

# CCI-22

Prof. Celso HIRATA

Sala 116 Tel. 347 5987

E mail : [hirata@comp.ita.br](mailto:hirata@comp.ita.br)

Instituto Tecnológico de Aeronáutica  
Departamento de Computação Científica  
Divisão de Ciência da Computação

30 de novembro de 2007

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Roteiro

## 1 Ajuste de funções


- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Introdução

A interpolação não é recomendada quando:

- É preciso obter um valor aproximado da função em algum ponto fora do intervalo de tabelamento, ou seja quando se quer extrapolar.
- Os valores tabelados são resultados de algum experimento físico ou de alguma pesquisa, porque, nestes casos, estes valores poderão conter erros inerentes que, em geral, não são previsíveis.

# Interpolação



# Roteiro

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Critérios para Medida de Qualidade do Ajuste

Seja  $R_i = f^*(x_i) - y_i$

Todos os erros devem tender a zero ou seja  $\forall i [R_i \rightarrow 0]$ .


$$f(x_i) = y_i = f^*(x_i), \text{ i.e. } R_i = 0, i = 1, \dots, n \quad (1)$$

Recai em interpolação.

# Soma do Erro

A soma dos erros devem ser tão pequena quanto possível, ou seja,  $\sum R_i$  deve ser minimizada.

Problema: soma nula de erros.





# Soma do Valor Absoluta do Erro

A soma dos erros em valor absoluto deve ser a menor possível, ou seja,

$$\sum_{i=1}^m |f(x_i) - y_i| \quad (2)$$

deve ser mínima.

Problema: esta soma não é nula, porém a função módulo não é diferenciável em seu ponto de mínimo. Com isso, temos dificuldades em achar o mínimo de tal soma.

# Tschebycheff

$$\max_{1 \leq i \leq n} |f^*(x_i) - y_i| \quad (3)$$

deve ser mínimo. Problema: a solução é muito difícil e não recomendada para cálculos manuais.

# Método dos Mínimos Quadrados

$$\sum_{i=1}^n R_i^2 \quad (4)$$

é minimizado.

Neste caso nunca teremos uma soma nula e a função quadrado é facilmente diferenciável. É o mais usado.

# Roteiro

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Método dos Mínimos Quadrados

Obter  $f^*(x)$  onde:

$$f^*(x) = c_1\phi_1(x) + c_2\phi_2(x) + \dots + c_n\phi_n(x) \quad (5)$$

$c_k$  desconhecidas,  $k = 1, \dots, n$  e  $\phi_1, \phi_2, \dots, \phi_n$  funções escolhidas de acordo com o Diagrama de Dispersão (dados experimentais).

Problema: determinar  $c_k$ 's de modo que a soma dos quadrados dos resíduos seja mínima. O resíduo é dado por:

$$R_i = f^*(x_i) - y_i \quad i=1, \dots, m \quad (6)$$

$m$  pontos tabelados ( $\geq n$  coeficientes)

Seja  $R$  a soma dos quadrados dos resíduos.

$$R = \sum_{i=1}^m R_i^2 = \sum_{i=1}^m (f^*(x_i) - y_i)^2 \quad (7)$$

Queremos:

$$\frac{\partial R}{\partial c_k} = 2 \sum_i [f^*(x_i) - y_i] \frac{\partial f^*(x_i)}{\partial c_k} = 0 \quad k=1, \dots, n \quad (8)$$

Como  $\frac{\partial f^*(x_i)}{\partial c_k} = \phi_k(x_i)$ ,  $k=1, \dots, n$ , então:

$$\sum_i [c_1 \phi_1(x_i) + c_2 \phi_2(x_i) + \dots + c_n \phi_n(x_i) - y_i] \phi_k(x_i) = 0 \quad (9)$$

Como  $k = 1, \dots, n$ , temos um sistema de equações algébricas:

$$k = 1 \rightarrow \sum_i [c_1 \phi_1(x_i) + c_2 \phi_2(x_i) + \dots + c_n \phi_n(x_i) - y_i] \phi_1(x_i) = 0$$

$$k = 2 \rightarrow \sum_i [c_1 \phi_1(x_i) + c_2 \phi_2(x_i) + \dots + c_n \phi_n(x_i) - y_i] \phi_2(x_i) = 0$$

$$\vdots$$

$$k = n \rightarrow \sum_i [c_1 \phi_1(x_i) + c_2 \phi_2(x_i) + \dots + c_n \phi_n(x_i) - y_i] \phi_n(x_i) = 0$$

Reescrevendo:

$$\begin{aligned}
 \left[ \sum_i \phi_1(x_i) \phi_1(x_i) \right] c_1 + \left[ \sum_i \phi_2(x_i) \phi_1(x_i) \right] c_2 + \dots + \left[ \sum_i \phi_n(x_i) \phi_1(x_i) \right] c_n &= \sum_i y_i \phi_1(x_i) \\
 \left[ \sum_i \phi_2(x_i) \phi_1(x_i) \right] c_1 + \left[ \sum_i \phi_2(x_i) \phi_2(x_i) \right] c_2 + \dots + \left[ \sum_i \phi_n(x_i) \phi_2(x_i) \right] c_n &= \sum_i y_i \phi_2(x_i) \\
 &\vdots \\
 \left[ \sum_i \phi_n(x_i) \phi_1(x_i) \right] c_1 + \left[ \sum_i \phi_n(x_i) \phi_1(x_i) \right] c_2 + \dots + \left[ \sum_i \phi_n(x_i) \phi_n(x_i) \right] c_n &= \sum_i y_i \phi_n(x_i)
 \end{aligned}$$

$n$  equações,  $n$  incógnitas  $\rightarrow$  Sistema de Equações (Normais)



Se  $\phi_1(x), \dots, \phi_n(x)$  forem linearmente independentes o determinante do sistema é diferente de zero e portanto o sistema tem solução única.

Demonstra-se também que  $R$  atinge seu valor mínimo nessa solução.


Veremos os casos mais comuns de ajuste: Ajuste polinomial

# Roteiro

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Ajuste a uma regra: Regressão Linear



Seja  $(x_i, y_i)$ ,  $i = 1, \dots, m$  onde  $y_i = f(x_i)$

Seja  $f^*(x) = a_0 + a_1x$  a reta que melhor se ajusta aos dados

Originalmente  $f^* = c_1\phi_1(x) + c_2\phi_2(x) + \dots + c_n\phi_n(x) = a_0 + a_1x$ .

Ou seja,  $c_1\phi_1(x) = a_0$  e  $c_2\phi_2(x) = a_1x$ .

Dessa forma  $c_1 = a_0$ ,  $\phi_1(x) = 1$ ,  $c_2 = a_1$  e  $\phi_2(x) = x$ .

Queremos achar  $c_1$  e  $c_2$ .

Sejam  $R_i = y_i - (a_0 + a_1 x_i)$  ou  $R_i = f_i - (a_0 + a_1 x_i)$  onde  $f_i = f(x_i)$ .

Pelo critério dos mínimos quadrados, para que tenhamos  $\sum R_i^2$  mínimo, é necessário que:

$$\frac{\partial R}{\partial a_0} = 0 \quad \text{e} \quad \frac{\partial R}{\partial a_1} = 0 \quad (10)$$

onde  $R = [f_1 - (a_0 + a_1 x_1)]^2 + [f_2 - (a_0 + a_1 x_2)]^2 + \dots + [f_m - (a_0 + a_1 x_m)]^2$

Teremos:

$$\begin{aligned}a_0 &= \frac{\sum_i x_i^2 \sum_i f_i - \sum_i x_i \sum_i x_i f_i}{m \sum_i x_i^2 - (\sum_i x_i)^2} \\a_1 &= \frac{m \sum_i x_i f_i - \sum_i x_i \cdot \sum_i f_i}{m \sum_i x_i^2 - (\sum_i x_i)^2} \\a_1 &= \frac{\sum_i x_i f_i - (\sum_i x_i \cdot \sum_i f_i)/m}{\sum_i x_i^2 - (\sum_i x_i)^2/m} \\a_0 &= f^* - a_1 f^*\end{aligned}$$

$$\text{onde } y^* = \frac{\sum_i f_i}{m} \text{ e } x^* = \frac{\sum_i x_i}{m}$$

Exemplo:

x	0.5	1	2	3	4
y	2500	2400	2000	1800	1500

$$x = 5, y = ?$$

$$x = 6, y = ?$$

$$\sum x_i = 10.5, \sum y_i = 10200 \text{ e } \sum x_i y_i = 19050$$

$$\sum x_i^2 = 30.25, (\sum x_i)^2 = 110.25$$

$$a_0 = 2646.95112 \text{ e } a_1 = -289.024390$$

$$y = 2646.95 - 289.02x$$

$$x = 5, y = 1202$$

$$x = 6, y = 913$$

# Roteiro

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial



# Ajuste usando polinômios

Polinômio de grau 2:  $f(x) = a_0 + a_1x + a_2x^2$

$$\begin{vmatrix} m & \sum_i x_i & \sum_i x_i^2 \\ \sum_i x_i & \sum_i x_i^2 & \sum_i x_i^3 \\ \sum_i x_i^2 & \sum_i x_i^3 & \sum_i x_i^4 \end{vmatrix} \begin{vmatrix} a_0 \\ a_1 \\ a_2 \end{vmatrix} = \begin{vmatrix} \sum_i y_i \\ \sum_i x_i y_i \\ \sum_i x_i^2 y_i \end{vmatrix}$$

Polinômio de grau  $n$ :  $f^*(x) = a_0 + a_1x + \dots + a_nx^n$

# Ajuste usando polinômios

Polinômio de grau  $n$ :  $f^*(x) = a_0 + a_1x + \dots + a_nx^n$

$$\begin{vmatrix} m & \sum_i x_i & \sum_i x_i^2 & \dots & \sum_i x_i^n \\ \sum_i x_i & \sum_i x_i^2 & \sum_i x_i^3 & \dots & \sum_i x_i^{n+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum_i x_i^n & \sum_i x_i^{n+1} & \sum_i x_i^{n+2} & \dots & \sum_i x_i^{2n} \end{vmatrix} \begin{vmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{vmatrix} = \begin{vmatrix} \sum_i y_i \\ \sum_i x_i y_i \\ \vdots \\ \sum_i x_i^{n-1} y_i \end{vmatrix}$$

# Ajuste usando polinômio - Exemplo

$t$	13.9	43.0	67.8	89.0	99.2
-----	------	------	------	------	------

---

$v$	1.04	1.12	1.19	1.24	1.27
-----	------	------	------	------	------

Seja  $v(t) = 1 + bt + ct^2$

$y(t) = v(t) - 1 = bt + ct^2$

$$\begin{bmatrix} \sum_i t_i^2 & \sum_i t_i^3 \\ \sum_i t_i^3 & \sum_i t_i^4 \end{bmatrix} \begin{bmatrix} b \\ c \end{bmatrix} = \begin{bmatrix} \sum_i t_i y_i \\ \sum_i t_i^2 y_i \end{bmatrix}$$

# Ajuste usando polinômio - Exemplo

$$\sum_i t_i = 312.9$$

$$\sum_i t_i y_i = 66.142$$

$$\sum_i t_i^2 = 24400.69$$

$$\sum_i t_i^2 y_i = 5661.0202$$

$$\sum_i t_i^3 = 2.0750189E6$$

$$\sum_i t_i^4 = 1.841675E8$$

resolvendo,

$$b = 0.003068189$$

$$c = 1.548545E - 7 \quad v(t) = 1 + bt + ct^2$$

# Ajuste usando polinômio - Exemplo

Verificação:

t	v(dado)	v(ajustado)	t	v(ajustado)
13.9	1.04	1.04	20	1.06
43.0	1.12	1.13	25	1.08
67.8	1.19	1.21	30	1.09
89.0	1.24	1.27	35	1.11
99.2	1.27	1.31	40	1.12

# Roteiro

## 1 Ajuste de funções

- Introdução
- Critérios para Medida de Qualidade do Ajuste
- Método dos Mínimos Quadrados
- Ajuste a uma reta: Regressão Linear
- Ajuste usando polinômios
- Ajuste: Caso não-linear
  - Ajuste Usando a Curva Potencial
  - Ajuste Usando a Curva Exponencial

# Caso não-linear

- Exponencial:  $y(x) = \alpha_1 e^{-\alpha_2 x}$ ,  $\alpha_1$  e  $\alpha_2$  coeficientes positivos.
- Para usar o método dos mínimos quadrados deve-se fazer linearização.


$$y(x) = \alpha_1 e^{-\alpha_2 x}$$

$$z = \ln(y) = \ln(\alpha_1) - \alpha_2 x$$

- Se  $a_1 = \ln(\alpha_1)$  e  $a_2 = -\alpha_2$ ,  $z = \ln(y) = a_1 + a_2 x$  é um problema linear nos parâmetros  $a_1$  e  $a_2$ , o método dos mínimos quadrados pode então ser aplicado na resolução do problema. Obtidos os parâmetros deste problema, usaremos estes valores para calcular os parâmetros originais.

# Exemplo

x	-1.0	-0.7	-0.4	-0.1	0.2	0.5	0.8	1.0
f(x)	36.547	17.264	8.155	3.852	1.820	0.860	0.406	0.246





# Exemplo

Isso nos sugere um ajuste:  $y(x) = \alpha_1 e^{-\alpha_2 x}$

Conforme vimos, a linearização a ser feita é:

$$z = \ln(y) = \ln(\alpha_1 e^{-\alpha_2 x}) = \ln(\alpha_1) - \alpha_2 x$$

Assim, em vez de ajustar  $y$ , ajustaremos  $z = \ln(y)$ , encontrando

$$z(x) = a_0 + a_1 x \text{ onde } a_0 = \ln(\alpha_1) \text{ e } a_1 = -\alpha_2$$

Temos pois:

x	-1.0	-0.7	-0.4	-0.1	0.2	0.5	0.8	1.0
z	3.599	2.849	2.099	1.349	0.599	-0.151	-0.901	-1.402

# Exemplo

$$\begin{vmatrix} m & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{vmatrix} \begin{vmatrix} a_0 \\ a_1 \end{vmatrix} = \begin{vmatrix} \sum_i z_i \\ \sum_i z_i x_i \end{vmatrix}$$

$$m = 8 \quad \sum_i x_i = 0.3 \quad \sum_i x_i^2 = 3.59 \quad \sum_i z_i = 8.041 \quad \sum_i z_i x_i = -8.646$$

$$\begin{vmatrix} 8 & 0.3 \\ 0.3 & 3.59 \end{vmatrix} \begin{vmatrix} a_0 \\ a_1 \end{vmatrix} = \begin{vmatrix} 8.041 \\ -8.646 \end{vmatrix}$$

# Exemplo

Assim:  $a_0 = 1.099$  e  $a_1 = -2.5$

$$\alpha_1 = e^{a_0} \rightarrow \alpha_1 = e^{1.099} = 3.001$$

$$\alpha_2 = -a_1 \rightarrow \alpha_2 = 2.5$$

E a função  $y(x) = \alpha_1 e^{\alpha_2 x}$  fica:

$$y(x) = 3.001e^{-2.5x}$$

# Ajuste Usando a Curva Potencial

$$y = \alpha_1 x^{\alpha_2}$$

$$z = \ln(y) = \ln(\alpha_1 x^{-\alpha_2}) = \ln(\alpha_1) - \alpha_2 \ln(x)$$

$$z = \ln(y) = a_0 + a_1 t$$

# Ajuste Usando a Curva Exponencial

$$y = \alpha_1 \alpha_2^x$$

$$\ln(y) = \ln \alpha_1 + x \ln(\alpha_2) = a_0 + a_1 x$$

# Teste de Alinhamento

Uma vez escolhida uma função não linear em  $\alpha_1, \alpha_2, \dots, \alpha_n$  para ajuste, uma forma de verificarmos se a função não linear escolhida é adequada ou não, usa-se o teste de alinhamento:

- 1 Fazer a ‘linearização’ da função linear escolhida;
- 2 Fazer o diagrama de dispersão dos novos dados;
- 3 Se os pontos do diagrama estiverem alinhados, isto significará que a função não linear escolhida foi uma boa escolha.