

# Otimização: Quadrados Mínimos Não-Lineares e Otimização Global

Hector Flores Callisaya

## 1 Introdução

## 2 Quadrados Mínimos Não-lineares

## 3 Métodos Quase-Newton




## 4 Otimização global

# Motivação: Problemas de empacotamento

- Empacotamento de círculos em círculos,
- Empacotamento de polítopos em regiões convexas,
- Empacotamento de elipses em polítopos,
- Itens com bordas suave em polítopos

$$\begin{cases} h_i(x) = 0, & \forall i = 1, \dots, m, \\ g_j(x) \leq 0, & \forall j = 1, \dots, p, \\ x \in \Omega, \end{cases}$$

onde as funções  $h_i, g_j : \mathbb{R}^n \rightarrow \mathbb{R}$  são suaves para todo  $i = 1, \dots, m$  e  $j = 1, \dots, p$ .



$$\begin{aligned} & \underset{x \in \mathbb{R}^n}{\text{Minimizar}} \quad \sum_{i=1}^m h_i(x)^2 + \sum_{i=1}^l \max\{0, g_i(x)\}^2, \\ & \text{sujeito a } x \in \Omega, \end{aligned}$$

onde  $m \geq n$

- $\Omega$  é um conjunto onde é fácil calcular a projeção  $P_\Omega$ .
- O problema é limitado inferiormente por 0.

$$\sum_{i=1}^m h_i(x^*)^2 + \sum_{i=1}^l \max\{0, g_i(x^*)\}^2 = 0 \iff h_i(x^*) = 0, g_i(x^*) \leq 0,$$

**É um problema de Otimização Global**

$$\begin{aligned} & \underset{x \in \mathbb{R}^n}{\text{Minimizar}} && f(x) \\ & \text{sujeito a} && h_i(x) = 0, \quad i = 1, \dots, m. \\ & && g_i(x) \leq 0, \quad i = 1, \dots, l. \\ & && x \in \Omega. \end{aligned}$$

Consideramos o Lagrangiano Aumentado definido por Powell, Hesstenes e Rockafellar

$$L_\rho(x, \lambda, \mu) = f(x) + \frac{\rho}{2} \left\| h(x) + \frac{\lambda}{\rho} \right\|_2^2 + \left\| \left( g(x) + \frac{\mu}{\rho} \right)_+ \right\|_2^2.$$

para  $\rho, \lambda \in \mathbb{R}^m, \mu \in \mathbb{R}_+^p, x \in \Omega$ .

$$\nabla_{(x, \lambda, \mu)} L_\rho(x, \lambda, \mu) = 0.$$

$$\begin{aligned} & \underset{x \in \mathbb{R}^n}{\text{Minimizar}} && f(x) \\ & \text{sujeito a} && h_i(x) = 0, \quad i = 1, \dots, m. \\ & && x \geq 0. \end{aligned}$$

$$L_\mu(x, \lambda) = f(x) - \mu \sum_{s=1}^n \log(x_s) + \sum_{s=1}^m \lambda_s h_s(x),$$

para  $\mu \in \mathbb{R}$ ,  $\lambda \in \mathbb{R}^m$ .

$$\nabla_{(x,\lambda)} L_\mu(x, \lambda) = 0.$$

## Resto

$$r_i(x_1, \dots, x_n) = 0, \quad i = 1, \dots, m.$$

$$\min_{x \in \mathbb{R}^n} f(x), \quad f(x) = \frac{1}{2} \sum_{i=1}^n r_i^2(x)$$

$$\nabla f(x) = \sum_{i=1}^m r_i(x) \nabla r_i(x) = J(x)^T r(x),$$

$$\nabla^2 f(x) = J(x)^T J(x) + \sum_{i=1}^m r_i(x) \nabla^2 r_i(x),$$

$$\nabla^2 f(x)[x^{k+1} - x^k] = -\nabla f(x^k)$$

# Métodos

- Método de Newton,

$$(J(x^k)^T J(x^k) + \sum_{j=1}^m r_j(x^k) \nabla^2 r_j(x^k)) d_N^k = -J(x^k)^T r(x_k),$$

- Método de Gauss - Newton,

$$(J(x^k)^T J(x^k)) d_{GN}^k = -J(x^k)^T r(x_k),$$

- Método de Levenberg - Marquardt

$$(J(x^k)^T J(x^k) + \mu_k I) d_{LM}^k = -J(x^k)^T r(x_k),$$

$$x^{k+1} = x^k + d^N, \quad x^{k+1} = x^k + d^{GN}, \quad x^{k+1} = x^k + d^{LM},$$

# Estimativas para o parâmetro de Levenberg-Marquadt

- Yamashita, N., Fukushima, M. com a suposição adicional

$$\|r(x^k)\| \geq c_1 d(x^k, X^*)$$

e fazendo

$$\mu_k = \|r(x_k)\|_2^2$$

mostram que é possível obter convergência quadrática sem ter não singularidade na solução do  $J(x^*)$ .

- Jin-yan and Ya-xiang Yuan (2004), mostram que é possível relaxar

$$\mu_k = \|r(x_k)\|_2^\delta$$

preservando convergência é também quadrática, onde  $\delta \in [1, 2]$

# Estratégias de globalização

- Métodos com busca linear

$$x^{k+1} = x^k + t_k d^k, \quad d_k = -Q_k \nabla f(x^k)$$

$t_k$  é calculado pela regra do Armijo

- Métodos de regiões de confiança

$$\min \Phi_k(x) \text{ sujeita a } x \in B(x^k, \delta_k) \quad (1)$$

# Métodos Quase-Newton

## Equação Secante

$$[H_{k+1}]_{n \times n} [s^k]_{n \times 1} = [y^k]_{m \times 1},$$

onde  $s^k = x^{k+1} - x^k$ ,  $y^k = \nabla f(x^{k+1}) - \nabla^k f(x^k)$

$$x^{k+1} = x^k - H_{k+1}^{-1} \nabla f(x^k)$$

Método de Davidon-Fletcher-Powell (DFP)

$$H_{k+1} = H_k + \frac{y^k (y^k)^T}{\langle y^k, s^k \rangle} - \frac{H_k s^k (H_k s^k)^T}{\langle H_k s^k, s^k \rangle}$$

Método de Broyden-Fletcher-Goldfarb-Shanno

$$H_{k+1} = H_k + \frac{(y_k - H_k s_k) s_k + s_k (y_k - H_k s_k)^T}{s_k^T s_k} - \frac{(y_k - H_k s_k)^T s_k s_k s_k^T}{(s_k^T s_k)^2}$$

# Barzilai and J.M. Borwein

Consideramos o problema

$$\min_{\alpha \in \mathbb{R}} \|\alpha I_n s^k - y^k\|_2^2$$

Tem como solução

$$\alpha_k = \frac{\langle s^k, y^k \rangle}{\langle s^k, s^k \rangle}$$

Globalização do método com busca linear tem a seguinte forma

$$x^{k+1} = x^k - t_k \alpha_k^{-1} \nabla f(x^k)$$

# Otimização global

## Problema principal de Otimização global


Dado um ponto estacionário (KKT), verificar quando é uma solução global.

- Não existe uma fórmula simples fácil de avaliar.


Porém, existem muitas heurísticas para encontrar o minimizador global, algumas são as seguintes:

- Multistart,
- Tunneling,
- $\alpha BB$ ,
- ...


# Empacotamento de círculos em elipse




(a) s2i01




(b) s2i02




(c) s2i03




(d) s2i04




(e) s2i05



(f) s2i06



(g) s2i07



(h) s2i08

# OBRIGADO!