

## O método do gradiente para minimizar o Quociente de Rayleigh

Breno Vieira Sousa,<sup>1</sup> Márcio Antônio de Andrade Bortoloti,<sup>2</sup> Teles Araújo Fernandes<sup>3</sup>  
Universidade Estadual do Sudoeste da Bahia, Vitória da Conquista, BA

O problema de determinar autovalor de matriz tem importantes aplicações. Por exemplo, o sistema de pesquisa da Google, [3], onde é utilizado um algoritmo de classificação, denominado *Page Rank*, que obtém uma classificação de pesquisas através do cálculo de autovalor da chamada matriz Google. Também podemos associar o cálculo de autovalores a problemas de processamento de sinais, veja [4]. É bem conhecido que toda matriz simétrica possui pelo menos um autovalor real, veja [5, Cap. 13, pag. 160]. Além disso, o valor mínimo da função Quociente de Rayleigh (QR), é o menor autovalor da matriz simétrica que define essa função, [1, Cap. 2, Prop. 2.1.2]. A função Quociente de Rayleigh é formalmente descrita por  $f : \mathbb{R}_*^n \rightarrow \mathbb{R}$ , tal que

$$f(x) = \frac{x^T A x}{x^T x}, \quad (1)$$

onde  $(\cdot)^T$  denota a matriz transposta,  $A$  é uma matriz simétrica de ordem  $n \times n$  e  $\mathbb{R}_*^n$  é o espaço  $n$ -dimensional sem a origem. Por outro lado, considerando  $\mathbb{S}^{n-1}$  a esfera  $n$ -dimensional podemos definir a função Quociente de Rayleigh dada em (1) assumindo  $g : \mathbb{S}^{n-1} \rightarrow \mathbb{R}$ , tal que

$$g(x) = x^T A x. \quad (2)$$

Neste trabalho, a fim de minimizar (1), isto é, determinar o menor autovalor da matriz  $A$ , estudamos o método do gradiente em contexto Euclidiano (GE). Apresentamos um estudo numérico comparando a eficiência do GE equipado com as métricas euclidiana, da soma e do máximo. Além disso, também apresentamos um estudo do método do gradiente em contexto Riemanniano (GR) para minimizar (2), comparando as duas estratégias GE e GR. Finalmente, desenvolvemos um estudo numérico comparando o desempenho computacional do Algoritmo 2, por atualizar as iteradas com duas estratégias distintas, isto é, utilizando duas retrações.

O que segue descreve formalmente o método do gradiente Euclidiano.

---

**Algoritmo 1:** Método do gradiente Euclidiano (GE)

---

1 Tome um ponto inicial  $x_0 \in \mathbb{R}^n$ ,  $\eta \in (0, 1)$ ,  $\epsilon > 0$  e faça  $k := 0$ .

2  $d_k := -\nabla f(x_k) = \frac{-2(A - f(x_k)I)x_k}{(x_k^T x_k)}$ .

3 Se  $\|d_k\|_E > \epsilon$  faça

$$\alpha_k := \max \{2^{-j} : f(x_k + 2^{-j} d_k) \leq f(x_k) - \eta 2^{-j} \|d_k\|_E^2, j \in \mathbb{N}\}. \quad (3)$$

4  $x_{k+1} := x_k + \alpha_k d_k$ .

5  $k \leftarrow k + 1$  e retome para o passo 2.

---

<sup>1</sup>3vieirabreno@gmail.com

<sup>2</sup>mbortoloti@uesb.edu.br

<sup>3</sup>telesfernandes@uesb.edu.br

No Algoritmo 1, o **passo 2** apresenta a direção de descida do gradiente da função QR. Além disso, no **passo 3**,  $\|d_k\|_E$  denota a norma euclidiana ou a norma do máximo ou a norma da soma.

Por sua vez, o método do gradiente Riemanniano é apresentado como segue:

---

**Algoritmo 2:** Método do gradiente Riemanniano (GR)

---

- 1 Tome um ponto inicial  $x_0 \in \mathbb{S}^n$ ,  $\eta \in (0, 1)$ ,  $\epsilon > 0$  uma retração  $R$  e faça  $k := 0$ .
- 2  $d_k := -\text{grad } f(x_k) = 2[x_k x_k^T - I]Ax_k$ .
- 3 Se  $\|d_k\|_R > \epsilon$  faça

$$\alpha_k := \max \{2^{-j} : f(R_{x_k}(2^{-j}v_k)) \leq f(x_k) - \eta 2^{-j} \|d_k\|_R^2, j \in \mathbb{N}\}. \quad (4)$$

- 4  $x_{k+1} := R_{x_k}(\alpha_k v_k)$ .
  - 5  $k \leftarrow k + 1$  e retome para o **passo 2**.
- 

Agora, apresentamos alguns comentários do Algoritmo 2. No **passo 2**, temos a direção de descida do gradiente Riemanniano da função Quociente de Rayleigh definida em (2). No **passo 3**, a métrica  $\|\cdot\|_R$  é a métrica induzida do  $\mathbb{R}^n$  e  $\alpha_k$  é dado pela busca de Armijo em contexto Riemanniano. Por fim, denotando  $T_x \mathbb{S}^{n-1}$  como o espaço tangente de  $\mathbb{S}^{n-1}$  no ponto  $x$ , no **passo 4** as estratégias de atualização das iteradas são dadas pelas seguintes retrações na esfera, veja [2],

$$R_x(v) = \cos(\|v\|_R)x + \frac{\text{sen}(\|v\|_R)}{\|v\|_R}v, \quad R_x(v) = \frac{x+v}{\|x+v\|_R}, \quad \forall x \in \mathbb{S}^{n-1} \text{ e } v \in T_x \mathbb{S}^{n-1}. \quad (5)$$

## Agradecimentos

Gostaríamos de agradecer ao professor Alfredo Noel Iusem (IMPA) que, por meio da FAPERJ, nos deu apoio financeiro na hospedagem. A UESB, agradecemos pelo apoio financeiro no transporte. Finalmente, agradecemos ao **Programa de Iniciação Científica - PIC/UESB**, o qual nos possibilitou desenvolver este trabalho.

## Referências

- [1] P. A. Absil, R. Mahony e R. Sepulchre. **Optimization algorithms on matrix manifolds**. Princeton University Press, 2009.
- [2] M. A. A. Bortoloti, T. A. Fernandes e O. P. Ferreira. “An efficient damped Newton-type algorithm with globalization strategy on Riemannian manifolds”. Em: **Journal of Computational and Applied Mathematics** 403 (2022), p. 113853.
- [3] K. Bryan e T. Leise. “The \$25,000,000,000 eigenvector: The Linear Algebra behind Google”. Em: **SIAM review** 48.3 (2006), pp. 569–581.
- [4] P. Comon e G. H. Golub. “Tracking a few extreme singular values and vectors in signal processing”. Em: **Proceedings of the IEEE** 78.8 (1990), pp. 1327–1343.
- [5] E. L. Lima. **Álgebra Linear: Coleção Matemática Universitária**. 1a. ed. Rio de Janeiro: IMPA, 2014. ISBN: 9788524403903.