

## Método de Newton Riemanniano Amortecido Aplicado a um Problema de Separação de Imagens

Maria C. B. dos Reis<sup>1</sup>, Marcio A. de A. Bortoloti<sup>2</sup>

Universidade Estadual do Sudoeste da Bahia, Vitória da Conquista, BA

A busca pelo aprimoramento de imagens é incentivada pelas diversas aplicações em que o reconhecimento e a análise de informações visuais são fundamentais, como em sistemas de vigilância e diagnósticos médicos. Em alguns contextos, as imagens capturadas podem conter sobreposições indesejadas que dificultam a identificação de elementos. Um exemplo disso ocorre quando um quadro é fotografado através de um vidro, resultando na captação simultânea da imagem do quadro e do reflexo do vidro, [2]. Problemas dessa natureza podem ser modelados a partir de técnicas de *Independent Component Analysis* (ICA), que visam estimar componentes independentes a partir de sinais multivariados disponíveis. Esses problemas correspondem a minimização da função objetivo

$$f(Y) = - \sum_{l=1}^N \|\text{diag}(Y^T A_l Y)\|_F^2, \quad (1)$$

onde  $Y \in \text{St}(p, n) = \{Y \in \mathbb{R}^{n \times p} \mid Y^T Y = I_p\}$ , em que  $I_p$  é a matriz identidade de ordem  $p$ , com  $p \leq n$ , as matrizes  $A_1, A_2, \dots, A_N$  estão associadas às imagens sobrepostas,  $\|\cdot\|_F$  é a norma de Frobenius e  $\text{diag}(M)$  denota a matriz diagonal cujos elementos coincidem com a diagonal principal da matriz  $M$ . Este problema é resolvido por [4] usando o método de Newton clássico, com uma estratégia de vetorização. Este método pode ser visto no Algoritmo 3.1 em [4].

Buscando garantir o decrescimento da função objetivo e obter um método mais eficiente, neste trabalho, vamos empregar o método de Newton, apresentado por [4], introduzindo a busca linear de Armijo. Essa busca fornece um comprimento de passo  $\alpha_k > 0$  que deve satisfazer

$$f(Y) - f(R_Y(\alpha_k \eta)) \geq -\sigma \langle \text{grad } f(Y), \alpha_k \eta \rangle, \quad (2)$$

em que  $R_Y(\alpha_k \eta) = qf(Y + \alpha_k \eta)$ , onde  $qf(\cdot)$  denota o fator  $Q$  da decomposição  $QR$  da matriz,  $\langle \text{grad } f(Y), \alpha_k \eta \rangle = \alpha_k \text{tr}(\text{grad } f(Y)^T \eta)$ , onde  $\text{tr}$  é o traço de uma matriz,  $\sigma \in (0, 1)$  e  $\eta$  pertence ao espaço tangente de  $\text{St}(p, n)$  em  $Y$ . Veja em [1].

Em nosso estudo, consideramos  $n = 3$  imagens disponíveis em [5], conforme mostra a Figura 1. As imagens foram carregadas como matrizes e, em seguida, recortadas de modo a obter a mesma quantidade de pixels, isto é, mesma dimensão  $x \times y$ . Além disso, em virtude das imagens serem coloridas, foi necessário transformá-las em preto e branco.



Figura 1: Imagens originais. Fonte: [5].

<sup>1</sup>maria.cbritois@gmail.com

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

As matrizes correspondentes a cada imagem foram vetorizadas, empilhando as colunas de cada matriz e obtendo 3 vetores  $I_1$ ,  $I_2$  e  $I_3$  com dimensão  $xy$  correspondente as imagens selecionadas. Em seguida, esses vetores foram organizados em uma matriz  $S = [I_1^T, I_2^T, I_3^T]^T$  de dimensão  $n \times xy$ . Por fim, calculamos a mistura  $X = MS$ , onde  $M$  é uma matriz aleatória, escolhida de modo que a soma dos elementos de cada linha seja igual a 1. Este produto gerou as imagens sobrepostas apresentadas na Figura 2.



Figura 2: Imagens sobrepostas. Fonte: Elaboração do autor.

A partir dessas imagens sobrepostas é possível obter aproximações das imagens originais sem qualquer informação sobre  $M$ . Uma das ferramentas usadas para isso é a função de contraste conhecida por JADE (*Joint approximate diagonalization of eigen-matrices*). Essa função é definida como a soma dos quadrados dos  $N$  culmulantes de quarta ordem. Para maiores detalhes veja [4]. Esses culmulantes fornecem informações sobre a distribuição não gaussiana destes sinais, permitindo identificar a não independência entre eles e, conseqüentemente, viabilizando a separação dos componentes misturados, [3]. Para os testes realizados, consideramos o tempo de CPU e o número de iterações, com o intuito de mostrar a eficiência do método de Newton amortecido para este problema, comparado ao método clássico.

## Agradecimentos

A autora Maria Clara Brito dos Reis agradece ao Programa de Educação Tutorial Institucional da Universidade Estadual do Sudoeste da Bahia (PETI/UESB) pelo apoio financeiro.

## Referências

- [1] P. A. Absil, R. Mahony e R. Sepulchre. **Optimization algorithms on matrix manifolds**. 1a. ed. Princeton University Press, 2009. ISBN: 978-0-691-13298-3.
- [2] H. Farid e E. H. Adelson. “Separating reflections from images by use of independent component analysis”. Em: **Journal of the Optical Society of America A** 16.9 (1999), pp. 2136–2145. DOI: 10.1364/josaa.16.002136.
- [3] A. Hyvärinen e E. Oja. “Independent component analysis: algorithms and applications”. Em: **Neural networks** 13.4-5 (2000), pp. 411–430. DOI: 10.1016/S0893-6080(00)00026-5.
- [4] H. Sato. “Riemannian Newton-type methods for joint diagonalization on the Stiefel manifold with application to independent component analysis”. Em: **Optimization** 66.12 (2017), pp. 2211–2231. DOI: 10.1080/02331934.2017.1359592.
- [5] L. de Vito. **ICA for Demixing Images**. Online. Acessado em: 13 de março de 2025, [ur-lhttps://github.com/ldv1/ICA\\_for\\_demixing\\_images/tree/master](https://github.com/ldv1/ICA_for_demixing_images/tree/master).