

# Otimização Não-Linear Restrita

De forma geral, um problema de otimização pode ser descrito por:

Minimizar  $f(\underline{x})$

Sujeito a  $h(\underline{x}) = 0$

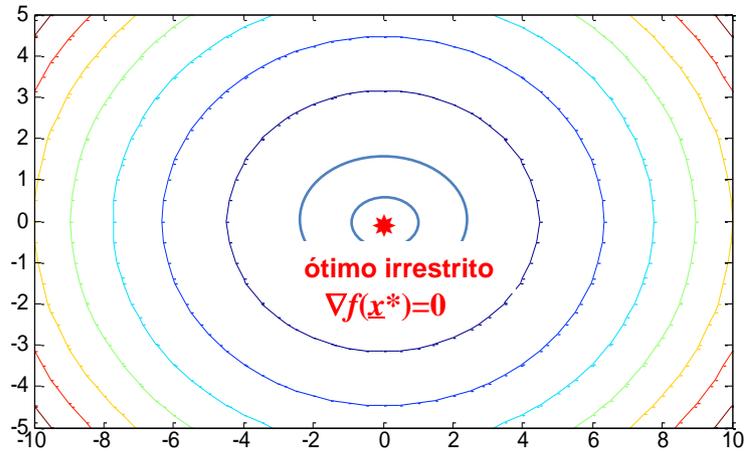
$g(\underline{x}) \leq 0$

$\underline{x} \in \Omega$

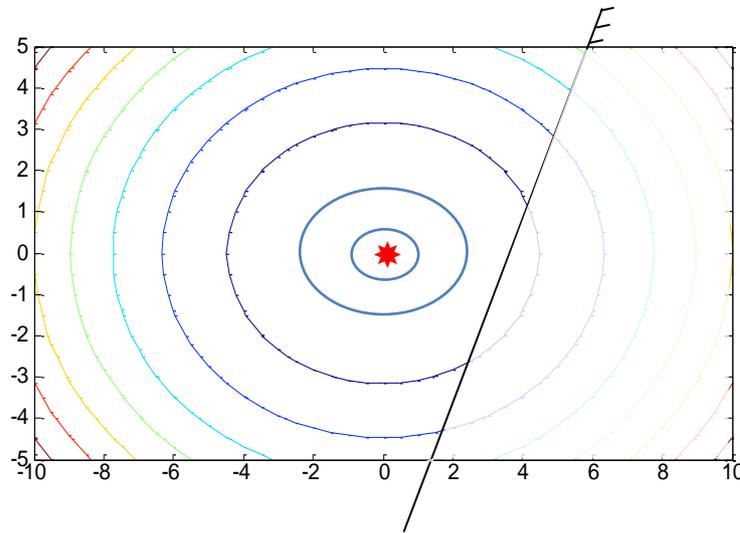
- Assim como visto nos POL, um ponto  $\underline{x} \in \Omega$  que satisfaça as restrições é denominado Ponto Factível (ou Viável).
- No espaço das soluções factíveis, uma restrição de desigualdade pode ser:
  - Ativa, quando  $g_i(\underline{x}) = 0$ , ou;
  - Inativa, quando  $g_i(\underline{x}) < 0$

# Otimização Não-Linear Restrita

## Considerações Gerais



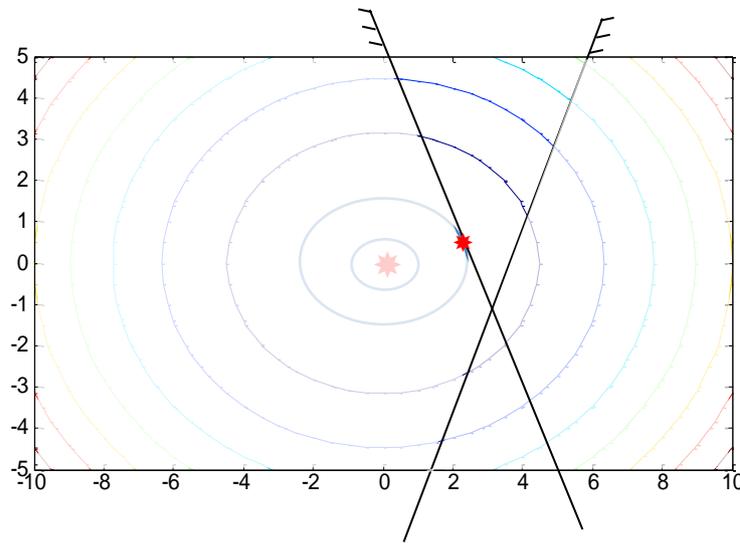
# Otimização Não-Linear Restrita



*Restrição não ativa  $\Rightarrow$  solução não muda*

# Otimização Não-Linear Restrita

## Considerações Gerais

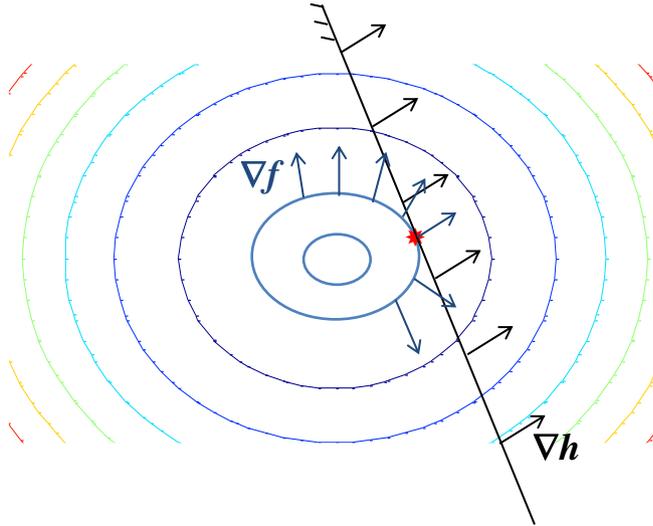


*Restrição ativa  $\Rightarrow$  solução muda (e ocorre sobre a restrição)*

*$\hookrightarrow$  logo, restrição de  $\leq$  se torna de  $=$*

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem (considerando restrições de igualdade):



Obs.: no ótimo  $\nabla h$  é colinear a  $\nabla f$

Teorema de Lagrange:

Seja  $\underline{x}^*$  um ponto extremo de  $f(\underline{x})$  sujeito às restrições  $h(\underline{x})$ . Então, existe um vetor  $\underline{\lambda}$  tal que:

$$\nabla f(\underline{x}^*) + \underline{\lambda}^t \cdot \nabla h(\underline{x}^*) = 0 \quad \Longrightarrow \quad \nabla [f(\underline{x}^*) + \underline{\lambda}^t \cdot h(\underline{x}^*)] = 0$$

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem (considerando restrições de igualdade):

Assim, as condições necessárias de 1ª ordem, considerando restrições de igualdade são dadas por:

$$\left\{ \begin{array}{l} \nabla \left( f(\underline{x}) + \underline{\lambda}^t \cdot \underline{h}(\underline{x}) \right) = \underline{0} \\ \underline{h}(\underline{x}) = \underline{0} \end{array} \right. \Rightarrow \left\{ \begin{array}{l} \nabla \mathcal{L}(\underline{x}, \underline{\lambda}) = \underline{0} \\ \underline{h}(\underline{x}) = \underline{0} \end{array} \right.$$

Logo, define-se a **Função Lagrangeana** do problema:

$$\mathcal{L}(\underline{x}, \underline{\lambda}) = f(\underline{x}) + \underline{\lambda}^t \cdot \underline{h}(\underline{x})$$

onde,  $\lambda$  é o *Multiplicador de Lagrange*

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem - Exemplo

$$\text{Min } f(x_1, x_2, x_3) = 400(x_1)^2 + 800(x_2)^2 + 1600(x_3)^2 + 200x_1x_2 + 400x_2x_3$$

$$\text{s.a. } 10x_1 + 10x_2 + 15x_3 = 12$$

$$x_1 + x_2 + x_3 = 1$$

Na forma padrão:

$$\text{Min } f(\underline{x})$$

$$\text{s.a. } h_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12 = 0$$

$$h_2(\underline{x}) = x_1 + x_2 + x_3 - 1 = 0$$

Assim, o Lagrangeano do problema fica:

$$\mathcal{L}(\underline{x}, \underline{\lambda}) = f(x_1, x_2, x_3) + \lambda_1 \cdot h_1(x_1, x_2, x_3) + \lambda_2 \cdot h_2(x_1, x_2, x_3)$$

$$= f(\underline{x}) + [\lambda_1 \quad \lambda_2] \begin{bmatrix} h_1(\underline{x}) \\ h_2(\underline{x}) \end{bmatrix}$$

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem - Exemplo

$$\text{Min } f(x_1, x_2, x_3) = 400(x_1)^2 + 800(x_2)^2 + 1600(x_3)^2 + 200x_1x_2 + 400x_2x_3$$

$$\text{s.a. } h_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12 = 0$$

$$h_2(\underline{x}) = x_1 + x_2 + x_3 - 1 = 0$$

A partir das condições necessárias, chega-se ao seguinte conjunto de equações:

$$\nabla_{\underline{x}} \mathcal{L} = 0 \left\{ \begin{array}{l} \frac{\partial \mathcal{L}}{\partial x_1} = 0 \Rightarrow \frac{\partial f(\underline{x})}{\partial x_1} + \lambda_1 \frac{\partial h_1(\underline{x})}{\partial x_1} + \lambda_2 \frac{\partial h_2(\underline{x})}{\partial x_1} = 800x_1 + 200x_2 + 10\lambda_1 + \lambda_2 = 0 \\ \frac{\partial \mathcal{L}}{\partial x_2} = 0 \Rightarrow \frac{\partial f(\underline{x})}{\partial x_2} + \lambda_1 \frac{\partial h_1(\underline{x})}{\partial x_2} + \lambda_2 \frac{\partial h_2(\underline{x})}{\partial x_2} = 1600x_2 + 200x_1 + 400x_3 + 10\lambda_1 + \lambda_2 = 0 \\ \frac{\partial \mathcal{L}}{\partial x_3} = 0 \Rightarrow \frac{\partial f(\underline{x})}{\partial x_3} + \lambda_1 \frac{\partial h_1(\underline{x})}{\partial x_3} + \lambda_2 \frac{\partial h_2(\underline{x})}{\partial x_3} = 3200x_3 + 400x_2 + 15\lambda_1 + \lambda_2 = 0 \end{array} \right.$$

$$\nabla_{\lambda} \mathcal{L} = 0 \left\{ \begin{array}{l} \frac{\partial \mathcal{L}}{\partial \lambda_1} = 0 \Rightarrow h_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12 = 0 \\ \frac{\partial \mathcal{L}}{\partial \lambda_2} = 0 \Rightarrow h_2(\underline{x}) = x_1 + x_2 + x_3 - 1 = 0 \end{array} \right.$$

(n + m) equações  
a  
(n + m) incógnitas  
n = nº variáveis  
m = nº restrições

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem - Exemplo

$$\text{Min } f(x_1, x_2, x_3) = 400(x_1)^2 + 800(x_2)^2 + 1600(x_3)^2 + 200x_1x_2 + 400x_2x_3$$

$$\text{s.a. } h_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12 = 0$$

$$h_2(\underline{x}) = x_1 + x_2 + x_3 - 1 = 0$$

Resolvendo o sistema de equações resultante:

$$\left\{ \begin{array}{l} 800x_1 + 200x_2 + 10\lambda_1 + \lambda_2 = 0 \\ 200x_1 + 1600x_2 + 400x_3 + 10\lambda_1 + \lambda_2 = 0 \\ 400x_2 + 3200x_3 + 15\lambda_1 + \lambda_2 = 0 \\ 10x_1 + 10x_2 + 15x_3 = 12 \\ x_1 + x_2 + x_3 = 1 \end{array} \right. \Rightarrow \left\{ \begin{array}{l} x_1^* = 0,5 \\ x_2^* = 0,1 \\ x_3^* = 0,4 \\ \lambda_1^* = -180 \\ \lambda_2^* = 1380 \end{array} \right. \quad f^* = 390$$

# Otimização Não-Linear Restrita

Condições de otimalidade de 1ª ordem - Exemplo

$$\text{Min } f(x_1, x_2, x_3) = 400(x_1)^2 + 800(x_2)^2 + 1600(x_3)^2 + 200x_1x_2 + 400x_2x_3$$

$$\text{s.a. } h_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12 = 0$$

$$h_2(\underline{x}) = x_1 + x_2 + x_3 - 1 = 0$$

Significado do Multiplicador de Lagrange ( $\lambda$ ):

Indica o quanto a Função Objetivo é alterada em função de modificações na restrição respectiva, representando assim, o “custo” marginal ou incremental (“*shadow price*”) do problema.

No exemplo, se o limite para  $h_1(x)$  passar de 12 para 12.1, ou seja  $h_1(x)$  passar a ser:

$$h'_1(\underline{x}) = 10x_1 + 10x_2 + 15x_3 - 12.1 = 0$$

A nova solução passa a ser, aproximadamente:

$$(f^*)' \approx f^* + (12 - 12.1) \lambda_1$$

$$\approx 390 + (-0.1)(-180) = 408$$