



Capítulo 5 - Optimização Não-Linear

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 2009/2010





Sumário

Problemas de Optimizaçã

- Definições

- Optimizaçã Unidimensional

- Optimizaçã Multidimensional

Considerações Finais



Optimiza o

- ▶ Dada uma fun 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 *fun o objetivo* f   normalmente deriv vel, podendo ser linear ao n o linear
- ▶ O conjunto restri 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 $\mathbf{S} = \mathbb{R}$ 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



Mtodo de Newton

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

$$x_{k+1} = x_k - f(x_k)/f'(x_k)$$

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

$$x_{k+1} = x_k - f'(x_k)/f''(x_k)$$

- ▶ Converte quadraticamente (duplica o nmero de dgitos correctos em cada iterao) para o mnimo desde que o ponto de partida esteja suficientemente prximo da soluo



Exemplo 1: Mtodo de Newton

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

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

e

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

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

$$x_{k+1} = x_k - (2x_k^2 - 1) / (2x_k(3 - 2x_k^2))$$

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

x_k	$f(x_k)$
1.000	0.132
0.500	0.111
0.700	0.071
0.707	0.071



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:

$$x_{k+1} = x_k - f'(x_k)/f''(x_k)$$

- ▶ 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:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_f^{-1}(\mathbf{x}_k)\nabla f(\mathbf{x}_k)$$

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

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



Método de Newton, continuaçã

- ▶ A matriz Hessiana nã é 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 δ_k , e depois actualiza-se a soluçã aproximada

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

- ▶ Convergência quadrática mas necessita de uma boa estimativa inicial da soluçã
- ▶ Necessita da segunda derivada da funçã



Exemplo 2: Mtodo de Newton

- ▶ Usar o mtodo de Newton para minimizar

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

- ▶ Gradiente e matriz Hessiana so 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  a soluço exacta deste problema



Método do Gradiente Conjugado

- ▶ Um outro método que não requer explicitamente as segundas derivadas é o método do *gradiente conjugado* (CG)
- ▶ CG gera uma sequência de direcções de procura conjugadas (ortogonais) entre elas
- ▶ Teoricamente, para funções objectivo quadráticas o CG converge para a solução exacta num numero máximo de n iterações, em que n é a dimensão do problema
- ▶ Também é eficiente para os outros tipos de problemas de minimizaçã sem restrições



Mtodo do Gradiente Conjugado, continuao

ALGORITMO DO GRADIENTE CONJUGADO

\mathbf{x}_0 = aproximao inicial

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

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

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

Escolher o α_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: Método do Gradiente Conjugado

- ▶ Usar o CG para minimizar $f(\mathbf{x}) = 0.5x_1^2 + 2.5x_2^2$
- ▶ Gradiente é igual a $\nabla f(\mathbf{x}) = \begin{bmatrix} x_1 \\ 5x_2 \end{bmatrix}$
- ▶ Escolhendo $\mathbf{x}_0 = [5 \quad 1]$ obtemos a direcçã 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 soluçã aproximada   $\mathbf{x}_1 = [3.333 \quad -0.667]^T$ 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.