

# Resolução de sistemas de equações lineares: Método dos Gradientes Conjugados

Marina Andretta/Franklina Toledo

ICMC-USP

21 de setembro de 2012

Baseado no livro Cálculo Numérico, de Neide B. Franco

# Método dos Gradientes Conjugados

Estamos interessados em resolver o sistema linear

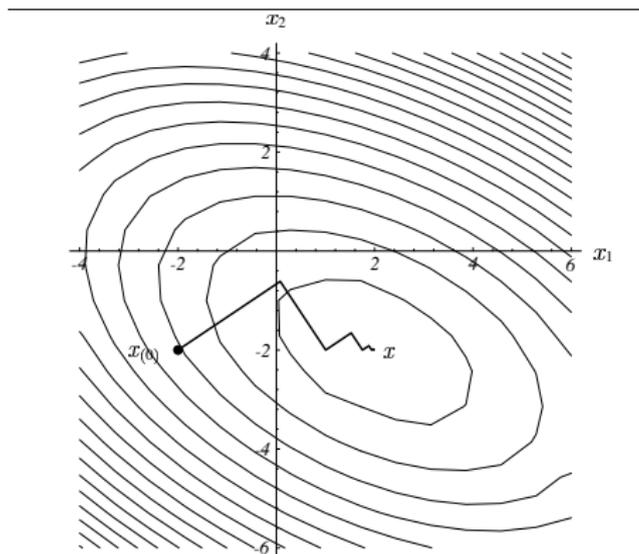
$$Ax = b,$$

com  $A \in \mathbf{R}^{n \times n}$  e  $b \in \mathbf{R}^n$  dados.

Quando a matriz  $A$  é esparsa, podemos não tê-la representada, mas dispor apenas de rotinas que calculem o produto de  $A$  por um dado vetor  $v$ . Neste caso, não é possível usar os métodos diretos ou os Métodos Jacobi-Richardson ou Gauss-Seidel.

# Método dos Gradientes Conjugados

Uma possibilidade, como já vimos, é utilizar o Método dos Gradientes. Uma desvantagem deste método é que sua convergência costuma ser muito lenta.



Fonte: Shewchuk, J R. *An Introduction to the Conjugate Gradient Method Without the Agonizing Pain* Edition 1. School of Computer Science Carnegie Mellon University Pittsburgh, PA, 1994.

# Método dos Gradientes Conjugados

Uma alternativa para resolver um sistema linear que veremos agora é o **Método dos Gradientes Conjugados**.

Este é um método iterativo, que parte da mesma ideia do Método dos Gradientes (minimizar uma função quadrática). No entanto, veremos que há um limitante para o número de iterações necessárias para que o **Método dos Gradientes Conjugados** convirja à solução do sistema linear.

# Método dos Gradientes Conjugados

Assim como no Método dos Gradientes, trocaremos o problema de encontrar uma solução para o sistema  $Ax = b$  pelo problema equivalente de encontrar um minimizador de  $\frac{1}{2}x^T Ax - b^T x$ , com **A simétrica e definida positiva**.

Dada a função  $f(x) = \frac{1}{2}x^T Ax - b^T x$ , lembre que:

$$\nabla f(x) = Ax - b;$$

$$\nabla^2 f(x) = A.$$

Encontrar a solução do sistema linear  $Ax = b$  é equivalente a encontrar o ponto  $x$  que satisfaz  $\nabla f(x) = Ax - b = 0$ , ou seja, o minimizador da função  $f$ .

# Método dos Gradientes Conjugados

Antes de descrever o **Método dos Gradientes Conjugados**, precisamos da seguinte definição:

**Definição 1:** *Dada uma aplicação linear  $A$  definida positiva, duas direções  $x$  e  $y$  são ditas conjugadas se*

$$(Ax)^T y = y^T Ax = 0.$$

# Método dos Gradientes Conjugados

A primeira iteração ( $k = 1$ ) do Método dos Gradientes Conjugados será igual à primeira iteração do Método dos Gradientes.

Ou seja, calculamos o resíduo

$$r_0 = Ax_0 - b$$

e definimos a direção

$$p_1 = -r_0.$$

# Método dos Gradientes Conjugados

O novo ponto é dado por

$$x_1 = x_0 + tp_1,$$

com

$$t = q_1 = -\frac{r_0^T p_1}{(Ap_1)^T p_1} = \frac{r_0^T r_0}{(Ar_0)^T r_0}.$$

(igual ao método do gradiente)

Portanto,

$$x_1 = x_0 - \frac{r_0^T r_0}{(Ar_0)^T r_0} r_0. \quad (1)$$

# Método dos Gradientes Conjugados

Para definir a direção  $p_k$ , para cada iteração  $k > 1$ , tomamos uma direção que seja conjugada à direção  $p_{k-1}$ , isto é, queremos que

$$(Ap_k)^T p_{k-1} = p_k^T Ap_{k-1} = 0.$$

Além disso, tomamos  $p_k$  como uma combinação linear de  $r_{k-1}$  e  $p_{k-1}$ .

Como o coeficiente de  $r_{k-1}$  nesta combinação linear não pode ser nulo, definimo-lo como -1. Assim,

$$p_k = -r_{k-1} + \alpha_{k-1}p_{k-1}. \quad (2)$$

# Método dos Gradientes Conjugados

Precisamos, então, definir o valor de  $\alpha_{k-1}$ .

Note que

$$p_k^T A p_{k-1} = 0 \Rightarrow (-r_{k-1} + \alpha_{k-1} p_{k-1})^T A p_{k-1} = 0 \Rightarrow$$

$$-r_{k-1}^T A p_{k-1} + \alpha_{k-1} p_{k-1}^T A p_{k-1} = 0.$$

Ou seja,

$$\alpha_{k-1} = \frac{r_{k-1}^T A p_{k-1}}{p_{k-1}^T A p_{k-1}}, \quad (3)$$

para  $k > 1$ .

# Método dos Gradientes Conjugados

Calculada a direção  $p_k$ , precisamos definir o tamanho de passo  $q_k$  para calcular

$$x_k = x_{k-1} + q_k p_k. \quad (4)$$

O tamanho de passo  $q_k$  é definido como o minimizador da função  $\frac{1}{2}x^T A x - b^T x$  na direção  $p_k$ . Ou seja,

$$q_k = -\frac{r_{k-1}^T p_k}{(A p_k)^T p_k}. \quad (5)$$

# Método dos Gradientes Conjugados

Note que  $\alpha_{k-1}$  e  $q_k$ , definidos em (3) e (5), respectivamente, sempre são maiores do que zero.

Como  $r_k = Ax_k - b$ , temos que

$$r_k = A(x_{k-1} + q_k p_k) - b = Ax_{k-1} - b + q_k A p_k \Rightarrow$$

$$r_k = r_{k-1} + q_k A p_k. \quad (6)$$

# Método dos Gradientes Conjugados

O **Método dos Gradientes Conjugados** é definido pelas fórmulas (1) a (6).

No entanto, podemos usar algumas propriedades sobre o resíduo  $r_k$  para simplificar os cálculos de  $\alpha_{k-1}$  e  $q_k$ .

# Método dos Gradientes Conjugados

- O resíduo na iteração  $k$  ( $r_k$ ) é ortogonal ao resíduo na iteração  $k - 1$  ( $r_{k-1}$ ). Ou seja,

$$r_k^T r_{k-1} = 0.$$

- O resíduo na iteração  $k$  ( $r_k$ ) é ortogonal à direção calculada na iteração  $k$  ( $p_k$ ). Ou seja,

$$r_k^T p_k = 0.$$

- O resíduo na iteração  $k$  ( $r_k$ ) é ortogonal à direção calculada na iteração  $k - 1$  ( $p_{k-1}$ ). Ou seja,

$$r_k^T p_{k-1} = 0.$$

# Método dos Gradientes Conjugados

Lembre-se que

$$q_k = -\frac{r_{k-1}^T p_k}{(A p_k)^T p_k}.$$

Com estas propriedades, temos que

$$-(r_{k-1}^T p_k) = -r_{k-1}^T (-r_{k-1} + \alpha_{k-1} p_{k-1}) =$$

$$r_{k-1}^T r_{k-1} - \alpha_{k-1} r_{k-1}^T p_{k-1} = r_{k-1}^T r_{k-1}$$

Ou seja,

$$q_k = \frac{r_{k-1}^T r_{k-1}}{(A p_k)^T p_k}.$$

O valor de  $\alpha_{k-1}$  é dado por

$$\alpha_{k-1} = \frac{r_{k-1}^T A p_{k-1}}{p_{k-1}^T A p_{k-1}}.$$

Como

$$r_k = r_{k-1} + q_k A p_k,$$

temos que

$$A p_{k-1} = \frac{1}{q_{k-1}} (r_{k-1} - r_{k-2}).$$

Usando as propriedades mencionadas, temos que

$$r_{k-1}^T A p_{k-1} = r_{k-1}^T \left( \frac{1}{q_{k-1}} (r_{k-1} - r_{k-2}) \right) =$$

$$\frac{1}{q_{k-1}} r_{k-1}^T r_{k-1} - \frac{1}{q_{k-1}} r_{k-1}^T r_{k-2} \Rightarrow$$

$$r_{k-1}^T A p_{k-1} = \frac{1}{q_{k-1}} r_{k-1}^T r_{k-1}.$$

# Método dos Gradientes Conjugados

Além disso,

$$p_{k-1}^T A p_{k-1} = p_{k-1}^T \left( \frac{1}{q_{k-1}} (r_{k-1} - r_{k-2}) \right) =$$

$$\frac{1}{q_{k-1}} p_{k-1}^T r_{k-1} - \frac{1}{q_{k-1}} p_{k-1}^T r_{k-2} = -\frac{1}{q_{k-1}} p_{k-1}^T r_{k-2} =$$

$$-\frac{1}{q_{k-1}} (-r_{k-2} + \alpha_{k-2} p_{k-2})^T r_{k-2} = -\frac{1}{q_{k-1}} (-r_{k-2}^T r_{k-2} + \alpha_{k-2} p_{k-2}^T r_{k-2}) =$$

$$\frac{1}{q_{k-1}} r_{k-2}^T r_{k-2} - \frac{\alpha_{k-2}}{q_{k-1}} p_{k-2}^T r_{k-2} \Rightarrow$$

$$p_{k-1}^T A p_{k-1} = \frac{1}{q_{k-1}} r_{k-2}^T r_{k-2}.$$

Portanto,

$$\alpha_{k-1} = \frac{r_{k-1}^T A p_{k-1}}{p_{k-1}^T A p_{k-1}} \Rightarrow$$

$$\alpha_{k-1} = \frac{r_{k-1}^T r_{k-1}}{r_{k-2}^T r_{k-2}}.$$

**Método dos Gradientes Conjugados:** dadas a dimensão  $n$ , uma matriz  $A \in \mathbf{R}^{n \times n}$  simétrica definida positiva, um vetor  $b \in \mathbf{R}^n$ , uma aproximação inicial  $x_0$ , uma tolerância  $TOL > 0$  e o número máximo de iterações  $MAXIT$ , devolve  $x_k$  uma aproximação da solução de  $Ax = b$  ou emite uma mensagem de erro.

**Passo 1:** Faça  $r_0 \leftarrow Ax_0 - b$ .

**Passo 2:** Se  $\|r_0\| < \epsilon$ , então

devolva  $x_0$  como solução e pare.

**Passo 3:** Faça  $p_1 \leftarrow -r_0$  e  $q_1 \leftarrow \frac{r_0^T r_0}{(Ar_0)^T r_0}$ .

**Passo 4:** Faça  $x_1 \leftarrow x_0 + q_1 p_1$ .

**Passo 5:** Se  $\|x_1 - x_0\| < \epsilon$  ou  $\frac{\|x_1 - x_0\|}{\|x_1\|} < \epsilon$ , então

devolva  $x_1$  como solução e pare.

**Passo 6:** Faça  $r_1 \leftarrow r_0 + q_1 Ap_1$  e  $k \leftarrow 2$ .

## Algoritmo - continuação

**Passo 7:** Enquanto  $k \leq MAXIT$ , execute os passos 8 a 14:

**Passo 8:** Se  $\|r_{k-1}\| < \epsilon$ , então

devolva  $x_{k-1}$  como solução e pare.

**Passo 9:** Faça  $\alpha_{k-1} \leftarrow \frac{r_{k-1}^T r_{k-1}}{r_{k-2}^T r_{k-2}}$ .

**Passo 10:** Faça  $p_k \leftarrow -r_{k-1} + \alpha_{k-1} p_{k-1}$ .

**Passo 11:** Faça  $q_k \leftarrow \frac{r_{k-1}^T r_{k-1}}{(Ap_k)^T p_k}$ .

**Passo 12:** Faça  $x_k \leftarrow x_{k-1} + q_k p_k$ .

**Passo 13:** Se  $\|x_k - x_{k-1}\| < \epsilon$  ou  $\frac{\|x_k - x_{k-1}\|}{\|x_k\|} < \epsilon$ , então  
devolva  $x_k$  como solução e pare.

**Passo 14:** Faça  $r_k \leftarrow r_{k-1} + q_k A p_k$  e  $k \leftarrow k + 1$ .

**Passo 15:** Escreva “o método falhou após  $MAXIT$  iterações” e pare.

**Teorema 1:** *No Método dos Gradientes Conjugados, as direções  $p_k$  formam um sistema de direções conjugadas e os resíduos formam um sistema ortogonal. Isto é, para  $i, j = 1, 2, \dots, i \neq j$ ,*

$$(Ap_i)^T p_j = 0$$

e

$$r_i^T r_j = 0.$$

**Teorema 2:** *Dado um sistema linear  $Ax = b$ ,  $A \in \mathbf{R}^{n \times n}$ ,  $b, x \in \mathbf{R}^n$ , o Método dos Gradientes Conjugados fornece a solução do sistema em, no máximo,  $n$  iterações.*

Vamos usar o Método dos Gradientes Conjugados para encontrar a solução do sistema linear

$$\begin{pmatrix} 10 & 1 & 0 \\ 1 & 10 & 1 \\ 0 & 1 & 10 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 11 \\ 11 \\ 1 \end{pmatrix}$$

com precisão  $10^{-2}$ , usando o ponto inicial  $x_0 = (0, 0, 0)^T$ .

Na primeira iteração ( $k = 1$ ), temos que

$$r_0 = \begin{pmatrix} -11 \\ -11 \\ -1 \end{pmatrix},$$

$$p_1 = -r_0, \quad q_1 = t_{\min} = 0.0902,$$

$$x_1 = \begin{pmatrix} 0.9922 \\ 0.9922 \\ 0.0902 \end{pmatrix} \quad \text{e} \quad r_1 = \begin{pmatrix} -0.0858 \\ 0.0044 \\ 0.8942 \end{pmatrix}.$$

# Exemplo

Para  $k = 2$ , temos

$$\alpha_1 = \frac{r_1^T r_1}{r_0^T r_0} = \frac{0.8070}{243} = 0.0033$$

e

$$p_2 = -r_1 + \alpha_1 p_1 = \begin{pmatrix} 0.0858 \\ -0.0044 \\ -0.8942 \end{pmatrix} + 0.0033 \begin{pmatrix} 11 \\ 11 \\ 1 \end{pmatrix} = \begin{pmatrix} 0.1221 \\ 0.0319 \\ -0.8909 \end{pmatrix}.$$

# Exemplo

Assim,

$$Ap_2 = \begin{pmatrix} 10 & 1 & 0 \\ 1 & 10 & 1 \\ 0 & 1 & 10 \end{pmatrix} \begin{pmatrix} 0.1221 \\ 0.0319 \\ -0.8909 \end{pmatrix} = \begin{pmatrix} 1.2529 \\ -0.4498 \\ -8.8771 \end{pmatrix},$$

$$(Ap_2)^T p_2 = 0.1530 - 0.0143 + 7.9086 = 8.0473$$

e

$$q_2 = \frac{r_1^T r_1}{(Ap_2)^T p_2} = \frac{0.8070}{8.0473} = 0.1003.$$

# Exemplo

Portanto,

$$x_2 = x_1 + q_2 p_2 = \begin{pmatrix} 0.9922 \\ 0.9922 \\ 0.0902 \end{pmatrix} + 0.1003 \begin{pmatrix} 0.1221 \\ 0.0319 \\ -0.8909 \end{pmatrix} = \begin{pmatrix} 1.0044 \\ 0.9954 \\ 0.0008 \end{pmatrix}$$

e

$$r_2 = r_1 + q_2 A p_2 = \begin{pmatrix} 0.0399 \\ -0.0407 \\ 0.0038 \end{pmatrix}.$$

# Exemplo

Para  $k = 3$ , temos

$$\alpha_2 = \frac{r_2^T r_2}{r_1^T r_1} = \frac{0.0033}{0.8070} = 0.0041$$

e

$$p_3 = -r_2 + \alpha_2 p_2 = \begin{pmatrix} -0.0394 \\ 0.0408 \\ -0.0001 \end{pmatrix}.$$

Assim,

$$Ap_3 = \begin{pmatrix} -0.3532 \\ 0.3685 \\ 0.0398 \end{pmatrix},$$

$$(Ap_3)^T p_3 = 0.0139 + 0.0150 - 0.0000 = 0.0289$$

e

$$q_3 = \frac{r_2^T r_2}{(Ap_3)^T p_3} = \frac{0.0033}{0.0289} = 0.1142.$$

Portanto,

$$x_3 = x_2 + q_3 p_3 = \begin{pmatrix} 0.9999 \\ 1.0001 \\ 0.0008 \end{pmatrix}.$$

Note que

$$\frac{\|x_3 - x_2\|_\infty}{\|x_3\|_\infty} = \frac{0.0047}{1.0001} \approx 0.0047 < 10^{-2}.$$