_0 + \sum_{k=1}^K \beta_k X_{kj} + \sum_k \sum_l \beta_{kl} X_{kj} X_{lj} + \varepsilon_j \quad j = 1, \dots, n$$

$$\Rightarrow Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1}$$

Notação matricial:  $Y$  é vetor de respostas

$X$  é matriz de variáveis explicativas

$\varepsilon$  é vetor de resíduos;  $\varepsilon = (Y - X\beta)$



Revisando

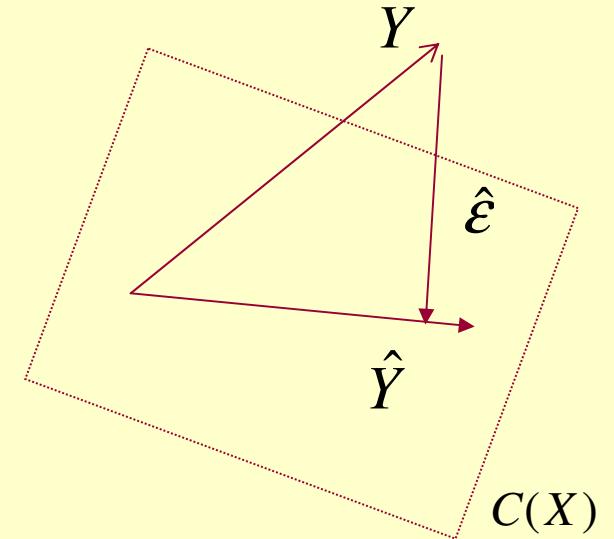
$$\Rightarrow Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1}$$

$$\hat{\beta} \quad ; \quad \min_{\beta=\hat{\beta}} S(\beta) = (Y - X\beta)'(Y - X\beta)$$

$$\Rightarrow X'X \hat{\beta} = X'Y$$

$$\Rightarrow \hat{\beta} = (X'X)^{-1} X'Y$$

$$\Rightarrow \hat{Y} = X \hat{\beta} = X (X'X)^{-1} X'Y = HY$$



Projeção  $HY$

Mínimos Quadrados Ponderados  $\hat{\beta}_W \quad ; \quad \min_{\beta=\hat{\beta}} S(\beta) = (Y - X\beta)' W(Y - X\beta)$

# Modelos de Regressão



Revisando

$$Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1} \quad \Rightarrow \quad \hat{\beta} = (X'X)^{-1} X'Y \quad \text{é estimador de M.Q.Ordinários}$$

$$\Rightarrow \hat{\beta}_1 = \frac{\sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\sum_{j=1}^n (x_j - \bar{x})^2} = \frac{\sum_{j=1}^n (x_j - \bar{x})y_j}{\sum_{j=1}^n (x_j - \bar{x})^2} = \sum_{j=1}^n w_j y_j \quad \Rightarrow \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

- **Teorema de Gauss-Markov:**

EMQ têm variância mínima na classe dos estimadores não viesados e que sejam funções lineares das observações



# Modelos de Regressão

Revisando

$$Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1} \quad \Rightarrow \quad \hat{\beta} = (X'X)^{-1} X'Y \quad \text{é estimador de MQO}$$

- Supondo que a variável explicativa é fixa e que os erros são  $iid (0; \sigma^2)$ :

$$\Rightarrow E(\hat{\beta}_1) = \beta_1, \quad E(\hat{\beta}_0) = \beta_0,$$

$$\Rightarrow Var(\hat{\beta}_0) = \frac{\sigma^2 \sum x_j^2}{n \sum (x_j - \bar{x})^2}, \quad Var(\hat{\beta}_1) = \frac{\sigma^2}{\sum (x_j - \bar{x})^2}, \quad \hat{\sigma}^2 = Var(\hat{\varepsilon}) = \frac{S(\hat{\beta}_0, \hat{\beta}_1)}{n-2}$$

$$\Rightarrow \text{se } \varepsilon_j \sim N: \quad y_j \sim N(\beta_0 + \beta_1 x_j; \sigma^2) \text{ e } \hat{\beta} \text{ são EMVS}$$

$$\Rightarrow t_{\hat{\beta}_0} = \frac{\hat{\beta}_0 - \beta_0}{\hat{\sigma}} \sqrt{\frac{n \sum (x_j - \bar{x})^2}{\sum x_j^2}} \sim t_{n-2} \quad t_{\hat{\beta}_1} = \frac{\hat{\beta}_1 - \beta_1}{\hat{\sigma}} \sqrt{\sum (x_j - \bar{x})^2} \sim t_{n-2}$$

# Modelos de Regressão



Revisando

$$Y_j = \bar{Y} + (Y_j - \hat{Y}_j) + (\hat{Y}_j - \bar{Y})$$

$$\sum_{j=1}^n (Y_j - \bar{Y})^2 = \underbrace{\sum_{j=1}^n (Y_j - \hat{Y}_j)^2}_{SQRes} + \underbrace{\sum_{j=1}^n (\hat{Y}_j - \bar{Y})^2}_{SQMod}$$

*SQTotal*

*SQRes*

*SQMod* =  $\hat{\beta}_1^2 \sum_{j=1}^n (x_j - \bar{x})^2$

$$\Rightarrow R^2 = \frac{QMMod}{QMTotal}$$

porcentagem da variabilidade de y explicada pelo modelo

$$\Rightarrow F = \frac{QMMod}{QM\ Res} = \frac{\sum (\hat{y}_j - \bar{y})^2 / 1}{\sum (y_j - \hat{y}_j)^2 / (n-2)} \sim F_{1;(n-2)}$$

# Modelos de Regressão



Revisando

## Análises Exploratórias

- Análises de Resíduos

⇒ Histogramas e box-plots dos resíduos

⇒ Quantis dos resíduos contra quantis da normal

⇒  $\hat{\varepsilon}_j \times \text{ordem(obs)}$ ;

$\hat{\varepsilon}_j \times x_j$  ;

$\hat{\varepsilon}_j \times \hat{y}_j$  ;

$y_j \times \hat{y}_j$

erros independentes

erros

homocedasticidade

falta de ajuste

independentes de X

$$\varepsilon_j = \varepsilon(x_j) ?$$

tendências não  
modeladas

$$\begin{aligned}\varepsilon &= y - \hat{y} \\ &= (y - \bar{y}) + (\bar{y} - \hat{y})\end{aligned}$$

# Modelos de Regressão

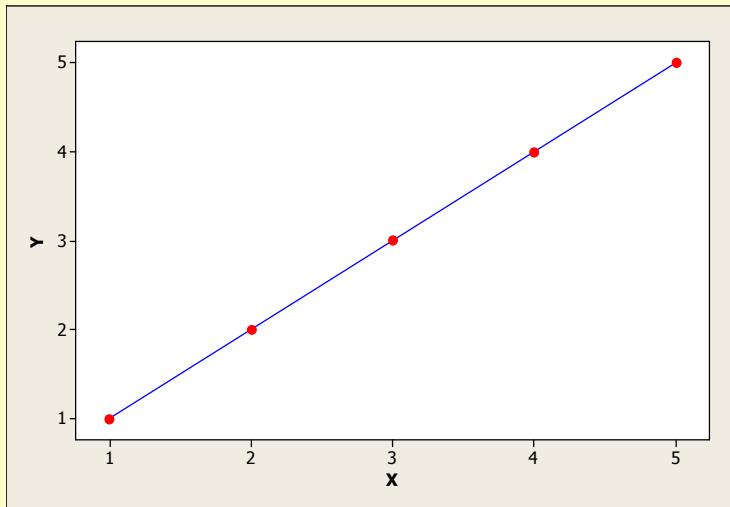


## Análises Exploratórias

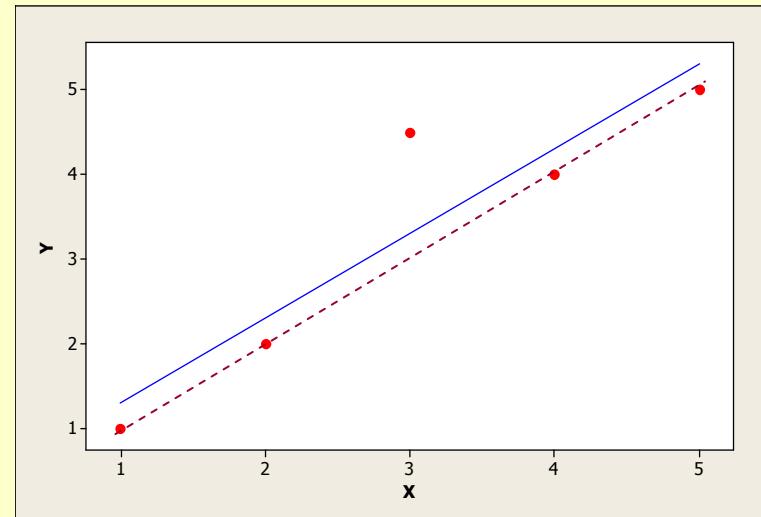
- Análises de Resíduos
  - ⇒ Histogramas e box-plots dos resíduos
  - ⇒ Quantis dos resíduos contra quantis da normal
  - ⇒  $\hat{\varepsilon}_j \times x_j$ ;  $\hat{\varepsilon}_j \times \text{ordem(obs)}$ ;  $\hat{\varepsilon}_j \times \hat{y}_j$ ;  $y_j \times \hat{y}_j$
- ◀
- Identificação de Pontos Aberrantes
- Identificação de Pontos de Alavanca
- Identificação de Pontos de Influência
- ...

# Pontos Discrepantes (Atípicos)

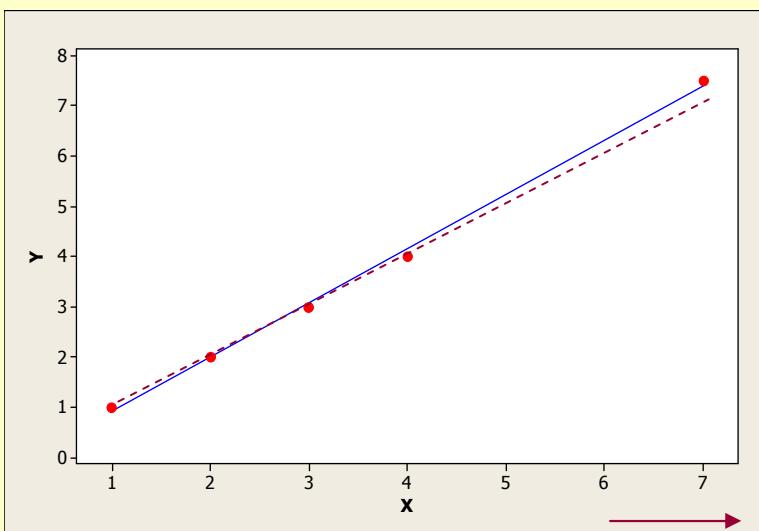
Ajuste perfeito



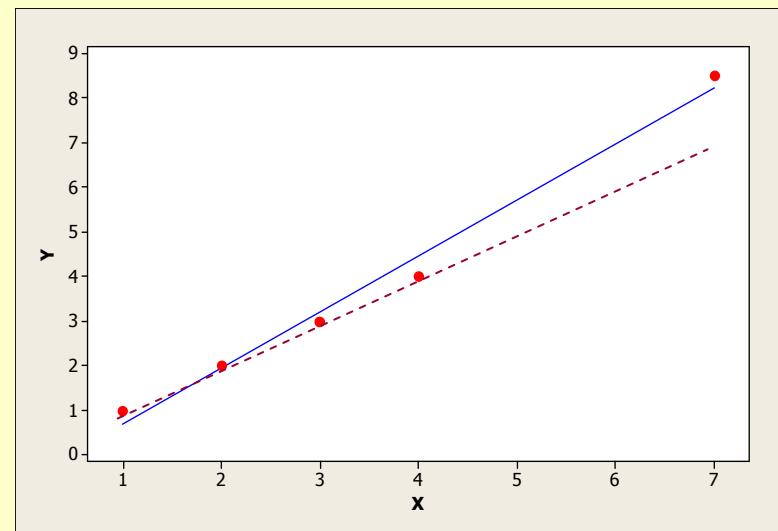
Ponto aberrante



Ponto de Alavanca



Ponto Influente (e de Alavanca)





# Modelos de Regressão

$$\Rightarrow Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \varepsilon_{n \times 1} \Rightarrow \hat{Y} = X \hat{\beta} = X (X'X)^{-1} X' Y = H Y$$

- Identificação de pontos de alavanca (alto leverage):

$$\hat{y}_j = \sum_{j=1}^n x_j' (X'X)^{-1} x_j y_j \Rightarrow \hat{y}_j = h_{jj} y_j + (1 - h_{jj}) x_j' \hat{\beta}_{(j)}$$

↑  
alavanca do valor ajustado  $\left( h_{jj} > \frac{2p}{n} \right)$

- Identificação de pontos aberrantes:

$$t_j^* = \frac{\hat{\varepsilon}_j}{s_{(j)}(1 - h_{jj})^{1/2}} \sim t_{n-p-1} \quad \text{resíduo studentizado (deletado)}$$

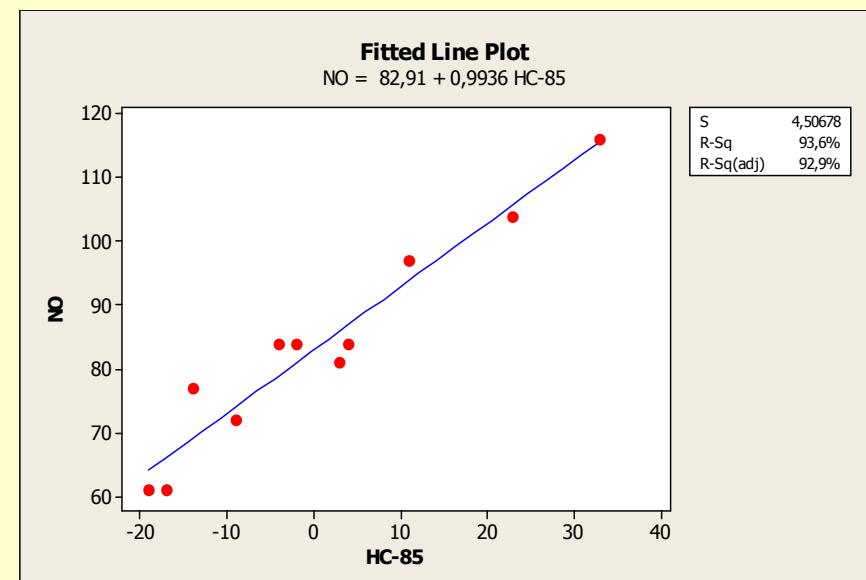
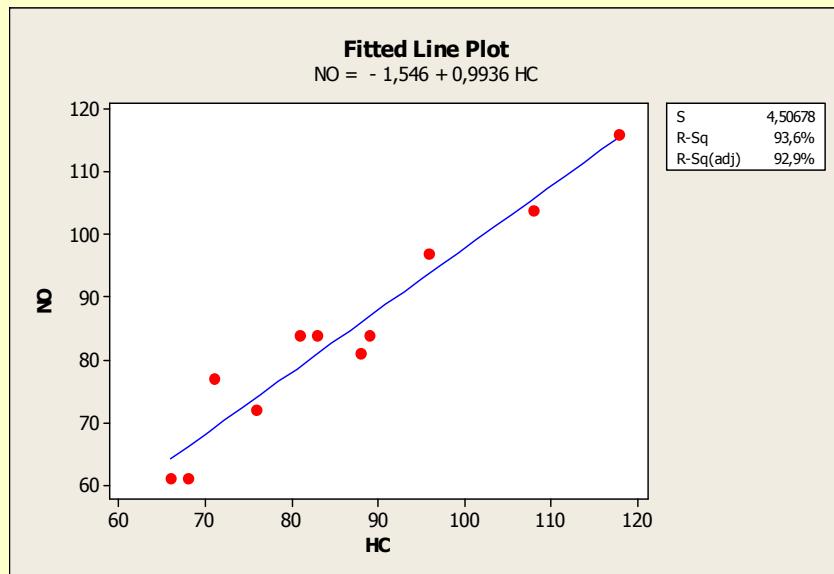
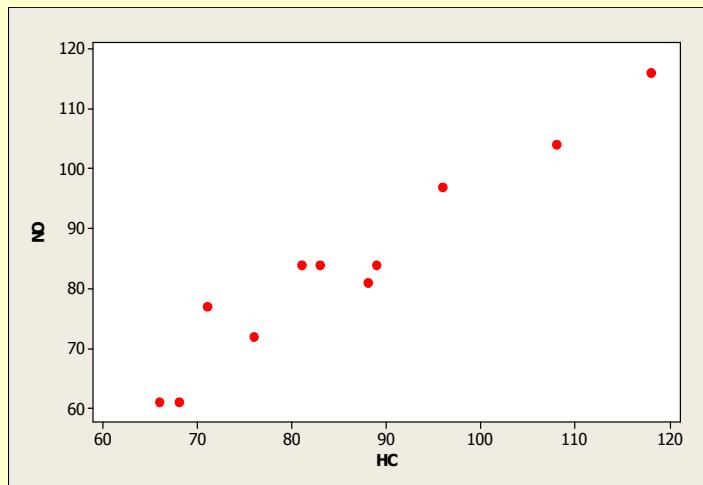
- Identificação de pontos influentes (Cook):

$$D_j = \frac{(\hat{\beta} - \hat{\beta}_{(j)})' X' X (\hat{\beta} - \hat{\beta}_{(j)})}{p s^2} > F_{p, (n-p-1)}(1 - \alpha)$$

$$\uparrow t_j^2 \text{ e/ou } \uparrow h_{jj} \Rightarrow \uparrow D_j$$

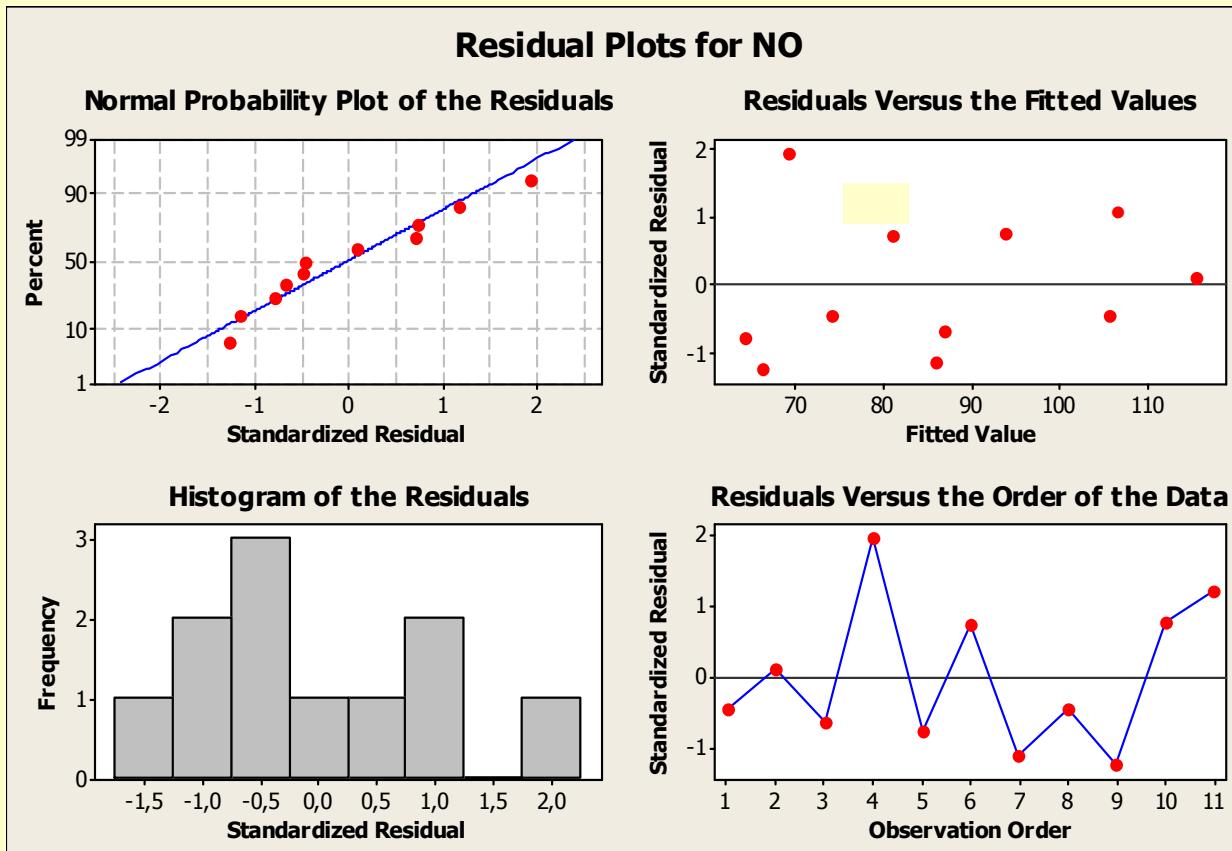
# Análise Exploratória - Regressão Linear

## Dados de Poluentes



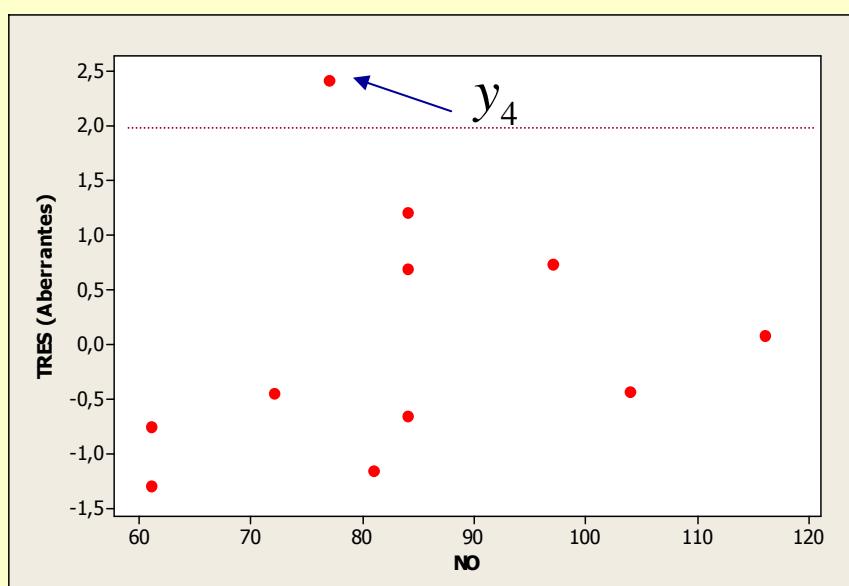
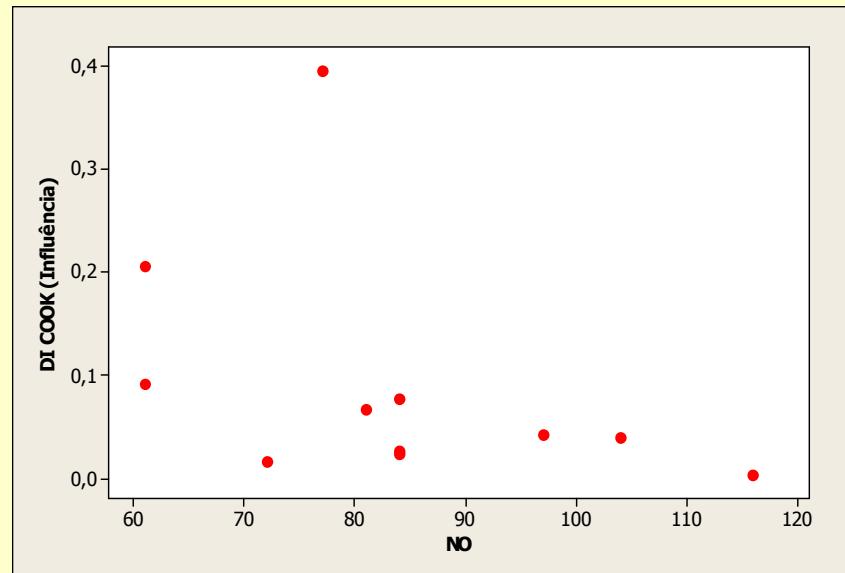
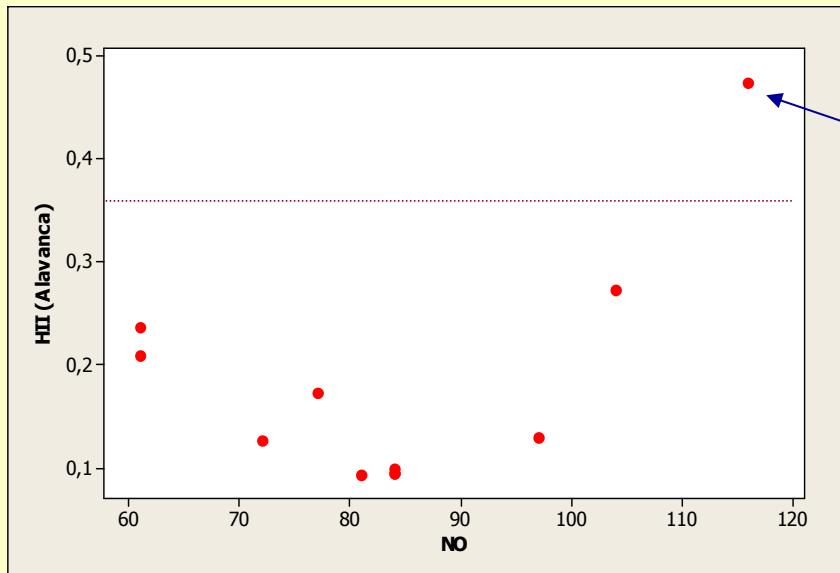
# Análise Exploratória - Regressão Linear

## Análise de Resíduos



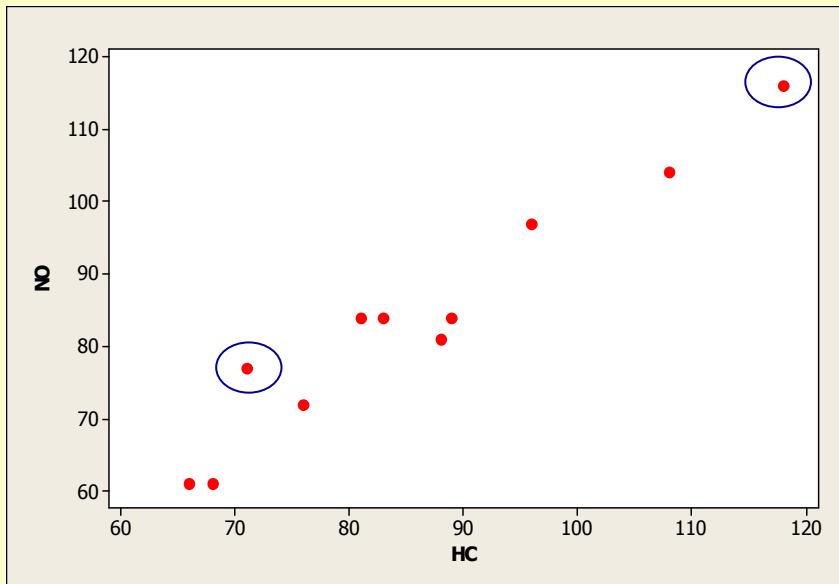
# Análise Exploratória - Regressão Linear Simples

## Dados de Poluentes



$$F_{2,8}(0,5) = 0,757$$

# Dados de poluentes ambientais

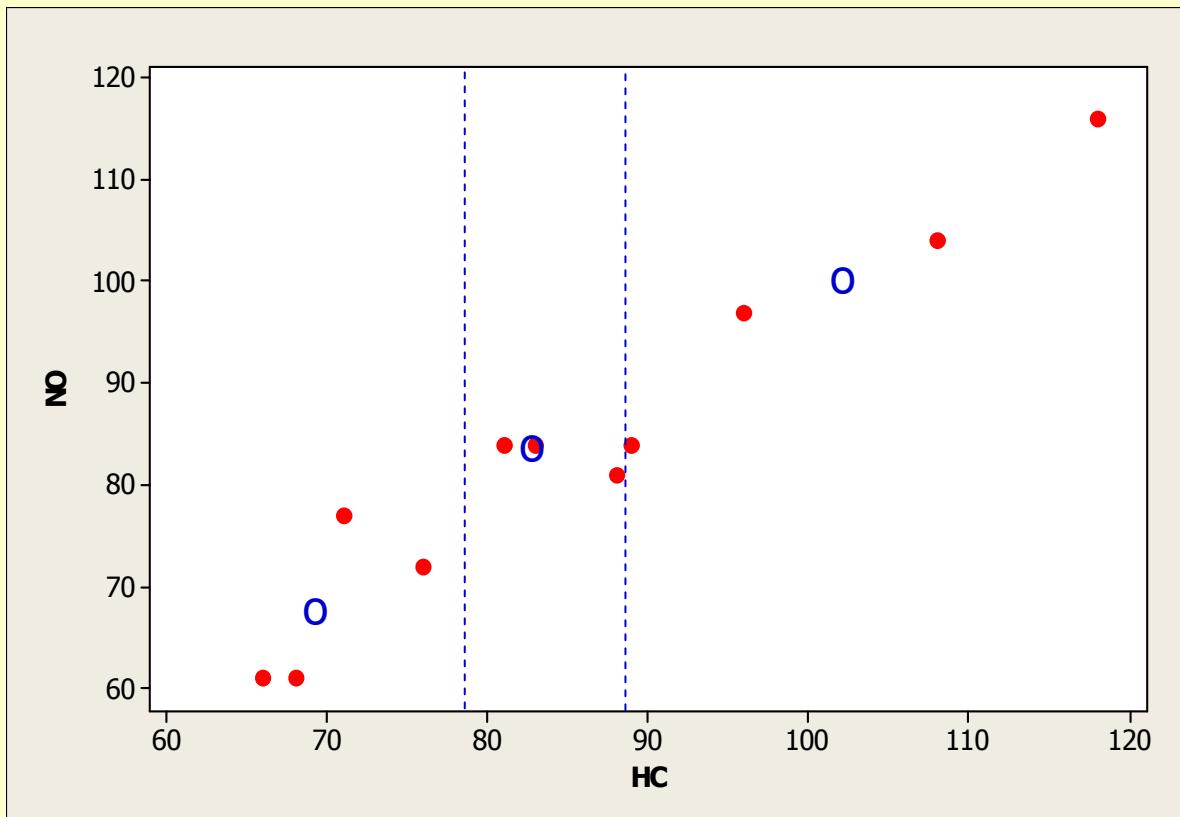


Day	Nitrogen Oxides	Hydrocarbons	
1	104	108	
2	116	118	Alavanca
3	84	89	
4	77	71	Aberrante
5	61	66	
6	84	83	
7	81	88	
8	72	76	
9	61	68	
10	97	96	
11	84	81	

# Análise Exploratória

## Régressão Linear Simples Robusta

### Dados de Poluentes



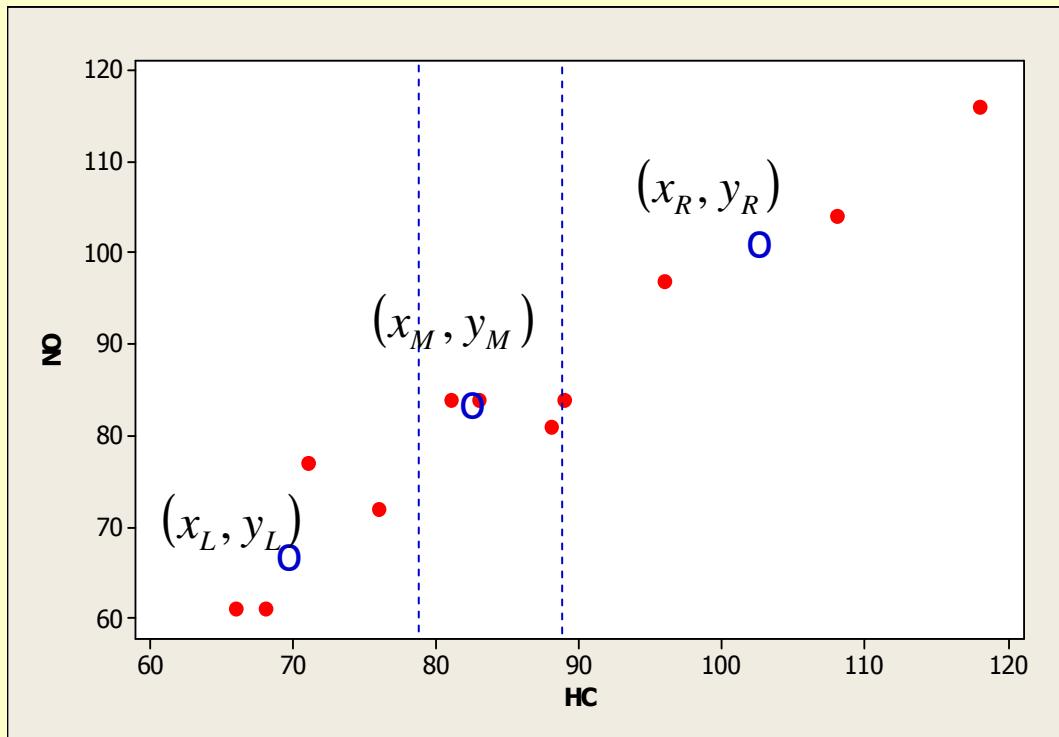
Método dos 3 Grupos

Construção de Linhas Resistentes

- Dividir os  $n$  pontos em Três grupos (por  $x$ )
- Calcular pontos “medianos” (em  $Y$ ) dentro de cada grupo

# Análise Exploratória - Linha Resistente

## Dados de Poluentes



E.M.Q:

$$\hat{\beta}_1 = \hat{\rho} \frac{s_y}{s_x} \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

## Pontos Medianos

$$(x_R, y_R) = (69.5; 66.5)$$

$$(x_M, y_M) = (83; 84)$$

$$(x_L, y_L) = (102; 100.5)$$

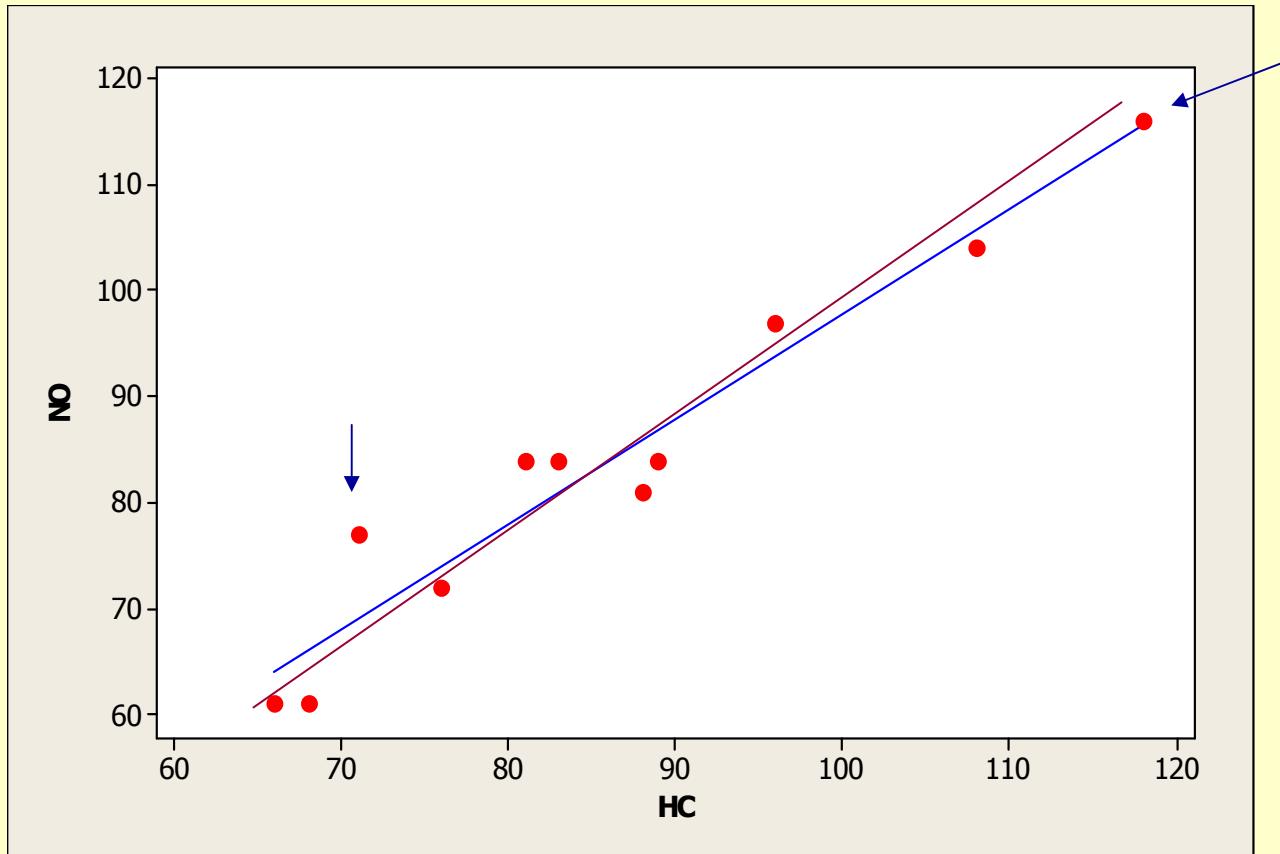
$$\hat{y}_R = a^0 + b^0 x \Rightarrow b^0 = 1.046 \quad a^0 = -5.06$$

$$\Rightarrow b^0 = \frac{y_R - y_L}{x_R - x_L}$$

$$\Rightarrow a^0 = \frac{1}{3} [(y_L - b^0 x_L) + (y_M - b^0 x_M) + (y_R - b^0 x_R)]$$

$\uparrow \quad \uparrow \quad \uparrow$   
 $a_L \quad a_M \quad a_R$

# Modelos de Regressão



- Reta de MQ:  $\hat{y} = -1.546 + 0.9936 x$
  - Linha Resistente (Método dos 3 Grupos):  $\hat{y}_R = -5.06 + 1.046 x$
- ➡ Comparar os resíduos. O que é esperado?

# Análise Exploratória - Linha Resistente

## Método dos 3 Grupos

Pontos Medianos

$$\hat{y} = a + bx$$

$$(x_R, y_R) \Rightarrow b^0 = \frac{y_R - y_L}{x_R - x_L}$$

$$(x_L, y_L) \Rightarrow a^0 = \frac{1}{3} [(y_L - b^0 x_L) + (y_M - b^0 x_M) + (y_R - b^0 x_R)]$$

Interpretação de  $a \Rightarrow$  Ajuste em torno de um valor central  $x = \tilde{x}$

$$\hat{y} = \tilde{a}^0 + b^0(x - \tilde{x})$$

$$\Rightarrow b^0 = \frac{y_R - y_L}{x_R - x_L}$$

$$\Rightarrow \tilde{a}^0 = \frac{1}{3} [y_L - b^0(x_L - \tilde{x})] + [y_M - b^0(x_M - \tilde{x})] + [y_R - b^0(x_R - \tilde{x})]$$



# Análise Exploratória

## Melhorando o Ajuste da Linha Resistente

Propriedade dos Resíduos: é esperado que os resíduos não contenham nenhuma informação que possa ser summarizada por meio de uma função linear dos valores X

$$\hat{\varepsilon}_j = y_j - (a^0 + b^0 x_j)$$

⇒ Considere os pontos:  $(x_j, \hat{\varepsilon}_j) \quad j=1, \dots, n$

Obtenha a Linha de Resistência:  $\hat{\varepsilon}_j \times x_j \Rightarrow \delta_b^1 \quad \delta_a^1$

Coeficientes Atualizados:  $b^1 = b^0 + \delta_b^1 \quad a^1 = a^0 + \delta_a^1$

⇒  $\hat{y}_j^1 = a^1 + b^1 x_j \Rightarrow \hat{\varepsilon}_j^1 = y_j - \hat{y}_j^1$

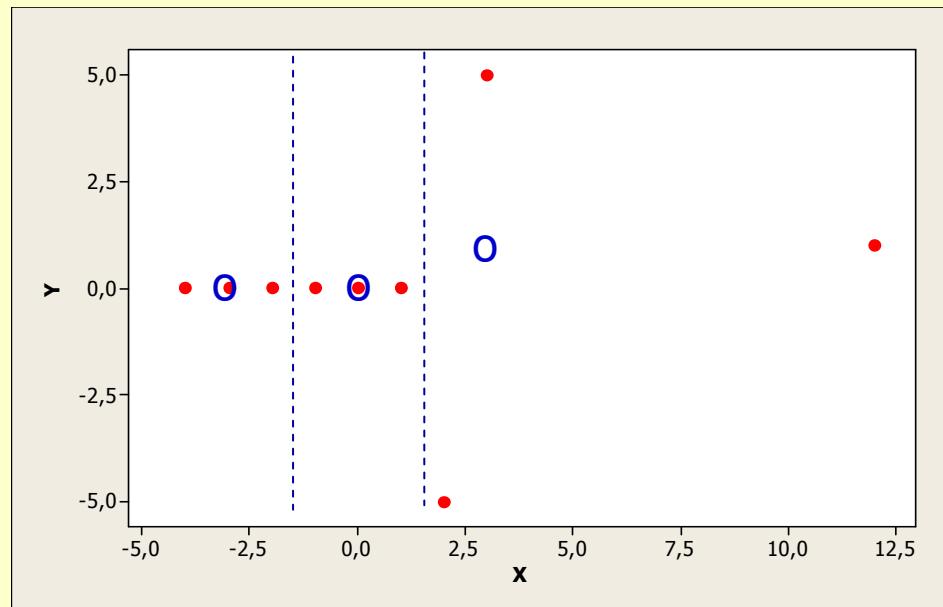
⇒ Considere os novos pontos:  $(x_j, \hat{\varepsilon}_j^1) \quad j=1, \dots, n$

$$b^2 = b^1 + \delta_b^2 \quad a^2 = a^1 + \delta_a^2 \quad \dots \quad \delta_b^I \rightarrow 0$$

# Análise Exploratória - Linha Resistente

Dados “Patológicos”  
(Hoaglin et al., 1983)

X	Y
-4	0
-3	0
-2	0
-1	0
0	0
1	0
2	-5
3	5
12	1



Iteração	Linha Ajustada
1	$0.167X + 0.333$
2	$-0.083X - 0.167$
3	$0.0292X + 0.583$
4	$-0.217X - 0.542$
5	$0.573X + 1.15$
6	$-0.693X - 1.39$
7	$0.833X + 1.67$
8	$-0.694X - 1.39$
9	$0.833X + 1.67$
10	$-0.694X - 1.39$

Em algumas situações extremas pode ocorrer problemas com o processo de convergência ⇒ proposta de correções no processo iterativo nas situações com pontos de alavancas

# Suavização

Considere  $(x_i, y_i)$ ,  $i=1, 2, \dots, n$

Objetivo: visualizar alguma “tendência” nos dados.

O primeiro passo é fazer o diagrama de dispersão das variaveis X e Y.

Nas técnicas de suavização, substituiremos o valor  $y$  do par  $(x, y)$  por um valor suavizado.

## Procedimentos:

- Médias móveis
- Medianas móveis
- Lowess

## Caso ideal:

temos vários valores de Y, para um dado valor de X. O valor suavizado poderia ser, por exemplo, a média condicional de Y, dado esse valor de X.

# Suavização – Médias Móveis

$$\hat{y}_t = \sum_{j=-m}^m c_j y_{t+j}, t = m+1, \dots, n-m$$

com:

$$\sum_{j=-m}^m c_j = 1.$$

Caso mais simples:  $c_j = 1/(2m+1)$

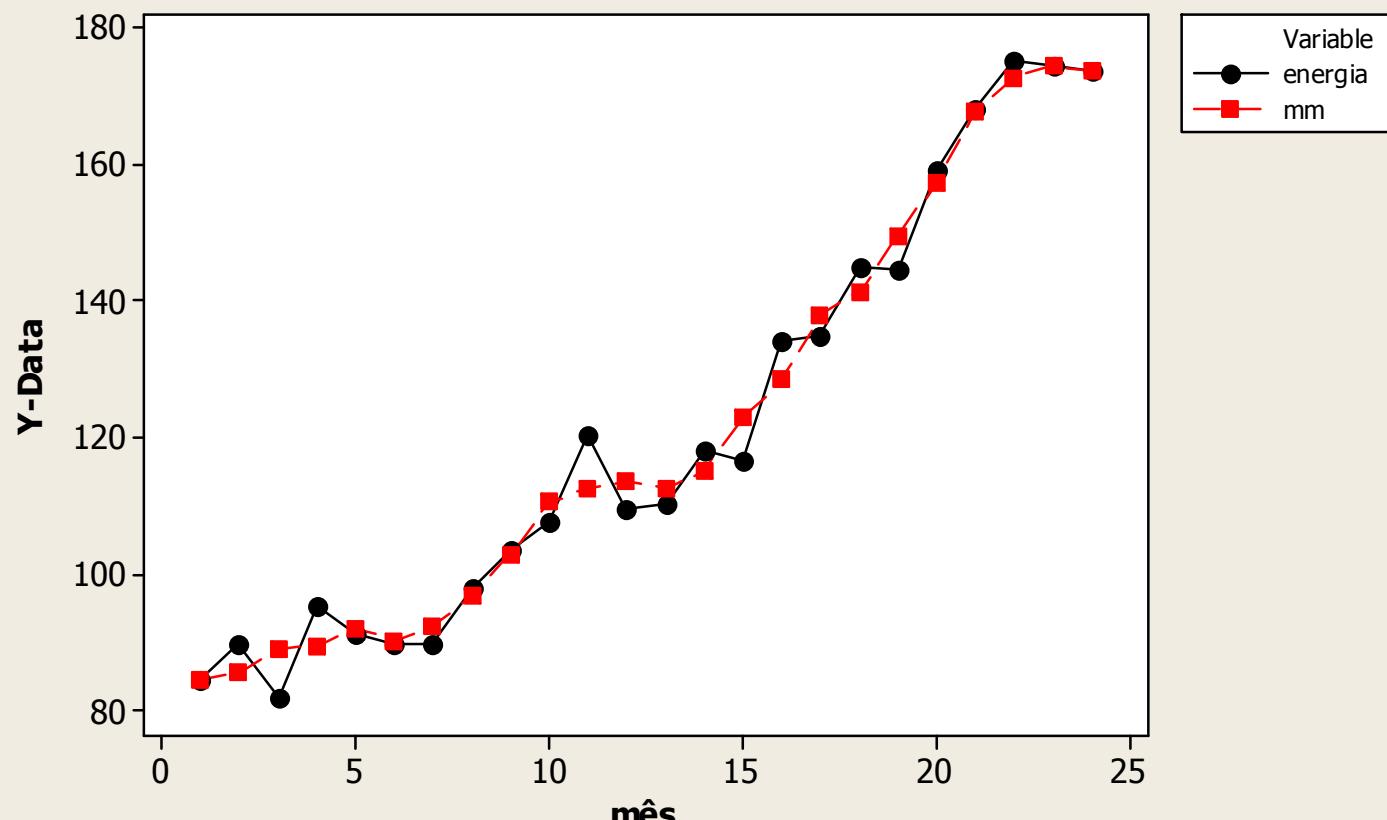
Técnica:  $(x_t, y_t)$  é substituído por  $(x_t, \hat{y}_t)$

Obs: perdemos  $m$  pares no inicio e  $m$  pares no final.

Consumo de Energia Elétrica no Espírito Santo, 01/1977-12/1978

mês	energia	M.M.(m=1)	Med.M(m=1)	mês	energia	M.M.(m=1)	Med.M(m=1)
1	84,60			13	110,30	112,67	110,30
2	89,90	85,47	84,60	14	118,10	114,97	116,50
3	81,90	89,07	89,90	15	116,50	122,93	118,10
4	95,40	89,50	91,20	16	134,20	128,47	134,20
5	91,20	92,13	91,20	17	134,70	137,90	134,70
6	89,80	90,23	89,80	18	144,80	141,30	144,40
7	89,70	92,47	89,80	19	144,40	149,47	144,80
8	97,90	97,00	97,90	20	159,20	157,27	159,20
9	103,40	102,97	103,40	21	168,20	167,53	168,20
10	107,60	110,47	107,60	22	175,20	172,63	174,50
11	120,40	112,53	109,60	23	174,50	174,47	174,50
12	109,60	113,43	110,30	24	173,70		

**Scatterplot of energia; mm vs mês**



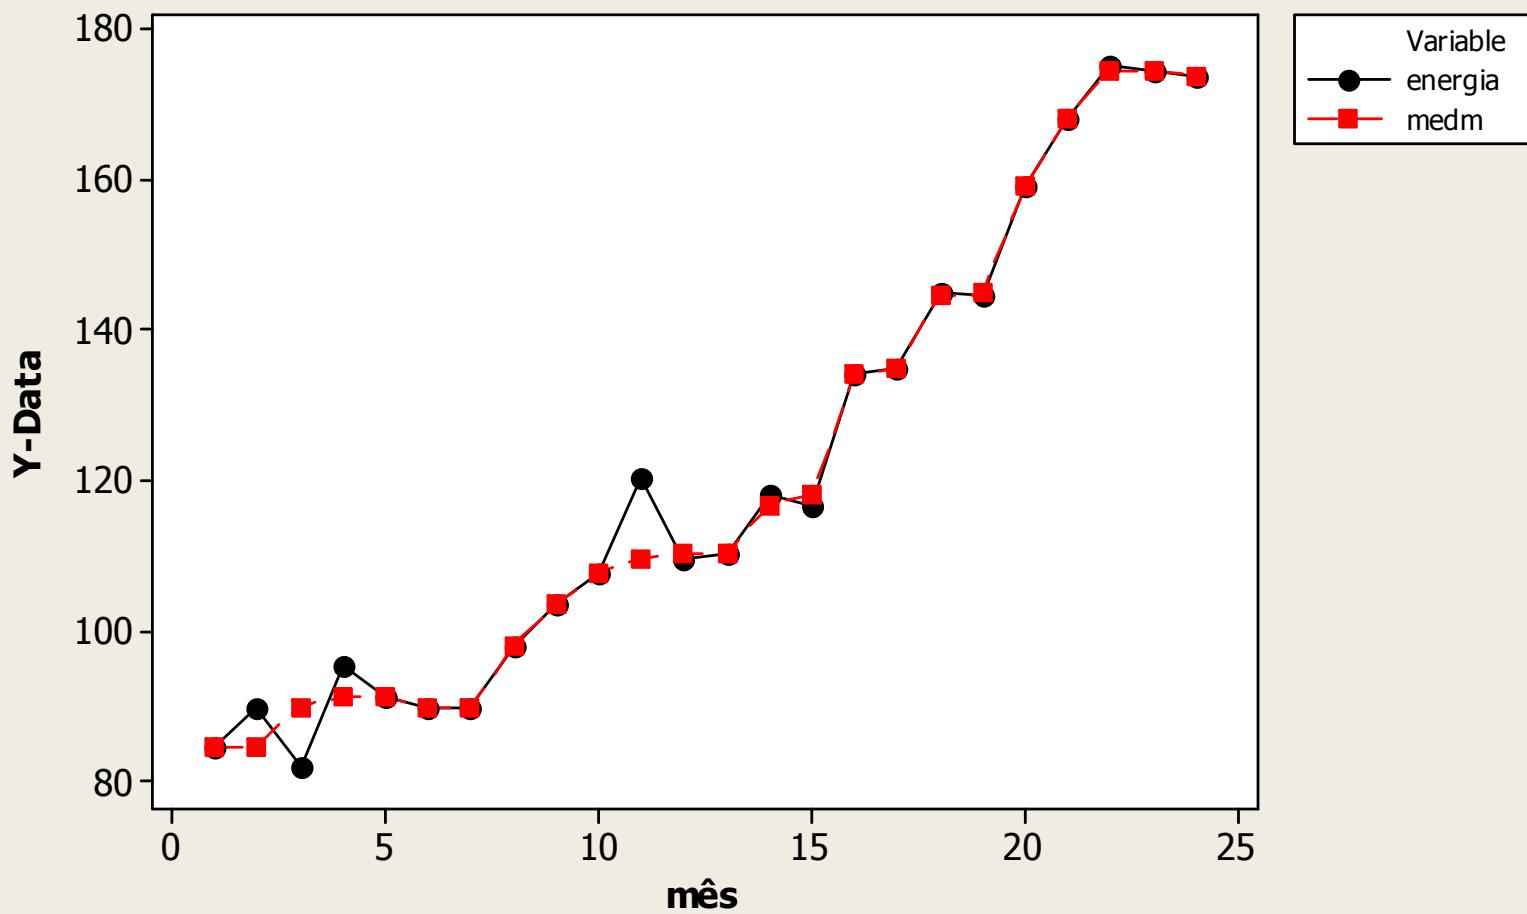
# Suavização: Medianas Móveis

$$\tilde{y}_t = mediana(y_{t-m}, y_{t-m+1}, \dots, y_{t+m})$$

Técnica:  $(x_t, y_t)$  é substituído por  $(x_t, \tilde{y}_t)$

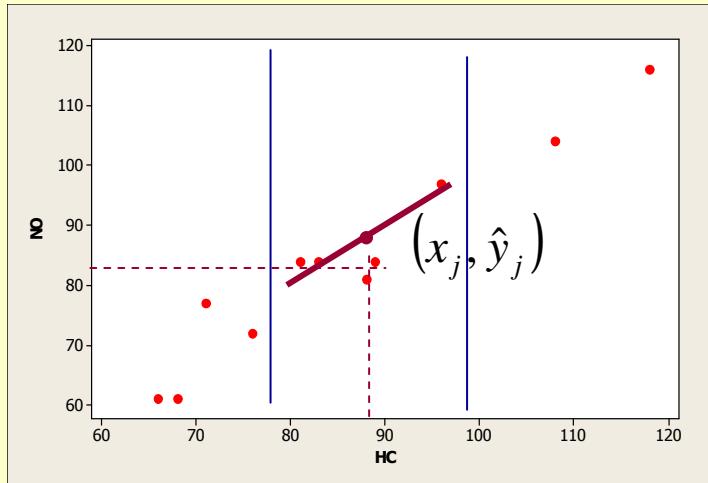
VANTAGEM: MEDIANA É UMA MEDIDA RESISTENTE A VALORES DISCREPANTES

### Scatterplot of energia; medm vs mês



# Suavização - Lowess

**Lowess: Locally weighted regression scatter plot smoothing**



Para obter  $(x_j, \hat{y}_j)$  :

- Abrir uma faixa vertical centrada em  $(x_j, y_j)$ , contendo  $q=[fn]$  pontos ( $0 < f < 1$ ). Quando maior o valor de  $f$ , mais suave será o ajustamento. S-Plus

$$1/3 \leq f \leq 2/3$$

- Definir pesos para os pontos vizinhos de  $(x_j, y_j)$

$$h(u) = \begin{cases} (1 - |u|^3)^3 & \text{se } |u| < 1 \\ 0 & \text{cc} \end{cases}$$

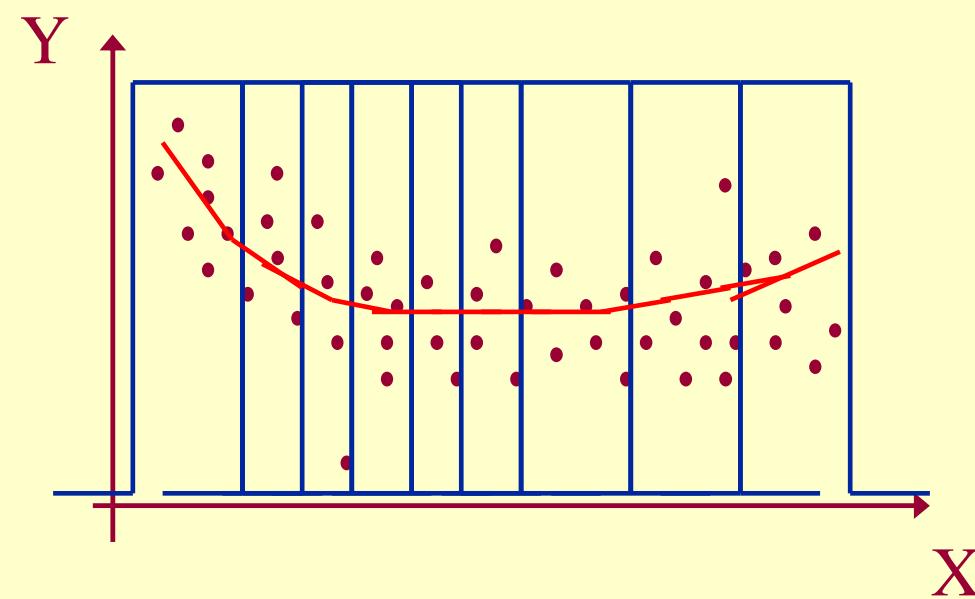
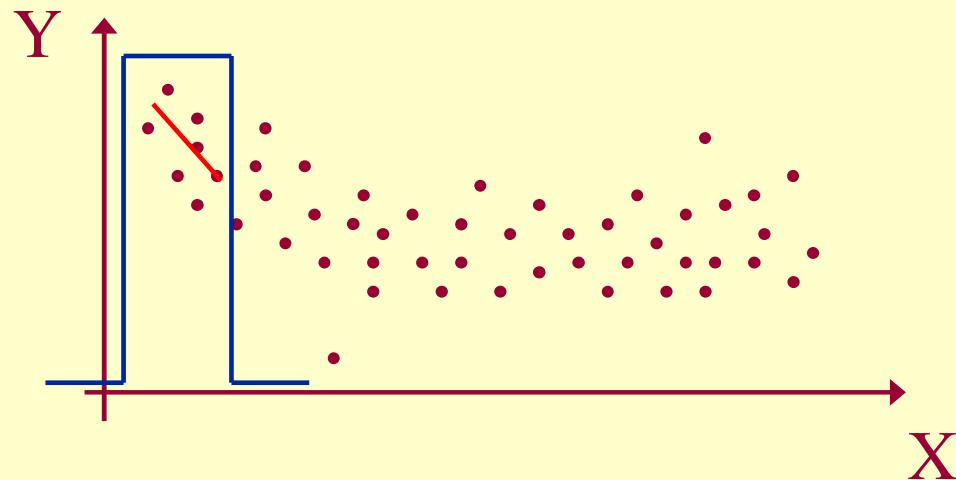
$$\Rightarrow \text{o peso atribuído a } (x_k, y_k) \text{ é } h(x_k) = h\left(\frac{x_j - x_k}{d_j}\right)$$

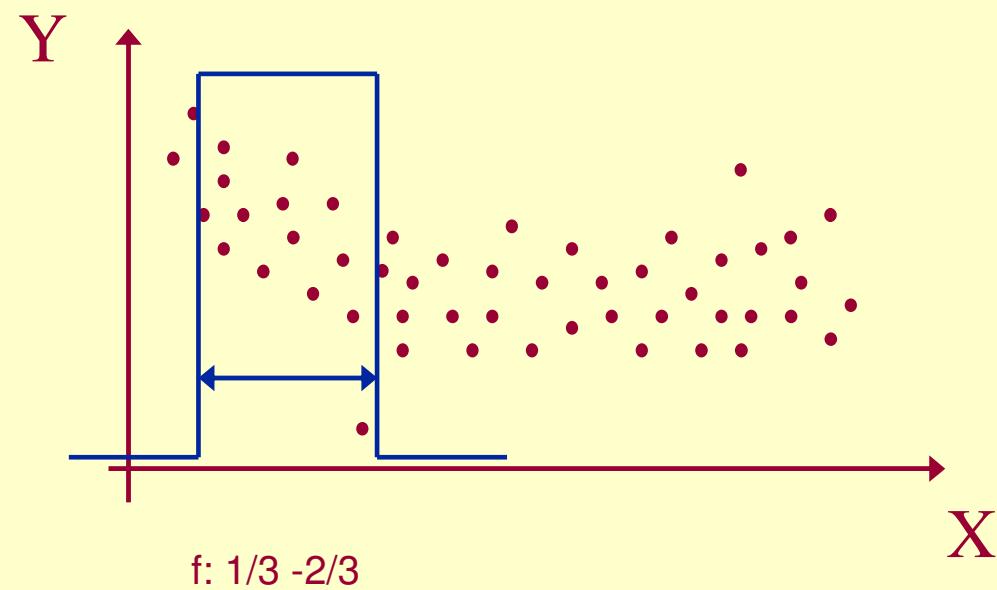
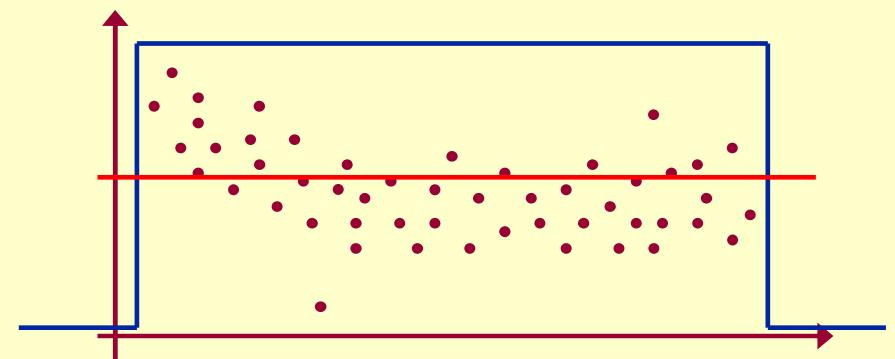
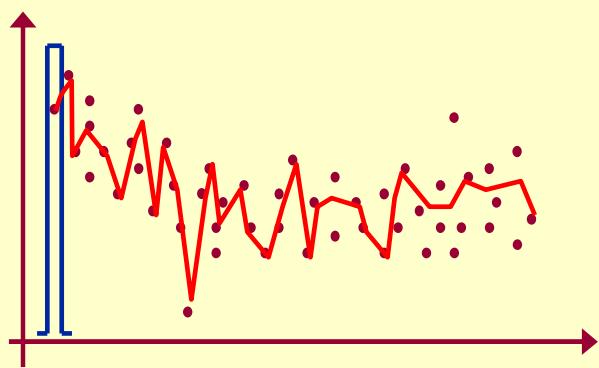
- Ajustamos uma reta aos  $q$  pontos (M.Q.P.)

distância ao vizinho  
mais afastado

$$\hat{y}_j = \hat{\alpha} + \hat{\beta} x_j; \quad \sum_{k=1}^n h(x_k) (y_k - \alpha - \beta x_k)^2$$

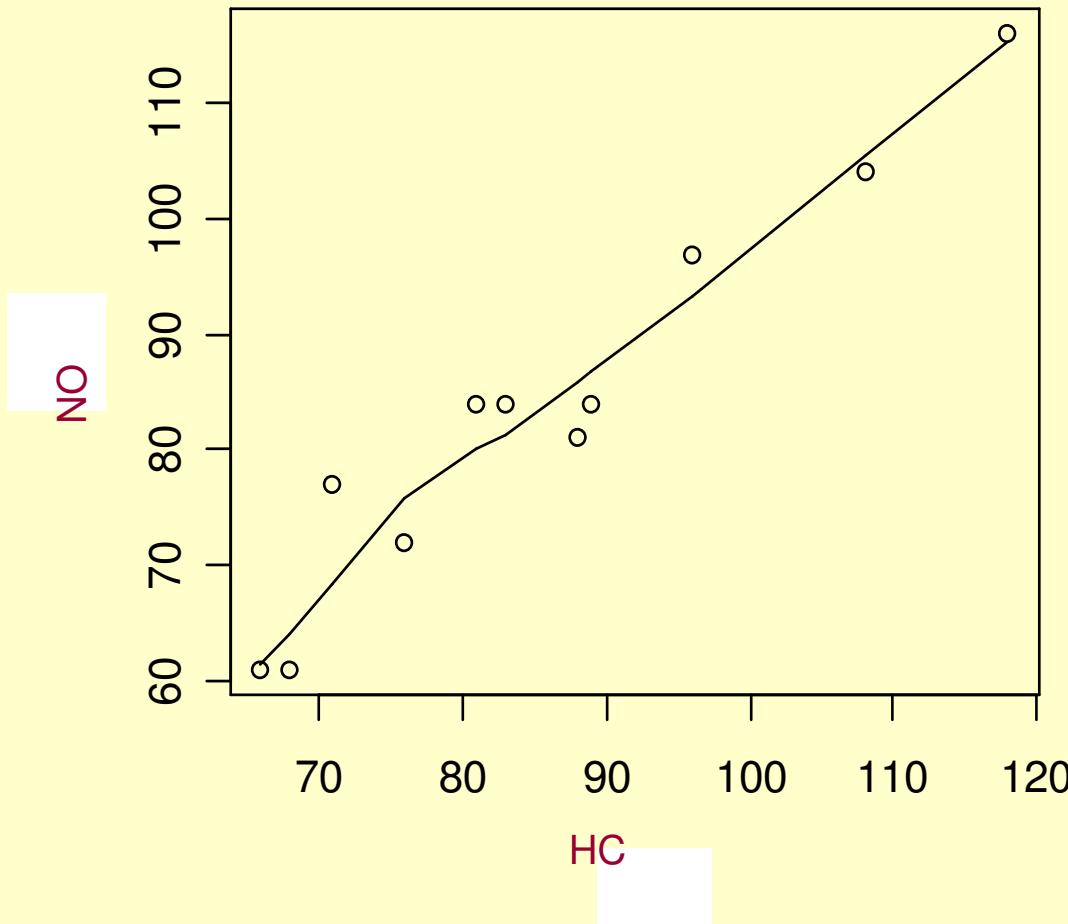
↑ resíduo: ↓ peso





# Suavização - Lowess

Dados de Poluente



> plot (x,y)

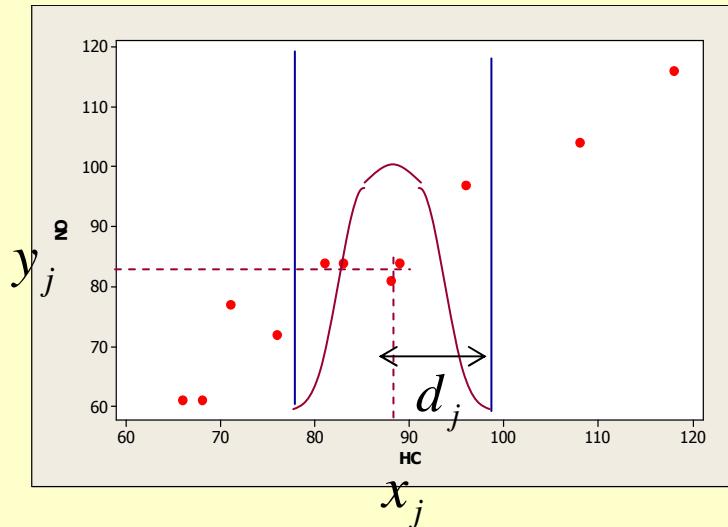
> lines(lowess(x,y,f=2/3))

# Suavização – Lowess Robusto

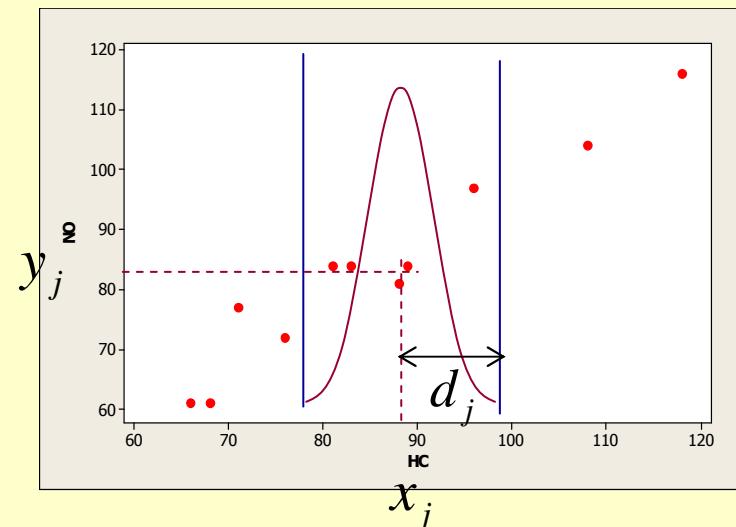
**Na presença de valores atípicos  $\Rightarrow$  Lowess Robusto (Iterativo)**

Atribuição de pesos robustos às observações  $(x_j, y_j)$

$h(u)$ : Tri-cúbica



$g(u)$ : Bi-quadrática



- Lowess (h)  $\Rightarrow$  Lowess robusto: pesos robustos (g)

$$\hat{\varepsilon}_j = y_j - \hat{y}_j \quad M\text{d} : \text{mediana dos valores} |\hat{\varepsilon}_j|$$

$$g(u) = \begin{cases} (1 - |u|^2)^2 & \text{se } |u| < 1 \\ 0 & \text{cc} \end{cases} \quad \Rightarrow \text{o peso atribuído a } (x_k, y_k) \text{ é } g(x_k) = g\left(\frac{\hat{\varepsilon}_k}{6M\text{d}}\right)$$

$$\hat{y}_j = \hat{\alpha} + \hat{\beta} x_j; \quad \sum_{k=1}^n g(x_k) (y_k - \alpha - \beta x_k)^2$$

## Procedimentos:

1. Calculamos os resíduos:  $\hat{\varepsilon}_j = y_j - \hat{y}_j$

Um gráfico de dispersão  $\hat{\varepsilon}_j \times x_j$  mostrará os valores discrepantes.

2. Definimos novos pesos  $g(x_k)$ . Assim,

a) Se  $\hat{\varepsilon}_j \ll 6m \Rightarrow g(x_j) \approx 1$

b) Se  $\hat{\varepsilon}_j \approx 6m \Rightarrow g(x_j) \cong 0$

Para dados normais  $6m \approx 4\sigma \rightarrow$  raramente teremos pesos pequenos.

3. Ajustamos uma nova reta aos  $q$  pontos, atribuindo a  $(x_k, y_k)$  o peso  $h_j(x_k)g(x_k)$ . Assim, se  $(x_k, y_k)$  for discrepante, o resíduo será grande e o peso final será pequeno. O procedimento deve ser repetido duas ou mais vezes.

# Uma v.a. qualitativa e outra quantitativa

Exemplo: sexo e salário

Técnica:

histograma, boxplot, ramo-e-folha, da variável salário para cada sexo e verificar como esta varia segundo os dois atributos: masculino e feminino.