

# Capítulo 5 - Optimização

Carlos Balsa

balsa@ipb.pt

Departamento de Matemática  
Escola Superior de Tecnologia e Gestão de Bragança

Mestrados em Engenharia da Construção  
Métodos de Aproximação em Engenharia  
1º Semestre 2010/2011



# Sumário

Problemas de Optimização

Optimização Unidimensional

Optimização Multidimensional

Considerações Finais

## Optimiza o

- ▶ Dada uma funç o  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  e um conjunto  $\mathbf{S} \subseteq \mathbb{R}^n$ , encontrar  $\mathbf{x}^* \in \mathbf{S}$  tal que  $f(\mathbf{x}^*) \leq f(\mathbf{x})$  para todo o  $\mathbf{x} \in \mathbf{S}$ .
- ▶  $\mathbf{x}^*$    chamado *minimizador* ou *m nimo* de  $f$
- ▶ Basta considerar a minimiza o, pois o m ximo de  $f$    igual ao m nimo de  $-f$
- ▶ A *funç o objectivo*  $f$    normalmente deriv vel, podendo ser linear ao n o linear
- ▶ O conjunto restriç o  $\mathbf{S}$    definido por um sistema de equa es e inequa es que pode ser linear ou n o linear
- ▶ Os pontos  $\mathbf{x} \in \mathbf{S}$  s o chamados pontos *pratic veis*
- ▶ Se  $\mathbf{S} = \mathbb{R}^n$  o problema n o tem restri es

## Problemas de Optimizaão

- ▶ Um problema genérico de optimizaão contínuo:

$$\min f(x) \text{ sujeito a } g(x) = 0 \text{ e } h(x) \leq 0$$

em que  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  e  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$

- ▶ **Programaão linear**:  $f$ ,  $g$  e  $h$  so todas lineares
- ▶ **Programaão no linear**: pelo menos uma das funões  $f$ ,  $g$  e  $h$   no linear
- ▶ Vamos considerar apenas os problemas de programaão no linear sem restriões

## Mtodo de Newton para Optimizaço Unidimensional

- ▶ *Mtodo de Newton* para a resoluço de  $f(x) = 0$ :

$$x_{k+1} = x_k - f(x_k)/f'(x_k), \quad \text{para } k = 0, 1, \dots$$

- ▶ Num problema de optimizaço o Mtodo de Newton  usado para a resoluço de  $f'(x) = 0$ :

$$x_{k+1} = x_k - f'(x_k)/f''(x_k), \quad \text{para } k = 0, 1, \dots$$

- ▶ Converte quadraticamente (duplica o nmero de dgitos correctos em cada iteraço  $k$ ) para o zero de  $f'(x)$  desde que o ponto de partida esteja suficientemente prximo da soluço

## Exemplo 1: Mtodo de Newton

- ▶ Usar o mtodo de Newton para minimizar  $f(x) = 0.5 - xe^{-x^2}$
- ▶ Primeira e a segunda derivada de  $f$  so dada por

$$f'(x) = (2x^2 - 1)e^{-x^2}$$

e

$$f''(x) = 2x(3 - 2x^2)e^{-x^2}$$

- ▶ Formula de recorrncia do Mtodo de Newton para encontrar o zero de  $f'(x)$  

$$x_{k+1} = x_k - (2x_k^2 - 1) / (2x_k(3 - 2x_k^2)), \quad \text{para } k = 0, 1, \dots$$

- ▶ Usando a estimativa inicial  $x_0 = 1$ , obtemos

$k$	$x_k$	$f(x_k)$
0	1.000	0.132
1	0.500	0.111
2	0.700	0.071
3	0.707	0.071

## Pontos Críticos

- ▶ Para funões de uma nica variável podemos encontrar o mnimo analisando os pontos em que a derivada  igual a zero
- ▶ Generalizaão a funões de  $n$  variáveis consiste em encontrar os **pontos crticos**, isto , a soluão do sistema no linear

$$\nabla f(x) = 0$$

em que  $\nabla f(x)$   o vector **gradiente de  $f$** , cuja  $i$ esima componente   $\partial f(x)/\partial x_i$

- ▶ Mas nem todos os pontos crticos so mnimos: podem ser tambm **mximos** ou **pontos de sela**

## Pontos Críticos de Funões Multidimensionais

- ▶ Para uma funão  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  duas vezes diferenciavel, podemos distinguir os pontos crticos através da **matriz Hessiana  $\mathbf{H}(\mathbf{x})$** , matriz das segundas derivadas parciais, definida por

$$\{\mathbf{H}(\mathbf{x})\}_{ij} = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}$$

que é simétrica

- ▶ Se no ponto  $x^*$ ,  $\mathbf{H}(x^*)$  é
  - ▶ Positiva definida, ento  $x^*$  é um mnimo de  $f$
  - ▶ Negativa definida, ento  $x^*$  é um mximo de  $f$
  - ▶ Indefinida, ento  $x^*$  é um ponto de sela de  $f$

## Pontos Críticos de uma Função Bidimensional

Regras práticas para verificar se a matriz é positiva definida:

- ▶ Factorização de Cholesky existe:  $A = LL^T$
- ▶ Valores próprios de  $A$  são todos positivos
- ▶ Todos os determinantes superiores esquerdos de  $A$  são positivos

Regras práticas para verificar se a matriz  $A$  é negativa definida:

- ▶ Valores próprios são todos negativos
- ▶ Determinantes superiores esquerdos de ordem par são positivos, de ordem ímpar são negativos

Regras práticas para verificar se a matriz é indefinida:

- ▶ Valores próprios positivos e negativos

## Pontos Crticos de uma Funço Bidimensional

Para uma funço  $f(x_1, x_2) : \mathbb{R}^2 \rightarrow \mathbb{R}$  duas vezes diferenciavel, podemos distinguir os seguintes casos

- ▶  $|\mathbf{H}(x^*)| > 0$  e  $\partial^2 f / \partial x_1^{*2} > 0$ , ento  $x^*$   um mnimo de  $f$
- ▶  $|\mathbf{H}(x^*)| > 0$  e  $\partial^2 f / \partial x_1^{*2} < 0$ , ento  $x^*$   um mximo de  $f$
- ▶  $|\mathbf{H}(x^*)| < 0$ , ento  $x^*$   um ponto sela  $f$

**Exerccio 1:** Determine os pontos crticos de cada uma das seguintes funçes e caracterize cada um deles como mnimo, mximo ou ponto de sela:

- ▶  $f(x, y) = 2x^2 - 2xy + 2y^2$
- ▶  $f(x, y) = x^4 - 4xy + y^4$

## Mtodo de Newton para Optimizaço Multidimensional

- ▶ Mtodo de Newton para minimizar uma funço unidimensional, procura o zero de  $f'(x)$  atravs da recorrncia:

$$x_{k+1} = x_k - f''(x_k)^{-1} f'(x_k), \quad \text{para } k = 0, 1, \dots$$

- ▶ No caso multidimensional o mtodo de Newton  usado para procurar o zero do gradiente da funço,  $\nabla f(\mathbf{x}) = 0$ , atravs da formula de recorrncia:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_f^{-1}(\mathbf{x}_k) \nabla f(\mathbf{x}_k), \quad \text{para } k = 0, 1, \dots$$

em que  $\mathbf{H}(\mathbf{x})$   a matriz Hessiana das segundas derivadas parciais

$$\{\mathbf{H}(\mathbf{x})\}_{ij} = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}$$

## Mtodo de Newton, continuaço

- ▶ A matriz Hessiana no  invertida explicitamente, em vez disso resolve-se o sistema linear

$$\mathbf{H}_f(\mathbf{x}_k)\delta_k = -\nabla f(\mathbf{x})$$

em ordem a  $\delta_k$ , e depois actualiza-se a soluço aproximada

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \delta_k$$

- ▶ Convergncia quadrtica mas necessita de uma boa estimativa inicial da soluço
- ▶ Necessita da segunda derivada da funço

## Exemplo 2: Metodo de Newton

- ▶ Usar o metodo de Newton para minimizar

$$f(\mathbf{x}) = 0.5x_1^2 + 2.5x_2^2$$

- ▶ Gradiente e matriz Hessiana sao dados por

$$\nabla f(\mathbf{x}) = \begin{bmatrix} x_1 \\ 5x_2 \end{bmatrix} \quad \text{e} \quad \mathbf{H}_f(\mathbf{x}) = \begin{bmatrix} 1 & 0 \\ 0 & 5 \end{bmatrix}$$

- ▶ Escolhendo  $\mathbf{x}_0 = \begin{bmatrix} 5 \\ 1 \end{bmatrix}$  obtemos  $\nabla f(\mathbf{x}_0) = \begin{bmatrix} 5 \\ 5 \end{bmatrix}$
- ▶ Resolvendo o sistema linear  $\mathbf{H}_f(\mathbf{x}_0)\delta_0 = -\nabla f(\mathbf{x}_0)$ , obtemos o passo  $\delta_0 = \begin{bmatrix} -5 \\ -1 \end{bmatrix}$ , e  $\mathbf{x}_1 = \mathbf{x}_0 + \delta_0 = \begin{bmatrix} 5 \\ 1 \end{bmatrix} + \begin{bmatrix} -5 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$  que e a soluao exacta deste problema

## M todo do Gradiente Conjugado

- ▶ Um outro m todo que n o requer explicitamente as segundas derivadas   o m todo do *gradiente conjugado* (CG)
- ▶ CG gera uma sequ ncia de direc es de procura conjugadas (ortogonais) entre elas
- ▶ Teoricamente, para fun es objectivo quadr ticas o CG converge para a solu o exacta num numero m ximo de  $n$  itera es, em que  $n$    a dimens o do problema

## Algoritmo do Gradiente Conjugado

$\mathbf{x}_0$  = aproximaão inicial

$\mathbf{g}_0 = \nabla f(\mathbf{x}_0)$

$\mathbf{s}_0 = -\mathbf{g}_0$

**for**  $k = 0, 1, 2, \dots$

Escolher o  $\alpha_k$  que minimiza  $f(\mathbf{x}_k + \alpha_k \mathbf{s}_k)$

$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{s}_k$

$\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$

$\beta_{k+1} = (\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}) / (\mathbf{g}_k^T \mathbf{g}_k)$

$\mathbf{s}_{k+1} = -\mathbf{g}_{k+1} + \beta_{k+1} \mathbf{s}_k$

**end**

### Exemplo 3: Mtodo do Gradiente Conjugado

- ▶ Usar o CG para minimizar

$$f(\mathbf{x}) = 0.5x_1^2 + 2.5x_2^2$$

- ▶ Gradiente  igual a  $\nabla f(\mathbf{x}) = \begin{bmatrix} x_1 \\ 5x_2 \end{bmatrix}$
- ▶ Escolhendo  $\mathbf{x}_0 = \begin{bmatrix} 5 & 1 \end{bmatrix}$  obtemos a direcço de procura inicial (corresponde ao gradiente negativo)

$$\mathbf{s}_0 = -\mathbf{g}_0 = -\nabla f(\mathbf{x}_0) = \begin{bmatrix} -5 \\ -5 \end{bmatrix}$$

- ▶ O mnimo exacto ao longo da linha de procura   $\alpha_0 = 1/3$ , pelo que a prxima soluço aproximada   $\mathbf{x}_1 = \begin{bmatrix} 3.333 & -0.667 \end{bmatrix}^T$  com o qual calculamos o novo gradiente

$$\mathbf{g}_1 = \nabla f(\mathbf{x}_1) = \begin{bmatrix} 3.333 \\ -3.333 \end{bmatrix}$$

## Exemplo, continuação

- ▶ Neste ponto, em vez de procurar na direcção do gradiente negativo calcula-se

$$\beta_1 = (\mathbf{g}_1^T \mathbf{g}_1) / (\mathbf{g}_0^T \mathbf{g}_0) = 0.444$$

que origina a nova direcção de procura

$$\mathbf{s}_1 = -\mathbf{g}_1 + \beta_1 \mathbf{s}_0 = \begin{bmatrix} -3.333 \\ 3.333 \end{bmatrix} + 0.444 \begin{bmatrix} -5 \\ -5 \end{bmatrix} = \begin{bmatrix} -5.556 \\ 1.111 \end{bmatrix}$$

- ▶ A deslocação ao longo desta linha que minimiza a função é  $\alpha_1 = 0.6$ , que origina a solução exacta  $\mathbf{x}_2 = [0 \ 0]^T$ , tal como seria de esperar para uma função quadrática

## Métodos Disponíveis na NMLibforOctave

- ▶ Método de Newton: `[] = opt_newton()`
- ▶ Mét. Gradiente Conjugado: `[] = opt_cg()`

## Bibliografia

Exposi o baseada essencialmente no cap tulo 6 de

- ▶ Michael T. Heath. "Scientific Computing an Introductory Survey". McGraw-Hill, 2002, New York.