

CCI-22



## Matemática Computacional

Carlos Alberto Alonso Sanches

CCI-22

## 6) Ajuste de Curvas

Método dos Mínimos Quadrados, Regressão Linear

CCI-22

- Introdução
- Método dos Mínimos Quadrados
- Regressão linear
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

CCI-22

- **Introdução**
- Método dos Mínimos Quadrados
- Regressão linear
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

## Definição

- Situações em que a interpolação não é aconselhável:
  - Quando se deseja obter um valor aproximado da função em algum ponto fora do intervalo de tabelamento, ou seja, quando se quer extrapolar
  - Quando os valores tabelados são resultados de algum experimento físico ou de alguma pesquisa, e por isso podem conter erros inerentes e não previsíveis
- Nesses casos, convém ajustar a função tabelada a uma função  $f^*$  que seja uma "boa aproximação" para os valores obtidos, e que permita a extrapolação

## Possíveis critérios de qualidade

- Dados  $m$  pontos experimentais  $\{(x_1, y_1), \dots, (x_m, y_m)\}$ , uma questão importante é estabelecer uma medida de qualidade para a função de ajuste
- Sejam  $R_i = f^*(x_i) - y_i$ ,  $1 \leq i \leq m$ , os resíduos ou erros desse ajuste. Possibilidades:
  - Fazer com que os resíduos tendam a zero
    - Equivaleria à interpolação...
  - Minimizar a soma dos resíduos
    - Não é um bom critério: pode haver soma nula, mas com valores grandes
  - Minimizar a soma dos módulos dos resíduos
    - É difícil encontrar seu mínimo, pois não é uma função diferenciável...
  - Critério de Tschebycheff: minimizar  $\max \{|R_i|\}$ 
    - Solução difícil e não recomendada para cálculos manuais
  - Critério dos mínimos quadrados: minimizar  $\sum R_i^2$ 
    - É o mais largamente utilizado

## CCI-22

- Introdução
- **Método dos Mínimos Quadrados**
- Regressão linear
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

## Método dos Mínimos Quadrados

- A técnica dos Mínimos Quadrados consiste no cálculo de  $n$  constantes  $c_i$  de uma função  $f^*$  que aproxima  $f$ :
  - $f^*(x) = c_1\Phi_1(x) + c_2\Phi_2(x) + \dots + c_n\Phi_n(x)$
- As funções  $\Phi_i(x)$ , que podem ser não lineares em  $x$ , são escolhidas de acordo com a natureza dos dados experimentais
- Lembrando que  $R_i = f^*(x_i) - y_i$ ,  $1 \leq i \leq m$ , seja  $R = \sum R_i^2 = \sum (c_1\Phi_1(x_i) + c_2\Phi_2(x_i) + \dots + c_n\Phi_n(x_i) - y_i)^2$
- $R$  é uma função dos  $c_j$ ,  $1 \leq j \leq n$ , e passará por um mínimo quando suas  $n$  derivadas parciais se anularem simultaneamente:
  - $\partial R / \partial c_j = 2 \sum [f^*(x_i) - y_i] \cdot \partial f^*(x_i) / \partial c_j = 0$ ,  $1 \leq j \leq n$
- Como  $\partial f^*(x_i) / \partial c_j = \Phi_j(x_i)$ , esse mínimo satisfaz:
  - $\sum (c_1\Phi_1(x_i) + c_2\Phi_2(x_i) + \dots + c_n\Phi_n(x_i) - y_i) \cdot \Phi_j(x_i) = 0$ ,  $1 \leq j \leq n$

## Equações normais

- Condições para que  $R = \sum_i R_i^2$  seja mínimo:  
 $\sum_i (c_1 \Phi_1(x_i) + c_2 \Phi_2(x_i) + \dots + c_n \Phi_n(x_i) - y_i) \cdot \Phi_j(x_i) = 0, 1 \leq j \leq n$
- Temos então um sistema  $Ac = y$  de  $n$  equações algébricas lineares, comumente chamadas de *equações normais*, que pode ser resolvido com técnicas já apresentadas:

$$A = \begin{bmatrix} \sum_i \Phi_1(x_i) \Phi_1(x_i) & \sum_i \Phi_2(x_i) \Phi_1(x_i) & \dots & \sum_i \Phi_n(x_i) \Phi_1(x_i) \\ \sum_i \Phi_2(x_i) \Phi_1(x_i) & \sum_i \Phi_2(x_i) \Phi_2(x_i) & \dots & \sum_i \Phi_n(x_i) \Phi_2(x_i) \\ \vdots & \vdots & \ddots & \vdots \\ \sum_i \Phi_n(x_i) \Phi_1(x_i) & \sum_i \Phi_n(x_i) \Phi_2(x_i) & \dots & \sum_i \Phi_n(x_i) \Phi_n(x_i) \end{bmatrix} \quad c = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_n \end{bmatrix} \quad y = \begin{bmatrix} \sum_i y_i \Phi_1(x_i) \\ \sum_i y_i \Phi_2(x_i) \\ \vdots \\ \sum_i y_i \Phi_n(x_i) \end{bmatrix}$$

- Se  $\Phi_1(x), \Phi_2(x), \dots, \Phi_n(x)$  forem linearmente independentes,  $\det(A) \neq 0$ , e o sistema terá solução única. Demonstra-se que, nesse caso,  $R$  atinge seu valor mínimo

## CCI-22

- Introdução
- Método dos Mínimos Quadrados
- Regressão linear**
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

## Regressão linear

- O caso particular em que a curva  $f$  é ajustada a uma reta chama-se *regressão linear*:  $f^*(x) = a_0 + a_1 x$
- Originariamente,  $f^*(x) = c_1 \Phi_1(x) + c_2 \Phi_2(x) + \dots + c_n \Phi_n(x)$ . Sem perda de generalidade, podemos dizer que  $c_1 \Phi_1(x) = a_0$  e  $c_2 \Phi_2(x) = a_1 x$
- Dessa forma,  $c_1 = a_0$ ,  $\Phi_1(x) = 1$ ,  $c_2 = a_1$  e  $\Phi_2(x) = x$
- Sabemos que  $R_i = f^*(x_i) - y_i = a_0 + a_1 x_i - y_i, 1 \leq i \leq m$
- Para que  $R = \sum_i R_i^2$  seja mínimo, é necessário que  $\partial R / \partial a_0 = 0$  e  $\partial R / \partial a_1 = 0$ :
  - $R = (a_0 + a_1 x_1 - y_1)^2 + (a_0 + a_1 x_2 - y_2)^2 + \dots + (a_0 + a_1 x_m - y_m)^2$
  - $\partial R / \partial a_0 = 2(a_0 + a_1 x_1 - y_1) + 2(a_0 + a_1 x_2 - y_2) + \dots + 2(a_0 + a_1 x_m - y_m)$
  - $\partial R / \partial a_1 = 2x_1(a_0 + a_1 x_1 - y_1) + 2x_2(a_0 + a_1 x_2 - y_2) + \dots + 2x_m(a_0 + a_1 x_m - y_m)$
  - $\partial R / \partial a_0 = 0 \Rightarrow m a_0 + (x_1 + \dots + x_m) a_1 = y_1 + \dots + y_m \Rightarrow m a_0 + \sum_i x_i a_1 = \sum_i y_i$
  - $\partial R / \partial a_1 = 0 \Rightarrow (x_1 + \dots + x_m) a_0 + (x_1^2 + \dots + x_m^2) a_1 = x_1 y_1 + \dots + x_m y_m \Rightarrow \sum_i x_i a_0 + \sum_i x_i^2 a_1 = \sum_i x_i y_i$
- Temos então um sistema linear com duas incógnitas ( $a_0$  e  $a_1$ ) e duas equações

## Regressão linear

$$m a_0 + \sum_i x_i a_1 = \sum_i y_i \\ \sum_i x_i a_0 + \sum_i x_i^2 a_1 = \sum_i x_i y_i$$

- Pela regra de Cramer:

$$a_0 = \frac{\sum_i x_i^2 \cdot \sum_i y_i - \sum_i x_i \cdot \sum_i x_i y_i}{m \sum_i x_i^2 - (\sum_i x_i)^2} \quad a_1 = \frac{m \sum_i x_i y_i - \sum_i x_i \cdot \sum_i y_i}{m \sum_i x_i^2 - (\sum_i x_i)^2}$$

- Desde que o denominador não seja nulo, esta solução é sempre definida
- Demonstra-se que  $m \sum_i x_i^2 - (\sum_i x_i)^2 = (\sum_i \sum_k (x_i - x_k)^2) / 2$
- Portanto, se os pontos  $x_i$  são distintos,  $a_0$  e  $a_1$  são únicos
- As expressões de  $a_0$  e  $a_1$  podem ser reescritas:

$$a_1 = \frac{\sum_i x_i y_i - (\sum_i x_i \cdot \sum_i y_i) / m}{\sum_i x_i^2 - (\sum_i x_i)^2 / m} \quad a_0 = y^* - a_1 x^* \\ y^* = \sum_i y_i / m \quad x^* = \sum_i x_i / m$$


## Exemplo

- A tabela abaixo mostra o desempenho de um torno de parafusos em função do seu tempo de uso. Fazer a projeção para 5 e 6 anos:

x (anos)	0,5	1	2	3	4
y (parafusos/dia)	2500	2400	2000	1800	1500

- Através de uma análise gráfica, é possível constatar que uma reta é um bom ajuste:

- $\sum x_i = 10,5$ ;  $\sum y_i = 10200$ ;  $\sum x_i y_i = 19050$ ;  
 $\sum x_i^2 = 30,25$ ;  $(\sum x_i)^2 = 110,25$
- $m = 5$
- $a_1 = (\sum x_i y_i - (\sum x_i \sum y_i)/m) / (\sum x_i^2 - (\sum x_i)^2/m)$   
 $= -2370/8,2 = -289,0244$
- $y^* = \sum y_i/m = 2040$
- $x^* = \sum x_i/m = 2,1$
- $a_0 = y^* - a_1 x^* = 2646,9511$
- $y = 2646,9511 - 289,0244x$
- $x = 5 \Rightarrow y = 1202$
- $x = 6 \Rightarrow y = 913$



## Regressão linear múltipla

- É possível estender a regressão linear para o caso de funções lineares de múltiplas variáveis:  $f(x_1, x_2, x_3, \dots, x_n)$
- Veremos um caso como exemplo:
  - $f(x_1, x_2) = a_0 + a_1 x_1 + a_2 x_2$
- Definição da função resíduo:
  - $R = \sum_i R_i^2 = \sum_i (a_0 + a_1 x_{1i} + a_2 x_{2i} - y_i)^2$
- Para que R seja mínimo, é necessário que:
  - $\partial R / \partial a_0 = 2 \sum_i (a_0 + a_1 x_{1i} + a_2 x_{2i} - y_i) = 0$
  - $\partial R / \partial a_1 = 2 \sum_i x_{1i} (a_0 + a_1 x_{1i} + a_2 x_{2i} - y_i) = 0$
  - $\partial R / \partial a_2 = 2 \sum_i x_{2i} (a_0 + a_1 x_{1i} + a_2 x_{2i} - y_i) = 0$

## Regressão linear múltipla

- Temos então um sistema linear com três incógnitas ( $a_0$ ,  $a_1$  e  $a_2$ ) e três equações
- Este sistema pode ser escrito na forma matricial abaixo:

$$\begin{bmatrix} m & \sum x_{1i} & \sum x_{2i} \\ \sum x_{1i} & \sum x_{1i}^2 & \sum x_{1i} x_{2i} \\ \sum x_{2i} & \sum x_{1i} x_{2i} & \sum x_{2i}^2 \end{bmatrix} \cdot \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{1i} y_i \\ \sum x_{2i} y_i \end{bmatrix}$$

- De modo análogo ao já visto, este sistema pode ser resolvido por algum método numérico
- Determina-se assim o plano que ajusta os pontos tridimensionais

## CCI-22

- Introdução
- Método dos Mínimos Quadrados
- Regressão linear
  - Ajuste a um polinômio
  - Ajuste a outras curvas
  - Qualidade do ajuste

## Ajuste a um polinômio

- Se a curva  $f$  for ajustada a um polinômio de grau  $n$ , teremos  $f^*(x) = a_0 + a_1x + \dots + a_nx^n$
- Seguindo o mesmo procedimento anterior, chegaremos ao seguinte sistema linear:

$$\begin{bmatrix} m & \sum x_i & \sum x_i^2 & \sum x_i^3 & \dots & \sum x_i^n \\ \sum x_i & \sum x_i^2 & \sum x_i^3 & \sum x_i^4 & \dots & \sum x_i^{n+1} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum x_i^n & \sum x_i^{n+1} & \sum x_i^{n+2} & \sum x_i^{n+3} & \dots & \sum x_i^{2n} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \\ \vdots \\ \sum x_i^n y_i \end{bmatrix}$$

## Exemplo 1


- Ajuste um polinômio de segundo grau aos dados abaixo:

x	0	1	2	3	4	5
y	2,1	7,7	13,6	27,2	40,9	61,1

- A partir desses dados, construímos o seguinte sistema:

$$\begin{bmatrix} m & \sum x_i & \sum x_i^2 \\ \sum x_i & \sum x_i^2 & \sum x_i^3 \\ \sum x_i^2 & \sum x_i^3 & \sum x_i^4 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \\ \sum x_i^2 y_i \end{bmatrix} \Rightarrow \begin{bmatrix} 6 & 15 & 55 \\ 15 & 55 & 225 \\ 55 & 225 & 979 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} 152,6 \\ 585,6 \\ 2488,8 \end{bmatrix}$$

- $m = 6$
- $\sum x_i = 15$ ;  $\sum y_i = 152,6$ ;  
 $\sum x_i^2 = 55$ ;  $\sum x_i^3 = 225$ ;  
 $\sum x_i^4 = 979$ ;  $\sum x_i y_i = 585,6$ ;  
 $\sum x_i^2 y_i = 2488,8$
- $a_0 = 2,47857$ ;  $a_1 = 2,35929$ ;  
 $a_2 = 1,86071$



## Exemplo 2

- Os dados abaixo correspondem ao volume do álcool anídrico em função da temperatura. Considerando um volume inicial de  $1\text{cm}^3$  a  $0^\circ\text{C}$ , deseje-se uma tabela do volume para temperaturas entre  $20$  e  $40^\circ\text{C}$

t ( $^\circ\text{C}$ )	13,9	43,0	67,8	89,0	99,2
v ( $\text{cm}^3$ )	1,04	1,12	1,19	1,24	1,27

- Ajustaremos  $v(t)$  a um polinômio de grau 2  $\checkmark a_0$
- Considerando o volume inicial, temos  $v^*(t) = 1 + a_1t + a_2t^2$
- Sistema de equações normais para as demais constantes:

$$\begin{bmatrix} \sum t_i^2 & \sum t_i^3 \\ \sum t_i^3 & \sum t_i^4 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum t_i v_i \\ \sum t_i^2 v_i \end{bmatrix} \Rightarrow \begin{bmatrix} 24400,69 & 2,0750189 \cdot 10^6 \\ 2,0750189 \cdot 10^6 & 1,841675 \cdot 10^8 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} 66,142 \\ 5661,0202 \end{bmatrix}$$

$$a_1 = 0,003068189$$

$$a_2 = 1,548545 \cdot 10^{-7}$$

t	13,9	20	25	30	35	40	43,0	67,8	89,0	99,2
v	1,04						1,12	1,19	1,24	1,27
$v^*$	1,04	1,06	1,08	1,09	1,11	1,12	1,13	1,21	1,27	1,31

## CCI-22


- Introdução
- Método dos Mínimos Quadrados
- Regressão linear
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

## Ajuste à curva exponencial

- Também é possível ajustar  $f$  a uma curva exponencial, fazendo-se antes uma troca de variáveis:
  - $f^*(x) = c_1 e^{kx}$ , onde  $c_1$  e  $k$  são constantes
  - $\ln f^*(x) = \ln c_1 + kx$
  - $z^*(x) = c_2 + kx$ , onde  $z^*(x) = \ln f^*(x)$
  - $z^*$  e  $x$  estão relacionadas linearmente: basta resolver a regressão linear
  - Depois de resolvido o sistema correspondente, volta-se ao problema original

## 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



A dispersão dos dados sugere um ajuste à curva exponencial

$$z^*(x) = c_2 + kx, \text{ onde } z^*(x) = \ln f^*(x)$$

x	-1,0	-0,7	-0,4	-0,1	0,2	0,5	0,8	1,0
z(x) = ln f(x)	3,599	2,849	2,099	1,349	0,599	-0,151	-0,901	-1,402



$$\begin{bmatrix} m & \sum x \\ \sum x & \sum x^2 \end{bmatrix} \begin{bmatrix} c_2 \\ k \end{bmatrix} = \begin{bmatrix} \sum z \\ \sum z x \end{bmatrix} \Rightarrow \begin{bmatrix} 8 & 0,3 \\ 0,3 & 3,59 \end{bmatrix} \begin{bmatrix} c_2 \\ k \end{bmatrix} = \begin{bmatrix} 8,041 \\ -8,646 \end{bmatrix}$$

$c_2 = 1,099$        $\ln f^*(x) = 1,099 - 2,5x$   
 $k = -2,5$                $f^*(x) = 3,001e^{-2,5x}$

## Ajuste a outras curvas

- $f^*(x) = ax^b$ 
  - $\ln f^*(x) = \ln a + b \cdot \ln x$
  - Sejam  $z^*(x) = \ln f^*(x)$  e  $t = \ln x$
  - Portanto,  $z^*(x) = \ln a + bt$
  - $z^*$  e  $t$  estão relacionadas linearmente
- $f^*(x) = ab^x$ 
  - $\ln f^*(x) = \ln a + x \cdot \ln b$
  - Seja  $z^*(x) = \ln f^*(x)$
  - Portanto,  $z^*(x) = \ln a + x \cdot \ln b$
  - $z^*$  e  $x$  estão relacionadas linearmente

## CCI-22

- Introdução
- Método dos Mínimos Quadrados
- Regressão linear
- Ajuste a um polinômio
- Ajuste a outras curvas
- Qualidade do ajuste

## Qualidade da regressão linear

- Quanto melhor for a qualidade da regressão linear, menor será o valor do resíduo  $R$ , onde  $R = \sum_i R_i^2 = \sum_i (f^*(x_i) - y_i)^2$
- Vamos definir o *resíduo em relação à média dos pontos experimentais*:  $R_M = \sum_i (y^* - y_i)^2$ , onde  $y^* = \sum_i y_i / m$
- O valor  $R_M - R$  quantifica a redução de erro decorrente da descrição dos dados em termos de uma reta, em vez de um ponto médio
- $(R_M - R)/R_M$  é o valor normalizado dessa redução
- O coeficiente de correlação  $r$  é definido como:

$$r = \frac{R_M - R}{R_M}$$

Critério absoluto, mas válido apenas para regressão linear


- Em um ajuste linear perfeito,  $r = 1$  (pois  $R = 0$ )
- Portanto, quanto mais próximo de 1 for o coeficiente de correlação, melhor será o ajuste da regressão linear

Critério relativo, válido para qualquer ajuste

## Teste de alinhamento

- Há uma maneira simples de averiguar se o ajuste de uma função não linear tem boa qualidade:
  - Nos pontos experimentais  $\{(x_1, y_1), \dots, (x_m, y_m)\}$ , fazer as correspondentes trocas de variáveis, de modo a que passem a obedecer uma relação linear
  - Fazer o diagrama de dispersão desses novos dados
  - Verificar o alinhamento dos pontos
- Exemplo:


$x$	-1,0	-0,7	-0,4	-0,1	0,2	0,5	0,8	1,0
$y = f(x)$	36,547	17,264	8,155	3,852	1,820	0,860	0,406	0,246
$z(x) = \ln f(x)$	3,599	2,849	2,099	1,349	0,599	-0,151	-0,901	-1,402



## Exemplo 1

- Ajuste uma curva à tabela abaixo, que fornece dados da evolução da população brasileira em milhões de habitantes:

$x = \text{ano}$	1872	1890	1900	1920	1940	1950	1960	1970	1980	1991
$y = \text{habitantes}$	9,9	14,3	17,4	30,6	41,2	51,9	70,2	93,1	119,0	146,2



- Suponhamos que a melhor curva seja uma exponencial
- Encontramos como resultado  $y = a \cdot e^{bx}$ , onde  $a = 2,3111 \cdot 10^{-18}$  e  $b = 0,0229$
- Fazendo as correspondentes trocas de variáveis para linearizar a relação, obtemos o coeficiente de correlação  $r = 0,99775$


## Exemplo 2

- Um objeto é suspenso em um túnel de vento e a força é medida em diversos níveis de velocidade:

$x \text{ (m/s)}$	10	20	30	40	50	60	70	80
$y \text{ (N)}$	25	70	380	550	610	1220	830	1450


- Através de regressão por mínimos quadrados, verifica-se qual é o melhor ajuste: com uma reta ou com uma equação de potência

$$y = 19,4702x - 234,2857$$



$$r = 0,9384$$

$$\ln y = -1,2941 + 1,9842 \cdot \ln x$$



$$r = 0,9737 \text{ melhor ajuste}$$

## Exemplo 2 (continuação)

- Um outro modo de verificar a qualidade da escolha é ajustar para uma reta os valores reais de  $y$  em função de seus correspondentes valores estimados (por reta ou por relação exponencial)
- Quando o ajuste for perfeito, será encontrada uma reta com coeficientes  $a_1 = 1$  e  $a_0 = 0$
- Resultados obtidos no caso anterior:

