

Método de Newton truncado

Marina Andretta

ICMC-USP

8 de outubro de 2018

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

Lembre-se que o passo de Newton p_k^N é calculado resolvendo-se o sistema linear simétrico

$$\nabla^2 f_k p_k^N = -\nabla f_k. \quad (1)$$

Para garantir convergência global, pedimos que a direção p_k^N seja de descida, o que acontece quando $\nabla^2 f_k$ é definida positiva.

Se a Hessiana $\nabla^2 f_k$ não é definida positiva ou está perto de ser singular, a direção p_k^N pode ser de subida ou pode ser excessivamente longa.

Para contornar este problema usaremos duas estratégias:

- 1 **Modificar a matriz Hessiana $\nabla^2 f_k$** antes ou durante a resolução do sistema (1) para que ela se torne suficientemente definida positiva. Este método é chamado de **método de Newton modificado**.
- 2 Resolver o sistema (1) usando um **método de gradientes conjugados** que pára quando uma direção de curvatura negativa é encontrada. Este método é chamado de **método de Newton truncado**.

Outra preocupação ao desenvolver métodos práticos do tipo Newton é manter o custo computacional o menor possível.

No **método de Newton truncado** isto é feito **terminando a iteração de gradientes conjugados antes da solução exata de (1)**. Este método de Newton *inexato*, então, calcula uma aproximação p_k do passo de Newton p_k^N .

Ao usar um **método direto** para resolver o sistema linear (1), **podemos aproveitar a esparsidade da matriz Hessiana** usando, por exemplo, a eliminação de Gauss esparsa.

Um dos problemas do **método de Newton** é ter de **resolver o sistema (1) exatamente**. Técnicas baseadas em eliminação de Gauss e outras fatorações podem ser custosas quando o número de variáveis é grande.

Uma solução precisa de (1) pode não ser garantida no caso geral, já que o modelo quadrático usado para gerar o sistema newtoniano pode não fornecer uma boa aproximação do comportamento de f , principalmente quando o iterando x_k está longe da solução x^* .

Assim, é interessante **resolver o sistema (1) usando um método iterativo** que pare em uma **solução aproximada (inexata) do sistema**.

A maior parte das regras para terminar um método iterativo para resolver o sistema (1) são baseadas no resíduo

$$r_k = \nabla^2 f_k p_k + \nabla f_k, \quad (2)$$

com p_k passo de Newton inexato.

Passos de Newton inexato

Como o tamanho do resíduo muda quando f é multiplicada por uma constante (ou seja, r_k não é invariante quanto ao escalamento de f), consideramos seu tamanho relativo ao vetor do lado direito de (1) - ou seja, ∇f_k .

Então, terminamos a execução do método iterativo quando

$$\|r_k\| \leq \eta_k \|\nabla f_k\|,$$

(3)

onde a sequência $\{\eta_k\}$, com $0 < \eta_k < 1$ para todo k , é chamada de *sequência de forcing*.

A ordem de convergência de métodos de Newton inexato, baseados em (1)-(3), é afetada pela sequência de *forcing*.

O primeiro resultado diz que convergência local é obtida apenas garantindo que η_k esteja longe de 1.

Teorema 1: *Suponha que $\nabla f(x)$ tenha derivada contínua em uma vizinhança da solução x^* . Suponha que $\nabla^2 f(x^*)$ seja definida positiva. Considere a iteração da forma $x_{k+1} = x_k + p_k$, com p_k que satisfaz $\|r_k\| \leq \eta_k \|\nabla f(x_k)\|$. Suponha que $\eta_k \leq \eta$ para alguma constante $\eta \in [0, 1)$.*

Então, se o ponto inicial x_0 está suficientemente próximo de x^ , a sequência $\{x_k\}$ converge para x^* linearmente. Ou seja, para todo k suficientemente grande, temos que*

$$\|x_{k+1} - x^*\| \leq c \|x_k - x^*\|, \quad 0 < c < 1.$$

Note que a hipótese sobre a sequência $\{\eta_k\}$ não é muito restritiva, no sentido que, se fosse relaxada, o algoritmo não convergiria.

Mais especificamente, se fosse permitido que $\eta_k \geq 1$, o passo $p_k = 0$ satisfaria (3) em toda iteração. Neste caso, o método faria $x_k = x_0$ para todo k e não convergiria para a solução.

Teorema 2: *Suponha que as condições do Teorema 1 valham e suponha que os iterandos $\{x_k\}$ gerados pelo método de Newton inexato convergem para x^* . Então a ordem de convergência é superlinear se $\eta_k \rightarrow 0$ e quadrática se $\eta_k = O(\|\nabla f(x_k)\|)$.*

Passos de Newton inexato

Para obter **convergência superlinear** podemos usar, por exemplo, $\eta_k = \min\{0.5, \sqrt{\|\nabla f_k\|}\}$. Usando $\eta_k = \min\{0.5, \|\nabla f_k\|\}$ obteríamos **convergência quadrática**.

Todos os resultados apresentados aqui têm natureza local: supõe-se que a sequência $\{x_k\}$ atinge uma vizinhança de x^* . Eles também supõem que o tamanho de passo unitário $\alpha_k = 1$ é tomado e, então, estratégias de globalização (busca linear e regiões de confiança) não atrapalham a rápida convergência.

Veremos agora que **estratégias de Newton inexato** podem ser incorporadas em **implementações de métodos de Newton com busca linear**, gerando algoritmos com **boas propriedades de convergência local e global**.

O **método de Newton truncado** consiste em utilizar o **método de gradientes conjugados** na resolução do sistema newtoniano (1), a fim de satisfazer uma condição do tipo (3)

$$\|r_k\| \leq \eta_k \|\nabla f_k\|.$$

Método de gradientes conjugados

O método de gradientes conjugados é um método iterativo que foi desenvolvido para resolver sistemas lineares $Ax = b$, com A simétrica e definida positiva.

Basicamente, este método parte de um ponto inicial $x^{(0)}$ e, a cada iteração k , calcula uma **direção conjugada** a todas as anteriores (ou seja, $(p^{(k)})^T A p^{(i)} = 0$, para todo $i < k$).

Calcula-se $x^{(k+1)} = x^{(k)} + \alpha^{(k)} p^{(k)}$, com $\alpha^{(k)} = -\frac{r_k^T p^{(k)}}{(p^{(k)})^T A p^{(k)}}$.

O método de gradientes conjugados encontra a solução do sistema linear em, no máximo, n iterações.

Método de gradientes conjugados

Método de gradientes conjugados: Dados um ponto inicial $x^{(0)}$, uma matriz A , um vetor b e um escalar $\epsilon > 0$.

Passo 1: Faça $r_0 \leftarrow Ax^{(0)} - b$, $p^{(0)} \leftarrow -r_0$, $k \leftarrow 0$.

Passo 2: Se $\|r_k\| \leq \epsilon$, pare com $x^{(k)}$ como solução.

Passo 3: Faça $\alpha^{(k)} \leftarrow \frac{r_k^T r_k}{(p^{(k)})^T A p^{(k)}}$.

Passo 4: Faça $x^{(k+1)} \leftarrow x^{(k)} + \alpha^{(k)} p^{(k)}$.

Passo 5: Faça $r_{k+1} \leftarrow r_k + \alpha^{(k)} A p^{(k)}$.

Passo 6: Faça $\beta^{(k+1)} \leftarrow \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k}$.

Passo 7: Faça $p^{(k+1)} \leftarrow -r_{k+1} + \beta^{(k+1)} p^{(k)}$.

Passo 8: Faça $k \leftarrow k + 1$ e volte para o Passo 2.

Note que o **método de gradientes conjugados** foi desenvolvido para a resolução de **sistemas lineares definidos positivos**. No entanto, a Hessiana poderia possuir autovalores negativos longe da solução.

Portanto, **terminamos a iteração de gradientes conjugados assim que uma direção de curvatura negativa é gerada**. Esta adaptação do método dos gradientes conjugados garante que a direção p_k é de descida e que a convergência rápida do método de Newton puro é conservada.

Método de Newton truncado

O sistema linear a ser resolvido é dados por

$$\nabla^2 f_k p_k = -\nabla f_k.$$

Usando a notação do algoritmo de gradientes conjugados, temos que $A = \nabla^2 f_k$ e $b = -\nabla f_k$.

Denotaremos por $\{x^{(i)}\}$ e $\{p^{(i)}\}$ os iterandos e direções de busca gerados pelo método de gradientes conjugados.

Método de Newton truncado

São impostas três condições ao **método de gradientes conjugados** para a resolução de sistema (1):

- 1 O ponto inicial para o método de gradientes conjugados é $x^{(0)} = 0$.
- 2 **Teste de curvatura negativa**: se uma direção $p^{(i)}$ gerada pelo método de gradientes conjugados é tal que $(p^{(i)})^T A p^{(i)} \leq 0$, verificamos se i é a primeira iteração. Em caso positivo, **terminamos a iteração de gradientes conjugados**, definimos $x^{(1)}$ como $p^{(0)}$ e paramos. Caso contrário, paramos o método de gradientes conjugados imediatamente e usamos a solução $x^{(i)}$.
- 3 A **direção de Newton** p_k é definida como o iterando final do método de gradientes conjugados $x^{(f)}$.

Método de Newton truncado

Se a condição $(p^{(i)})^T A p^{(i)} \leq 0$ não é satisfeita, o método dos gradientes é o mesmo apresentado anteriormente.

Uma direção $p^{(i)}$ que satisfaz essa condição com desigualdade estrita é chamada de **direção de curvatura negativa** para A .

Note que, **se uma direção de curvatura negativa é encontrada** na primeira iteração do **método de gradientes conjugados**, a direção $-\nabla f_k$ **será usada no método de Newton**. Daí a razão para usar o ponto inicial $x^{(0)} = 0$.

É possível mostrar que, se uma direção de curvatura negativa é encontrada em uma iteração $i > 1$ do método de gradientes conjugados, a aproximação $x^{(i-1)}$ é uma direção de descida.

Método de Newton truncado

Note que o método de Newton truncado não usa a Hessiana $\nabla^2 f_k$ de maneira explícita, apenas em produtos matriz-vetor. Assim, o usuário pode fornecer uma rotina que calcula o produto $\nabla^2 f_k v$, para um dado vetor v , em vez de fornecer uma rotina que calcule $\nabla^2 f_k$.

Para definir o método de Newton truncado com busca linear usaremos $\eta_k = \min\{0.5, \sqrt{\|\nabla f_k\|}\}$ para garantir convergência superlinear.

Método de Newton truncado com busca linear: Dado um ponto inicial x_0 e um escalar $\epsilon > 0$.

Passo 1: Faça $k \leftarrow 0$.

Passo 2: Se $\|\nabla f(x_k)\| \leq \epsilon$, pare com x_k como solução.

Passo 3: Calcule uma direção de busca p_k aplicando o método de gradientes conjugados para resolver o sistema $\nabla^2 f_k p_k = -\nabla f_k$, com ponto inicial $x^{(0)} = 0$.

Pare quando $\|r_k\| \leq \min\{0.5, \sqrt{\|\nabla f_k\|}\} \|\nabla f_k\|$ ou uma direção de curvatura negativa for encontrada.

Passo 4: Faça $x_{k+1} \leftarrow x_k + \alpha_k p_k$, α_k satisfaz condições de Wolfe ou é calculado usando *backtracking* com Armijo.

Passo 5: Faça $k \leftarrow k + 1$ e volte para o Passo 2.