

Preliminares:

- $\mathbf{x}^T \mathbf{y}$ representa o produto escalar, (\mathbf{x}, \mathbf{y}) , entre dois vetores do \mathbb{R}^n .
- \mathbf{x} e \mathbf{y} são ortogonais se e somente se $\mathbf{x}^T \mathbf{y} = 0$.
- Se A é uma matriz simétrica positiva definida então:
 - Se \mathbf{x} é um vetor não-nulo então $\mathbf{x}^T A \mathbf{x} > 0$;
 - $\text{Det}(A) > 0$.
 - A tem auto-valores positivos
 - Os elementos diagonais de A são positivos;
- $(AB)^T = B^T A^T$
- $\mathbf{r} = \mathbf{b} - A\mathbf{x}$ - vetor residual. Se \mathbf{x} é solução do sistema linear $A\mathbf{x} = \mathbf{b}$ então $\mathbf{r} = \mathbf{0}$ (vetor nulo).

Seja o sistema linear simétrico positivo definido $A\mathbf{x} = \mathbf{b}$ onde:

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}$$

e consideremos a função $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ definida por

$$\begin{aligned} f : \mathbb{R}^2 &\rightarrow \mathbb{R} \\ \mathbf{x} &\rightarrow f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T A \mathbf{x} - \mathbf{b}^T \mathbf{x} + c, \quad c \in \mathbb{R} \end{aligned}$$

ou seja,

$$\begin{aligned} f(\mathbf{x}) &= \frac{1}{2}[x_1 \ x_2] \begin{bmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} - [b_1 \ b_2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + c \\ &= \frac{1}{2}[x_1 \ x_2] \begin{bmatrix} a_{11}x_1 + a_{12}x_2 \\ a_{12}x_1 + a_{22}x_2 \end{bmatrix} - (b_1x_1 + b_2x_2) + c. \end{aligned}$$

Logo,

$$f(\mathbf{x}) = \frac{1}{2} \left\{ a_{11}x_1^2 + a_{22}x_2^2 + 2a_{12}x_1x_2 \right\} - (b_1x_1 + b_2x_2) + c.$$

Observamos que:

- A é uma matriz SPD e portanto a_{11} e a_{22} são positivos.
- Desde que $f(\mathbf{x})$ é uma função quadrática de \mathbf{x} , do cálculo diferencial, sabemos que necessariamente, $f(\mathbf{x})$ possui um ponto crítico, \mathbf{x}^* (onde $f'(\mathbf{x}^*) = 0$) de modo que $f(\mathbf{x}^*)$ é um ponto de mínimo de $f(\mathbf{x})$.

Calculando $f'(\mathbf{x})$ vem:

$$f'(\mathbf{x}) = \nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \end{bmatrix} = \begin{bmatrix} \frac{1}{2} \{ 2a_{11}x_1 + 2a_{12}x_2 \} - b_1 \\ \frac{1}{2} \{ 2a_{22}x_2 + 2a_{12}x_1 \} - b_2 \end{bmatrix} = \begin{bmatrix} a_{11}x_1 + a_{12}x_2 - b_1 \\ a_{11}x_2 + a_{12}x_1 - b_2 \end{bmatrix} = A\mathbf{x} - \mathbf{b}.$$

Logo, $f'(\mathbf{x}) = 0 \iff A\mathbf{x} = \mathbf{b} \iff \mathbf{x}$ é solução do sistema linear $A\mathbf{x} = \mathbf{b}$.

Conclusões:

- Se f tem ponto de mínimo então existe \mathbf{x}^* tal que $f'(\mathbf{x}^*) = 0 \implies A\mathbf{x}^* - \mathbf{b} = \mathbf{0} \implies A\mathbf{x}^* = \mathbf{b}$.
Portanto, \mathbf{x}^* é sol. do sistema linear $A\mathbf{x} = \mathbf{b}$.
- Se \mathbf{x}^* é sol. do sistema linear $\implies A\mathbf{x}^* = \mathbf{b} \implies A\mathbf{x}^* - \mathbf{b} = \mathbf{0} \implies f'(\mathbf{x}^*) = 0 \implies \mathbf{x}^*$ é ponto crítico de $f(\mathbf{x})$. Como A é SPD então \mathbf{x}^* é ponto de mínimo de $f(\mathbf{x})$.
- Portanto, para encontrar a solução do sistema linear $A\mathbf{x}^* = \mathbf{b}$ basta encontrar o ponto de mínimo de $f(\mathbf{x})$.

iv) Do cálculo, sabemos que $f'(\mathbf{x}) = \nabla f(\mathbf{x})$ é um vetor que aponta na direção de maior crescimento da função $f(\mathbf{x})$ e portanto, o vetor $-\nabla f(\mathbf{x})$ aponta em uma direção de menor crescimento da função $f(\mathbf{x})$.

Isso significa que: dados \mathbf{x} e $\lambda > 0$, $f(\mathbf{x} - \lambda \nabla f(\mathbf{x})) < f(\mathbf{x})$. Vamos utilizar essa propriedade de $f(\mathbf{x})$ para calcular seu ponto crítico \mathbf{x}^* (e portanto a solução do sistema linear $A\mathbf{x} = \mathbf{b}$).

Método dos Gradientes

Sem perda de generalidades, podemos considerar agora: A uma matriz SPD e

$$\begin{aligned} f : \mathbb{R}^n &\rightarrow \mathbb{R} \\ \mathbf{x} &\rightarrow f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T A \mathbf{x} - \mathbf{b}^T \mathbf{x} + c, \quad c \in \mathbb{R} \end{aligned}$$

Nesse método, a solução do sistema linear é obtida pela procura do ponto de mínimo da função $f(\mathbf{x})$ como segue.

Dada uma aproximação inicial, $\mathbf{x}^{(0)}$, para a solução do sistema linear $A\mathbf{x} = \mathbf{b}$, uma nova aproximação é calculada por meio de uma correção de $\mathbf{x}^{(0)}$ na direção $-\nabla f(\mathbf{x}^{(0)}) = \mathbf{b} - A\mathbf{x}^{(0)} = \mathbf{r}^{(0)}$ que aponta na direção em que f decresce mais rapidamente (o ponto de mínimo de f que é a solução do sistema linear).

De fato temos que $-\nabla f(\mathbf{x}^{(k)}) = \mathbf{b} - A\mathbf{x}^{(k)} = \mathbf{r}^{(k)}$. Seja $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \lambda \mathbf{r}^{(0)}$. Sabemos que $f(\mathbf{x}^{(1)}) < f(\mathbf{x}^{(0)})$, $\forall \lambda > 0$. O valor de λ é calculado de modo que $f(\mathbf{x}^{(1)})$ seja minimizada em relação a λ , ou seja, quando $\frac{\partial f(\mathbf{x}^{(1)})}{\partial \lambda} = 0$.

Do cálculo, temos:

$$\frac{\partial f(\mathbf{x}^{(1)})}{\partial \lambda} = \left(f'(\mathbf{x}^{(1)})\right)^T \frac{\partial \mathbf{x}^{(1)}}{\partial \lambda} = \left(f'(\mathbf{x}^{(1)})\right)^T \mathbf{r}^{(0)} = 0. \quad (1)$$

Essa equação sugere que λ seja calculado de modo que $f'(\mathbf{x}^{(1)})$ e $\mathbf{r}^{(0)}$ sejam ortogonais. Substituindo $f'(\mathbf{x}^{(1)}) = \mathbf{r}^{(1)}$ na eq. (1), vem:

$$(\mathbf{r}^{(1)})^T \mathbf{r}^{(0)} = 0 \quad (2)$$

$$\left[\mathbf{b} - A\mathbf{x}^{(1)}\right]^T \mathbf{r}^{(0)} = 0, \text{ desde que } \mathbf{r}^{(1)} = \mathbf{b} - A\mathbf{x}^{(1)} \quad (3)$$

$$\left[\mathbf{b} - A(\mathbf{x}^{(0)} + \lambda \mathbf{r}^{(0)})\right]^T \mathbf{r}^{(0)} = 0, \text{ desde que } \mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \lambda \mathbf{r}^{(0)} \quad (4)$$

$$\left[\mathbf{b} - A\mathbf{x}^{(0)}\right]^T \mathbf{r}^{(0)} - \lambda \left[A\mathbf{r}^{(0)}\right]^T \mathbf{r}^{(0)} = 0 \quad (5)$$

$$(\mathbf{r}^{(0)})^T \mathbf{r}^{(0)} = \lambda \left[A\mathbf{r}^{(0)}\right]^T \mathbf{r}^{(0)} \quad (6)$$

$$\therefore \lambda = \frac{(\mathbf{r}^{(0)})^T \mathbf{r}^{(0)}}{(\mathbf{r}^{(0)})^T A \mathbf{r}^{(0)}}. \quad (7)$$

Tendo calculado, $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \lambda \mathbf{r}^{(0)}$, o cálculo de $\mathbf{x}^{(2)}$ segue a mesma metodologia, ou seja, $\mathbf{x}^{(2)} = \mathbf{x}^{(1)} + \lambda \mathbf{r}^{(1)}$ onde o cálculo de λ conduz a $\lambda = \frac{(\mathbf{r}^{(1)})^T \mathbf{r}^{(1)}}{(\mathbf{r}^{(1)})^T A \mathbf{r}^{(1)}}$.

ALGORITMO MÉTODO DOS GRADIENTES (ou MÉTODO DE MÁXIMA DESCIDA)

Dada uma aproximação inicial $\mathbf{x}^{(0)}$ para a solução do sistema linear $A\mathbf{x} = \mathbf{b}$, o método iterativo *MÉTODOS DOS GRADIENTES* calcula aproximações $\mathbf{x}^{(k+1)}$ como segue:

Para $k = 0, 1, \dots$, faça

- ▶ Calcule o residuo $\mathbf{r}^{(k)}$

$$\mathbf{r}^{(k)} = \mathbf{b} - A\mathbf{x}^{(k)}$$

- ▶ Calcule λ_k

$$\lambda_k = \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{r}^{(k)})^T A \mathbf{r}^{(k)}}$$

- ▶ Calcule $\mathbf{x}^{(k+1)}$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \lambda_k \mathbf{r}^{(k)}$$

MÉTODO DOS GRADIENTES CONJUGADOS

Deficiência do método dos gradientes: as direções adotadas podem ser reusadas \implies convergência lenta.

Para evitar que uma mesma direção $\mathbf{r}^{(k)}$ se repita, o **Método dos Gradientes Conjugados** propõe uma alteração no Método dos Gradientes: as direções de busca são definidas por vetores A – *ortogonais*. como segue:

VETORES A-ORTOGONAIS: Dois vetores não-nulos \mathbf{x} e \mathbf{y} são A-ortogonais se $(\mathbf{x}^T, A\mathbf{y}) = (\mathbf{y}^T, A\mathbf{x}) = 0$.

Dado $\mathbf{x}^{(0)}$, faça $\mathbf{d}^{(0)} = \mathbf{r}^{(0)} = \mathbf{b} - A\mathbf{x}^{(0)}$. O valor de $\mathbf{x}^{(1)}$ é calculado por $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \lambda^{(0)}\mathbf{d}^{(0)}$.

Para obter o tamanho do passo $\lambda^{(0)}$, procedemos como no caso do Método dos Gradientes, isto é,

$$\frac{\partial (f(\mathbf{x}^{(1)}))}{\partial d\lambda} = f'(\mathbf{x}^{(1)}) \frac{d\mathbf{x}^{(1)}}{d\lambda} = -(\mathbf{r}^{(1)})^T \mathbf{d}^{(0)} = 0 \quad (\text{queremos que } \lambda \text{ minimize } f(\mathbf{x}^{(1)}))$$

Logo,

$$\begin{aligned} (\mathbf{r}^{(1)})^T \mathbf{d}^{(0)} = 0 &\implies (\mathbf{d}^{(0)})^T \mathbf{r}^{(1)} = 0 \implies (\mathbf{d}^{(0)})^T (\mathbf{b} - A\mathbf{x}^{(1)}) = 0 \\ &\implies (\mathbf{d}^{(0)})^T (\mathbf{b} - A(\mathbf{x}^{(0)} + \lambda^{(0)}\mathbf{d}^{(0)})) = 0 \\ &\implies (\mathbf{d}^{(0)})^T \left(\underbrace{\mathbf{b} - A\mathbf{x}^{(0)}}_{\mathbf{r}^{(0)}} - \lambda^{(0)} A \mathbf{d}^{(0)} \right) = 0 \\ &\implies (\mathbf{d}^{(0)})^T \mathbf{r}^{(0)} - \lambda^{(0)} (\mathbf{d}^{(0)})^T A \mathbf{d}^{(0)} = 0 \\ &\implies \lambda^{(0)} = \frac{(\mathbf{d}^{(0)})^T \mathbf{r}^{(0)}}{(\mathbf{d}^{(0)})^T A \mathbf{d}^{(0)}} \implies \lambda^{(0)} = \frac{(\mathbf{r}^{(0)})^T \mathbf{r}^{(0)}}{(\mathbf{d}^{(0)})^T A \mathbf{d}^{(0)}} \end{aligned}$$

Para que $\mathbf{r}^{(1)} = \mathbf{r}^{(0)} - \lambda^{(0)} A \mathbf{d}^{(0)}$ seja ortogonal a nova direção $\mathbf{d}^{(1)} = \mathbf{r}^{(1)} - \beta^{(1)} \mathbf{d}^{(0)}$ é necessário escolher um valor conveniente para $\beta^{(1)}$. Logo, impondo $(\mathbf{r}^{(1)})^T \mathbf{d}^{(1)} = 0$, vem

$$(\mathbf{r}^{(1)})^T \mathbf{d}^{(1)} = 0 \implies \left(\mathbf{r}^{(0)} - \frac{(\mathbf{r}^{(0)})^T \mathbf{r}^{(0)}}{(\mathbf{d}^{(0)})^T A (\mathbf{d}^{(0)})} A \mathbf{d}^{(0)} \right)^T (\mathbf{r}^{(1)} + \beta^{(1)} \mathbf{d}^{(0)}) = 0$$

Nessa fórmula, fazendo os cálculos, simplificações e remanejamentos, pode-se mostrar que obtém-se:

$$\beta^{(1)} = \frac{(\mathbf{r}^{(1)})^T \mathbf{r}^{(1)}}{(\mathbf{r}^{(0)})^T \mathbf{r}^{(0)}}$$

Em geral, dado $\mathbf{x}^{(0)}$, as aproximações $\mathbf{x}^{(k+1)}$ no método dos gradientes conjugados são calculadas pelo seguinte algoritmo:

- ▶ $\mathbf{d}^{(0)} = \mathbf{r}^{(0)} = \mathbf{b} - A \mathbf{x}^{(0)}$
- ▶ Para $k = 0, 1, \dots$
 - ▶ $\lambda^{(k)} = \frac{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}{(\mathbf{d}^{(k)})^T A (\mathbf{d}^{(k)})}$
 - ▶ $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \lambda^{(k)} \mathbf{d}^{(k)}$
 - ▶ $\mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} - \lambda^{(k)} A \mathbf{d}^{(k)}$
 - ▶ $\beta^{(k+1)} = \frac{(\mathbf{r}^{(k+1)})^T \mathbf{r}^{(k+1)}}{(\mathbf{r}^{(k)})^T \mathbf{r}^{(k)}}$
 - ▶ $\mathbf{d}^{(k+1)} = \mathbf{r}^{(k+1)} + \beta^{(k+1)} \mathbf{d}^{(k)}$

EXEMPLO: Os sistemas lineares abaixo tem sol. exata $\mathbf{x} = [1 \ 1 \ 1 \ 1 \ 1]^T$.

$$\begin{array}{ccc}
 \overbrace{b1=[0.1 \ 0.1 \ 0.1 \ 0.1 \ 0.1]} & \overbrace{b2=[0 \ 1 \ 1 \ 1 \ 1]} & \overbrace{b3=[-1 \ 0 \ 0 \ 1 \ 2]} \\
 \underbrace{\begin{bmatrix} 4.1 & -1 & -1 & -1 & -1 \\ -1 & 4.1 & -1 & -1 & -1 \\ -1 & -1 & 4.1 & -1 & -1 \\ -1 & -1 & -1 & 4.1 & -1 \\ -1 & -1 & -1 & -1 & 4.1 \end{bmatrix}}_{A1} & \underbrace{\begin{bmatrix} 4 & -1 & -1 & -1 & -1 \\ -1 & 5 & -1 & -1 & -1 \\ -1 & -1 & 5 & -1 & -1 \\ -1 & -1 & -1 & 5 & -1 \\ -1 & -1 & -1 & -1 & 5 \end{bmatrix}}_{A2} & \underbrace{\begin{bmatrix} 3 & -1 & -1 & -1 & -1 \\ -1 & 4 & -1 & -1 & -1 \\ -1 & -1 & 4 & -1 & -1 \\ -1 & -1 & -1 & 5 & -1 \\ -1 & -1 & -1 & -1 & 6 \end{bmatrix}}_{A3}
 \end{array}$$

Dados utilizados: $\mathbf{x}^{(0)} = \mathbf{0}$, $TOL = 10^{-3}$ - Critério parada: $\|\mathbf{r}^{k+1}\|_2 < TOL$.

$\mathbf{x}^{(1)} - \ \mathbf{r}^{(1)}\ _2 = 0.0$	$\mathbf{x}^{(27)} - \ \mathbf{r}^{(27)}\ _2 = 0.8453 \cdot 10^{-3}$	$\mathbf{x}^{(105)} - \ \mathbf{r}^{(105)}\ _2 = 0.9799 \cdot 10^{-3}$
0.999999	0.999418258666992	0.997215533669189
0.999999	0.999529361724854	0.997796038750797
0.999999	0.999529361724854	0.997796038750797
0.999999	0.999529361724854	0.998176249205648
0.999999	0.999529361724854	0.998444609213319

Resultados obtidos com o metodo gradiente conjugado

$\mathbf{x}^{(1)} - \ \mathbf{r}^{(1)}\ _2 = 0.0$	$\mathbf{x}^{(2)} - \ \mathbf{r}^{(2)}\ _2 = 0.0$	$\mathbf{x}^{(4)} - \ \mathbf{r}^{(4)}\ _2 = 0.1166 \cdot 10^{-8}$
0.9999999999999997	1.0000000000000000	1.0000000000000000
0.9999999999999997	1.0000000000000000	1.0000000000000000
0.9999999999999997	1.0000000000000000	1.0000000000000000
0.9999999999999997	1.0000000000000000	1.0000000000000000
0.9999999999999997	1.0000000000000000	1.0000000000000000