

Método dos gradientes (ou método de máxima descida)

Marina Andretta

ICMC-USP

12 de agosto de 2014

Baseado no livro Numerical Optimization, de J. Nocedal e S. J. Wright.

O **método dos gradientes** (ou **método de máxima descida**) para resolução de problemas de minimização irrestrita é um método de busca linear que usa a direção

$$p_k = -\nabla f_k.$$

(1)

Note que, neste caso,

$$p_k^T \nabla f_k = -\|\nabla f_k\|_2^2 < 0.$$

Ou seja, p_k é uma direção de descida.

Além disso,

$$\cos \theta_k = \frac{-\nabla f_k^T p_k}{\|\nabla f_k\| \|p_k\|} = 1.$$

Pela [condição de Zoutendijk](#), temos que

$$\lim_{k \rightarrow \infty} \|\nabla f_k\| = 0.$$

Portanto, o método dos gradientes produz uma sequência de gradientes que converge para zero, dado que ele use uma busca linear que satisfaça as condições de Wolfe.

Pode-se mostrar também que a sequência gerada pelo método dos gradientes converge quando o tamanho de passo é calculado usando *backtracking* e satisfaz a condição de Armijo.

Ordem de convergência

Para estudar a ordem de convergência do **método dos gradientes**, vamos nos concentrar primeiro no caso ideal, no qual a função objetivo é uma quadrática e a busca linear é exata.

Considere, então, o problema

$$\text{Minimizar } f(x) = \frac{1}{2}x^T Qx - b^T x, \quad (2)$$

com Q simétrica e definida positiva.

Ordem de convergência




Figura : Exemplo método de máxima descida (Figura 3.7 de Numerical Optimization, de J. Nocedal e S. J. Wright)

Neste caso, o gradiente de f é dado por

$$\nabla f(x_k) = Qx - b.$$

Assim, o **minimizador** x^* é a solução única do sistema linear $Qx = b$.

Ordem de convergência

Calculamos o tamanho de passo α_k que minimiza a função

$$\phi(\alpha) = f(x_k + \alpha p_k) = f(x_k - \alpha \nabla f_k).$$

Derivando ϕ em relação a α , temos que

$$\alpha_k = \frac{\nabla f_k^T \nabla f_k}{\nabla f_k^T Q \nabla f_k}.$$

Ordem de convergência

Se usamos o minimizador exato α_k como tamanho de passo no método dos gradientes para a função f , temos que

$$x_{k+1} = x_k - \left(\frac{\nabla f_k^T \nabla f_k}{\nabla f_k^T Q \nabla f_k} \right) \nabla f_k. \quad (3)$$

Como $\nabla f_k = Qx_k - b$, esta equação fornece uma fórmula fechada para x_{k+1} em relação a x_k .

Ordem de convergência

Para quantificar a ordem de convergência, introduzimos a norma

$$\|x\|_Q^2 = x^T Q x.$$

Usando a relação $Qx^* = b$, temos que

$$\frac{1}{2} \|x - x^*\|_Q^2 = f(x) - f(x^*). \quad (4)$$

Ordem de convergência

Usando a igualdade (3) e o fato de que $\nabla f_k = Q(x_k - x^*)$, temos que

$$\|x_{k+1} - x^*\|_Q^2 = \left\{ 1 - \frac{(\nabla f_k^T \nabla f_k)^2}{(\nabla f_k^T Q \nabla f_k)(\nabla f_k^T Q^{-1} \nabla f_k)} \right\} \|x_k - x^*\|_Q^2.$$

Esta equação descreve o decréscimo exato de f a cada iteração.

Como é difícil interpretar a expressão dentro das chaves, é mais conveniente limitá-la em termos do número de condição do problema.

Teorema 1: Quando o método dos gradientes com busca linear exata é aplicado na resolução do problema de minimizar a função fortemente convexa (2), a norma do erro (4) satisfaz

$$\|x_{k+1} - x^*\|_Q^2 \leq \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^2 \|x_k - x^*\|_Q^2, \quad (5)$$

onde $0 < \lambda_1 \leq \dots \leq \lambda_n$ são os autovalores de Q .

Ordem de convergência

As inequações (5) e (4) mostram que os valores f_k da função convergem ao mínimo com uma **razão linear**.

Um caso especial deste resultado é aquele em que **todos os autovalores da matriz Q são iguais** (Q é um múltiplo da matriz identidade). Neste caso, a convergência do método é obtida em **apenas uma iteração**.

Quando Q é um múltiplo da identidade, as curvas de nível de f são círculos e a direção de máxima descida sempre aponta para o minimizador.

Ordem de convergência

Em geral, conforme o número de condição $\kappa(Q) = \lambda_n/\lambda_1$ aumenta, as curvas de nível da quadrática se tornam mais alongadas e o zigue-zague obtido pela sequência de pontos calculada pelo método dos gradientes se pronuncia. Neste caso, a inequação (5) implica que a convergência se degrada.

Apesar de a inequação (5) ser um limitante para o pior caso do algoritmo, ela fornece uma indicação precisa do comportamento do algoritmo quando $n > 2$.

Teorema 2: *Suponha que $f : \mathbf{R}^n \rightarrow \mathbf{R}$ tenha segunda derivada contínua e que os iterandos gerados pelo método dos gradientes com busca linear exata converjam a um ponto x^* no qual a Hessiana $\nabla^2 f(x^*)$ seja definida positiva.*

Então,

$$f(x_{k+1}) - f(x^*) \leq \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^2 [f(x_k) - f(x^*)],$$

onde $0 < \lambda_1 \leq \dots \leq \lambda_n$ são os autovalores de $\nabla^2 f(x^)$.*

Ordem de convergência

Em geral, não podemos esperar que a ordem de convergência melhore se uma busca linear inexata for usada. Portanto, o Teorema 2 mostra que o método dos gradientes pode ter a convergência inaceitavelmente lenta mesmo quando a Hessiana da função objetivo é bem-condicionada.

Por exemplo, se $\kappa(Q) = 800$, $f(x_1) = 1$ e $f(x^*) = 0$, o Teorema 2 sugere que o valor da função ainda será aproximadamente 0.08 depois de mil iterações do método dos gradientes.