

# Uma nova taxa de convergência para o Método do Gradiente aplicado à minimização de funções quadráticas

**Tatiane Cazarin da Silva**

Programa de Pós Graduação em Métodos Numéricos em Engenharia - PPGMNE/UFPR

81531-980, Curitiba, PR

UTFPR - Departamento de Matemática

Campus Campo Mourão

87301-899, Campo Mourão, PR

E-mail: tatianecazarin@utfpr.edu.br

**Ademir Alves Ribeiro**

UFPR - Departamento de Matemática

81531-980, Curitiba, PR

E-mail: ademir.ribeiro@ufpr.br

**Gislaine Aparecida Pericaro**

UNESPAR - Departamento de Matemática

Campus Campo Mourão

87303-100, Campo Mourão, PR

E-mail: gapericaro@fecilcam.br

**Resumo:** *Realizamos neste trabalho um estudo sobre a velocidade de convergência do Método do Gradiente aplicado à minimização de funções quadráticas convexas com busca exata. Destacamos a ocorrência de uma nova taxa de convergência para a sequência gerada pelo algoritmo, diferente das apresentadas na literatura, a qual demonstramos para o caso  $2 \times 2$ .*

**Palavras-chave:** *Gradiente, velocidade, convergência*

## 1. Introdução

Um problema de otimização irrestrita, matematicamente, é definido como

$$\begin{aligned} &\text{minimizar} && f(x) \\ &\text{sujeito a} && x \in \mathbb{R}^n, \end{aligned} \tag{1}$$

em que assumimos que a função objetivo  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é continuamente diferenciável.

Os pontos  $x^*$  candidatos a minimizadores locais da função objetivo são chamados de pontos estacionários, e satisfazem a condição  $\nabla f(x^*) = 0$ , denominada condição necessária de otimalidade. Muitos métodos de otimização se contentam em encontrar pontos estacionários para o problema empregando um processo iterativo.

Dentre os métodos clássicos empregados na resolução do problema (1) temos o Método do Gradiente, o Método de Newton, o Método das Direções Conjugadas e os Métodos de Quase-Newton (IZMAILOV e SOLODOV, 2007; RIBEIRO e KARAS, 2013).

Neste trabalho estudamos o Método do Gradiente, que escolhe como direção de descida a direção oposta ao vetor gradiente da função objetivo avaliada no ponto corrente e definimos para o passo, a busca exata, que procura o minimizador da função ao longo desta direção. O algoritmo do Gradiente encontra-se estruturado a seguir.

**Algoritmo 1:** Algoritmo do Gradiente

Dado:  $x^0 \in \mathbb{R}^n$

$k = 0$

REPITA enquanto  $\nabla f(x^k) \neq 0$

Defina  $d = -\nabla f(x^k)$

Obtenha  $t > 0$  tal que  $f(x^k + td) < f(x^k)$

Faça  $x^{k+1} = x^k + td$

$k = k + 1$

A convergência global do Algoritmo 1 foi comprovado por Ribeiro e Karas (2013). Estamos particularmente interessados em estabelecer uma taxa de convergência linear para o algoritmo do Gradiente, quando aplicado a uma função quadrática dada por

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

com  $A \in \mathbb{R}^{n \times n}$ ,  $A \succ 0$ ,  $b \in \mathbb{R}^n$  e  $c \in \mathbb{R}$ , com o tamanho do passo  $t$  determinado por busca exata. A taxa de convergência discutida aqui não está presente na literatura e se diferencia das demais, apresentadas adiante, por considerar a norma euclidiana e a busca exata.

Este trabalho está estruturado da seguinte forma: na Seção 2 são apresentadas diferentes abordagens para a taxa de convergência para o Método do Gradiente, na Seção 3 é discutida a conjectura proposta para a taxa de convergência e realizadas algumas considerações finais.

**2. Abordagens para a taxa de convergência do Método do Gradiente**

Diversas são as taxas de convergência para o Método do Gradiente encontradas na literatura, como por exemplo nos trabalhos de Boyd e Vandenberghe (2004), Freund (2004) e Saad (2005). Destacamos duas abordagens em especial, propostas por Bertsekas (1995) e Karas, Mota e Ribeiro (2005), respectivamente.

Bertsekas (1995) apresenta a taxa de convergência clássica para o método do Gradiente, tomando a função quadrática e a norma euclidiana, dada por:

$$\frac{\|x^{k+1} - x^*\|_2}{\|x^k - x^*\|_2} \leq \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}, \tag{3}$$

onde  $\lambda_1$  e  $\lambda_n$  são respectivamente, o maior e menor autovalor de  $A$ , com tamanho de passo fixo, dado por  $t = \frac{2}{\lambda_1 + \lambda_n}$ .

Karas, Mota e Ribeiro (2005) verificaram que essa taxa clássica não é satisfeita quando a busca exata é aplicada, ou seja, quando  $t$  é calculado por  $t = \frac{d^T d}{d^T A d}$ . Nesse contexto, estabeleceram então uma taxa para a velocidade de convergência do algoritmo do Gradiente com busca exata e norma euclidiana, dada por  $\|x^{k+1} - x^*\|_2 \leq \gamma \|x^k - x^*\|_2$ , onde  $\gamma = \sqrt{1 - \frac{\lambda_1}{\lambda_n}}$ . Esse resultado estabelece uma relação entre a velocidade de convergência associada à norma euclidiana dos termos da sequência gerada pelo Algoritmo 1. Analisando a taxa  $\gamma$ , temos que

$$\sqrt{1 - \frac{\lambda_1}{\lambda_n}} \geq 1 - \frac{\lambda_1}{\lambda_n}, \tag{4}$$

pois  $\left(1 - \frac{\lambda_1}{\lambda_n}\right) \in [0, 1)$ . Nesse sentido, verificamos por meio de experimentos numéricos que a taxa de convergência do método proposto pode ser dada por um valor menor

$$\tilde{\gamma} = 1 - \frac{\lambda_1}{\lambda_n}, \tag{5}$$

demonstrado algebricamente para o caso  $2 \times 2$ , conforme apresentado na seção a seguir.

### 3. A nova taxa de convergência

Considere o algoritmo do Gradiente aplicado à minimização da função quadrática dada em (2), para  $n = 2$ , onde assumimos, sem perda de generalidade, que  $b = 0$  e  $c = 0$ . Assim, dado um ponto corrente  $x^k$ , temos  $x^{k+1} = x^k + td$  em que

$$d = -Ax^k. \tag{6}$$

A decomposição espectral da matriz  $A$  nos permite escrever  $A = PDP^T$  em que  $D$  é uma matriz diagonal formada pelos autovalores de  $A$  e  $P$  é a matriz cujas colunas são os respectivos autovetores. Assim, substituindo  $A = PDP^T$  em (6) e definindo  $y^k = P^T x^k$ , obtemos a seguinte expressão para o tamanho do passo determinado por busca exata

$$t = \frac{d^T d}{d^T A d} = \frac{(y^k)^T D^2 y^k}{(y^k)^T D^3 y^k} \tag{7}$$

e

$$x^{k+1} = x^k + td = P(y^k - tDy^k) = Py^{k+1}. \tag{8}$$

Sendo assim, tomando a matriz diagonal formada pelos autovalores de  $A$ , temos:

$$D = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} = \lambda_1 \begin{pmatrix} 1 & 0 \\ 0 & \frac{\lambda_2}{\lambda_1} \end{pmatrix} = \lambda_1 \begin{pmatrix} 1 & 0 \\ 0 & \lambda \end{pmatrix} = \lambda_1 B, \tag{9}$$

onde  $\frac{\lambda_2}{\lambda_1} = \lambda$ . Substituindo (9) em (7) obtemos  $t = \frac{1}{\lambda_1} s$ , onde  $s$  é o tamanho do passo pela busca exata aplicado na quadrática definida pela matriz  $B$  a partir do ponto  $y$  e o novo iterando passa a ser definido como

$$y^{k+1} = y^k - tDy^k = y^k - sBy^k. \tag{10}$$

Assim, para o caso  $2 \times 2$  o nosso objetivo se torna verificar que  $\frac{\|y^{k+1}\|_2}{\|y^k\|_2} \leq 1 - \frac{1}{\lambda}$ .

Seja  $y^k = \begin{pmatrix} p \\ q \end{pmatrix}$  o ponto corrente. Podemos supor, sem perda de generalidade, que  $\|y^k\|_2 = 1$ .

Então, temos que  $d = -\begin{pmatrix} p \\ \lambda q \end{pmatrix}$  e o tamanho do passo é dado por  $t = \frac{d^T d}{d^T B d} = \frac{p^2 + \lambda^2 q^2}{p^2 + \lambda^3 q^2}$ , permitindo escrever:

$$y^{k+1} = y^k + td = \frac{(\lambda - 1)pq}{p^2 + \lambda^3 q^2} \begin{pmatrix} \lambda^2 q \\ -p \end{pmatrix}.$$

Portanto, a nossa conjectura,  $\frac{\|y^{k+1}\|_2}{\|y^k\|_2} \leq 1 - \frac{1}{\lambda}$ , pode ser reescrita como

$$\frac{p^2 q^2}{(p^2 + \lambda^3 q^2)^2} (p^2 + \lambda^4 q^2) \leq \frac{1}{\lambda^2}.$$

Desde que  $p^2 + q^2 = 1$ , definimos a função  $\varphi : [0, 1] \rightarrow \mathbb{R}$  por

$$\varphi(q) = (1 - q^2 + \lambda^3 q^2)^2 - \lambda^2 q^2 (1 - q^2) (1 - q^2 + \lambda^4 q^2),$$

e o objetivo torna-se provar que  $\varphi(q) \geq 0$  para todo  $q \in [0, 1]$ . Reescrevendo  $\varphi(q)$ , temos que

$$\varphi(q) = 1 + (2\lambda^3 - \lambda^2 - 2)q^2 + (-2\lambda^3 + 2\lambda^2 + 1)q^4 + (\lambda^2(\lambda^4 - 1))q^6,$$

e, tomando  $a = 2\lambda^3 - \lambda^2 - 2$ ,  $b = -2\lambda^3 + 2\lambda^2 + 1$  e  $c = \lambda^2(\lambda^4 - 1)$ , podemos escrever

$$\varphi(q) = 1 + aq^2 + bq^4 + cq^6. \tag{11}$$

Analisando os valores mínimos que a função assume para diferentes valores de  $\lambda$ , podemos verificar que  $\min \varphi(q) \geq 0$ , para todo  $\lambda$ , conforme pode ser observado na Figura 1.




Figura 1:  $\min \varphi(q)$

Dessa forma, vamos agora provar que o mínimo de  $\varphi$  é positivo partindo da análise de algumas propriedades das funções

$$a(\lambda) = 2\lambda^3 - \lambda^2 - 2 \quad \text{e} \quad b(\lambda) = -2\lambda^3 + 2\lambda^2 + 1.$$

Inicialmente, percebemos que cada uma das funções apresenta apenas uma raiz, denotadas respectivamente por  $\lambda_a$  e  $\lambda_b$ , com  $0 < \lambda_a < \lambda_b$ . A fim de verificar que  $\varphi(q) \geq 0$  para todo  $q \in [0, 1]$ , analisaremos a função considerando 3 subintervalos, sendo estes  $\lambda \in [\lambda_a, \lambda_b]$ ,  $\lambda < \lambda_a$  e  $\lambda > \lambda_b$ , apresentados nos Lemas a seguir.

**Lema 1.** *Considere  $\lambda \in [\lambda_a, \lambda_b]$  e a corresponde função  $\varphi$  dada por (11). Então  $\varphi(q) \geq 0$  para todo  $q \in [0, 1]$ .*

*Prova.* Primeiro, note que  $a, b \geq 0$  para  $\lambda_a \leq \lambda \leq \lambda_b$ . Além disso,  $c = \lambda^2(\lambda^4 - 1) > 0$  para todo  $\lambda > 1$ . Então,

$$\varphi(q) = 1 + aq^2 + bq^4 + cq^6 > 0$$

para todo  $q \in [0, 1]$ . □

Agora, vamos ver o que acontece quando  $\lambda \geq \lambda_b$ . Note que  $\varphi'(q) = 2q(a + 2bq^2 + 3cq^4)$  e considere o discriminante

$$\Delta = 4(b^2 - 3ac). \tag{12}$$

**Lema 2.** Se  $\lambda > \lambda_b$ , então  $\Delta < 0$ .

*Prova.* Primeiramente, afirmamos que

$$9\lambda^6 - 20\lambda^4 + 3\lambda^2 + 12 > 0. \tag{13}$$

De fato, se considerarmos  $\mu = \lambda^2$ , a expressão (13) pode ser reescrita por  $9\mu^3 - 20\mu^2 + 3\mu + 12$  o que é fácil verificar ser positivo. Agora, já que  $\lambda_b > 54$ , nós temos  $\lambda > 54$ ,  $6\lambda^7 > 152\lambda^6$  e  $2\lambda^3 > 52\lambda^2$ . Isto por sua vez, implica que

$$6\lambda^7 + 2\lambda^3 + 4\lambda + 1 > 152\lambda^6 + 52\lambda^2 + 6.$$

Por (13), concluímos que

$$152\lambda^6 + 52\lambda^2 + 6 > 3\lambda^6 + 10\lambda^4 + \lambda^2.$$

Assim,

$$6\lambda^7 + 2\lambda^3 + 4\lambda + 2 > 3\lambda^6 + 10\lambda^4 + \lambda^2 + 1.$$

Multiplicando por  $\lambda^2$ , obtemos

$$6\lambda^9 + 2\lambda^5 + 4\lambda^3 + 2\lambda^2 > 3\lambda^8 + 10\lambda^6 + \lambda^4 + \lambda^2 > 3\lambda^8 + 10\lambda^6 + \lambda^4 + 1,$$

o que significa que

$$\Delta = 4(-6\lambda^9 + 3\lambda^8 + 10\lambda^6 - 2\lambda^5 + \lambda^4 - 4\lambda^3 - 2\lambda^2 + 1) < 0,$$

completando a prova. □

**Lema 3.** *Se  $\lambda > \lambda_b$ , então  $\varphi(q) > 0$  para todo  $q \in [0, 1]$ .*

*Prova.* Pelo Lema 2, concluímos que  $a + 2bq^2 + 3cq^4 > 0$  para todo  $q \in \mathbb{R}$ , uma vez que o discriminante é negativo. Assim,

$$\varphi'(q) = 2q(a + 2bq^2 + 3cq^4) > 0$$

para todo  $q > 0$ , o que nos permite concluir que a função  $\varphi$  é crescente nesse intervalo. Desde que  $\varphi(0) = 1$ , concluímos que  $\varphi(q) \geq 0$  para todo  $q \in [0, 1]$ . □

Para finalizar a análise, devemos verificar o caso em que  $\lambda \in (1, \lambda_a)$ . Isso será feito para provar que o mínimo global de  $\varphi$  é positivo.

**Lema 4.** *Suponha que  $\lambda \in (1, \lambda_a)$  e considere o mínimo global positivo,  $q^*$ , de  $\varphi$ . Então  $\varphi(q^*) \geq 0$ .*

*Prova.* Note primeiro que neste caso temos  $a < 0$  e  $b > 0$ . Além disso,  $c = \lambda^2(\lambda^4 - 1) > 0$ . Então,  $\Delta' = b^2 - 3ac > b^2 > 0$ . Além do mais, devido ao fato de que  $q^*$  é uma raiz de  $a + 2bq^2 + 3cq^4 = 0$ , temos uma expressão explícita, ou seja,

$$q^* = \sqrt{\frac{-b + \sqrt{\Delta'}}{3c}}.$$

Afirmamos então que

$$1 + a(q^*)^2 > 0. \tag{14}$$

O que é equivalente a provar que  $3c - ab > -a\sqrt{\Delta'}$ , que é,

$$3c + a^3 - 2ab > 0. \tag{15}$$

Uma vez que  $a + b > 0$ , temos  $-ab > a^2$ . Então, usando o fato de que  $a > -1$ , obtemos

$$3c + a^3 - 2ab > 3c + 2a^2 - 1. \tag{16}$$

Note, na Figura 2, que a função  $\lambda \mapsto a^2(\lambda)$  é decrescente e  $\lambda \mapsto c(\lambda)$  é crescente em  $(1, \lambda_a)$ .

Então, para  $1 < \lambda \leq 1.067$ , temos

$$3c + 2a^2 > 2a^2 > 1 \tag{17}$$

e, para  $1.067 \leq \lambda < \lambda_a$

$$3c + 2a^2 > 3c > 1. \tag{18}$$

De (16)-(18), concluímos (15) e consequentemente, (14). Além disso, usando o fato de que  $b, c > 0$ , obtemos

$$\varphi(q^*) = 1 + a(q^*)^2 + b(q^*)^4 + c(q^*)^6 > 0$$

□




Figura 2: Gráficos de  $\lambda \mapsto 2a^2(\lambda)$  e  $\lambda \mapsto 3c(\lambda)$ .

Podemos resumir o que foi provado nos lemas anteriores no seguinte resultado:

**Teorema 1.** *Considere a função quadrática dada em (2), com  $n = 2$ , e a sequência gerada pelo algoritmo do Gradiente com busca exata. Então, para todo  $k \in \mathbb{N}$ ,*

$$\|x^{k+1} - x^*\|_2 \leq \left(1 - \frac{\lambda_1}{\lambda_n}\right) \|x^k - x^*\|_2.$$

### Considerações finais

O Método do Gradiente aplicado à minimização de funções quadráticas é linearmente convergente. A taxa que verifica a convergência local do algoritmo é apresentada e discutida na literatura fazendo associações aos autovalores da matriz  $A$ . Neste trabalho apresentamos uma nova taxa de convergência para o algoritmo do Gradiente, com busca exata, aplicado à minimização de funções quadráticas convexas. A partir de inúmeros testes computacionais, conjecturamos que o Teorema 1 seja válido para todo  $n \in \mathbb{N}$ .

### Referências

- [1] A. A. Ribeiro e E. W. Karas, “Otimização Contínua: aspectos teóricos e computacionais”, Cengage Learning Editora, 2013.
- [2] A. Izmailov e M. Solodov, “Otimização”, IMPA, 2007.
- [3] D. P. Bertsekas, “Nonlinear Programming”, Athena Scientific, 1995.
- [4] E. W. Karas, A. M. Mota e A. A. Ribeiro, On the convergence rate of the Cauchy algorithm in the l2 norm, em “Technical Report”, Dep. Mathematics, Federal University of Paraná, 2005.
- [5] R. M. Freund, The Steepest Descent Algorithm for Unconstrained Optimization and a Bisection Line-search Method, *Journal of Massachusetts Institute of Technology*, 2004.
- [6] S. Boyd e L. Vandenbergue, “Convex Optimization”, Cambridge University, 2004.
- [7] Y. Saad, “Iterative Methods for Sparse Linear Systems”, PWS Publishing Company, 2000.