

Método do gradiente espectral

(1)

Quase-Newton: $x^{k+1} = x^k - B_k^{-1} \nabla f(x^k)$,

$B_{k+1} S_k = y_k$ (equação secante), onde

$S_k = x^{k+1} - x^k$ e $y_k = \nabla f(x^{k+1}) - \nabla f(x^k)$.

Escolha simples: $B_{k+1} = \sigma_{k+1} I$, $\sigma_{k+1} > 0$.

Esta escolha não satisfaz a equação secante em geral, mas podemos procurar o σ_{k+1} que

melhor aproxima a equação secante

(2)

" $(\sigma I) s_k = y_k$ " no seguinte sentido:

$$\min_{\sigma} \frac{1}{2} \|\sigma s_k - y_k\|^2$$

Este problema é convexo e pode ser resolvido anulando a derivada da função objetivo:

$$0 = \frac{d}{d\sigma} \left(\frac{1}{2} \|\sigma s_k - y_k\|^2 \right) = (\sigma s_k - y_k)^t s_k$$

$$\Rightarrow \boxed{\sigma_{k+1} = \frac{s_k^t y_k}{s_k^t s_k}} \quad (\text{sempre que } s_k \neq 0)$$

Seendo $B_{k+1} = \sigma_{k+1} I$, temos $B_{k+1}^{-1} = \frac{1}{\sigma_{k+1}} I$. [3

Agregando busca linear, temos a iteração

$$x^{k+1} = x^k - t_k \lambda_k \nabla f(x^k), \quad \lambda_k = \frac{1}{\sigma_k} = \frac{s_{k-1}^t s_{k-1}}{s_{k-1}^t y_{k-1}}$$

(desde que $s_{k-1}^t y_{k-1} > 0$),

com passo $t_k > 0$. Esta é a iteração do método do gradiente espectral.

Observe que se trata de uma espécie de "gradiente escalado", com direção $d^k = -\lambda_k \nabla f(x^k)$.

Sobre o cálculo do passo espectral λ_k

14

1) Assim como nos métodos quase-Newton, o primeiro passo λ_0 deve ser fornecido (lembre-se que $B_0 = \frac{1}{\lambda_0} I$ é dada pelo usuário).

Uma escolha que funciona bem é

$$\lambda_0 = \min \left\{ \lambda_{\max}, \max \left\{ \lambda_{\min}, \frac{1}{\|\nabla f(x^0)\|_{\infty}} \right\} \right\},$$

onde $0 < \lambda_{\min} < \lambda_{\max}$ são parâmetros.

Note que se $\nabla f(x^0) = 0$, nada mais é necessário pois x^0 já é solução.

15

λ_{\min} , λ_{\max} são limites para λ que visam manter certa estabilidade numérica. A expressão anterior é a projeção de $\frac{1}{\|\nabla f(x^0)\|_{\infty}}$ sobre o intervalo $[\lambda_{\min}, \lambda_{\max}]$.

Na prática, $\lambda_{\min} = 10^{-30}$ e $\lambda_{\max} = 10^{30}$.

$\lambda \in [\lambda_{\min}, \lambda_{\max}]$ serve ainda para convergência

teórica. (não vamos fazer aqui).

16

2) Se $s_{k-1}^t y_{k-1} \leq 0$, $\frac{1}{\sigma_k} = \frac{s_{k-1}^t s_{k-1}}{s_{k-1}^t y_{k-1}}$ será

negativo ou mesmo não definido. Neste caso tomamos

$$\lambda_k = \lambda_{\max}.$$

ou seja, tenta-se "andar ao máximo" na direção $-\nabla f(x^k)$, deixando todo ajuste para a busca linear.

Sobre o cálculo de t_k (busca linear) [7]

O método

$$x^{k+1} = x^k - t_k \lambda_k \nabla f(x^k), \quad \lambda_k \in [\lambda_{\min}, \lambda_{\max}]$$

converge globalmente se $t_k > 0$ é calculado como no esquema geral de descida, isto é,

"Armijo + interpolação quadrática
+ backtracking + salvaguardas".

Porém, se $t_k < 1$ estaremos descartando 18
o passo espectral λ_k , que contém informa-
ção valiosa da equação recorrente.

Em outras palavras, gostaríamos que $t_k = 1$
com frequência, mesmo que eventualmente
 f aumente. Ou seja, queremos "passos
verdadeiros" do método espectral

$$x^{k+1} = x^k - \lambda_k \nabla f(x^k).$$

Para tanto, $t_k > 0$ deve satisfazer a

(9)

condição de passo "relaxada"

$$f(x^k - t \lambda_k \nabla f(x^k)) \leq f_{\max} - t \eta \lambda_k \|\nabla f(x^k)\|^2 \quad (*),$$

onde

$$f_{\max} = \max \{ f(x^k), f(x^{k-1}), \dots, f(x^{k-m}) \},$$

$m > 0$ parâmetro (na prática, $m = 100$).

A busca linear com (*) é "não monótona" pois permite f crescer eventualmente.

Observe que (*) é Coniço com a direção $d^k = -\lambda_k \nabla f(x^k)$ trocando $f(x^k)$

por f_{\max} (verifique). Claro que


"Coniço tradicional \Rightarrow (*)" ((*) é mais frouxa)

Em implementações, armazenamos o vetor das M últimas f , que é iniciado com todas as entradas $= -\infty$.

Armijo tradicional


(10.5)

passos
aceitáveis



Armijo "não monotone"

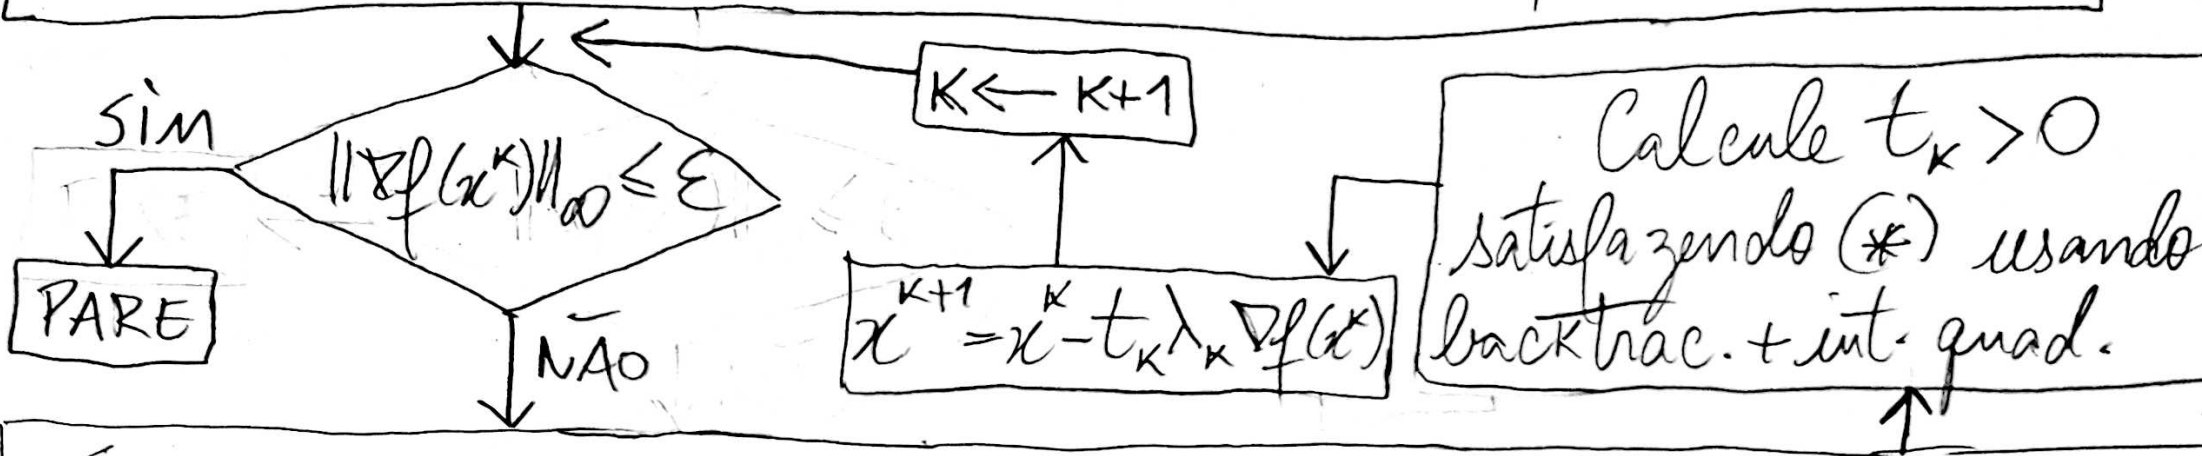
passos
aceitáveis



Método do gradiente espectral

(11)

Dados $x^0 \in \mathbb{R}^m$, $0 < \lambda_{\min} < \lambda_{\max}$, $M > 0$, $\epsilon > 0$, $k \leftarrow 0$



Se $k=0$, $\lambda_0 = \min\{\lambda_{\max}, \max\}\lambda_{\min}$, $\forall \|\nabla f(x^0)\|_\infty \leq \epsilon$

Se $k \geq 1$,

$$\lambda_k = \begin{cases} \min\{\lambda_{\max}, \max\}\lambda_{\min}, & \frac{t}{s_{k-1}} y_{k-1} \leq 0 \\ \lambda_{\max} & \text{caso contrário} \end{cases}$$

caso $\frac{t}{s_{k-1}} y_{k-1} > 0$

Observações:

12

1) o método do gradiente espectral é barato (= método gradiente) e logo é adequado a problemas com muitas variáveis.

2) numericamente é muito bom para minimizar funções não convexas quaisquer.

3) Mesmo com Armijo modificado (*), a convergência é global.

4) O nome "espectral" vem do fato de

13

$$\sigma_{k+1} = \frac{s_k^t y_k}{s_k^t s_k} \text{ ser um quociente de Rayleigh (que}$$

é usado para descrever autovalores) da seguinte "hessiana média":

$$\tilde{B} = \int_0^1 \nabla^2 f(x^k + t s_k) dt.$$

De fato, defina

$$g(t) = \nabla f(x^k + t s_k), \quad t \in [0, 1].$$

Então

14

$$\int_0^1 g'(t) dt = g(1) - g(0)$$

$$\Rightarrow \int_0^1 \nabla^2 f(x^k + ts_k) s_k dt = \nabla f(x^k + s_k) - \nabla f(x^k) = y_k$$

$$\Rightarrow \left[\int_0^1 \nabla^2 f(x^k + ts_k) dt \right] s_k = y_k,$$

ou seja, $\tilde{B} s_k = y_k$. Logo, temos o quociente de Rayleigh

$$\frac{s_k^t \tilde{B} s_k}{s_k^t s_k} = \frac{s_k^t y_k}{s_k^t s_k} = \sigma_{k+1}.$$