

## CAP. 7 - Lista de exercícios

1) Determine (a partir da definição de concavidade e convexidade) a concavidade ou convexidade das funções:

(a)  $f(x_1, x_2) = (x_1 - 2)^2 + 3 \cdot (x_2 + 1)^2$  no domínio:  $x_1, x_2 \geq 0$ ;


$$G(x) := \nabla_x f(x) \qquad G(x) \rightarrow \begin{pmatrix} 2 \cdot x_1 - 4 \\ 6 \cdot x_2 + 6 \end{pmatrix}$$

$$H(x) := \text{Jacob}(G(x), x) \qquad H(x) \rightarrow \begin{pmatrix} 2 & 0 \\ 0 & 6 \end{pmatrix}$$


$$\text{eigenvals}(H(x)) \rightarrow \begin{pmatrix} 6 \\ 2 \end{pmatrix} \qquad \implies \text{função convexa!}$$

$$f(y, z) := f1\left(\begin{pmatrix} y \\ z \end{pmatrix}\right)$$

M := CreateMesh(f, 0, 4, 0, 2)



M



M

(b)  $f(x_1, x_2, x_3) = 2 \cdot x_1^2 + x_2^2 - 3 \cdot x_3^2$  no domínio:  $x_1, x_2, x_3 \geq 0$ .

$$G(x) := \nabla_x f(x) \qquad G(x) \rightarrow \begin{pmatrix} 4 \cdot x_1 \\ 2 \cdot x_2 \\ -6 \cdot x_3 \end{pmatrix}$$

$$H(x) := \text{Jacob}(G(x), x) \qquad H(x) \rightarrow \begin{pmatrix} 4 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & -6 \end{pmatrix}$$


$$\text{eigenvals}(H(x)) \rightarrow \begin{pmatrix} 4 \\ 2 \\ -6 \end{pmatrix} \qquad \implies \text{função nem côncava nem convexa!}$$

$$f_0(y, z) := f_2 \left( \begin{pmatrix} y \\ z \\ 0 \end{pmatrix} \right) \quad f_1(y, z) := f_2 \left( \begin{pmatrix} y \\ 0 \\ z \end{pmatrix} \right) \quad f_2(y, z) := f_2 \left( \begin{pmatrix} 0 \\ y \\ z \end{pmatrix} \right)$$


M0 := CreateMesh (f\_0, 0, 1, 0, 2)

M1 := CreateMesh (f\_1, 0, 2, 0, 2)


M2 := CreateMesh (f\_2, 0, 2, 0, 2)



M0



M1



M2

2) Determine a localização e a natureza dos pontos estacionários das funções abaixo, determine também (em cada caso) o máximo e o mínimo globais:

(a)  $f(x) = \frac{2 \cdot x}{1 + x^2}$  para  $x \geq 0$ ;

$$G(x) := \nabla_x f(x)$$



$$G(x) = 0 \implies x_0 := 1$$

$$G(x) \text{ simplify } \rightarrow -\frac{2 \cdot (x^2 - 1)}{(x^2 + 1)^2}$$

$$H(x) := \text{Jacob}(G(x), x) \quad H(x) \text{ simplify} \rightarrow \frac{4 \cdot x(x^2 - 3)}{(x^2 + 1)^3}$$

$$H(x_0) = -1$$

==> máximo global



(b)  $f(x) = \frac{\text{sen}(x)}{x}$  para  $-\pi \leq x \leq \pi$ ;

$$G(x) := \nabla_x f(x) \quad G(x) \text{ collect} \rightarrow -\frac{\sin(x) - x \cdot \cos(x)}{x^2}$$



$$x_0 := \text{root}(G(x), x, -\pi, \pi) \quad x_0 = 0$$

Nota:  $\lim_{x \rightarrow 0} G(x) \rightarrow 0$

$$H(x) := \text{Jacob}(G(x), x) \quad H(x) \text{ simplify} \rightarrow -\frac{x^2 \cdot \sin(x) - 2 \cdot \sin(x) + 2 \cdot x \cdot \cos(x)}{x^3}$$

$$H(x_0) = -0.333$$

==> máximo global



(c)  $f(x) = e^{-x^2} \cdot \sin(x)$  para  $0 \leq x \leq \pi$ ;



$G(x) := \nabla_x f(x)$                        $G(x)$  simplify  $\rightarrow e^{-x^2} \cdot (\cos(x) - 2 \cdot x \sin(x))$

$x_0 := \text{root}(G(x), x, 0, \pi)$                        $x_0 = 0.653$

$H(x) := \text{Jacob}(G(x), x)$                        $H(x)$  factor  $\rightarrow e^{-x^2} \cdot (4 \cdot x^2 \cdot \sin(x) - 3 \cdot \sin(x) - 4 \cdot x \cdot \cos(x))$

$H(x_0) = -1.867$

==> máximo global



(d)  $f(x_1, x_2) = x_1^3 - 3 \cdot x_1 \cdot x_2 + 3 \cdot x_2^2$ ;

$G(x) := \nabla_x f(x)$                        $G(x)$  simplify  $\rightarrow \begin{bmatrix} 3 \cdot (x_0)^2 - 3 \cdot x_1 \\ 6 \cdot x_1 - 3 \cdot x_0 \end{bmatrix}$

$x(x) := 2 \cdot x_1$

$r(x) := 3 \cdot x(x)^2 - 3 \cdot x_1$  factor  $\rightarrow 3 \cdot x_1 \cdot (4 \cdot x_1 - 1) = 0$

$x_{o1} := \begin{pmatrix} 0 \\ 0 \end{pmatrix}$                        $G(x_{o1}) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$                        $x_{o2} := \begin{pmatrix} \frac{1}{2} \\ \frac{1}{4} \end{pmatrix}$                        $G(x_{o2}) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$

$H(x) := \text{Jacob}(G(x), x)$                        $H(x)$  factor  $\rightarrow \begin{pmatrix} 6 \cdot x_0 & -3 \\ -3 & 2 \cdot 3 \end{pmatrix}$

$H(x_{o1}) = \begin{pmatrix} 0 & -3 \\ -3 & 6 \end{pmatrix}$

$H(x_{o2}) = \begin{pmatrix} 3 & -3 \\ -3 & 6 \end{pmatrix}$

$\text{eigenvals}(H(x_{o1})) = \begin{pmatrix} -1.243 \\ 7.243 \end{pmatrix}$


$\text{eigenvals}(H(x_{o2})) = \begin{pmatrix} 1.146 \\ 7.854 \end{pmatrix}$

==> ponto sela


==> mínimo global

$$f(y, z) := \text{fd} \left( \begin{pmatrix} y \\ z \end{pmatrix} \right)$$

M := CreateMesh (f, -1, 2, -1, 2)



M



M

(e)  $f(x_1, x_2) = -x_1^2 - \frac{1}{2} \cdot x_2^2 + x_1 \cdot x_2 + x_1$  para  $x_1, x_2 \geq 0$ .

$$G(x) := \nabla_x f(x)$$

$$G(x) \text{ simplify } \rightarrow \begin{pmatrix} x_1 - 2 \cdot x_2 + 1 \\ x_2 - x_1 \end{pmatrix}$$

$$x(x_1) := x_1$$

$$r(x_1) := x_1 - 2 \cdot x(x_1) + 1 \rightarrow 1 - x_1 = 0$$

$$x_0 := \begin{pmatrix} 1 \\ 1 \end{pmatrix} \quad G(x_0) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$H(x) := \text{Jacob}(G(x), x)$$


$$H(x) \text{ factor } \rightarrow \begin{pmatrix} -2 & 1 \\ 1 & -1 \end{pmatrix}$$

$$\text{eigenvals}(H(x_0)) = \begin{pmatrix} -2.618 \\ -0.382 \end{pmatrix}$$


==> máximo global

$$f(y, z) := \text{fe} \left( \begin{pmatrix} y \\ z \end{pmatrix} \right)$$

M := CreateMesh (f, 0, 4, 0, 4)



M



M

$$\text{TOL} := 10^{-9}$$

7) Em um reator químico é conduzida uma reação química irreversível de segunda ordem, o processo é em batelada. O balanço de massa do reagente é descrito pela equação diferencial:

$$\frac{dc(t)}{dt} = -k \cdot [c(t)]^2 \quad \text{com } c(0) = c_0$$

A variação da concentração do reagente com o tempo é medida construindo-se a tabela:

t (min)	1	2	3	4	5	7	10	12	15	20	25
c x100 (mol/lit)	4.049	3.086	2.604	2.222	1.912	1.524	1.142	0.980	0.741	0.649	0.521

Baseado nestes dados estime os valores de  $k$  e de  $c_0$ .

Resolução: Reescrevendo a equação na forma:

$$-\frac{dc(t)}{[c(t)]^2} = k \cdot dt \Rightarrow \frac{1}{c(t)} - \frac{1}{c_0} = k \cdot t \Rightarrow c(t) = \frac{c_0}{1 + k \cdot c_0 \cdot t} = \frac{c_0}{1 + c_1 \cdot t} \quad \text{sendo: } c_1 = k \cdot c_0$$

Definindo:  $S(c_0, c_1) = \sum_{i=1}^{11} \left[ c_{\text{exp}}(t_i) - \frac{c_0}{1 + c_1 \cdot t_i} \right]^2$ , assim:

$$\frac{\partial S(c_0, c_1)}{\partial c_0} = -2 \sum_{i=1}^{11} \frac{1}{(1 + c_1 \cdot t_i)} \cdot \left[ c_{\text{exp}}(t_i) - \frac{c_0}{1 + c_1 \cdot t_i} \right] = 0 \Rightarrow c_0(c_1) = \frac{\sum_{i=1}^{11} \left( \frac{c_{\text{exp}}(t_i)}{1 + c_1 \cdot t_i} \right)}{\sum_{i=1}^{11} \frac{1}{(1 + c_1 \cdot t_i)^2}}$$

e

$$\frac{\partial S(c_0, c_1)}{\partial c_1} = 2c_0 \sum_{i=1}^{11} \frac{t_i}{(1 + c_1 \cdot t_i)^2} \cdot \left[ c_{\text{exp}}(t_i) - \frac{c_0}{1 + c_1 \cdot t_i} \right] = 0 \Rightarrow$$

$$f(c_1) = \sum_{i=1}^{11} \frac{t_i}{(1 + c_1 \cdot t_i)^2} \cdot \left[ c_{\text{exp}}(t_i) - \frac{c_0(c_1)}{1 + c_1 \cdot t_i} \right] = 0$$

$$t := \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 7 \\ 10 \\ 12 \\ 15 \\ 20 \\ 25 \end{pmatrix} \quad c := \begin{pmatrix} 4.049 \\ 3.086 \\ 2.604 \\ 2.222 \\ 1.912 \\ 1.524 \\ 1.142 \\ .98 \\ .741 \\ .649 \\ .521 \end{pmatrix} \cdot 10^{-2} \quad i := 0..10$$

Solução do Problema *Linear* Considerando o Ajuste de  $1/c$  versus  $t$ , para dar o chute inicial

$$y_i := \frac{1}{c_i} \quad a_0 := \text{intercept}(t, y) \quad a_1 := \text{slope}(t, y) \quad C_0 := \frac{1}{a_0} \quad C_1 := \frac{a_1}{a_0}$$



Primeiro Método: anulando as duas derivadas da soma do quadrado dos erros

$$g(\alpha) := \frac{\sum_i \frac{c_i}{1 + \alpha \cdot t_i}}{\sum_i \frac{1}{(1 + \alpha \cdot t_i)^2}} \quad f(\alpha) := \sum_i \left[ \frac{t_i}{(1 + \alpha \cdot t_i)^2} \cdot \left[ c_i - \frac{g(\alpha)}{(1 + \alpha \cdot t_i)} \right] \right] \quad \alpha := C_1 \quad f(\alpha) = 3.3165 \times 10^{-5}$$

$$\alpha := \text{root}(f(\alpha), \alpha) \quad \alpha = 0.391076$$

$$c_{\text{inicial}} := g(\alpha) \quad k := \frac{\alpha}{c_{\text{inicial}}} \quad c_{\text{inicial}} \cdot 100 = 5.610581 \quad k = 6.970327$$

$$c_{\text{mod}}(t) := \frac{c_{\text{inicial}}}{1 + \alpha \cdot t} \quad d := \begin{pmatrix} c_{\text{inicial}} \\ \alpha \end{pmatrix} \quad j := 0..100 \quad \tau_j := t_{10} \cdot \frac{j}{100}$$



Segundo Método: usando direto a função Minimize do MATHCAD

$$S(C) := \sum_i \left( c_i - \frac{C_0}{1 + C_1 \cdot t_i} \right)^2 \quad C := \text{Minimize}(S, C) \quad C^T = (0.056106 \quad 0.391075)$$

$$C_{\text{inicial}} := C_0 \quad K := \frac{C_1}{C_0} \quad C_{\text{inicial}} \cdot 100 = 5.610571 \quad K = 6.970315$$

$$S(C) = 1.247749 \times 10^{-6} \quad S(d) = 1.247749 \times 10^{-6} \quad |C - d| = 1.4 \times 10^{-6}$$

$$S(C) - S(d) = 1.842756 \times 10^{-15}$$

$$\text{TOL} := 10^{-9}$$

8) A intensidade de radiação de uma fonte radioativa é expressa por:  $I(t) = I_0 \cdot e^{-\alpha t}$ .

Determine os valores de  $I_0$  e de  $\alpha$  que melhor ajustem os dados experimentais abaixo:

$t$	0.2	0.3	0.4	0.5	0.6	0.7	0.8
$I(t)$	3.16	2.38	1.75	1.34	1.00	0.74	0.56

$$i := 0..6 \quad t_i := .2 + .1 \cdot i \quad I := \begin{pmatrix} 3.16 \\ 2.38 \\ 1.75 \\ 1.34 \\ 1.00 \\ 0.74 \\ 0.56 \end{pmatrix} \quad y := \ln(I)$$

Solução do Problema *Linear* Considerando o Ajuste de  $\ln[I(t)]$  versus  $t$ , para dar o chute inicial

$$a_0 := \text{intercept}(t, y) \quad a_1 := \text{slope}(t, y) \quad a_0 := e^{a_0} \quad a^T = (5.631019 \quad -2.888285)$$

Primeiro Método) Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear

$$p := \frac{\sum_{i=0}^5 (I_i \cdot I_{i+1})}{\sum_{i=0}^5 (I_i)^2} \quad p = 0.749248 \quad C_1 := 10 \cdot \ln(p) \quad C_0 := \frac{\sum_i (e^{C_1 \cdot t_i} \cdot I_i)}{\sum_i e^{2 \cdot C_1 \cdot t_i}} \quad C^T = (5.629403 \quad -2.886846)$$

$$g(\alpha) := \frac{\sum_i (e^{\alpha \cdot t_i} \cdot I_i)}{\sum_i e^{2 \cdot \alpha \cdot t_i}} \quad f(\alpha) := \sum_i [t_i \cdot e^{\alpha \cdot t_i} \cdot (I_i - g(\alpha) \cdot e^{\alpha \cdot t_i})] \quad \alpha := C_1 \quad f(\alpha) = -3.01368 \times 10^{-4}$$



$$\alpha := \text{root}(f(\alpha), \alpha) \quad C := \begin{pmatrix} g(\alpha) \\ \alpha \end{pmatrix} \quad C^T = (5.636061 \quad -2.890593)$$

$$S(C) := \sum_i (I_i - C_0 \cdot e^{C_1 \cdot t_i})^2 \quad S(C) = 8.939661 \times 10^{-4} \quad I_{\text{mod}}(t) := C_0 \cdot e^{C_1 \cdot t}$$

Segundo Método) Usando a função Minimize do MATHCAD

$$c := \text{Minimize}(S, a) \quad c^T = (5.636061 \quad -2.890593) \quad S(c) = 8.939661 \times 10^{-4}$$

$$j := 0..100 \quad \tau_j := t_6 \cdot \frac{j}{100}$$





$$\text{TOL} := 10^{-9}$$

9)  $y$  é uma função de  $x$  dada pela tabela abaixo, sabe-se que esta dependência é expressa por:  $y(x) = A \cdot e^{-\alpha \cdot x} + B \cdot e^{-\beta \cdot x}$ . Determine os valores de  $A$ ,  $B$ ,  $\alpha$  e  $\beta$ .

x	0.4	0.5	0.6	0.7	0.8	0.9	1.0	1.1
y(x)	2.31604	2.02877	1.78030	1.56513	1.37854	1.21651	1.07561	0.95289

$$x := \begin{pmatrix} .4 \\ .5 \\ .6 \\ .7 \\ .8 \\ .9 \\ 1.0 \\ 1.1 \end{pmatrix} \quad y := \begin{pmatrix} 2.31604 \\ 2.02877 \\ 1.78030 \\ 1.56513 \\ 1.37854 \\ 1.21651 \\ 1.07561 \\ 0.95289 \end{pmatrix}$$

Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear por Newton-Raphson

$$s := \begin{bmatrix} \sum_{i=0}^5 (y_i)^2 & \sum_{i=0}^5 (y_i \cdot y_{i+1}) \\ \sum_{i=0}^5 (y_i \cdot y_{i+1}) & \sum_{i=0}^5 (y_{i+1})^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=0}^5 (y_i \cdot y_{i+2}) \\ \sum_{i=0}^5 (y_{i+1} \cdot y_{i+2}) \end{bmatrix}$$

$$s = \begin{pmatrix} 0.79045 \\ -1.7799 \end{pmatrix} \quad s_2 := 1$$

$$v := \text{polyroots}(s) \quad v = \begin{pmatrix} 0.85039 \\ 0.92951 \end{pmatrix}$$

$$\lambda := 10 \cdot \ln(v) \quad \lambda = \begin{pmatrix} -1.62059 \\ -0.73095 \end{pmatrix}$$

$$i := 0..7 \quad j := 0..1 \quad A_{i,j} := e^{\lambda_j \cdot x_i} \quad c := (A^T \cdot A)^{-1} \cdot A^T \cdot y \quad c^T = (2.99719 \quad 1.00284)$$

$$a := \begin{pmatrix} c_0 \\ \lambda_0 \\ c_1 \\ \lambda_1 \end{pmatrix}$$

$$y_{\text{mod}}(x, \alpha) := \alpha_0 \cdot e^{\alpha_1 \cdot x} + \alpha_2 \cdot e^{\alpha_3 \cdot x} \quad \text{erro}(i, \alpha) := y_i - y_{\text{mod}}(x_i, \alpha)$$

$$S(\alpha) := \sum_i \text{erro}(i, \alpha)^2 \quad S(a) = 1.81 \times 10^{-11} \quad \delta := 10^{-6} \quad I := \text{identity}(4)$$



$$g(\alpha) := \begin{cases} g_0 \leftarrow \sum_i (e^{\alpha_1 \cdot x_i} \cdot \text{erro}(i, \alpha)) \\ g_1 \leftarrow \sum_i (e^{\alpha_1 \cdot x_i} \cdot x_i \cdot \text{erro}(i, \alpha)) \\ g_2 \leftarrow \sum_i (e^{\alpha_3 \cdot x_i} \cdot \text{erro}(i, \alpha)) \\ g_3 \leftarrow \sum_i (e^{\alpha_3 \cdot x_i} \cdot x_i \cdot \text{erro}(i, \alpha)) \end{cases}$$

$$J(\alpha) := \begin{cases} f \leftarrow g(\alpha) \\ \text{for } j \in 0..3 \\ \quad \beta \leftarrow \alpha + \delta \cdot I^{(j)} \\ \quad J^{(j)} \leftarrow \frac{g(\beta) - f}{\delta} \end{cases}$$

$$\text{solução}(\alpha) := \begin{cases} \text{flag} \leftarrow 0 \\ f \leftarrow g(\alpha) \\ \text{while } \text{flag} = 0 \\ \quad \beta \leftarrow \alpha - J(\alpha)^{-1} \cdot f \\ \quad f \leftarrow g(\beta) \\ \quad \text{flag} \leftarrow 1 \text{ if } |\beta - \alpha| < \text{TOL} \\ \quad \text{flag} \leftarrow 1 \text{ if } |f| < \text{TOL} \\ \quad \alpha \leftarrow \beta \end{cases}$$

$$a^T = (2.99719 \quad -1.62059 \quad 1.00284 \quad -0.73095) \quad \alpha := \text{solução}(a) \quad \alpha^T = (2.99616 \quad -1.62083 \quad 1.00391 \quad -0.73129) \quad S(\alpha) = 1.61 \times 10^{-11}$$

$$j := 0..50 \quad X_j := .4 + .7 \cdot \frac{j}{50} \quad |\alpha - a| = 1.54 \times 10^{-3}$$



Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear pelo *Minimize* do MATHCAD

$$c := \text{Minimize}(S, a) \quad c^T = (2.99719 \quad -1.62059 \quad 1.00284 \quad -0.73095)$$

$|c - a| = 0$  Observa-se que o *Minimize* não conseguiu refinar os valores dos coeficientes!

10)  $y$  é uma função de  $x$  dada pela tabela abaixo, sabe-se que esta dependência é expressa por:  $y(x) = C \cdot e^{-ax} \cdot \text{sen}(b \cdot x)$ . Determine os valores de  $\underline{C}$ ,  $\underline{a}$  e  $\underline{b}$

$x$	0.0	0.2	0.4	0.6	0.8	1.0	1.2	1.4	1.6
$y(x)$	0.00000	0.15398	0.18417	0.16156	0.12301	0.08551	0.05537	0.03362	0.01909

$$\text{TOL} := 10^{-9} \quad i := 0..8 \quad x_i := i \cdot 0.2$$

$$y := \begin{pmatrix} .00000 \\ .15398 \\ .18417 \\ .16156 \\ .12301 \\ .08551 \\ .05537 \\ .03362 \\ .01909 \end{pmatrix}$$

Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear por Newton-Raphson

$$s := \begin{bmatrix} \sum_{i=0}^6 (y_i)^2 & \sum_{i=0}^6 (y_i \cdot y_{i+1}) \\ \sum_{i=0}^6 (y_i \cdot y_{i+1}) & \sum_{i=0}^6 (y_{i+1})^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=0}^6 (y_i \cdot y_{i+2}) \\ \sum_{i=0}^6 (y_{i+1} \cdot y_{i+2}) \end{bmatrix}$$

$$s = \begin{pmatrix} 0.38135 \\ -1.19607 \end{pmatrix} \quad s_2 := 1$$

$$v := \text{polyroots}(s) \quad v = \begin{pmatrix} 0.59803 + 0.15395i \\ 0.59803 - 0.15395i \end{pmatrix}$$

$$a := 5 \cdot \ln(|\text{Re}(v_0)|) \quad b := 5 \cdot |\text{arg}(v_1)| \quad a = -2.57053 \quad b = 1.2598$$

$$C := \frac{\sum_i (e^{a \cdot x_i} \cdot \sin(b \cdot x_i) \cdot y_i)}{\sum_i (e^{a \cdot x_i} \cdot \sin(b \cdot x_i))^2} \quad C = 1.08661$$

$$y_{\text{mod}}(x, \alpha) := \alpha_0 \cdot e^{\alpha_1 \cdot x} \cdot \sin(\alpha_2 \cdot x) \quad \text{erro}(i, \alpha) := y_i - y_{\text{mod}}(x_i, \alpha)$$

$$S(\alpha) := \sum_i \text{erro}(i, \alpha)^2$$

$$c := \begin{pmatrix} C \\ a \\ b \end{pmatrix} \quad S(c) = 2.14 \times 10^{-4} \quad \delta := 10^{-6} \quad I := \text{identity}(3)$$

$$g(\alpha) := \begin{cases} g_0 \leftarrow \sum_i (e^{\alpha_1 \cdot x_i} \cdot \sin(\alpha_2 \cdot x_i) \cdot \text{erro}(i, \alpha)) \\ g_1 \leftarrow \sum_i (e^{\alpha_1 \cdot x_i} \cdot \sin(\alpha_2 \cdot x_i) \cdot x_i \cdot \text{erro}(i, \alpha)) \\ g_2 \leftarrow \sum_i (e^{\alpha_1 \cdot x_i} \cdot \cos(\alpha_2 \cdot x_i) \cdot x_i \cdot \text{erro}(i, \alpha)) \\ g \end{cases}$$

$$J(\alpha) := \begin{cases} f \leftarrow g(\alpha) \\ \text{for } j \in 0..2 \\ \beta \leftarrow \alpha + \delta \cdot I^{(j)} \\ J^{(j)} \leftarrow \frac{g(\beta) - f}{\delta} \\ J \end{cases}$$



```

solução(α) :=
  flag ← 0
  f ← g(α)
  while flag = 0
    β ← α - J(α)-1 · f
    f ← g(β)
    flag ← 1 if |β - α| < TOL
    flag ← 1 if |f| < TOL
    α ← β
  β

```

$\alpha := \text{solução}(c) \quad \alpha^T = (1.00011 \quad -2.41007 \quad 1.25987)$   
 $S(\alpha) = 4.29 \times 10^{-11}$

$j := 0..50 \quad X_j := 1.6 \cdot \frac{j}{50} \quad |\alpha - a| = 5.24$



Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear pelo *Minimize* do MATHCAD

$\beta := \text{Minimize}(S, c) \quad \beta^T = (1.00011 \quad -2.41007 \quad 1.25987) \quad |\alpha - \beta| = 3.3555 \times 10^{-7}$   
 $S(\beta) = 4.29 \times 10^{-11}$   
 Valor *quase* idêntico ao obtido por Newton-Raphson

11)  $y$  é uma função de  $x$  dada pela tabela abaixo, sabe-se que esta dependência é expressa por:  $y(x) = A \cdot e^{-\alpha x} + B$ . Determine os valores de  $A$ ,  $B$  e  $\alpha$

x	1.0	1.2	1.4	1.6	1.8	2.0	2.2	2.4	2.6	2.8	3.0
y(x)	3.00767	2.79720	2.61553	2.45874	2.32340	2.20659	2.10576	2.01874	1.94363	1.87880	1.82284

TOL :=  $10^{-9}$     i := 0..10     $x_i := 1 + .2 \cdot i$

y :=  $\begin{pmatrix} 3.00767 \\ 2.79720 \\ 2.61553 \\ 2.45874 \\ 2.32340 \\ 2.20659 \\ 2.10576 \\ 2.01874 \\ 1.94363 \\ 1.87880 \\ 1.82284 \end{pmatrix}$

$\delta := 10^{-6}$     I := identity(3)

Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear por Newton-Raphson

$$b := \frac{\sum_{i=0}^8 [(y_{i+1} - y_i) \cdot (y_{i+2} - y_{i+1})]}{\sum_{i=0}^8 (y_{i+1} - y_i)^2} \quad s := \begin{bmatrix} b \\ -(1+b) \\ 1 \end{bmatrix} \quad v := \text{polyroots}(s) \quad v = \begin{pmatrix} 0.86313 \\ 1 \end{pmatrix} \quad b = 0.86313$$

$$\alpha := 5 \cdot \ln(b) \quad A_{1,0} := 1 \quad A_{1,1} := e^{\alpha \cdot x_i} \quad c := (A^T \cdot A)^{-1} \cdot A^T \cdot y \quad c = \begin{pmatrix} 1.46996 \\ 3.20994 \end{pmatrix} \quad c_2 := \alpha \quad c^T = (1.46996 \quad 3.20994 \quad -0.73596)$$

$$y_{\text{mod}}(x, \alpha) := \alpha_0 + \alpha_1 \cdot e^{\alpha_2 \cdot x} \quad \text{erro}(i, \alpha) := y_i - y_{\text{mod}}(x_i, \alpha) \quad S(\alpha) := \sum_i \text{erro}(i, \alpha)^2 \quad S(c) = 1.22 \times 10^{-10}$$

$$g(\alpha) := \begin{cases} g_0 \leftarrow \sum_i \text{erro}(i, \alpha) \\ g_1 \leftarrow \sum_i (e^{\alpha_2 \cdot x_i} \cdot \text{erro}(i, \alpha)) \\ g_2 \leftarrow \sum_i (e^{\alpha_2 \cdot x_i} \cdot x_i \cdot \text{erro}(i, \alpha)) \end{cases} \quad g$$



$$J(\alpha) := \begin{cases} f \leftarrow g(\alpha) \\ \text{for } j \in 0..2 \\ \beta \leftarrow \alpha + \delta \cdot I^{(j)} \\ J^{(j)} \leftarrow \frac{g(\beta) - f}{\delta} \end{cases} \quad J$$

$$\text{solução}(\alpha) := \begin{cases} \text{flag} \leftarrow 0 \\ f \leftarrow g(\alpha) \\ \text{while } \text{flag} = 0 \\ \beta \leftarrow \alpha - J(\alpha)^{-1} \cdot f \\ f \leftarrow g(\beta) \\ \text{flag} \leftarrow 1 \text{ if } |\beta - \alpha| < \text{TOL} \\ \text{flag} \leftarrow 1 \text{ if } |f| < \text{TOL} \\ \alpha \leftarrow \beta \end{cases} \quad \beta$$

$$\alpha := \text{solução}(c) \quad \alpha^T = (1.46998 \quad 3.20997 \quad -0.73598) \quad S(\alpha) = 6.72 \times 10^{-11}$$

$j := 0..50$

$$X_j := 1 + \frac{j}{20}$$



Construindo a equação de diferenças como chute inicial e depois resolvendo a regressão não linear pelo *Minimize* do MATHCAD

$$\beta := \text{Minimize}(S, c) \quad \beta^T = (1.46998 \quad 3.20997 \quad -0.73598) \quad S(\beta) = 6.72 \times 10^{-11}$$

$$|\alpha - \beta| = 4.02 \times 10^{-7} \quad \text{Valor quase idêntico ao obtido por Newton-Raphson}$$

12) Através de fotografias estroboscópicas de pequenas bolhas de ar é possível medir o perfil de velocidade próxima à parede de um tubo no qual escoava um fluido. Com um número de Reynolds de 1200 e com um tubo de 1 polegada de diâmetro interno os seguintes pontos experimentais são obtidos:

y (distância à parede) cm	u (velocidade) cm/s	y (distância à parede) cm	u (velocidade) cm/s
0.003	0.03	0.056	0.85
0.021	0.32	0.061	0.92
0.025	0.30	0.070	1.05
0.025	0.33	0.078	1.117
0.037	0.57	0.085	1.32
0.043	0.66	0.092	1.38
0.049	0.74	0.106	1.57
0.053	0.80	0.113	1.65
0.055	0.84		

A função que melhor ajusta o perfil de velocidade é:  $u(y) = p \cdot y + q \cdot y^2$ , baseado nos dados acima determine os valores de  $p$  e  $q$ .

TOL :=  $10^{-9}$

```

y := (.003
      .021
      .025
      .025
      .037
      .043
      .049
      .053
      .055
      .056
      .061
      .070
      .078
      .085
      .092
      .106
      .113)
u := (.03
      .32
      .30
      .33
      .57
      .66
      .74
      .80
      .84
      .85
      .92
      1.05
      1.117
      1.32
      1.38
      1.57
      1.65)

```

```

i := 0..16      Ai,0 := yi      Ai,1 := (yi)2

```

```

c := (AT·A)-1 · AT · u      c = (15.12523
      -2.71883)

```

```



umod(y,c) := y · (c0 + c1 · y)

```

```

j := 0..100      Yj := y16 ·  $\frac{j}{100}$ 

```



13) Os coeficientes de transferência de calor em trocadores de calor são adequadamente modelados por expressão do tipo:

$$Nu = \alpha \cdot Re^\beta \cdot Pr^\gamma \cdot r^\delta$$

Onde  $Nu$ ,  $Re$  e  $Pr$  são, respectivamente, os números de Nusselt, Reynolds e Prandtl e  $r$  é a razão entre a viscosidade à temperatura média do fluido e à temperatura da parede;  $\alpha$ ,  $\beta$ ,  $\gamma$  e  $\delta$  são constantes. Os seguintes dados experimentais estão disponíveis:

$Nu$	$Re$	$Pr$	$r$
277	49000	2.30	0.947
348	68600	2.28	0.954
421	84800	2.27	0.959
223	34200	2.32	0.943
177	22900	2.36	0.936
114.8	1321	246	0.592
95.9	931	247	0.583
68.3	518	251	0.579
49.1	346	273	0.290
56.0	122.9	1518	0.294
39.9	54.0	1590	0.279
47.0	84.6	1521	0.267
94.2	1249	107.4	0.724
99.9	1021	186	0.612
83.1	465	414	0.512
35.9	54.8	1302	0.273

Estimar os valores de  $\alpha$ ,  $\beta$ ,  $\gamma$  e  $\delta$  que melhor ajustam os pontos acima.

$$TOL := 10^{-9}$$

$$A := \begin{pmatrix} 277 & 49000 & 2.3 & .947 \\ 348 & 68600 & 2.28 & .954 \\ 421 & 84800 & 2.27 & .959 \\ 223 & 34200 & 2.32 & .943 \\ 177 & 22900 & 2.36 & .936 \\ 114.8 & 1321 & 246 & .592 \\ 95.9 & 931 & 247 & .583 \\ 68.3 & 518 & 251 & .579 \\ 49.1 & 346 & 273 & .29 \\ 56 & 122.9 & 1518 & .294 \\ 39.9 & 54 & 1590 & .279 \\ 47 & 84.6 & 1521 & .267 \\ 94.2 & 1249 & 107.4 & .724 \\ 99.9 & 1021 & 186 & .612 \\ 83.1 & 465 & 414 & .512 \\ 35.9 & 54.8 & 1302 & .273 \end{pmatrix}$$

Estimativa Inicial dos Parâmetros a Partir da Regressão Linear do Logaritmo da Função

$$i := 0..15 \quad B_{i,0} := 1 \quad k := 1..3 \quad B^{(k)} := \ln(A^{(k)})$$

$$c := (B^T \cdot B)^{-1} \cdot B^T \cdot \ln(A^{(0)}) \quad c^T = (-0.63 \quad 0.56 \quad 0.25 \quad -0.07) \quad a_0 := e^{c_0} \quad a_k := c_k$$

$$\text{Nusselt}(i, a) := a_0 \cdot (A_{i,1})^{a_1} \cdot (A_{i,2})^{a_2} \cdot (A_{i,3})^{a_3} \quad a^T = (0.5347 \quad 0.5588 \quad 0.2524 \quad -0.0677)$$



Minimização da Função Soma dos Quadrados dos Erros pelo *Minimize*


$$S(a) := \sum_i (A_{i,0} - \text{Nusselt}(i, a))^2 \quad S(a) = 2.82 \times 10^3$$

$$b := \text{Minimize}(S, a) \quad b^T = (0.1512 \quad 0.6716 \quad 0.337 \quad -0.0991) \quad S(b) = 8.2 \times 10^2$$

Minimização da Função Soma dos Quadrados dos Erros Relativos pelo *Minimize*

$$S_{\text{rel}}(a) := \sum_i \left(1 - \frac{\text{Nusselt}(i, a)}{A_{i,0}}\right)^2 \quad S_{\text{rel}}(a) = 0.14 \quad S_{\text{rel}}(b) = 0.19$$

$$c := \text{Minimize}(S_{\text{rel}}, a) \quad c^T = (0.5714 \quad 0.5519 \quad 0.2546 \quad -0.0052) \quad S_{\text{rel}}(c) = 0.13 \quad xx := \begin{pmatrix} 25 \\ 300 \end{pmatrix} \quad n := 0..1$$



$$E_{1_i} := |A_{i,0} - \text{Nusselt}(i, b)| \quad E_{2_i} := |A_{i,0} - \text{Nusselt}(i, c)| \quad \max(E_1) = 12.44 \quad \max(E_2) = 51.28$$

$$\text{Erel}_{1_i} := \frac{E_{1_i}}{A_{i,0}} \cdot 100 \quad \text{Erel}_{2_i} := \frac{E_{2_i}}{A_{i,0}} \cdot 100 \quad \max(\text{Erel}_1) = 24.86 \quad \max(\text{Erel}_2) = 23.13$$

14) Encontre o mínimo das seguintes funções objetivo usando os métodos diretos e indiretos descritos nas seções 7.2 e 7.3 e compare os resultados em termos do número de funções objetivo avaliadas por cada método:

a)  $S(x) = 100 (x_2 - x_1^2)^2 + (1 - x_1)^2$

R:  $x_0 = [1 \ 1]^T \quad S(x_0) = 0$

b)  $S(x) = [1,5 - x_1 (1 - x_2)]^2 + [2,25 - x_1 (1 - x_2^2)]^2 + [2,625 - x_1 (1 - x_2^3)]^2$

R:  $x_0 = [3 \ 0,5]^T \quad S(x_0) = 0$

c)  $S(x) = 4 x_1^2 - 2 x_1 x_2 + x_2^2$

R:  $x_0 = [0 \ 0]^T \quad S(x_0) = 0$

d)  $S(x) = \exp(x_1) (4 x_1^2 + 2 x_2^2 + 4 x_1 x_2 + 2 x_2 + 1)$

R:  $x_0 = [0,5 \ -1]^T \quad S(x_0) = 0$

e)  $S(x) = 4 (x_1 - 5)^2 + (x_2 - 6)^2$

R:  $x_0 = [5 \ 6]^T \quad S(x_0) = 0$

f)  $S(x) = x_1^2 - 5 x_1 + 3 x_2^2 + 3$

R:  $x_0 = [2,5 \ 0]^T \quad S(x_0) = -3,25$

g)  $S(x) = (x_1 - 2)^2 + (x_2 - 1)^2$

R:  $x_0 = [2 \ 1]^T \quad S(x_0) = 0$