

## O MÉTODO DOS GRADIENTES CONJUGADOS

Joelson Joventino Santos<sup>1</sup> - joelson.joventino@estudante.ufcg.edu.br  
Sabrina Kely Jacinto Xavier<sup>1</sup> - sabrina.kely@estudante.ufcg.edu.br  
Luiz Antônio da Silva Medeiros<sup>1</sup> - luiz.silva@professor.ufcg.edu.br

<sup>1</sup>Universidade Federal de Campina Grande, Unidade Acadêmica de Matemática - Campina Grande, PB, Brasil

**Resumo:** Os Métodos Gradientes Conjugados têm sido estudados desde a década de 1950, a motivação para tal era a solução de sistemas provenientes da discretização de equações diferenciais parciais viabilizadas pela entrada dos computadores nos cálculos científicos. Neste presente trabalho, buscamos apresentar e introduzir o Método dos Gradientes Conjugados, desde a sua fundamentação teórica à implementação do algoritmo estabelecido pelo Método, estabelecendo assim suas propriedades e aplicações.

**Palavras-chave:** Gradiente Conjugado; Otimização; Programação Não-Linear; Métodos Computacionais

### 1. Introdução

Os Métodos Gradientes Conjugados (MGC) têm sido estudados desde a década de 1950, a motivação para tal era a solução de sistemas provenientes da discretização de equações diferenciais parciais viabilizadas pela entrada dos computadores nos cálculos científicos. A base para o que seria futuramente desenvolvido é amplamente creditado ao trabalho de Hestenes e Stiefel (1952).

Para uma matriz  $A$  definida positiva, resolver sistemas da forma  $Ax = b$ , equivale a minimizar a função vetorial

$$f(x) = \frac{1}{2}x^T Ax - b^T x + c,$$

onde  $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ . Com efeito, sendo  $A$  definida positiva, a função quadrática é convexa e portanto possui um único ponto crítico que é seu minimizador. Ou seja,

$$x^* = \operatorname{argmin} \left\{ \frac{1}{2}x^T Ax - b^T x + c, \quad x \in \mathbb{R}^n \right\} \Leftrightarrow \nabla f(x^*) = 0 \Leftrightarrow Ax^* = b.$$

Iremos inicialmente, apresentar algumas definições e resultados importantes acerca da construção do Método dos Gradientes Conjugados de forma a apresentar as ferramentas utilizadas no desenvolvimento teórico. Dessa forma, os resultados a seguir são cruciais para um melhor entendimento da parte prática do MGC.

Seja  $A$  uma matriz  $n \times n$  simétrica definida positiva. Os vetores  $d_0, d_1, \dots, d_k$  são chamados A-conjugados se

$$d_i^T A d_j = 0, \quad \text{para todo } i \neq j.$$

com  $i, j = 0, 1, \dots, k$ .

Perceba que essa definição pode ser ampliada para matrizes que não sejam definidas positivas. Porém, caso  $A$  seja definida positiva e  $d_0, d_1, \dots, d_k$  não nulos, então esses vetores são linearmente independentes.

**Teorema 1.** Considere o problema

$$\text{minimize } f(x) = \frac{1}{2}x^T Ax - b^T x + c,$$

onde  $A \in \mathbb{R}^{n \times n}$  é simétrica definida positiva,  $b \in \mathbb{R}^n$  e  $c \in \mathbb{R}$ . Sejam  $d_0, d_1, \dots, d_{n-1}$  direções A-conjugadas e seja  $x_0 \in \mathbb{R}^n$  um ponto inicial arbitrário. Definimos

$$x_{k+1} = x_k + \lambda_k d_k,$$

onde  $\lambda_k$  é o passo ótimo da minimização de  $f(x_k + \lambda d_k)$ . Segue daí os seguintes resultados:



$$(i) \lambda_k = \frac{-\nabla f(x_k)^T d_k}{d_k^T A d_k};$$

$$(ii) \nabla f(x_k)^T d_j = 0, j = 0, 1, \dots, k-1;$$

(iii)  $x_n$  é o mínimo de  $f$  em  $\mathbb{R}^n$ .

**Teorema 2. (Teorema dos Subespaços Expandidos)** Sob as mesmas hipóteses do Teorema 1, temos que  $x_k$  minimiza  $f$  em  $B_k = \{d_0, d_1, \dots, d_{k-1}\}$ , para  $k = 1, \dots, n$ .

## 2. Metodologia

Esta foi uma pesquisa realizada de forma exploratória, onde estudamos os principais livros e artigos de autores que são referência na área de Otimização, dentre eles Friedlander (1994), Bertsekas (1996), Burden e Faires (2003), Martinez e Santos (2020), Izmailov e Solodov (2018). Semanalmente eram expostos, em encontros; nossos estudos na forma de seminários, nesses seminários sob orientação do Prof. Dr. Luiz Antônio da Silva Medeiros discutimos e demonstramos todos os conceitos aqui apresentados.

## 3. Resultado e discussão

O método de Gradiente Conjugado (MGC) proposto por Hestenes e Stiefel, no ano de 1952, gera um conjunto de  $n$  direções conjugadas e de descida para  $f : d_0, d_1, \dots, d_{n-1}$ , com  $d_0 = -\nabla f(x_0)$  e

$$d_{k+1} = -\nabla f(x_{k+1}) + \beta_k d_k, \quad (1)$$

onde  $\beta_k$  é um escalar e deve ser escolhido de modo que duas direções seguidas  $d_k$  e  $d_{k+1}$  sejam A-conjugadas, ou seja,  $d_{k+1}^T A d_k = 0$ , assim

$$\beta_k = \frac{\nabla f(x_{k+1})^T A d_k}{d_k^T A d_k}. \quad (2)$$

**Teorema 3.** As direções  $d_k$ ,  $k = 0, 1, \dots, n-1$  gerados por 1 e 2 são direções A-conjugadas.

**Teorema 4.** Depois de  $k$  iterações do MGC, os gradientes  $\nabla f(x_0), \nabla f(x_1), \dots, \nabla f(x_{k-1})$  são mutuamente ortogonais.

A maneira de calcular o resíduo  $r_k$  em uma iteração  $k$  ( $r_k = b - A x_k = -\nabla f(x_k)$ ), assim como  $\lambda_k$  e  $\beta_k$ , não é única, existem diversas fórmulas cujas combinações fornecem várias versões do MGC. No entanto, apesar de que todas essas versões sejam matematicamente equivalentes, sua implementação computacional não é. Buscamos a versão que apresenta em termos de trabalho computacional, memória gasta e precisão. Segundo Bertsekas (1996) tal versão calcula  $r_k, \lambda_k$  e  $\beta_k$  da seguinte forma:

$$(i) \lambda_k = \frac{r_k^T r_k}{d_k^T A d_k};$$

$$(ii) r_{k+1} = r_k - \lambda_k A d_k;$$

$$(iii) \beta_k = \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k}.$$

Através da construção feita até aqui com base nos últimos resultados, podemos exibir um algoritmo de Gradiente Conjugado propício ao uso com fins de otimização de funções quadráticas:

- Inicialização: São dados a estimativa  $0 < x_0 \in \mathbb{R}^n$  e  $\epsilon > 0$ ;

$$d_0 = r_0 = -\nabla f(x_0) = b - Ax_0; \text{ (se } d_0 = 0 \text{ paramos)}$$

$$\delta_0 = r_0^T r_0;$$

$$k = 0;$$

- Para  $k = 0, 1, \dots$

$$h_k = Ad_k; \lambda_k = \frac{\delta_0}{d_k^T h_k};$$

$$x_{k+1} = x_k + \lambda_k d_k; r_{k+1} = r_k + \lambda_k d_k; \text{ (se } < r_k \text{ devolve)}$$

Se  $\|r_{k+1}\| < \epsilon$ , saída com  $x_* = x_{k+1}$ ; (paramos)

$$\delta_1 = r_{k+1}^T r_{k+1};$$

$$\beta_k = \frac{\delta_1}{\delta_0};$$

$$\delta_0 = \delta_1; \text{ (aqui muda a iteração)}$$

$$d_{k+1} = r_{k+1} + \beta_k d_k.$$

Quanto à memória ocupada: são necessários vetores de dimensão  $n$  para armazenar  $h, x, r, d$  e uma matriz de dimensão  $n \times n$  para armazenar  $A$  (numa implementação para sistemas esparsos, o armazenamento de  $A$  depende de seu número de elementos não nulos e da estrutura de dados usada).

Quanto ao esforço computacional gasto: temos, por iteração, um produto de matriz por vetor ( $Ad_k$ ) e dois produtos internos, além das multiplicações por escalar e adições envolvidas nas fórmulas recursivas. Logo, o número de operações por iteração é  $O(2n^2)$ .

Com considerações adicionais pode se mostrar um resultado "mais forte" sobre a convergência do MGC, conforme estabelece o teorema a seguir.

**Teorema 5.** *Se a matriz  $A$  de ordem  $n$  possui  $n$  autovalores distintos, então O MGC converge, no máximo, em  $n$  iterações.*

Por fim, apresentamos em prática o algoritmo recém exibido e a aplicação do Método do Gradiente Conjugado. Optamos por exibir um exemplo de uma função quadrática bidimensional, justamente para acompanhar geometricamente as sequências geradas pelo métodos evidenciando as suas propriedades.

**Exemplo 1.** *Dada a função quadrática  $f(x) = \frac{3}{2}x^2 - 2x + 2xy + 8y + 3y^2$ , ao aplicarmos o algoritmo apresentado, tomando como ponto inicial  $x_0 = (-2, 2)$ , obtemos os seguintes resultados:*

	$d_i$	$\delta_i$	$h_i$	$\lambda_i$	$x_{i+1}$	$r_{i+1}$	$\beta_i$
$i = 0$	(12; 8)	208	(52; 72)	13/75	(0.08; -0.613)	(2.986; -4.48)	0.139
$i = 1$	(4.654; -3.368)	28.9865	(7.226; -10.9)	0.4121	(2; -2)	(0; 0)	-

Tabela 1: Resultado do Algoritmo MGC aplicado à função do Exemplo 1

Dessa forma, como  $r_2 = (0; 0)$  podemos concluir que  $x_2 = (2; -2)$  é o minimizador desta função, ou seja, o vetor  $x^* = x_2 = (2; -2)$  é solução do sistema  $Ax = b$ , onde

$$A = \begin{bmatrix} 3 & 2 \\ 2 & 6 \end{bmatrix} \quad e \quad b = \begin{bmatrix} 2 \\ -8 \end{bmatrix}$$

Graficamente, temos a seguinte representação do processo de minimização desta função através do algoritmo:

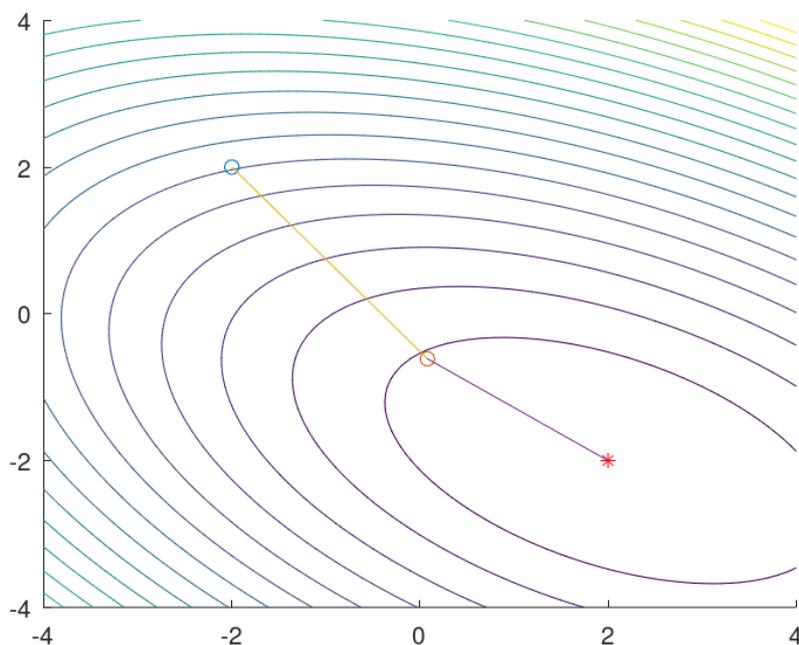


Figura 1: Algoritmo MGC do Exemplo 1 utilizando o OCTave.

## 4. Conclusões

A pesquisa permitiu estabelecer o Método dos Gradientes Conjugados, bem como suas propriedades, de modo a permitir definir o seu algoritmo para obter os pontos críticos de funções quadráticas ao tempo de analisar a sua convergência. Para isto, aplicamos o método em exemplos bidimensionais para melhor visualização e entendimento do algoritmo. Entretanto, da pesquisa, entendemos que o MGC pode ser utilizado também para matrizes definidas negativas e algumas vezes, para matrizes quadradas arbitrárias, estas sem garantias de que o algoritmo convirja.

## Agradecimentos

O presente trabalho é fruto de uma Iniciação Científica parcialmente financiada pelo MEC/FNDE/PET.

## Referências

- BERTSEKAS, D. P. *Nonlinear programming*. Belmont, Massachusetts: Athena Scientific, 1996. Citado na página 2.
- BURDEN, R. L.; FAIRES, J. D. *Análise Numérica*. São Paulo - SP: Thompson Learning, 2003. Citado na página 2.
- FRIEDLANDER, A. *Elementos de programação não linear*. Campinas - SP: Editora da Unicamp, 1994. Citado na página 2.
- HESTENES, M. R.; STIEFEL, E. Methods of conjugate gradients for solving linear systems. *Journal of research of the National Bureau of Standards*, v. 49, p. 409–436, 1952. Citado na página 1.
- IZMAILOV, A.; SOLODOV, M. *Otimização: Métodos Computacionais. Volume 2*. Rio de Janeiro - RJ: IMPA, 2018. Citado na página 2.
- MARTINEZ, J. M.; SANTOS, S. A. *Métodos Computacionais de Otimização*. Campinas - SP: Editora da Unicamp, 2020. Citado na página 2.