

## Globalização do Método de Newton: Análise comparativa entre estratégias de Buscas Lineares em um Método Híbrido

Márcio Antônio de Andrade Bortoloti<sup>1</sup>, Maria Clara Brito dos Reis<sup>2</sup>  
Universidade Estadual do Sudoeste da Bahia, Vitória da Conquista, BA

Neste trabalho, apresentamos um estudo de um método de Newton globalizado para determinar o minimizador de uma função objetivo  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  duas vezes continuamente diferenciável. O Método de Newton (MN) destaca-se por apresentar taxa de convergência superlinear, podendo chegar a quadrática, sob algumas hipóteses. Contudo, uma dificuldade do MN reside na exigência de um chute inicial próximo à solução. Para contornar essa dificuldade, pode-se empregar estratégias para o fornecimento de chutes iniciais mais adequados para o MN. Uma delas consiste em utilizar a direção de descida do gradiente da função objetivo. O método que utiliza essa direção de descida é conhecido como Método do Gradiente (MG) e é caracterizado pela convergência global da sequência gerada. Apesar disso, essa convergência tende a ser lenta com taxa linear, tornando-o menos eficiente, veja [1]. Buscando reunir a característica global do MG com as boas taxas de convergência do MN, consideramos um método que gera uma sequência com o emprego da direção de descida do gradiente. Este fornece um chute apropriado para as direções de descida dadas pelo MN. Essas direções são obtidas pelas soluções  $d^k$  da equação linear

$$H(x^k)d^k = -\nabla f(x^k), \quad (1)$$

onde  $H(x^k)$  é a matriz Hessiana de  $f$  no ponto  $x^k$ . Além da direção de descida, o estabelecimento de uma busca linear é fundamental na construção da sequência  $x^k$ .

Neste estudo, consideraremos as buscas monotônicas de Armijo, Goldstein e Wolfe, veja [2]. Estas serão testadas tanto na fase inicial conduzida pelo MG quanto na fase de aceleração promovida pelo MN. O objetivo é investigar o desempenho dessas combinações equipadas em um Método Híbrido (MH) ao determinar o mínimo global da função objetivo.

A Regra de Armijo consiste em encontrar um comprimento de passo que assegure uma redução suficiente em  $f$ , isto é, determinar um valor  $\alpha^k > 0$  que satisfaça, para  $\sigma \in (0, 1)$  a condição

$$f(x^k + \alpha^k d^k) \leq f(x^k) + \sigma \alpha^k \langle f'(x^k), d^k \rangle. \quad (2)$$

Na Regra de Goldstein é adicionada à condição de Armijo, uma desigualdade com o intuito de descartar comprimentos de passo excessivamente pequenos. Essa regra busca determinar, para  $0 < \sigma_1 < \sigma_2 < 1$ , um  $\alpha^k > 0$  tal que

$$f(x^k) + \sigma_1 \alpha^k \langle f'(x^k), d^k \rangle \leq f(x^k + \alpha^k d^k) \leq f(x^k) + \sigma_2 \alpha^k \langle f'(x^k), d^k \rangle. \quad (3)$$

Adicionalmente, a Regra de Wolfe complementa a desigualdade de Armijo com uma condição de curvatura, estipulando que, além da redução suficiente em  $f$ , para  $0 < \sigma_1 < \sigma_2 < 1$ , o comprimento de passo  $\alpha^k > 0$  deve cumprir

$$\begin{aligned} f(x^k + \alpha^k d^k) &\leq f(x^k) + \sigma_1 \alpha^k \langle f'(x^k), d^k \rangle \\ \langle f'(x^k + \alpha^k d^k), d^k \rangle &\geq \sigma_2 \langle f'(x^k), d^k \rangle. \end{aligned} \quad (4)$$

<sup>1</sup>mbortoloti@uesb.edu.br

<sup>2</sup>maria.cbritois@gmail.com

A garantia da existência do comprimento de passo para cada uma das buscas comentadas acima está apresentada em [1].

O algoritmo a seguir detalha a globalização do método de Newton realizada por meio do MH.

---

**Algoritmo 1:** Método Híbrido (MH)

---

- 1 Tome um ponto inicial  $x^0 \in \mathbb{R}^n$  e  $\varepsilon > 0$ .
  - 2 Defina  $k = 0$ .
  - 3 **Repita** enquanto  $\nabla f(x^k) \neq 0$ .
  - 4     **Se**  $\|\nabla f(x^k)\| > \varepsilon$
  - 5         Calcule  $d^k = -\nabla f(x^k)$
  - 6     **Senão**
  - 7         Calcule  $d^k$  por (1).
  - 8 Calcule  $\alpha^k$  por (2), (3) ou (4).
  - 9 Defina  $x^k = x^k + \alpha^k d^k$
  - 10 Defina  $k \leftarrow k + 1$  e retorne para o passo 3
- 

Gostaríamos de destacar que entre as linhas 4 e 7 do algoritmo, o parâmetro  $\varepsilon$  indica quando a troca da direção de descida ocorrerá. Em outras palavras, quando a norma do gradiente se torna suficientemente pequena, a direção do MG é alterada para a direção do MN.

O desempenho do Algoritmo 1 será avaliado utilizando funções do CUTEst, [3]. Esta implementação será realizada em Linguagem de Programação Julia e os códigos-fonte estarão disponíveis no endereço <https://github.com/petimatematica/HGMM>. Neste contexto, *performance profiles* serão elaborados com o objetivo de analisar os resultados alcançados ao comparar a eficiência de diferentes combinações das buscas lineares dadas por (2), (3) e (4).

## 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] Alexey Izmailov e Mikhail Solodov. **Otimização, volume 2: métodos computacionais**. IMPA, 2018.
- [2] Jorge Nocedal e Stephen J Wright. **Numerical optimization**. Springer, 1999.
- [3] Nicholas IM Gould, Dominique Orban e Philippe L Toint. “CUTEst: a constrained and unconstrained testing environment with safe threads for mathematical optimization”. Em: **Computational optimization and applications** 60 (2015), pp. 545–557.