

Matemática Numérica II

Trabalho de Março

Catarina Silva

Pergunta 1

Seja $R: D \subset \mathbb{R}^n \rightarrow \mathbb{R}^m$ uma função continuamente diferenciável numa vizinhança de x_k . Denotemos por $J(x) \in \mathbb{R}^{m \times n}$ a matriz Jacobiana, em x , da função vectorial R . Prove que se a característica de $J(x_k)$ for igual a n então o passo Gauss-Newton

$$p_k = - (J(x_k)^T J(x_k))^{-1} J(x_k)^T R(x_k)$$

Em direcção de descida para a função $f(x) = R(x)^T R(x)/2$.

O problema anterior é traduzido pela seguinte implicação

$Car(n) = n \Rightarrow$ o passo Gauss – Newton $p_k = - (J(x_k)^T J(x_k))^{-1} J(x_k)^T R(x_k)$
é uma direcção de descida para a função $f(x) = R(x)^T R(x)/2$.

- Uma das condições para que o método de Gauss-Newton esteja bem definido, este tem de gerar iterações de modo que $J(x_k)^T J(x_k)$ seja não singular.
- **Proposição:** Seja $f: D \subset \mathbb{R}^n \rightarrow \mathbb{R}$ uma função direcção de continuamente diferenciável em D aberto e $x_* \in D$. A direcção de descida em x_* se $-\nabla f(x_*)^T p > 0$.

Provemos primeiro que está bem definida.

- Consideremos então λ valor próprio de $A^T A$, então $Av = \lambda v$, para v vector próprio associado λ .

Deste modo $v^T A^T A v = v^T \lambda v \Leftrightarrow (Av)^T Av = \lambda v^T v$, com $v^T v = \|v\|^2$

$$\Leftrightarrow \lambda = \frac{\|Av\|^2}{\|v\|^2}, \text{ onde } \frac{\|Av\|^2}{\|v\|^2} > 0 \quad (1)$$

- $(J(x_k)^T J(x_k))_{ij} = \begin{bmatrix} \frac{dr_j}{dx_i} \\ \vdots \\ \frac{dr_i}{dx_1}, \dots, \frac{dr_i}{dx_n} \\ \vdots \\ \frac{dr_j}{dx_n} \end{bmatrix} = (J(x_k)^T J(x_k))_{ji}$ ou seja, é Simétrica (2)

Logo todos os valores próprios de $J(x_k)^T J(x_k)$ são positivos por (1). Como é simétrica por (2) concluímos que $J(x_k)^T J(x_k)^{-1}$ é definida positiva (3).

Provemos agora a direcção de descida, ou seja que $-\nabla f(x_*)^T p > 0$.

$$-\nabla f(x)^T p_k = (J(x)^T R(x))^T (J(x)^T J(x))^{-1} J(x)^T R(x) > 0 \text{ por (3)}$$

1. Considere a função de Rosenbrock

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2 .$$

- a) Mostre que $x_* = [1 \ 1]^T$ é o único minimizante local de f e que $\nabla^2 f(x_*)$ é definida positiva.
-

Provemos então o pedido, para tal é necessário ter em conta a seguinte definição

Se $f : D \subset \mathbb{R}^n \rightarrow \mathbb{R}$, D aberto, for duas vezes continuamente diferenciável em D , se $x^ \in D$ tal que $\nabla f(x^*) = 0$ e $\nabla^2 f(x^*)$ for definida positiva, então x^* é um minimizante local de f .*

Queremos então encontrar os extremos, e se estes existirem serão os nossos pontos críticos. Calculemos então os pontos do domínio onde o vector gradiente se anula.

$$\nabla f(x_1, x_2) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \end{bmatrix} = \begin{bmatrix} 400x_1^3 - 400x_1x_2 + 2x_1 - 2 \\ 200(x_2 - x_1^2) \end{bmatrix}$$

$$\nabla f(x_1, x_2) = 0 \Leftrightarrow \begin{bmatrix} 400x_1^3 - 400x_1x_2 + 2x_1 - 2 \\ 200(x_2 - x_1) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \Leftrightarrow \begin{cases} x_1 = 1 \\ x_2 = 1 \end{cases}$$

Determine o minimizante de f usando o método de Newton e método de BFGS. Considere $x_0 = [-1.2 \ 1]^T$ e $B_0 = (\nabla^2 f(x_0))^{-1}$. Faça uma tabela de valores $\|x_k - x_*\|$ até 40 iterações para os dois métodos.

- b) Se usarmos o método de descida mais rápida para resolver o problema da alínea anterior observa-se que são necessárias 5264 iterações para reduzir a norma do gradiente para 10^{-5} . Quantas iterações dos métodos de Newton e BFGS são necessárias para fazer o mesmo?

Pergunta 3

Prove que nas condições do Teorema da convergência local do método de Newton e do segundo Teorema da Aula 5, temos que (a) e (b) são equivalentes

$$\text{a) } \lim_{k \rightarrow \infty} \frac{\|J(x_k)(p_k - s_k)\|}{\|s_k\|} = 0 \quad \text{b) } \lim_{k \rightarrow \infty} \frac{\|p_k - s_k\|}{\|s_k\|} = 0$$

Onde $s_k = -A_k^{-1}F(x_k)$, $p_k = -J(x_k)^{-1}F(x_k)$. As matrizes A_k são as do método de Broyden.

Como queremos provar a equivalência, ou seja,

$$\lim_{k \rightarrow \infty} \frac{\|J(x_k)(p_k - s_k)\|}{\|s_k\|} = 0 \Leftrightarrow \lim_{k \rightarrow \infty} \frac{\|p_k - s_k\|}{\|s_k\|} = 0$$

teremos de provar nos dois sentidos.

Pelo teorema temos da aula 5:

$$(A_k - J(x_k))s_k = A_k s_k - J(x_k)s_k = -F(x_k) - J(x_k)s_k = J(x_k)(p_k - s_k)$$

Provemos então no sentido \Leftarrow

$$\lim_{k \rightarrow \infty} \frac{\|J(x_k)(p_k - s_k)\|}{\|s_k\|} \leq \lim_{k \rightarrow \infty} \|J(x_k)\| \frac{\|p_k - s_k\|}{\|s_k\|}$$

E por hipótese temos

$$\lim_{k \rightarrow \infty} \frac{\|p_k - s_k\|}{\|s_k\|} = 0$$

Basta provar que $J(x_k)$ é limitada, para que $\|J(x_k)\|$ seja limitada.

Então pelo teorema da aula 5, J é contínua à Lipschitz, isto é,

$$\|J(x_k) - J(x_*)\| \leq \gamma \|x_k - x_*\|.$$

$$\text{Como } \left| \|J(x_k)\| - \|J(x_*)\| \right| \leq \|J(x_k) - J(x_*)\| \text{ e}$$

$$\left| \|J(x_k)\| - \|J(x_*)\| \right| \leq \gamma \|x_k - x_*\|.$$

$$\text{Temos então que } \|J(x_k)\| - \|J(x_*)\| \leq \gamma \|x_k - x_*\|$$

Logo $\|J(x_k)\| \leq \|J(x_*)\| + \gamma \|x_k - x_*\|$, ou seja limitada como queríamos.

Provemos então no sentido \Rightarrow

$$(A_k - J(x_k))s_k = J(x_k)(p_k - s_k)$$

$$p_k - s_k = J(x_k)^{-1}(A_k - J(x_k))s_k$$

$$\lim_{k \rightarrow \infty} \frac{\|p_k - s_k\|}{\|s_k\|} = \lim_{k \rightarrow \infty} \frac{\|J(x_k)^{-1}(A_k - J(x_k))s_k\|}{\|s_k\|} \leq \lim_{k \rightarrow \infty} \|J(x_k)^{-1}\| \frac{\|(A_k - J(x_k))s_k\|}{\|s_k\|}$$
$$\lim_{k \rightarrow \infty} \frac{\|(A_k - J(x_k))s_k\|}{\|s_k\|} = 0$$

Logo é igual a 0.