

## Algoritmos de Otimização Não-lineares Sem Restrições <sup>1</sup>

Por que estudar?

Algoritmos para solução de problemas com restrições baseiam-se em algoritmos para solução de problemas sem restrições (métodos de penalização, obtenção da direção de busca, etc...);

Princípio Básico: Problema de n variáveis  $\Rightarrow$  Problema de uma variável

$$\mathbf{x} = \mathbf{x}_0 + \alpha \mathbf{s}_0 \Rightarrow f(\mathbf{x}) = f(\mathbf{x}_0 + \alpha \mathbf{s}_0) = f(\alpha) \Rightarrow \text{Encontrar } \alpha$$

Procedimento Típico

- Encontrar  $\mathbf{s}_0$  em  $\mathbf{x}_0$  que reduza função objetivo
- Encontrar  $\alpha$  na direção de  $\mathbf{s} \Rightarrow \mathbf{x}_0 + \alpha \mathbf{s}_0$  (busca unidimensional)
- Verificar convergência: se satisfeita  $\Rightarrow \mathbf{x} = \mathbf{x}^*$ , pare, caso contrário  $\Rightarrow \mathbf{x}_{i+1} = \mathbf{x}$  e  $i = i+1$

Prof. Dr. Emilio C. Nelli Silva

## Algoritmos de Otimização Não-lineares Sem Restrições <sup>2</sup>

- Classificação
- Ordem Zero  $\Rightarrow$  utiliza somente o valor da função objetivo. Usados quando a função não é diferenciável ou quando a função é altamente não-linear, sendo difícil obter as derivadas de forma precisa.  
Ex.: Método das Direções Conjugadas de Powell
  - Primeira Ordem  $\Rightarrow$  utiliza o valor e gradiente da função  
Ex.: Método "Steepest Descent" e Método dos Gradientes Conjugados
  - Segunda Ordem  $\Rightarrow$  utiliza o valor, gradiente e matriz Hessiana da função.  
Ex.: Método de Newton e Quasi-Newton

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Ordem Zero

3

Usados quando o valor da função é obtido com precisão pobre  $\Rightarrow$  valores de derivadas (ou gradientes) não são confiáveis.

### Método das Direções Conjugadas de “Powell”

Baseado na minimização de uma função quadrática considerando direções  $Q$ -conjugadas linearmente independentes. Função quadrática:

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{b}^T \mathbf{x} + \mathbf{c}$$

Direções  $Q$ -conjugadas:  $\mathbf{s}_i^T \mathbf{Q} \mathbf{s}_j = 0$  para  $i \neq j$

“Se  $f$  for minimizada ao longo de cada direção  $\mathbf{s}$ , então o mínimo de  $f$  será encontrado no (ou antes) do  $n^{\text{ésimo}}$  passo independentemente do ponto inicial, dado que erros de arredondamento não sejam acumulados.”

Powell  $\Rightarrow$  método conveniente de gerar direções  $Q$ -conjugadas linearmente independentes. Se direções geradas são linearmente dependentes  $\Rightarrow$  não converge para o mínimo.

Prof. Dr. Emilio C. Nelli Silva

## Método das Direções Conjugadas de Powell

4

Procedimento:

1. Minimize  $f$  ao longo das direções coordenadas (busca univariada), iniciando em  $\mathbf{x}_0^k$  e gerando os pontos  $\mathbf{x}_1^k, \dots, \mathbf{x}_n^k$  onde  $k$  é o número do ciclo;
2. Após encerrar a busca univariada encontre o índice  $m$  correspondente à direção em que a função  $f$  apresenta o maior decréscimo indo de  $\mathbf{x}_{m-1}^k$  para  $\mathbf{x}_m^k$ ;
3. Calcule a direção “padrão”  $\mathbf{s}_p^k = \mathbf{x}_n^k - \mathbf{x}_0^k$  e determine o valor de  $\alpha$  que minimize  $f$  tal que:  $\mathbf{x} = \mathbf{x}_0^k + \alpha \mathbf{s}_p^k$

4. Se

$$|\alpha| < \left[ \frac{f(\mathbf{x}_0^k) - f(\mathbf{x}_0^{k+1})}{f(\mathbf{x}_{m-1}^k) - f(\mathbf{x}_m^k)} \right]^{\frac{1}{2}}$$

então utilize as mesmas direções para a próxima busca univariada. Se a equação NÃO for satisfeita, então substitua a  $m^{\text{ésima}}$  direção pela direção padrão  $\mathbf{s}_p^k$

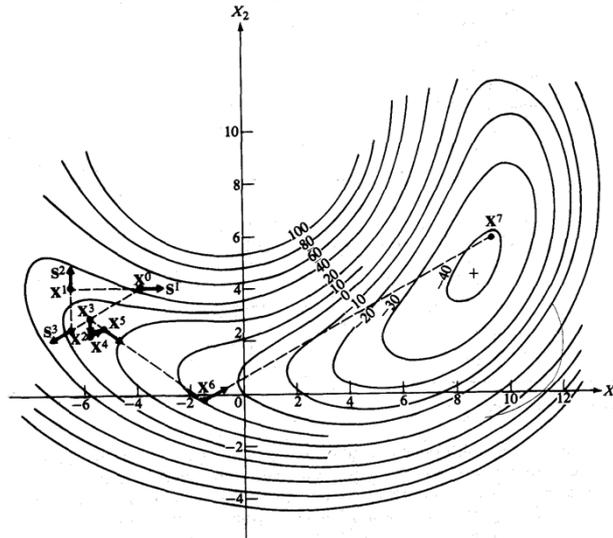
5. Comece a nova busca univariada com as direções obtidas no passo 4, e repita os passos 2, 3, e 4 até que a convergência seja atingida, ou seja:  $\|\mathbf{x}_{k+1} - \mathbf{x}^k\| \leq \epsilon$

Prof. Dr. Emilio C. Nelli Silva

## Método das Direções Conjugadas de Powell

5

Interpretação do Método de Direções Conjugadas de "Powell":

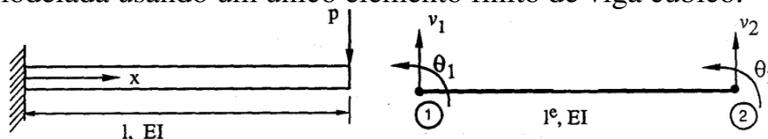


Prof. Dr. Emilio C. Nelli Silva

## Exemplo

6

Problema de estudo: Determinação da máxima deflexão e rotação da extremidade de uma viga através da minimização da sua energia potencial total modelada usando um único elemento finito de viga cúbico.



Formulação do elemento:

$$v(\xi) = \left[ \begin{matrix} (1 - 3\xi^2 + 2\xi^3) & l(\xi - 2\xi^2 + \xi^3) & (3\xi^2 - 2\xi^3) & l(-\xi^2 + \xi^3) \end{matrix} \right] \left\{ \begin{matrix} v_1 \\ \theta_1 \\ v_2 \\ \theta_2 \end{matrix} \right\}$$

onde:  $\xi = x/l$ . A energia potencial correspondente do modelo de viga é dado por:

$$\Pi = \frac{EI}{2l^3} \int_0^l \left( \frac{d^2v}{d\xi^2} \right)^2 d\xi + pv_2$$

Como a viga está engastada em  $\xi = 0 \Rightarrow v_1 = \theta_1 = 0$ , substituindo em  $v(\xi)$ :

$$\Pi = \frac{EI}{2l^3} (12v_2^2 + 2\theta_2^2 l^2 - 12v_2\theta_2 l) + pv_2 \text{ e definindo: } f = \frac{2\Pi l^3}{EI}; x_1 = v_2; x_2 = \theta_2 l \Rightarrow$$

$$f = 12x_1^2 + 4x_2^2 - 12x_1x_2 + 2x_1$$

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

7

$$\text{Min } f = 12x_1^2 - 12x_1x_2 + 4x_2^2 + 2x_1 \quad \mathbf{x}_0^1 = (-1, -2)^T \text{ e } f(\mathbf{x}_0^1) = 2$$

$$(\mathbf{x}^* = (-1/3, -1/2)^T \text{ solução exata})$$

Solução:

$$\mathbf{s}_1^1 = (1, 0)^T \Rightarrow \mathbf{x}_1^1 = \begin{Bmatrix} -1 \\ -2 \end{Bmatrix} + \alpha \begin{Bmatrix} 1 \\ 0 \end{Bmatrix} = \begin{Bmatrix} -1+\alpha \\ -2 \end{Bmatrix} \Rightarrow f(\alpha) = 12(-1+\alpha)^2 + 4(-2)^2 - 12(-1+\alpha)(-2) +$$

$$+ 2(-1+\alpha) \Rightarrow \text{Min } f \Rightarrow \alpha = -1/12 \Rightarrow \mathbf{x}_1^1 = \begin{Bmatrix} -13/12 \\ -2 \end{Bmatrix} \text{ e } f(\mathbf{x}_1^1) = 1,9166; \mathbf{s}_2^1 = (0, 1)^T \Rightarrow \mathbf{x}_2^1 = \begin{Bmatrix} -13/12 \\ -2 \end{Bmatrix} +$$

$$+ \alpha \begin{Bmatrix} 0 \\ 1 \end{Bmatrix} = \begin{Bmatrix} -13/12 \\ -2+\alpha \end{Bmatrix} \Rightarrow \text{Min } f \Rightarrow \alpha = 3/8 \Rightarrow \mathbf{x}_2^1 = \begin{Bmatrix} -13/12 \\ -13/8 \end{Bmatrix} \text{ e } f(\mathbf{x}_2^1) = 1,3541 \Rightarrow \mathbf{s}_p^1 = \mathbf{x}_2^1 - \mathbf{x}_0^1 = \begin{Bmatrix} -1/12 \\ 3/8 \end{Bmatrix} \Rightarrow$$

$$\Rightarrow \mathbf{x}_0^2 = \begin{Bmatrix} -1 \\ -2 \end{Bmatrix} + \alpha \begin{Bmatrix} -1/12 \\ 3/8 \end{Bmatrix} = \begin{Bmatrix} -1-\alpha/12 \\ -2+3\alpha/8 \end{Bmatrix} \Rightarrow \text{Min } f \Rightarrow \alpha = 40/49 \Rightarrow \mathbf{x}_0^2 = \begin{Bmatrix} -157/147 \\ -83/49 \end{Bmatrix} \text{ e } f(\mathbf{x}_0^2) = 1,31972$$

$$|\alpha| = \frac{40}{49} < \left[ \frac{2 - 1,31972}{1,9166 - 1,3541} \right]^{1/2}$$

Ciclo	$x_1$	$x_2$	$f$
0	-1.0	-2.0	2.0
1	-1.083334	-2.0	1.916667
1	-1.083334	-1.625	1.354167
2	-0.895834	-1.625	0.9322967
2	-0.895834	-1.34375	0.6158854
2	-0.33334	-0.499999	-0.333333

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

8

Utilizam os valores da função objetivo e de suas derivadas (gradientes) em relação às variáveis de projeto.

Métodos de primeira ordem possuem uma taxa de convergência linear ou superlinear, ou seja, considerando:

$$\|\mathbf{x}_{k+1} - \mathbf{x}^*\| \leq c_k \|\mathbf{x}_k - \mathbf{x}^*\|^p$$

a seqüência  $\mathbf{x}_k$  apresenta:

- convergência linear para  $\mathbf{x}^*$ , se  $p=1$  e  $c_k$  é constante.
- convergência superlinear para  $\mathbf{x}^*$ , se  $p=1$  e  $c_k$  é uma seqüência que converge para zero.

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

9

### Método “Steepest Descent”

$$\begin{aligned} \text{Min}_s \quad & \nabla f^T \mathbf{s} = \sum_{i=1}^n \frac{\partial f}{\partial x_i} s_i \\ \text{tal que} \quad & \mathbf{s}^T \mathbf{s} = 1 \end{aligned} \quad L(\mathbf{s}, \lambda) = \nabla f^T \mathbf{s} + \lambda(\mathbf{s}^T \mathbf{s} - 1) \Rightarrow \frac{\partial L}{\partial \mathbf{s}} = \nabla f + 2\lambda \mathbf{s} = 0 \Rightarrow$$

$$\Rightarrow \mathbf{s} = -\frac{\nabla f}{2\lambda} \Rightarrow \mathbf{s}^T \mathbf{s} = 1 \Rightarrow \|\nabla f\|^2 = 4\lambda^2 \Rightarrow 2\lambda = \|\nabla f\| \Rightarrow$$

Solução:  $\mathbf{s} = -\frac{\nabla f}{\|\nabla f\|}$  onde  $\|\cdot\|$  é a norma Euclideana

Assim:  $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha \mathbf{s} \Rightarrow$  otimização (busca) unidimensional

Se a função  $f$  é quadrática:  $f = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{b}^T \mathbf{x} + c \Rightarrow \alpha^* = -\frac{(\mathbf{x}_k^T \mathbf{Q} + \mathbf{b}^T) \mathbf{s}}{\mathbf{s}^T \mathbf{Q} \mathbf{s}}$   
simétrica ↙

Desempenho do Método  $\Rightarrow$  Número de Condicionamento (CN) da matriz

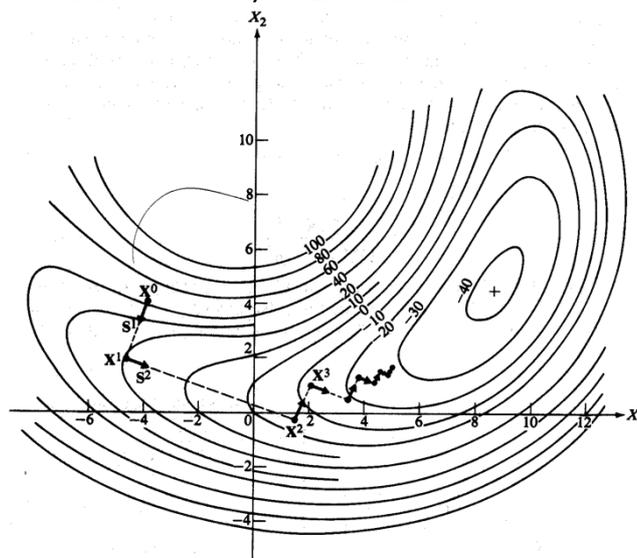
$\mathbf{Q}$ :  
 $\text{CN} = \frac{\lambda_{\max}}{\lambda_{\min}}$  se CN é alto  $\Rightarrow$  progresso lento e padrão “zig-zag”  
 (fenômeno “hemstitching”)

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

10

Interpretação do Método “Steepest Descent”:

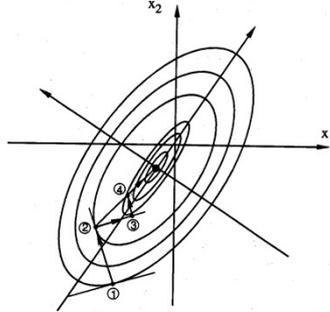


Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

11

Agora, vejamos o Exemplo:  $f = 12x_1^2 - 12x_1x_2 + 4x_2^2 + 2x_1$

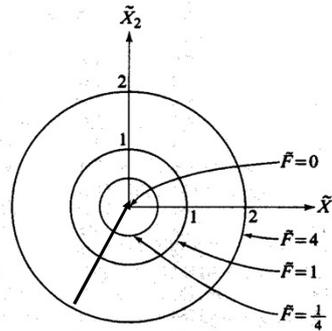


Mas, considerando a transformação de variáveis:

$$y_1 = \left( x_1 - \frac{1}{2}x_2 \right); \quad y_2 = \frac{x_2}{\sqrt{12}} \Rightarrow$$

$$\Rightarrow f(y_1, y_2) = y_1^2 + y_2^2 + \frac{1}{6}(y_1 + \sqrt{3}y_2)$$

(CN = 1)



Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

12

Assim, o método apresenta uma taxa linear de convergência sem a transformação de variáveis. Como é difícil encontrar a transformação correta  $\Rightarrow$  Método dos Gradientes Conjugados

Método dos Gradientes Conjugados (“Fletcher-Reeves”)

Direções  $\mathbf{s}_{k+1}$  e  $\mathbf{s}_k$  são Q-conjugadas:  $\Rightarrow \mathbf{s}_{k+1}^T \mathbf{Q} \mathbf{s}_k = 0$

Algoritmo:

1. Calcular  $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_{k+1} \mathbf{s}_k$  onde  $\alpha_{k+1}$  é determinado tal que  $\frac{df(\alpha_{k+1})}{d\alpha_{k+1}} = 0$
2.  $\mathbf{s}_k = \mathbf{g}_k = -\nabla f(\mathbf{x}_k)$  se  $k=0$  e  $\mathbf{s}_k = \mathbf{g}_k + \beta_k \mathbf{s}_{k-1}$  se  $k > 0$  com

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad \text{e} \quad \mathbf{g}_k = -\nabla f(\mathbf{x}_k)$$

3. Se  $\|\mathbf{g}_{k+1}\|$  ou  $|f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)|$  é suficientemente pequeno, pare.

Caso Contrário:

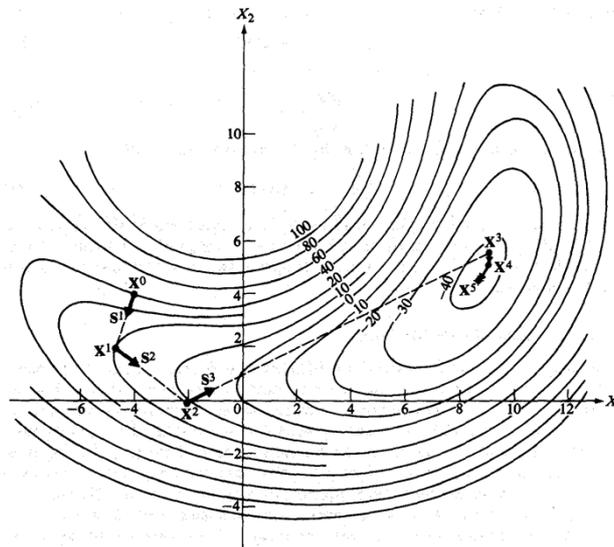
4. Se  $k < n$  vá para 1, ou recomece.

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Primeira Ordem

13

Interpretação do Método dos Gradientes Conjugados:



Prof. Dr. Emilio C. Nelli Silva

## Exemplo

14

$$\text{Min } f = 12x_1^2 - 12x_1x_2 + 4x_2^2 + 2x_1$$

Solução:

$$\mathbf{x}_0^T = (-1, -2) \Rightarrow \nabla f(\mathbf{x}_0) = \begin{Bmatrix} 24x_1 - 12x_2 + 2 \\ 8x_2 - 12x_1 \end{Bmatrix}_{\mathbf{x}=\mathbf{x}_0} \Rightarrow \mathbf{s}_0 = -\nabla f(\mathbf{x}_0) = \begin{Bmatrix} -2 \\ 4 \end{Bmatrix} \Rightarrow \mathbf{x}_1 = \begin{Bmatrix} -1 \\ -2 \end{Bmatrix} + \alpha_1 \begin{Bmatrix} -2 \\ 4 \end{Bmatrix} \Rightarrow$$

$$\Rightarrow f(\alpha_1) = 12(-1 - 2\alpha_1)^2 + 4(-1 + 4\alpha_1)^2 - 12(-1 - 2\alpha_1)(-2 + 4\alpha_1) + 2(-1 - 2\alpha_1) \Rightarrow \frac{df}{d\alpha_1} = 0 \Rightarrow$$

$$\Rightarrow \alpha_1 = 0,048077 \Rightarrow \mathbf{x}_1 = \begin{Bmatrix} -1,0961 \\ -1,8077 \end{Bmatrix} \text{ e } \nabla f(\mathbf{x}_1) = \begin{Bmatrix} -2,6154 \\ -1,3077 \end{Bmatrix} \Rightarrow \mathbf{s}_1 = -\nabla f(\mathbf{x}_1) + \beta_1 \mathbf{s}_0 \Rightarrow$$

$$\Rightarrow \beta_1 = \frac{(-2,6154)^2 + (-1,3077)^2}{(-2)^2 + (4)^2} = 0,4275 \Rightarrow \mathbf{s}_1 = \begin{Bmatrix} -2,6154 \\ -1,3077 \end{Bmatrix} + 0,4275 \begin{Bmatrix} -2 \\ 4 \end{Bmatrix} = \begin{Bmatrix} 1,76036 \\ 3,0178 \end{Bmatrix} \text{ e}$$

$$\mathbf{x}_2 = \begin{Bmatrix} -1,0961 \\ -1,8077 \end{Bmatrix} + \alpha_2 \begin{Bmatrix} 1,76036 \\ 3,0178 \end{Bmatrix} \Rightarrow \frac{df(\alpha_2)}{d\alpha_2} = 0 \Rightarrow \alpha_2 = 0,4334 \Rightarrow \mathbf{x}_2 = \mathbf{x}^* = \begin{Bmatrix} -0,3334 \\ -0,5 \end{Bmatrix}$$

$$\text{e } \nabla f(\mathbf{x}_2) = \begin{Bmatrix} 0 \\ 0 \end{Bmatrix} \Rightarrow \begin{Bmatrix} -2 \\ 4 \end{Bmatrix} \begin{bmatrix} 24 & -12 \\ -12 & 8 \end{bmatrix} \begin{Bmatrix} 1,76036 \\ 3,0178 \end{Bmatrix} \cong 0$$

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Segunda Ordem

15

### Método de Newton

A direção  $s$  é obtida resolvendo-se o problema:

$$\begin{array}{l} \text{Min}_s \quad \nabla f^T s = \sum_{i=1}^n \frac{\partial f}{\partial x_i} s_i \\ \text{tal que} \quad s^T Qs = 1 \end{array}$$

Solução:  $L(s, \lambda) = \nabla f^T s + \lambda(s^T Qs - 1) \Rightarrow \frac{\partial L}{\partial s} = \nabla f + 2\lambda Qs = 0 \Rightarrow$   
 $\Rightarrow s = -\frac{Q^{-1}\nabla f}{2\lambda} \Rightarrow s = -Q^{-1}\nabla f \Rightarrow Qs = -\nabla f$  deve ser positiva-definida  
 $\Rightarrow x_{k+1} = x_k + \alpha_{k+1}s_k$

$$Qs = -\nabla f \left\{ \begin{array}{l} \bullet n^3 \text{ operações na solução} \\ \bullet \frac{n(n+1)}{2} \text{ elementos devem ser} \\ \quad \text{calculados para montar } Q \end{array} \right.$$

Método de Quasi-Newton

Prof. Dr. Emilio C. Nelli Silva

## Métodos de Segunda Ordem

16

### Método de Quasi-Newton

$$\underbrace{\nabla f(x_{k+1}) - \nabla f(x_k)}_{y_k} \cong \underbrace{Q}_{A_k} \underbrace{(x_{k+1} - x_k)}_{p_k} \Rightarrow y_k = A_k p_k \text{ e } B_{k+1} y_k = p_k$$

aproximação

relação da secante ou Quasi-Newton

$B_{k+1}$  é a aproximação de  $Q^{-1}$ . Eventualmente:  $B_{k+1}A_k = I$   
 $A_k$  e  $B_k$  devem permanecer positivo-definidos. Após obter  $B_k$ :

$$x_{k+1} = x_k - \alpha_{k+1}s_k \text{ e } s_k = -B_k \nabla f(x_k)$$

Aproximação BFGS para  $B_k$ : 
$$B_{k+1} = \left[ I - \frac{p_k y_k^T}{p_k^T y_k} \right] B_k \left[ I - \frac{y_k^T p_k}{p_k^T y_k} \right] + \frac{p_k p_k^T}{p_k^T y_k}$$

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

17

$$\text{Min } f = 12x_1^2 - 12x_1x_2 + 4x_2^2 + 2x_1 \quad \mathbf{x}_0^T = (-1, -2); \quad \text{Solução:}$$

Iniciamos com a direção do “Steepest Descent” e  $\mathbf{B}_0 = \mathbf{I}$  (positiva definida):

$$\mathbf{x}_1 = \begin{Bmatrix} -1.0961 \\ -1.8077 \end{Bmatrix} \text{ e } \nabla f(\mathbf{x}_1) = \begin{Bmatrix} -2.6154 \\ -1.3077 \end{Bmatrix} \Rightarrow \mathbf{p}_0 = \begin{Bmatrix} -1.0961 \\ -1.8077 \end{Bmatrix} - \begin{Bmatrix} -1 \\ -2 \end{Bmatrix} = \begin{Bmatrix} -0.0961 \\ 0.1923 \end{Bmatrix} \text{ e como } \mathbf{s}_0 =$$

$$-\mathbf{B}_0 \nabla f(\mathbf{x}_0) = -\mathbf{I} \nabla f(\mathbf{x}_0) = \begin{Bmatrix} 2 \\ -4 \end{Bmatrix} \Rightarrow \mathbf{y}_0 = \begin{Bmatrix} -2.6154 \\ -1.3077 \end{Bmatrix} - \begin{Bmatrix} 2 \\ -4 \end{Bmatrix} = \begin{Bmatrix} -4.6154 \\ 2.6923 \end{Bmatrix} \Rightarrow \mathbf{p}_0^T \mathbf{y}_0 = 0.96127 \text{ e}$$

$$\mathbf{p}_0^T \mathbf{y}_0 = \begin{Bmatrix} -0.0961 \\ 0.1923 \end{Bmatrix} \begin{Bmatrix} -4.6154 & 2.6923 \end{Bmatrix} = \begin{bmatrix} 0.44354 & -0.25873 \\ -0.88754 & 0.51773 \end{bmatrix} \Rightarrow$$

$$\Rightarrow \mathbf{B}_1 = \left( \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \frac{1}{0.96127} \begin{bmatrix} 0.44354 & -0.25873 \\ -0.88754 & 0.51773 \end{bmatrix} \right) \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \left( \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \frac{1}{0.96127} \begin{bmatrix} 0.44354 & -0.88754 \\ -0.25873 & 0.51773 \end{bmatrix} \right)$$

$$+ \frac{1}{0.96127} \begin{bmatrix} 0.00923 & -0.01848 \\ -0.01848 & 0.03698 \end{bmatrix} = \begin{bmatrix} 0.37213 & 0.60225 \\ 0.60225 & 1.10385 \end{bmatrix} \Rightarrow \mathbf{s}_1 = - \begin{bmatrix} 0.37213 & 0.60225 \\ 0.60225 & 1.10385 \end{bmatrix} \begin{Bmatrix} -2.6154 \\ -1.3077 \end{Bmatrix} =$$

$$= \begin{Bmatrix} 1.7608 \\ 3.0186 \end{Bmatrix} \Rightarrow \mathbf{x}_2 = \begin{Bmatrix} -1.0961 \\ -1.8077 \end{Bmatrix} + \alpha_2 \begin{Bmatrix} 1.7608 \\ 3.0186 \end{Bmatrix} \Rightarrow \mathbf{x}_2 = \begin{Bmatrix} -0.3333 \\ -0.5 \end{Bmatrix} \text{ e } \nabla f(\mathbf{x}_2) \equiv \begin{Bmatrix} 0 \\ 0 \end{Bmatrix} \text{ (convergência)}$$

$$\text{Verifica-se que: } \mathbf{B}_2 = \begin{bmatrix} 0.1667 & 0.25 \\ 0.25 & 0.5 \end{bmatrix} = \mathbf{Q}^{-1}$$

Prof. Dr. Emilio C. Nelli Silva

## Utilização do SCILAB

18

Rotina SCILAB para resolver problemas sem restrição: **OPTIM**

[f,[xopt,[gradopt,[work]]]] = optim(costf,[contr],x0,['algo'],[df0,[mem]],  
[work],[stop],[in']) resolve o problema:

$$\begin{array}{l} \text{Min costf}(\mathbf{x}) \\ \mathbf{x} \\ \text{tal que } \mathbf{b}_1 \leq \mathbf{x} \leq \mathbf{b}_s \end{array}$$

- costf - função a ser minimizada
- $\mathbf{x}_{\text{opt}}$  - vetor da solução ótima;
- $\mathbf{x}_0$  - chute inicial de  $\mathbf{x}$ ;
- f - valor ótimo da função;
- contr - 'b',  $\mathbf{b}_1$ ,  $\mathbf{b}_s$ ;
- algo - 'qn' (Quasi-Newton); 'gc' (gradientes conjugados); 'nd' (não-diferenciável - método de ordem zero);

Prof. Dr. Emilio C. Nelli Silva

## Utilização do SCILAB

19

- mem - número de variáveis usadas na aproximação da matriz Hessiana;
- stop - 'ar' (palavra chave); 'nap' (máximo número de chamadas da função); 'iter' (máximo número de iterações permitida); 'epsg' (valor de corte na norma do gradiente); 'epsf' (valor de corte na variação de costf); 'epsx' (vetor com valores de corte para  $\mathbf{x}$ );
- gradopt - gradiente de costf é fornecido;
- work - vetor para 'restart';

Prof. Dr. Emilio C. Nelli Silva

## Algoritmos de Otimização Não-lineares Sem Restrições <sup>20</sup>

Algumas considerações:

- Solução de Sistemas de Equações Lineares e Não-lineares:

Condição necessária na minimização da energia potencial  $\Rightarrow$  Gradiente da energia é nulo  $\Rightarrow \nabla f(\mathbf{x}) = \mathbf{g}(\mathbf{x}) = 0$

Problema equivalente a:  $\text{Min } f = \frac{1}{2} \mathbf{g}^T \mathbf{g}$  ou seja:  
 $\mathbf{Ax} = \mathbf{b} \equiv \text{Min } \frac{1}{2} (\mathbf{Ax} - \mathbf{b})^T (\mathbf{Ax} - \mathbf{b})$

Na análise não-linear estrutural são obtidos as posições de equilíbrio estáveis e instáveis (se o método não convergir para um mínimo local)

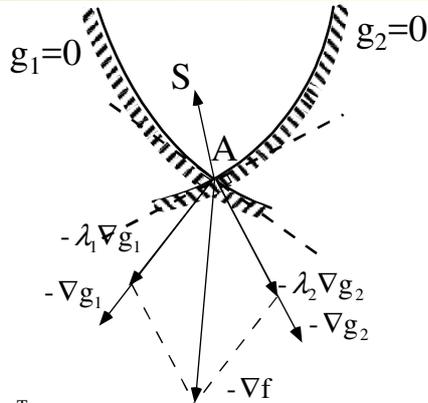
- Algoritmos Probabilísticos:

- \* buscam o mínimo global
- \* ferramentas poderosas para problemas com variáveis discretas
- \* utilizam processo de busca randômica guiada por decisões probabilísticas.

Prof. Dr. Emilio C. Nelli Silva

## Condições KKT de Optimalidade

21



$$s^T \nabla g_j \geq 0 \text{ (direção viável)}$$

$$s^T \nabla f < 0 \text{ (direção útil)}$$

$$\text{Como } s^T \nabla f = \sum_{j=1}^{n_g} \lambda_j s^T \nabla g_j \Rightarrow$$

$$\Rightarrow s^T \nabla f < 0 \text{ é impossível se } \lambda_j \geq 0$$

$x^*$  é mínimo local se:

$$L(x, \lambda) = f(x) - \sum_{j=1}^{n_g} \lambda_j (g_j - t_j^2) \Rightarrow$$

$$1. x^* \text{ é viável} \Rightarrow g_j(x^*) \leq 0 \quad j = 1, n_g$$

$$2. \nabla f(x^*) - \sum_{j=1}^{n_g} \lambda_j^* \nabla g_j(x^*) = 0;$$

$$\lambda_j^* \geq 0;$$

$$3. \lambda_j^* g_j(x^*) = 0 \Rightarrow \therefore \text{ se } \lambda_j = 0 \Rightarrow \\ \Rightarrow g_j \text{ não está ativo}$$

Caso particular:

$$s^T \nabla f = s^T \nabla g_j = 0 \Rightarrow \text{altas derivadas}$$

$\perp$  gradiente      tangente à  
    restrição

Prof. Dr. Emilio C. Nelli Silva

## Condições KKT de Optimalidade

22

KKT são condições necessárias porém não suficientes para optimalidade

KKT é condição suficiente quando:

- se  $n_{\text{restrições ativas}} = n_{\text{variáveis}}$ :

$n$  direções linearmente independentes

$$s^T \nabla g_j = 0 \quad \text{única solução: } s = 0$$

$n$  equações linearmente independentes

Obs.: restrições ativas com gradientes linearmente independentes.

- se  $n_{\text{restrições ativas}} \neq n_{\text{variáveis}}$ : condição de suficiência necessita de altas derivadas  $\Rightarrow$  matriz Hessiana deve ser positiva-definida:

$$s^T (\nabla^2 L) s > 0 \text{ para todo } s \text{ tal que } s^T \nabla g_j = 0 \text{ (restrições ativas com } \lambda_j > 0)$$

- Problemas Convexos

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

23

$\text{Min } f = -x_1^3 - 2x_2^2 + 10x_1 - 6 - 2x_2^3$   
 $x_1, x_2$   
 tal que  $g_1 = 10 - x_1x_2 \geq 0$   
 $g_2 = x_1 \geq 0$   
 $g_3 = 10 - x_2 \geq 0$

**Solução: Condições KKT:**

$$L = -x_1^3 - 2x_2^2 + 10x_1 - 6 - 2x_2^3 - \lambda_1(10 - x_1x_2) - \lambda_2x_1 + \lambda_3(10 - x_2)$$

$$\frac{\partial f}{\partial x_1} + \lambda_1 \frac{\partial g_1}{\partial x_1} + \lambda_2 \frac{\partial g_2}{\partial x_1} = -3x_1^2 + 10 + \lambda_1x_2 - \lambda_2 = 0$$

$$\frac{\partial f}{\partial x_2} + \lambda_1 \frac{\partial g_1}{\partial x_2} + \lambda_3 \frac{\partial g_3}{\partial x_2} = -4x_2 - 6x_2^2 + \lambda_1x_1 - \lambda_3 = 0$$

Casos possíveis a serem analisados:

$\lambda_1 \quad \lambda_2 \quad \lambda_3$

Caso 1:  $\begin{bmatrix} 0 & 0 & 0 \end{bmatrix}$

Caso 2:  $\begin{bmatrix} \neq 0 & 0 & \neq 0 \end{bmatrix}$

Caso 3:  $\begin{bmatrix} \neq 0 & 0 & 0 \end{bmatrix}$

Caso 4:  $\begin{bmatrix} 0 & \neq 0 & 0 \end{bmatrix}$

Caso 5:  $\begin{bmatrix} 0 & 0 & \neq 0 \end{bmatrix}$

Caso 6:  $\begin{bmatrix} 0 & \neq 0 & \neq 0 \end{bmatrix}$

Caso 7:  $\begin{bmatrix} \neq 0 & \neq 0 & \neq 0 \end{bmatrix}$

$n$  restrições ativas  $\neq n$  variáveis ?

**Matrix Hessiana:**

$$\frac{\partial^2 L}{\partial x_1^2} = -6x_1; \quad \frac{\partial^2 L}{\partial x_2^2} = -4 - 12x_2;$$

$$\frac{\partial^2 L}{\partial x_1 \partial x_2} = -\lambda_1 = \frac{\partial^2 L}{\partial x_2 \partial x_1} \Rightarrow \nabla^2 L = \begin{bmatrix} -6x_1 & -\lambda_1 \\ -\lambda_1 & -4 - 12x_2 \end{bmatrix}$$

→ Não é possível

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

24

Caso 1:  $x_1 = 1,826; x_2 = 0 \Rightarrow f = 6,17 \Rightarrow \nabla^2 L = \begin{bmatrix} -6x_1 & \lambda_1 \\ \lambda_1 & -4 - 12x_2 \end{bmatrix}$  negativa definida → Ponto de máximo

Caso 2:  $x_1 = 1; x_2 = 10; \lambda_1 = -0,7; \lambda_3 = 639,3$  **Nem mínimo, nem máximo**

Caso 3:  $\begin{cases} -3x_1^2 + 10 + \lambda_1x_2 = 0 \\ -4x_2 - 6x_2^2 + \lambda_1x_1 = 0 \\ x_1x_2 = 10 \end{cases} \Rightarrow \begin{matrix} x_1 = 3,847 \\ x_2 = 2,599 \\ \lambda_1 = 13,24 \end{matrix} \Rightarrow \nabla^2 L = \begin{bmatrix} -23,08 & 13,24 \\ 13,24 & -35,19 \end{bmatrix}$  negativa definida

$f = -73,08$

Caso 4:  $\begin{cases} -3x_1^2 + 10 - \lambda_2 = 0 \\ -4x_2 - 6x_2^2 = 0 \end{cases} \Rightarrow \begin{matrix} x_1 = 0 & x_2 = 0 & \lambda_2 = 10 & f = -6 \\ x_1 = 0 & x_2 = -2/3 & \lambda_2 = 10 & f = -6,99 \end{matrix}$   $\Rightarrow s^T \nabla^2 L s < 0$   
Não é mínimo

Caso 5:  $\begin{cases} -3x_1^2 + 10 = 0 \\ -4x_2 - 6x_2^2 - \lambda_3 = 0 \end{cases} \Rightarrow x_1 = 1,826 \quad x_2 = 10 \quad \lambda_3 = 640 \quad f = -2194 \Rightarrow \nabla^2 L$  negativa definida

Caso 6:  $x_1 = 0; x_2 = 10; \lambda_2 = 10; \lambda_3 = 640; f = -2206$  KKT é satisfeita e n° de restrições ativas = n° de variáveis de projeto

Prof. Dr. Emilio C. Nelli Silva

## Cálculo dos Multiplicadores de Lagrange

25

Importante para verificação das condições KKT da solução ótima.

Seja a condição necessária de optimalidade:  $\nabla f - \mathbf{N}\lambda = 0$

onde:  $n_{ij} = \frac{\partial g_j}{\partial x_i}$   $j = 1, \dots, r$  (restrição ativas)

$i = 1, \dots, n$  (número de variáveis de projeto)

$r < n \Rightarrow n^\circ \text{ de incógnitas } (\lambda) < n^\circ \text{ de equações}$

Solução: Mínimos Quadrados

$$u = \mathbf{N}\lambda - \nabla f \Rightarrow \text{Min } \|u\|^2 = (\mathbf{N}\lambda - \nabla f)^T (\mathbf{N}\lambda - \nabla f) \Rightarrow$$

$$\Rightarrow 2\mathbf{N}^T \mathbf{N}\lambda - 2\mathbf{N}^T \nabla f = 0 \Rightarrow \lambda = (\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T \nabla f$$

Se a condição de estacionaridade é satisfeita a solução será exata, assim:

$$\mathbf{P}\nabla f = 0, \quad \text{onde } \mathbf{P} = \mathbf{I} - \mathbf{N}(\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T$$

$\mathbf{P}$  - Matriz de Projeção

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

26

Min  $f = x_1 + x_2 + x_3$   
 $x_1, x_2, x_3$   
 tal que  $g_1 = 8 - x_1^2 - x_2^2 \geq 0$   
 $g_2 = x_3 - 4 \geq 0$   
 $g_3 = x_2 + 8 \geq 0$

Checar se  $(-2, -2, 4)$  é mínimo local:

$$g_1 = 0; \quad g_2 = 0; \quad g_3 = 6 \Rightarrow$$

$$\left. \begin{aligned} \frac{\partial g_1}{\partial x_1} = -2x_1 = 4; \quad \frac{\partial g_1}{\partial x_2} = -2x_2 = 4; \quad \frac{\partial g_1}{\partial x_3} = 0 \\ \frac{\partial g_2}{\partial x_1} = 0; \quad \frac{\partial g_2}{\partial x_2} = 0; \quad \frac{\partial g_2}{\partial x_3} = 1 \end{aligned} \right\} \Rightarrow \mathbf{N} = \begin{bmatrix} 4 & 0 \\ 4 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\frac{\partial f}{\partial x_1} = \frac{\partial f}{\partial x_2} = \frac{\partial f}{\partial x_3} = 1 \Rightarrow \nabla f = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}; \quad \mathbf{N}^T \mathbf{N} = \begin{bmatrix} 32 & 0 \\ 0 & 1 \end{bmatrix}; \quad \mathbf{N}^T \nabla f = \begin{bmatrix} 8 \\ 1 \end{bmatrix} \Rightarrow \lambda = (\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T \nabla f = \begin{bmatrix} 1/4 \\ 4 \end{bmatrix}$$

$\mathbf{P}\nabla f = [\mathbf{I} - \mathbf{N}(\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T] \nabla f = 0$  e todos os multiplicadores de Lagrange são positivos, mas como  $r \neq n \Rightarrow$  matriz Hessiana

Note que:

deve ser obtida para verificar KKT

$$\nabla f - \mathbf{N}\lambda = 0 \Rightarrow \left. \begin{aligned} 1 - 4\lambda_1 = 0 \\ 1 - 4\lambda_1 = 0 \\ 1 - \lambda_2 = 0 \end{aligned} \right\} \text{linearmente dependentes}$$

Prof. Dr. Emilio C. Nelli Silva

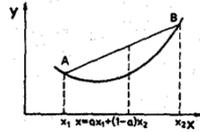
# Problemas Convexos

27

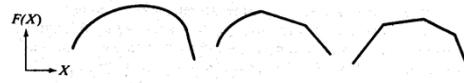
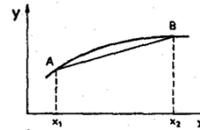
Problema convexo  $\Rightarrow$  Função objetivo e domínio viável são convexos

## Função Convexa

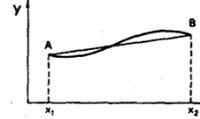
$$f[\alpha x_2 + (1-\alpha)x_1] \leq \alpha f(x_2) + (1-\alpha)f(x_1), \quad 0 < \alpha < 1 \quad \text{Exemplos:}$$



Funções Convexas



Funções Côncavas



Funções nem convexas nem côncavas

Função Convexa  $\Rightarrow$  Matriz Hessiana é positiva semi-definida;

Função Côncava  $\Rightarrow$  Matriz Hessiana é negativa semi-definida;

Função Linear é convexa.

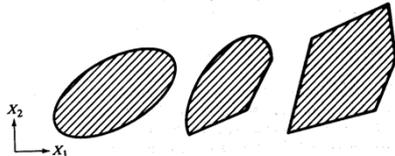
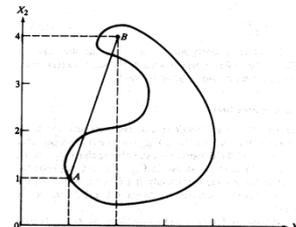
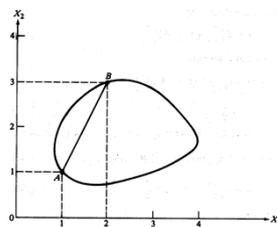
Prof. Dr. Emilio C. Nelli Silva

# Problemas Convexos

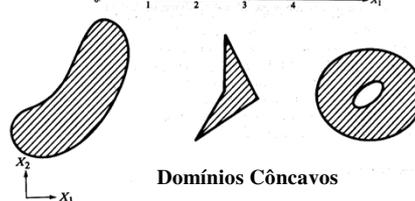
28

## Domínio Convexo

Seja:  $w = \alpha x_2 + (1-\alpha)x_1, \quad 0 < \alpha < 1$  Se  $w \in \text{domínio}$  para  $\forall x_1, x_2 \Rightarrow \text{domínio é convexo}$



Domínios Convexos



Domínios Côncavos

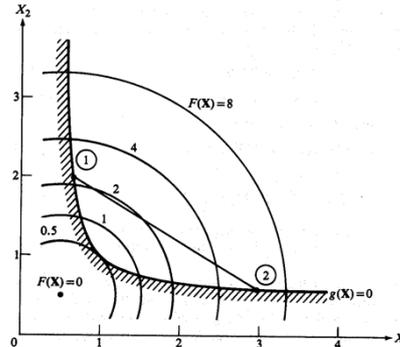
Domínio é convexo se  $\left\{ \begin{array}{l} \text{Todas as restrições de desigualdade são côncavas} \\ \text{Todas as restrições de igualdade são lineares} \end{array} \right.$

Prof. Dr. Emilio C. Nelli Silva

# Problemas Convexos

29

Exemplo de Problema Convexo:



**Vantagem** dos problemas convexos:

- Ótimo Global
- KKT são também condições suficientes

A maior parte dos problemas são não convexos ➡ aproximados por uma série de problemas convexos, por exemplo, programação linear.

Prof. Dr. Emilio C. Nelli Silva

# Exemplo

30

Verificar se o problema é convexo:

$$\begin{aligned} \text{Min}_{x_1, x_2} \quad & f = 3x_1 + \sqrt{3}x_2 \\ \text{tal que} \quad & g_1 = 3 - \frac{18}{x_1} - \frac{6\sqrt{3}}{x_2} \geq 0 \\ & g_2 = x_1 - 5,73 \geq 0 \\ & g_3 = x_2 - 7,17 \geq 0 \end{aligned}$$

$f, g_2, g_3 \Rightarrow$  Funções Lineares

Função  $g_1$ : Matriz Hessiana vale  $A_1 = \begin{bmatrix} -36/x_1^3 & 0 \\ 0 & -12\sqrt{3}/x_2^3 \end{bmatrix}$

Assim a matriz Hessiana é negativa definida ➡  $g_1$  é côncava

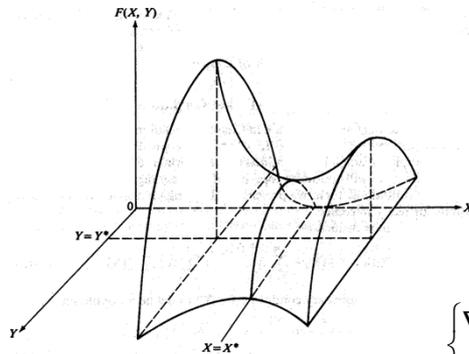
Portanto como a função objetivo é linear (convexa) e as restrições são lineares ou côncavas (domínio convexo) ➡ problema é convexo.

Assim, KKT são condições suficientes para o mínimo.

Prof. Dr. Emilio C. Nelli Silva

## Ponto Sela (“Saddle Point”)

31



Uma função  $F(\mathbf{x}, \mathbf{y})$  possui ponto “sela” se:

$$F(\mathbf{x}^*, \mathbf{y}) \leq F(\mathbf{x}^*, \mathbf{y}^*) \leq F(\mathbf{x}, \mathbf{y}^*)$$

$$F(\mathbf{x}^*, \mathbf{y}^*) \begin{cases} \text{mínimo em } \mathbf{x} \\ \text{máximo em } \mathbf{y} \end{cases}$$

No caso da função

Lagrangeana:  $L(\mathbf{x}^*, \lambda^*)$

$$\begin{cases} \nabla_{\mathbf{x}} L(\mathbf{x}^*, \lambda^*) = 0 \\ \nabla_{\lambda} L(\mathbf{x}^*, \lambda^*) = 0 \end{cases} \text{ e } \begin{cases} \nabla_{\lambda} L(\mathbf{x}^*, \lambda) \leq 0 \\ \nabla_{\mathbf{x}} L(\mathbf{x}, \lambda^*) \geq 0 \end{cases}$$

Solução do Ponto Sela  $\rightarrow$  Problema Min Max:

$$L(\lambda) = \min_{\mathbf{x}} L(\mathbf{x}, \lambda) \Rightarrow \max_{\lambda} L(\lambda) = \max_{\lambda} \min_{\mathbf{x}} L(\mathbf{x}, \lambda)$$

ou:

$$L(\mathbf{x}) = \max_{\lambda} L(\mathbf{x}, \lambda) \Rightarrow \min_{\mathbf{x}} L(\mathbf{x}) = \min_{\mathbf{x}} \max_{\lambda} L(\mathbf{x}, \lambda)$$

$$\max_{\lambda} \min_{\mathbf{x}} L(\mathbf{x}, \lambda) \equiv \min_{\mathbf{x}} \max_{\lambda} L(\mathbf{x}, \lambda)$$

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

32

Ex.:

$$\begin{aligned} &\text{Min}_{\mathbf{x}} \frac{1}{\mathbf{x}} \\ &\text{tal que } \mathbf{x} - 1 \leq 0 \\ &\mathbf{x} \geq 0 \end{aligned}$$

O Lagrangeano do problema vale:

$$L(\mathbf{x}, \lambda) = \frac{1}{\mathbf{x}} + \lambda(\mathbf{x} - 1)$$

Calculando o mínimo em  $\mathbf{x}$ :  $\nabla_{\mathbf{x}} L(\mathbf{x}, \lambda) = 0 \Rightarrow -\frac{1}{\mathbf{x}^2} + \lambda = 0 \Rightarrow$

$$\Rightarrow \mathbf{x} = \pm \frac{1}{\sqrt{\lambda}} \text{ (mas } \mathbf{x} \geq 0) \Rightarrow \mathbf{x} = \frac{1}{\sqrt{\lambda}} \Rightarrow L(\lambda) = \sqrt{\lambda} + \lambda \left( \frac{1}{\sqrt{\lambda}} - 1 \right) = 2\sqrt{\lambda} - \lambda$$

Calculando o máximo em  $\lambda$ :  $\nabla_{\lambda} L(\lambda) = \frac{1}{\sqrt{\lambda}} - 1 \Rightarrow \lambda^* = 1 \Rightarrow \mathbf{x}^* = 1$

Ponto “Sela”:  $\therefore (\mathbf{x}^*, \lambda^*) = (1, 1)$

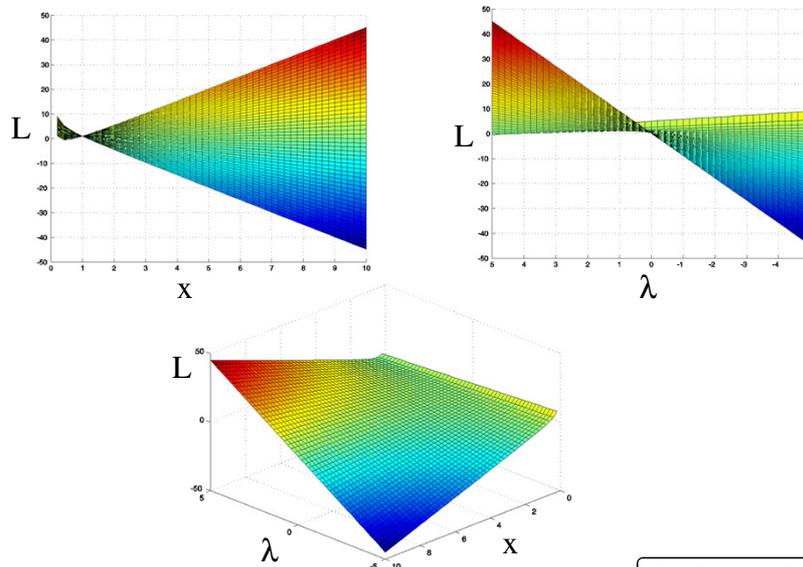
Os gradientes devem ser contínuos em  $\mathbf{x}$  e  $\lambda$ , caso contrário, outra abordagem de solução para o problema Min Max deve ser utilizada.

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

33

Plotagem da função Lagrangeana:



Prof. Dr. Emilio C. Nelli Silva

## Dualidade

34

“Primal”

$$\begin{aligned} \text{Min } f_p &= \mathbf{c}^T \mathbf{x} \\ \text{tal que } \mathbf{Ax} &\leq \mathbf{b} \\ \mathbf{x} &\geq \mathbf{0} \end{aligned}$$

m restrições  
n variáveis de projeto  
 $m > n$

$\equiv$

$$f_{p \min} = f_{D \max}$$

“Dual”

$$\begin{aligned} \text{Max } f_D &= -\boldsymbol{\lambda}^T \mathbf{b} \\ \text{tal que } \mathbf{A}^T \boldsymbol{\lambda} &\geq -\mathbf{c} \\ \boldsymbol{\lambda} &\geq \mathbf{0} \end{aligned}$$

n restrições  
m variáveis de projeto  
 $m > n$

Demonstração:

$$\begin{aligned} L(\mathbf{x}, \boldsymbol{\lambda}) &= \mathbf{c}^T \mathbf{x} + \boldsymbol{\lambda}^T \{\mathbf{Ax} - \mathbf{b}\} \Rightarrow \nabla_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\lambda}) = \mathbf{c} + \mathbf{A}^T \boldsymbol{\lambda} \stackrel{\substack{\uparrow \\ \mathbf{x}^* \text{ é mínimo}}}{\geq \mathbf{0}} \Rightarrow \mathbf{c} \mathbf{x}^* + \boldsymbol{\lambda}^T \mathbf{Ax}^* = 0 \Rightarrow \\ L(\boldsymbol{\lambda}) &= -\boldsymbol{\lambda}^T \mathbf{b} \text{ deve ser maximizada } \Rightarrow \text{problema “Dual” e: } f(\mathbf{x}^*) = L(\boldsymbol{\lambda}^*) \end{aligned}$$

Se:  $\lambda_j \neq 0 \Rightarrow j^{\text{ésima}}$  restrição é ativa no problema “primal”  
 $\lambda_j = 0 \Rightarrow j^{\text{ésima}}$  restrição é inativa no problema “primal”

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

35

$$\text{Min } f = -4x_1 - x_2 + 50$$

$$\begin{array}{l} x_1, x_2 \\ \text{tal que} \\ x_1 - x_2 \leq 2 \\ x_1 + 2x_2 \leq 8 \\ x_1 + x_2 \leq 10 \\ -5x_1 + x_2 \leq 5 \\ x_1 \geq 0; \quad x_2 \geq 0 \end{array}$$

$$\Rightarrow \mathbf{c} = \begin{Bmatrix} -4 \\ -1 \end{Bmatrix}; \mathbf{A} = \begin{Bmatrix} 1 & -1 \\ 1 & 2 \\ 1 & 1 \\ -5 & 1 \end{Bmatrix}; \mathbf{b} = \begin{Bmatrix} 2 \\ 8 \\ 10 \\ 5 \end{Bmatrix} \Rightarrow$$

$$\text{Max } L = -2\lambda_1 - 8\lambda_2 - 10\lambda_3 - 5\lambda_4 + 50$$

$$\begin{array}{l} \lambda_1, \lambda_2, \lambda_3, \lambda_4 \\ \text{tal que} \\ \lambda_1 + \lambda_2 + \lambda_3 - 5\lambda_4 \geq 4 \\ -\lambda_1 + 2\lambda_2 + \lambda_3 + \lambda_4 \geq 1 \\ \lambda_i \geq 0; \quad i=1,4 \end{array}$$

$$\Rightarrow \lambda^* = \begin{Bmatrix} 7/3 \\ 5/3 \\ 0 \\ 0 \end{Bmatrix} \Rightarrow L(\lambda^*) = 32 \Rightarrow$$

$$\Rightarrow \nabla_x L(\mathbf{x}^*, \lambda^*) = \mathbf{c} + \mathbf{A}^T \lambda = 0 \Rightarrow \begin{Bmatrix} -4 \\ -1 \end{Bmatrix} + \begin{bmatrix} 1 & 1 & 1 & -5 \\ -1 & 2 & 1 & 1 \end{bmatrix} \begin{Bmatrix} 7/3 \\ 5/3 \\ 0 \\ 0 \end{Bmatrix} = \begin{Bmatrix} 0 \\ 0 \end{Bmatrix} \Rightarrow \mathbf{x}^* = \begin{Bmatrix} 4 \\ 2 \end{Bmatrix} \Rightarrow f(\mathbf{x}^*) = 32$$

$$x_1^* - x_2^* = 2; \quad x_1^* + 2x_2^* = 8$$

Prof. Dr. Emilio C. Nelli Silva

## Programação Quadrática

36

Um problema de Programação Quadrática é definido como:

$$\begin{array}{l} \text{Min } F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b} \mathbf{x} \\ \text{tal que } \mathbf{B} \mathbf{x} \leq \mathbf{c} \\ \mathbf{x} \geq \mathbf{0} \end{array}$$

Matriz Hessiana

Suponha  
n variáveis de projeto  
e m restrições

O Lagrangeano do problema é igual à:

$$L(\mathbf{x}, \lambda) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b} \mathbf{x} + \lambda^T (\mathbf{B} \mathbf{x} - \mathbf{c}) \Rightarrow \nabla_x L(\mathbf{x}, \lambda) = \mathbf{A} \mathbf{x} + \mathbf{b} + \mathbf{B}^T \lambda = 0 \Rightarrow$$

$$\Rightarrow \mathbf{x} = -\mathbf{A}^{-1} (\mathbf{b} + \mathbf{B}^T \lambda) \Rightarrow L(\lambda) = -\frac{1}{2} \lambda^T \mathbf{D} \lambda - \mathbf{d} \cdot \lambda - \frac{1}{2} \mathbf{b}^T \mathbf{A}^{-1} \mathbf{b} \rightarrow \text{Termo constante}$$

onde:  $\mathbf{D} = \mathbf{B} \mathbf{A}^{-1} \mathbf{B}^T$  e  $\mathbf{d} = \mathbf{c} + \mathbf{B} \mathbf{A}^{-1} \mathbf{b}$

Assim resolve-se o novo problema usando o conceito da dualidade:

$$\begin{array}{l} \text{Max } L(\lambda) = -\frac{1}{2} \lambda^T \mathbf{D} \lambda - \mathbf{d} \cdot \lambda \\ \lambda \\ (\lambda \geq \mathbf{0}) \end{array}$$

m variáveis de projeto  
com simples restrições

Prof. Dr. Emilio C. Nelli Silva

## Utilização do SCILAB

37

Rotina SCILAB para resolver programação quadrática: **QUAPRO**

$[x, \text{lagr}, f] = \text{quapro}(Q, p, C, b, ci, cs, mi, x_0)$  resolve o problema:

matriz simétrica (nxn)

$$\text{Min}_x f = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{p}^T \mathbf{x}$$

tal que  $\mathbf{C}_1 \mathbf{x} = \mathbf{b}_1$   
 $(m_1 \times n)$

$$\mathbf{C}_2 \mathbf{x} \leq \mathbf{b}_2$$

$$(m_d \times n)$$

$$\mathbf{c}_i \leq \mathbf{x} \leq \mathbf{c}_s$$

$$\mathbf{C} = [\mathbf{C}_1, \mathbf{C}_2]$$

$$(m_i + m_d) \times n$$

$$\mathbf{b} = [\mathbf{b}_1, \mathbf{b}_2]$$

$$1 \times (m_i + m_d)$$

- $x$  - vetor da solução ótima;
- $\text{lagr}$  - vetor de multiplicadores de Lagrange ( $n+m_i+m_d$ ). Se o valor de um multiplicador é zero, a restrição correspondente está inativa, caso contrário está ativa no ponto ótimo;
- $f$  - valor ótimo da função;
- $m_i$  - número de restrições de igualdade;
- $x_0$  - chute inicial de  $x$ ; ou “ $x_0=v$ ” o cálculo é iniciado num vértice do domínio; ou “ $x_0=g$ ” o valor inicial é arbitrário;

Prof. Dr. Emilio C. Nelli Silva

## Algoritmos de Otimização Não-lineares Com Restrições

38

- Classificação
- Métodos Diretos  $\Rightarrow$  verificam as restrições após seguirem o procedimento do algoritmo de otimização sem restrição.  
Ex.: Método das Projeções do Gradiente e dos Gradientes Reduzidos e Método das Direções Viáveis
  - Métodos Indiretos  $\Rightarrow$  transformam o problema com restrição num problema sem restrição.  
Ex.: Métodos de Penalização e Método de Lagrange Aumentado

Prof. Dr. Emilio C. Nelli Silva

Método das Projeções do Gradientes e dos Gradientes Reduzidos

1) Inicialmente consideremos restrições lineares:

$$\begin{aligned} & \text{Min}_{\mathbf{x}} f(\mathbf{x}) \\ & \text{tal que } \mathbf{g}_j = \mathbf{a}_j^T \mathbf{x} - \mathbf{b}_j \geq 0 \\ & \quad j=1, \dots, n_g \end{aligned}$$

Considerando  $r$  restrições ativas:  
 $\mathbf{g}_a = \mathbf{N}^T \mathbf{x} - \mathbf{b} = 0$  onde:  $n_{ij} = a_{ij}$   
 Hipótese básica do método:  $\mathbf{x}_{i+1} = \mathbf{x}_i + \alpha \mathbf{s}$   
 Caminha na fronteira das restrições

$\mathbf{x}$  se encontra no subespaço tangente às restrições ativas, assim:  
 $\mathbf{N}^T \mathbf{x}_{i+1} = \mathbf{N}^T \mathbf{x}_i + \alpha \mathbf{N}^T \mathbf{s} \Rightarrow \mathbf{b} = \mathbf{b} + \alpha \mathbf{N}^T \mathbf{s} \Rightarrow \mathbf{N}^T \mathbf{s} = 0$

A direção  $\mathbf{s}$  é obtida através da solução do problema:

$$\begin{aligned} & \text{Min}_{\mathbf{s}} \mathbf{s}^T \nabla f \\ & \text{tal que } \mathbf{N}^T \mathbf{s} = 0 \\ & \quad \mathbf{s}^T \mathbf{s} = 1 \end{aligned}$$

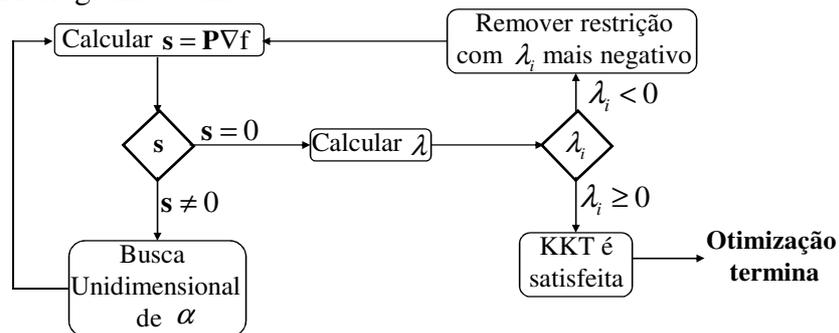
$$\begin{aligned} L &= \mathbf{s}^T \nabla f - \mathbf{s}^T \mathbf{N} \lambda - \mu (\mathbf{s}^T \mathbf{s} - 1) \Rightarrow \frac{\partial L}{\partial \mathbf{s}} = \nabla f - \mathbf{N} \lambda - 2\mu \mathbf{s} = 0 \Rightarrow \\ & \Rightarrow \mathbf{N}^T \nabla f - \mathbf{N}^T \mathbf{N} \lambda = 0 \Rightarrow \lambda = (\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T \nabla f \Rightarrow \\ & \Rightarrow \mathbf{s} = \frac{1}{2\mu} [\mathbf{I} - \mathbf{N}(\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T] \nabla f = \frac{1}{2\mu} \mathbf{P} \nabla f \end{aligned}$$

onde para  $\mathbf{w}$  arbitrário,  $\mathbf{P}\mathbf{w}$  é o subespaço tangente às restrições ativas, pois:  
 $\mathbf{N}^T \mathbf{P}\mathbf{w} = \mathbf{N}^T [\mathbf{I} - \mathbf{N}(\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T] \mathbf{w} = 0$

Prof. Dr. Emilio C. Nelli Silva

Método das Projeções do Gradientes e dos Gradientes Reduzidos 40

Fluxograma do método:



Verificação da violação das restrições:

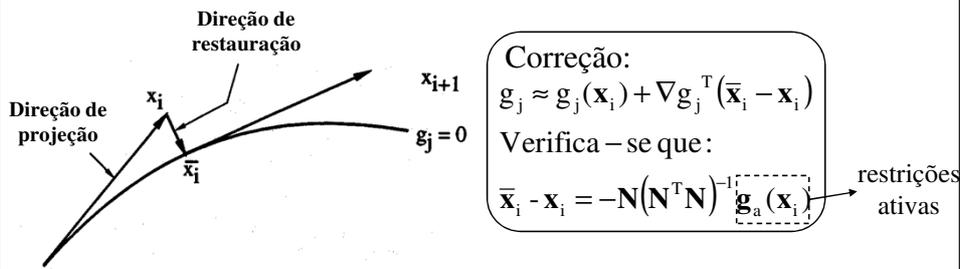
$$\mathbf{g}_j = \mathbf{a}_j^T (\mathbf{x}_i + \alpha \mathbf{s}) - \mathbf{b}_j \geq 0 \Rightarrow \alpha \leq - \frac{(\mathbf{a}_j^T \mathbf{x}_i - \mathbf{b}_j)}{\mathbf{a}_j^T \mathbf{s}} = - \frac{\mathbf{g}_j(\mathbf{x}_i)}{\mathbf{a}_j^T \mathbf{s}}$$

Válido se  $\mathbf{a}_j^T \mathbf{s} < 0$ , caso contrário não há valor limite superior de  $\alpha$  devido à  $j$ -ésima restrição. O valor limite de  $\alpha$  vale:

$$\bar{\alpha} = \min_{\substack{\alpha_j > 0 \\ \text{restr. ativas}}} \alpha_j$$

Prof. Dr. Emilio C. Nelli Silva

2) Considerando restrições não-lineares  
 Lineariza-se a restrição em torno de  $x_i \Rightarrow$  busca unidimensional move para fora da fronteira da restrição  $\Rightarrow$  correção



$\alpha$  é determinado especificando uma redução  $\gamma$  na função objetivo:

$$f(x_i) - f(x_{i+1}) \cong \nabla f^T(x_i - x_{i+1}) \approx \gamma f(x_i) \Rightarrow \alpha^* = -\frac{\gamma f(x_i)}{s^T \nabla f}$$

$$\Rightarrow x_{i+1} = x_i + \alpha^* s - N(N^T N)^{-1} g_a$$

Exemplo

Min  $f = 3x_1 + \sqrt{3}x_2$   
 tal que  $g_1 = 3 - \frac{18}{x_1} - \frac{6\sqrt{3}}{x_2} \geq 0$   
 $g_2 = x_1 - 5.73 \geq 0$   
 $g_3 = x_2 - 7.17 \geq 0$

$x_0 = (11,61; 7,17) \Rightarrow g_1 = 0, g_3 = 0 \Rightarrow f = 47,25 \Rightarrow$   
 $\Rightarrow \nabla f = \begin{Bmatrix} 3 \\ \sqrt{3} \end{Bmatrix}; \nabla g_1 = \begin{Bmatrix} 0,1335 \\ 0,2021 \end{Bmatrix}; \nabla g_3 = \begin{Bmatrix} 0 \\ 1 \end{Bmatrix}; N = \begin{bmatrix} 0,1335 & 0 \\ 0,2021 & 1 \end{bmatrix} \Rightarrow$   
 $\Rightarrow P = 0 \Rightarrow s = 0 \Rightarrow \lambda = \begin{Bmatrix} 22,47 \\ -2,798 \end{Bmatrix} \Rightarrow$  elimina-se  $g_3$ , assim:

$N = \begin{bmatrix} 0,1335 \\ 0,2021 \end{bmatrix} \Rightarrow P = \begin{bmatrix} 0,6962 & -0,46 \\ -0,46 & 0,3036 \end{bmatrix} \Rightarrow s = -P \nabla f = \begin{Bmatrix} -1,29 \\ 0,854 \end{Bmatrix}$

Para 5% de redução na função objetivo ( $\gamma = 0,05$ ):  $\alpha^* = \frac{0,05 \times 47,25}{[-1,29 \ 0,854] \begin{Bmatrix} 3 \\ \sqrt{3} \end{Bmatrix}} = 0,988$

Como não há violação da restrição  $\Rightarrow$  não há correção:

$x_1 = x_0 + \alpha^* s = \begin{Bmatrix} 11,61 \\ 7,17 \end{Bmatrix} + 0,988 \begin{Bmatrix} -1,29 \\ 0,854 \end{Bmatrix} = \begin{Bmatrix} 10,34 \\ 8,01 \end{Bmatrix} \Rightarrow f(x_1) = 44,89;$

$g(x_1) = -0,0382 \Rightarrow$  Restrição  $g_1$  ativa  $\Rightarrow N = \nabla g_1 = \begin{Bmatrix} 0,1684 \\ 0,1620 \end{Bmatrix} \Rightarrow$

$\Rightarrow P = \begin{bmatrix} 0,4806 & -0,4996 \\ -0,4996 & 0,5194 \end{bmatrix} \Rightarrow$

## Exemplo

43

$$\Rightarrow \mathbf{s} = -\mathbf{P}\nabla f = \begin{Bmatrix} -0,5764 \\ 0,5991 \end{Bmatrix}; \gamma = 0,025 \Rightarrow \alpha = -\frac{0,025 \times 44,89}{[-0,5764 \quad 0,5991] \begin{Bmatrix} 3 \\ \sqrt{3} \end{Bmatrix}} = 1,62$$

Como  $g_1$  é violada  $\Rightarrow$  há correção

$$\mathbf{g}_a = -0,0382 \Rightarrow -\mathbf{N}(\mathbf{N}^T\mathbf{N})^{-1}\mathbf{g}_a = \begin{Bmatrix} 0,118 \\ 0,113 \end{Bmatrix} \Rightarrow \mathbf{x}_2 = \mathbf{x}_1 + \alpha^*\mathbf{s} - \mathbf{N}(\mathbf{N}^T\mathbf{N})^{-1}\mathbf{g}_a = \begin{Bmatrix} 10,34 \\ 8,01 \end{Bmatrix} +$$

$$-1,62 \begin{Bmatrix} 0,576 \\ -0,599 \end{Bmatrix} + \begin{Bmatrix} 0,118 \\ 0,113 \end{Bmatrix} = \begin{Bmatrix} 9,52 \\ 9,10 \end{Bmatrix} \Rightarrow f(\mathbf{x}_2) = 44,32; g_1(\mathbf{x}_2) = -0,0328$$

$$\mathbf{x}^* = \begin{Bmatrix} 9,464 \\ 9,464 \end{Bmatrix} \Rightarrow f(\mathbf{x}^*) = 44,78 \quad (\text{Solução Ótima})$$

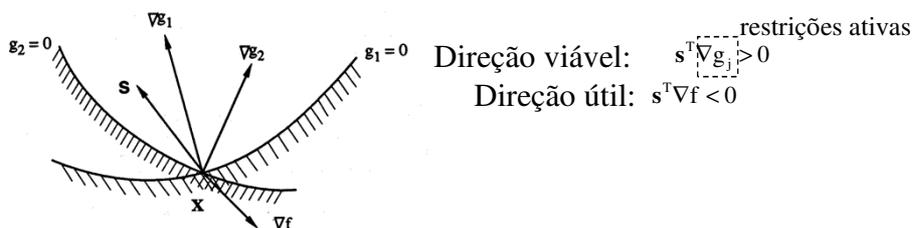
Prof. Dr. Emilio C. Nelli Silva

## Métodos Diretos

44

### Método das Direções Viáveis

Procura-se afastar da fronteira das restrições. Inicia-se na fronteira do domínio viável.



Assim, a direção  $\mathbf{s}$  é obtida através da solução do problema de otimização:

$$\begin{aligned} \text{Min } & \beta \\ \text{tal que } & -\mathbf{s}^T \nabla \mathbf{g}_j + \theta_j \beta \leq 0 \\ & \mathbf{s}^T \nabla f + \beta \leq 0 \quad \theta_j \geq 0 \\ & |s_i| \leq 1 \end{aligned}$$

Programação Linear

Se  $\beta_{\max} = 0 \Rightarrow$  condições KKT são satisfeitas.

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

45

$$\begin{aligned} \text{Min} \quad & f = 3x_1 + \sqrt{3}x_2 \\ \text{tal que} \quad & g_1 = 3 - \frac{18}{x_1} - \frac{6\sqrt{3}}{x_2} \geq 0 \\ & g_2 = x_1 - 5.73 \geq 0 \\ & g_3 = x_2 - 7.17 \geq 0 \end{aligned}$$

$$\mathbf{x}_0^T = (11,61; 7,17) \Rightarrow g_1 = 0, g_3 = 0 \Rightarrow f = 47,25 \Rightarrow$$

$$\Rightarrow \nabla f = \begin{Bmatrix} 3 \\ \sqrt{3} \end{Bmatrix}; \nabla g_1 = \begin{Bmatrix} 0,1335 \\ 0,2021 \end{Bmatrix}; \nabla g_3 = \begin{Bmatrix} 0 \\ 1 \end{Bmatrix}$$

Selecionando  $\theta_1 = \theta_2 = 1$ , tem-se:

$$\begin{aligned} \text{Min} \quad & \beta \\ \text{tal que} \quad & -0,1335s_1 - 0,2021s_2 + \beta \leq 0 \\ & -s_2 + \beta \leq 0 \\ & 3s_1 + \sqrt{3}s_2 + \beta \leq 0 \\ & -1 \leq s_1 \leq 1 \\ & -1 \leq s_2 \leq 1 \end{aligned}$$

Solução:  $s_1 = -0,6172; s_2 = 1 \Rightarrow$

Busca unidimensional:

$$\Rightarrow \mathbf{x}_1 = \begin{Bmatrix} 11,61 \\ 7,17 \end{Bmatrix} + \alpha \begin{Bmatrix} -0,6172 \\ 1 \end{Bmatrix}$$

$\alpha$  é limitado por  $g_1 \Rightarrow \alpha < 5,385 \Rightarrow$

$$\Rightarrow \alpha = 5,385 \Rightarrow \mathbf{x}_1 = \begin{Bmatrix} 8,29 \\ 12,56 \end{Bmatrix} \Rightarrow f(\mathbf{x}_1) = 46,62$$

Próxima iteração (somente  $g_1$  ativo):

$$\nabla_{g_1} = \begin{Bmatrix} -\frac{18}{x_1^2} \\ \frac{6\sqrt{3}}{x_2^2} \end{Bmatrix} = \begin{Bmatrix} 0,2619 \\ 0,0659 \end{Bmatrix};$$

$$\nabla f = \begin{Bmatrix} 3 \\ 3\sqrt{3} \end{Bmatrix}$$

Prof. Dr. Emilio C. Nelli Silva

## Exemplo

46

$$\begin{aligned} \text{Min} \quad & \beta \\ \text{tal que} \quad & -0,2619s_1 - 0,0659s_2 + \beta \leq 0 \\ & 3s_1 + \sqrt{3}s_2 + \beta \leq 0 \\ & -1 \leq s_1 \leq 1 \\ & -1 \leq s_2 \leq 1 \end{aligned}$$

Solução:  $s_1 = 0,5512; s_2 = -1 \Rightarrow$

Busca unidimensional:

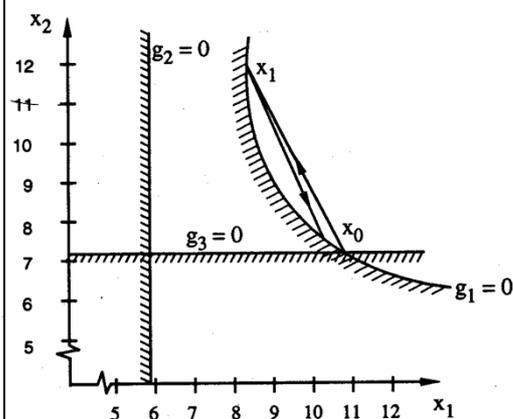
$$\Rightarrow \mathbf{x}_2 = \begin{Bmatrix} 8,29 \\ 12,56 \end{Bmatrix} + \alpha \begin{Bmatrix} 0,5512 \\ -1 \end{Bmatrix}$$

$\alpha$  é limitado por  $g_1 \Rightarrow \alpha < 4,957 \Rightarrow$

$$\Rightarrow \alpha = 4,957 \Rightarrow \mathbf{x}_2 = \begin{Bmatrix} 11,02 \\ 7,60 \end{Bmatrix} \Rightarrow f(\mathbf{x}_2) = 46,22$$

$$\mathbf{x}^* = \begin{Bmatrix} 9,464 \\ 9,464 \end{Bmatrix} \Rightarrow f(\mathbf{x}^*) = 44,78$$

(Solução Ótima)



Prof. Dr. Emilio C. Nelli Silva