

# Método do Gradiente Espectral Projetado para minimização em caixas

Marina Andretta

ICMC-USP

09 de novembro de 2010

# Problema com restrições de caixa

Vamos nos concentrar em problemas apenas com **restrições de caixa**. Ou seja, estamos interessados em resolver o seguinte problema:

$$\begin{array}{ll} \text{Minimizar} & f(x) \\ \text{Sujeita a} & x \in \Omega = \{x \mid \ell \leq x \leq u\}, \end{array} \quad (1)$$

onde

- $x, \ell, u \in (\mathbf{R} \cup \{-\infty, +\infty\})^n$ ,
- $f : \mathbf{R}^n \rightarrow \mathbf{R}$  função suave.

# Problema com restrições de caixa

Como vimos, as condições necessárias de primeira ordem para que um ponto  $x^*$  seja solução para um problema do tipo

$$\begin{array}{ll} \text{Minimizar} & f(x) \\ \text{Sujeita a} & c_i(x) = 0, \quad i \in \mathcal{E}, \\ & c_i(x) \geq 0, \quad i \in \mathcal{I}, \end{array} \quad (2)$$

com restrições satisfazendo LICQ, é que exista um vetor  $\lambda^*$  tal que as condições KKT sejam satisfeitas. Ou seja,

$$\begin{array}{ll} \nabla_x \mathcal{L}(x^*, \lambda^*) & = 0, \\ c_i(x^*) & = 0, \quad \forall i \in \mathcal{E}, \\ c_i(x^*) & \geq 0, \quad \forall i \in \mathcal{I}, \\ \lambda_i^* & \geq 0, \quad \forall i \in \mathcal{I}, \\ \lambda_i^* c_i(x^*) & = 0, \quad \forall i \in \mathcal{E} \cup \mathcal{I}. \end{array} \quad (3)$$

# Problema com restrições de caixa

A condição **LICQ** é a seguinte: dados um ponto  $x^*$  e o conjunto de restrições ativas  $\mathcal{A}(x^*)$ , dizemos que a condição de qualificação de restrição de independência linear (LICQ) vale se o conjunto dos gradientes das restrições ativas  $\{\nabla c_i(x^*), i \in \mathcal{A}(x^*)\}$  é **linearmente independente**.

Note que, no caso do **problema (1)**, que tem apenas restrições de caixa, a condição **LICQ sempre pode ser satisfeita**.

# Problema com restrições de caixa

O gradiente de cada restrição é uma coluna da matriz identidade multiplicada por 1 ou -1.

Dois gradientes de restrições ativas seriam **linearmente dependentes** apenas quando uma variável  $x_i$  fosse igual tanto a seu limitante inferior como ao seu limitante superior. Ou seja, **apenas quando  $\ell_i = x_i = u_i$** .

Neste caso, a **variável  $x_i$  é fixa** e a restrição  $\ell_i \leq x_i \leq u_i$  pode ser eliminada do problema.

Consideraremos, daqui em diante, apenas problemas (1) com  $\ell_i < u_i$ , para todo  $i$ .

# Problema com restrições de caixa

Assim, as condições necessárias de primeira ordem para que um ponto  $x^*$  seja solução de (1) são

$$\begin{aligned} \nabla f(x^*) - \sum_{i \in \mathcal{I}_\ell} \lambda_i^* e_i + \sum_{i \in \mathcal{I}_u} \mu_i^* e_i &= 0, \\ x_i - \ell_i &\geq 0, \quad \forall i \in \mathcal{I}_\ell, \\ u_i - x_i &\geq 0, \quad \forall i \in \mathcal{I}_u, \\ \lambda_i^* &\geq 0, \quad \forall i \in \mathcal{I}_\ell, \\ \mu_i^* &\geq 0, \quad \forall i \in \mathcal{I}_u, \\ \lambda_i^* (x_i - \ell_i) &= 0, \quad \forall i \in \mathcal{I}_\ell, \\ \mu_i^* (u_i - x_i) &= 0, \quad \forall i \in \mathcal{I}_u, \end{aligned} \tag{4}$$

com  $\mathcal{I}_\ell$  e  $\mathcal{I}_u$  conjunto dos índices das restrições  $\ell_i \leq x_i$ ,  $\ell_i \in \mathbf{R}$  e  $x_i \leq u_i$ ,  $u_i \in \mathbf{R}$ , respectivamente.  $e_i$   $i$ -ésima coluna da matriz identidade.

Antes de prosseguir, vamos definir a **projeção ortogonal** de um ponto  $x$  no conjunto viável  $\Omega$ . Esta será denotada por  $P_{\Omega}(x)$ .

$$P_{\Omega}(x) = \begin{cases} x_i, & \text{se } l_i \leq x_i \leq u_i, \\ l_i, & \text{se } x_i < l_i, \\ u_i, & \text{se } x_i > u_i, \end{cases}$$

Note que um ponto  $x^*$  satisfaz

$$P_{\Omega}(x^* - \nabla f(x^*)) - x^* = 0,$$

se e somente se este ponto  $x^*$  também satisfaz as condições KKT (exercício).

# Método do Gradiente Espectral Projetado

O método do **Gradiente Espectral Projetado (SPG)** é usado para resolver o seguinte problema:

$$\begin{array}{ll} \text{minimizar} & f(x) \\ \text{sujeita a} & x \in \Omega, \end{array}$$

onde  $f$  é uma função em  $C^1$ ,  $x \in \mathbf{R}^n$  e  $\Omega$  é um conjunto convexo fechado.

# Método do Gradiente Espectral Projetado

Estamos interessados no caso em que  $\Omega$  é uma caixa.

A idéia do algoritmo é a seguinte: na iteração  $k$ , calculamos uma direção de descida  $p_k \in \Omega$  e fazemos uma busca linear para que  $x_k + \alpha_k p_k$  satisfaça a condição de Armijo.

Quando isso acontece, temos o novo ponto  $x_{k+1} = x_k + \alpha_k p_k \in \Omega$ .

A direção  $p_k$  é calculada com base na projeção ortogonal de  $-\lambda_k \nabla f(x_k)$  no conjunto  $\Omega$ , onde  $\lambda_k$  (chamado de passo espectral) é um escalar calculado a partir de informações fornecidas pelo ponto atual  $x_k$  e pelo ponto  $x_{k-1}$  da iteração anterior.

# Método do Gradiente Espectral Projetado

**Método SPG:** Dados  $x_0 \in \Omega$ ,  $\epsilon > 0$ ,  $0 < \lambda_{\min} < \lambda_{\max} < \infty$ ,  $c \in (0, \frac{1}{2})$ ,  $0 < \rho_1 < \rho_2 < 1$ .

**Passo 1:** Faça  $k \leftarrow 0$ .

**Passo 2:** Se  $\|P_{\Omega}(x_k - \nabla f(x_k)) - x_k\| \leq \epsilon$ , pare com  $x_k$  como solução.

**Passo 3:** Calcule  $s_k = x_k - x_{k-1}$  e  $y_k = \nabla f(x_k) - \nabla f(x_{k-1})$ .

**Passo 4:** Se  $s_k^T y_k \leq 0$  então  
faça  $\lambda_k \leftarrow \lambda_{\max}$ .

Senão

$$\text{faça } \lambda_k \leftarrow \min \left\{ \lambda_{\max}, \max \left\{ \lambda_{\min}, \frac{s_k^T s_k}{s_k^T y_k} \right\} \right\}$$

**Passo 5:** Calcule  $p_k = P_{\Omega}(x_k - \lambda_k \nabla f(x_k)) - x_k$

**Passo 6:** Faça  $\alpha \leftarrow 1$ .

**Passo 7:** Se  $f(x_k + \alpha p_k) \leq f(x_k) + c\alpha \nabla f_k^T p_k$  então  
faça  $\alpha_k \leftarrow \alpha$ .

Senão

faça  $\alpha \leftarrow \alpha_{novo} \in [\rho_1\alpha, \rho_2\alpha]$  e repita o Passo 7.

**Passo 8:** Faça  $x_{k+1} \leftarrow x_k + \alpha_k p_k$ .

**Passo 9:** Faça  $k \leftarrow k + 1$ .

**Passo 10:** Volte para o Passo 2.

# Método do Gradiente Espectral Projetado

O valor obtido para  $\lambda_k$  possui alguma informação de segunda ordem da função objetivo. Na verdade, temos que

$$\left(\frac{1}{\lambda_k}\right) I = \underset{D}{\operatorname{argmin}} \quad \|Ds_k - y_k\|$$

sujeita a  $D = \gamma I,$

onde  $I$  é a matriz identidade.

Ou seja,  $\left(\frac{1}{\lambda_k}\right) I$  é a matriz diagonal que melhor aproxima a equação **secante** (equação esta que é uma aproximação da hessiana da função objetivo).

Quanto à convergência do algoritmo do Gradiente Espectral Projetado, temos que todo ponto de acumulação da seqüência  $\{x_k\}$  gerada por ele é um ponto estacionário restrito.

Uma maneira de calcular  $\lambda_0$  é calcular um  $\bar{x}$  dando um passo muito pequeno a partir de  $x_0$  na direção de  $-\nabla f(x_0)$ .

Neste caso, esperamos que a função objetivo decresça e satisfaça a condição de Armijo.

Por isso utilizamos, para calcular  $\lambda_0$ , os mesmos passos usados para calcular  $\lambda_k$ , considerando  $\bar{x}$  como  $x_k$  e  $x_0$  como  $x_{k-1}$ .

**Cálculo do passo espectral inicial:** Dados  $\epsilon_{rel}, \epsilon_{abs} > 0$  e  $x_0 \in \Omega$ .

**Passo 1:** Calcule  $\alpha_{peq} = \max\{\epsilon_{rel}\|x_0\|_\infty, \epsilon_{abs}\}$ .

**Passo 2:** Calcule  $\bar{x} = x_0 - \alpha_{peq} \nabla f(x_0)$ .

**Passo 3:** Calcule  $\bar{s} = \bar{x} - x_0$ .

**Passo 4:** Calcule  $\bar{y} = \nabla f(\bar{x}) - \nabla f(x_0)$ .

**Passo 5:** Se  $\bar{s}^T \bar{y} \leq 0$  então  
faça  $\lambda_0 \leftarrow \lambda_{max}$ .

Senão

faça  $\lambda_0 \leftarrow \min \left\{ \lambda_{max}, \max \left\{ \lambda_{min}, \frac{\bar{s}^T \bar{s}}{\bar{s}^T \bar{y}} \right\} \right\}$ .

# Cálculo do tamanho de passo

Uma forma simples é calcular  $\alpha \leftarrow \frac{\alpha_k}{2}$ .

Uma forma mais interessante é utilizar a **interpolação quadrática uni-dimensional**  $q(w)$  tal que  $q(0) = f(x_k)$ ,  $q(\alpha) = f(x_k + \alpha p_k)$  e  $\nabla q(0) = \nabla f(x_k)^T p_k$ .

Para obter  $\alpha_{\text{nov}}o$ , calculamos o mínimo de  $q(w)$  e fazemos a salvaguarda (lembre-se que estamos interessados em  $\alpha_{\text{nov}}o \in [\rho_1 \alpha, \rho_2 \alpha]$ ).

A seguir estão os passos utilizados para a escolha de  $\alpha_{\text{nov}}o$  utilizando a interpolação quadrática e salvaguarda:

# Cálculo do tamanho de passo

**Cálculo do tamanho de passo:** Dados  $p_k \in \mathbf{R}^n$  direção de descida,  $\alpha > 0$  e  $x_k \in \Omega$ .

**Passo 1:** Calcule  $\alpha_{tent} = -\frac{\alpha^2 \nabla f(x_k)^T p_k}{2(f(x_k + \alpha p_k) - f(x_k) - \alpha \nabla f(x_k)^T p_k)}$ .

**Passo 2:** Se  $(\alpha_{tent} \geq \rho_1 \alpha)$  e  $(\alpha_{tent} \leq \rho_2 \alpha)$  então  
faça  $\alpha_{novo} \leftarrow \alpha_{tent}$ .

Senão

faça  $\alpha_{novo} \leftarrow \frac{\alpha}{2}$ .