

# Método de restrições ativas para minimização em caixas

Marina Andretta

ICMC-USP

16 de novembro de 2010

# Problema com restrições de caixa

Estamos interessados em resolver o problema

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

(1)

com

- $x, \ell, u \in \mathbf{R}^n$ ,  $\ell < u$ , e
- $f : \mathbf{R}^n \rightarrow \mathbf{R}$  suave.

Denotaremos o gradiente da função  $f$  por  $g$ .

# Método de restrições ativas

Se fosse possível saber o conjunto de restrições ativas na solução, o ponto  $x^*$  solução do problema (1) seria “facilmente” calculado (pois o problema se tornaria irrestrito).

Métodos de restrições ativas tentam, a cada iteração, descobrir qual o conjunto de restrições ativas na solução.

Se detectam que o conjunto  $W$  de restrições que supunham ser ativas na solução está incorreto, utilizam algum critério para acrescentar ou remover restrições de  $W$ .

# Método de restrições ativas

O método de restrições ativas que estudaremos parte de um conjunto de restrições ativas  $W$ .

A cada iteração, **fixa as variáveis de  $W$  e resolve um subproblema irrestrito, usando apenas as variáveis livres.**

Se a solução do subproblema for também a solução do problema original (1), o conjunto  $W$  está correto e o método para.

**Se a solução do subproblema não for solução do problema original (1), o conjunto  $W$  é modificado e inicia-se uma nova iteração.**

# Método de restrições ativas

Note que, ao fixar algumas variáveis do conjunto  $\Omega$ , estamos **definindo faces** deste conjunto.

Podemos então **dividir a região viável  $\Omega$  em faces abertas disjuntas**.

Para todo  $I \subset \{1, 2, \dots, n, n+1, n+2, \dots, 2n\}$  definimos

$$F_I = \left\{ x \in \Omega \left| \begin{array}{ll} x_i = l_i, & \text{se } i \in I, \\ x_i = u_i, & \text{se } n+i \in I, \\ l_i < x_i < u_i & \text{caso contrário} \end{array} \right. \right\}.$$

# Método de restrições ativas

O conjunto  $\Omega$  é a união das faces abertas.

Definimos  $V_I$  o menor espaço afim que contém  $F_I$  e  $S_I$  o subespaço vetorial paralelo a  $V_I$ .

Definimos o gradiente projetado contínuo como

$$g_P(x) = P_{\Omega}(x - g(x)) - x.$$

Lembre-se que um ponto viável  $x_k$  satisfaz as condições **KKT** se e somente se  $g_P(x_k) = 0$ .

# Método de restrições ativas

Para todo  $x \in F_I$ , definimos o gradiente interno como

$$g_I(x) = P_{S_I}[g_P(x)].$$

Ou seja,

$$[g_I(x)]_i = \begin{cases} [g_P(x)]_i & , \text{ se } x_i \text{ é livre,} \\ 0 & , \text{ caso contrário} \end{cases}$$

Note que a norma de  $g_I(x)$  sempre é menor ou igual à norma de  $g_P(x)$ .

A idéia do método de restrições ativas é a seguinte:

- O conjunto viável é dividido em faces abertas e, a cada iteração  $k$ , tem-se um ponto  $x_k$  pertencente a uma dessas faces.
- No início de cada iteração, verifica-se qual a relação entre a norma do gradiente interno e a norma do gradiente projetado contínuo.
- Quando a norma do gradiente projetado contínuo  $g_P$  é “muito maior” que a norma do gradiente interno  $g_I$ , decide-se **mudar de face**.
- Quando a norma do gradiente projetado contínuo  $g_P$  não é “muito maior”, decide-se **continuar na mesma face**.



# Teste para decidir se permanece na face

O teste principal, usado para decidir se permanecemos ou não na face atual, é

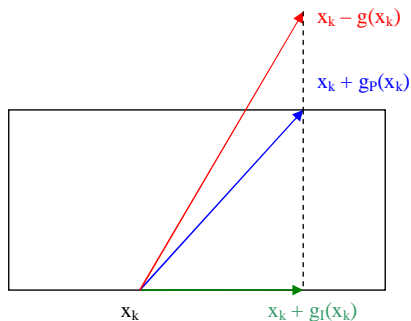
$$\|g_I(x_k)\| \geq \eta \|g_P(x_k)\|,$$

para  $\eta \in (0, 1)$ .

A ideia deste teste é: se a função objetivo parece **diminuir mais saindo da face** (norma de  $g_P$  “muito maior” do que a norma de  $g_I$ ), decidimos **abandonar** a face corrente.

Se ficar na **face atual parece promissor**, decidimos **permanecer** na face corrente.

# Teste para decidir se permanece na face



Como  $\|\nearrow\|$  é “maior” do que  $0.1\|\searrow\|$ , decidimos permanecer na face.

# O que fazer para permanecer ou abandonar uma face

Para **permanecer na face atual**, precisamos resolver um **problema de minimização** com algumas **variáveis** do problema original **fixas** em seus limitantes.

Em vez de encontrar o minimizador na face, realizamos apenas uma iteração de **um método para minimização “irrestrita”** para calcular um ponto  $x_{k+1}$  no fecho da face atual, no qual há **decréscimo do valor da função objetivo**.

# O que fazer para permanecer ou abandonar uma face

Para **abandonar a face**, fazemos **uma iteração do método SPG** (Gradiente Espectral Projetado), que fornecerá um novo ponto  $x_{k+1}$  **viável** em uma nova face, com **valor de função objetivo menor**.

Calculado o novo ponto, verificamos se encontramos a solução do problema original. Em caso negativo, verificamos novamente se vale a pena ou não permanecer na face atual e repetimos o procedimento.

**Método de restrições ativas:** Dados  $x_0 \in \Omega$  e  $\eta \in (0, 1)$ .

**Passo 1:** Faça  $k \leftarrow 0$ .

**Passo 2:** Se  $\|g_P(x_k)\| \leq \epsilon$ , pare com  $x_k$  como solução.

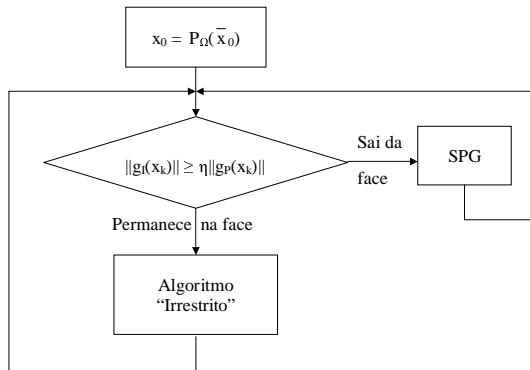
**Passo 3:** Se  $\|g_I(x_k)\| \geq \eta \|g_P(x_k)\|$ ,  
suponha, sem perda de generalidade, que as variáveis livres em  $F_I$  são  $x_1, \dots, x_m$  e que as variáveis restantes estão fixas em  $\bar{x}_{m+1}, \dots, \bar{x}_n$  ( $\bar{x}_i \in \{l_i, u_i\}$ , para  $m+1 \leq i \leq n$ ). Defina  $\bar{f}(x_1, \dots, x_m) = f(x_1, \dots, x_m, \bar{x}_{m+1}, \dots, \bar{x}_n)$ ,  $\forall x_1, \dots, x_m \in \mathbf{R}$ . Use uma iteração de um algoritmo “irrestrito” para calcular  $x_{k+1} \in \bar{F}_I$  minimizador de  $\bar{f}$ .

Senão

faça uma iteração do SPG para calcular  $x_{k+1}$ .

**Passo 4:** Faça  $k \leftarrow k + 1$  e volte para o Passo 2.

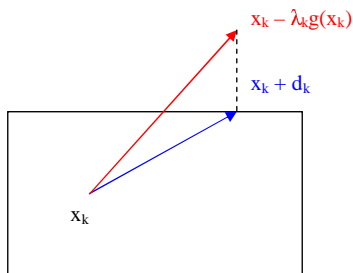
# Método de restrições ativas



Note que, como o valor da função objetivo sempre diminui, quando uma face é abandonada ela nunca é visitada novamente.

Como o número de faces é finito e tanto o SPG como o algoritmo “irrestrito” possuem convergência garantida, este método de restrições ativas converge em um número finito de iterações para a solução do problema (1).

# Como sair da face: método SPG



- $s_k = x_k - x_{k-1}$ ,  $y_k = g(x_k) - g(x_{k-1})$
- $\lambda_k = \frac{s_k^T s_k}{s_k^T y_k}$
- $d_k = P_{\Omega}(x_k - \lambda_k g(x_k)) - x_k$



Em cada face  $F_I$  estamos interessados em resolver o seguinte problema “irrestrito”

$$\text{Minimizar } \bar{f}(x_1, \dots, x_m), \quad (2)$$

- $x_1, \dots, x_m$  variáveis livres e  $\bar{x}_{m+1}, \dots, \bar{x}_n$  variáveis fixas em  $F_I$
- $\bar{f}(x_1, \dots, x_m) = f(x_1, \dots, x_m, \bar{x}_{m+1}, \dots, \bar{x}_n)$ , para todo  $x_1, \dots, x_m \in \mathbf{R}$

# Permanecer na face: minimização na face

Para resolver o **problema (2)**, qualquer **algoritmo irrestrito** pode ser usado.

No entanto, é preciso tomar cuidado para que as **restrições do problema original (1)** nas **variáveis livres  $x_1, \dots, x_m$**  sejam respeitadas, mantendo os iterandos do método de restrições ativas sempre viáveis.

# Minimização na face com busca linear

Se o método escolhido para fazer a minimização na face for de busca linear, a **viabilidade do ponto**  $x_{k+1} = x_k + \alpha_k p_k$  é **garantida** pelo seguinte procedimento:

- Calcula-se  $\alpha_{\max}$  o maior escalar entre 0 e 1 tal que  $x_k + \alpha_{\max} p_k \in \Omega$ .

$$\alpha_{\max} = \max\{\alpha \in [0, 1] \mid x_k + \alpha p_k \in \Omega\}.$$

- O **tamanho de passo inicial** para a busca linear é tomado como  $\alpha_{\max}$ .

**Iteração do algoritmo “irrestrito” com busca linear:** Seja  $k$  a iteração atual. Dados  $x_k$  viável,  $\epsilon > 0$  e  $c \in (0, 1)$ .

**Passo 1:** Se  $\|\nabla \bar{f}(x_k)\| \leq \epsilon$  então pare e com  $x_k$  minimizador na face.

**Passo 2:** Calcule uma direção de descida  $p_k$ .

**Passo 3:** Calcule  $\alpha_{\max} = \max\{\alpha \in [0, 1] \mid x_k + \alpha p_k \in \Omega\}$ .

**Passo 4:** Se  $\alpha_{\max} < 1$  e  $\bar{f}(x_k + \alpha_{\max} p_k) < \bar{f}(x_k)$  então

faça  $x_{k+1} = x_k + \alpha_{\max} p_k$  e pare.

**Passo 5:** Calcule  $\alpha_k \leq \alpha_{\max}$  que satisfaz condições de Wolfe ou é calculado usando *backtracking* com Armijo.

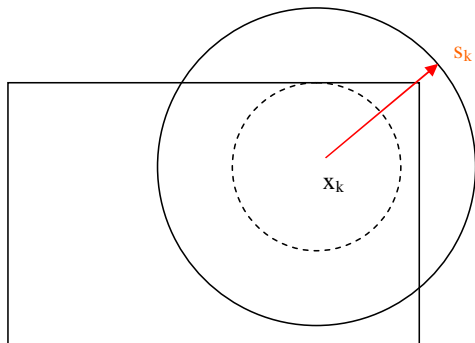
**Passo 6:** Faça  $x_{k+1} \leftarrow x_k + \alpha_k p_k$ .

# Minimização na face com regiões de confiança

Se o método escolhido para fazer a minimização na face for de regiões de confiança, a **viabilidade do ponto**  $x_{k+1} = x_k + p_k$  **é garantida** pelo seguinte procedimento:

- Se a solução do subproblema de regiões de confiança gera um ponto  $x_k + p_k \notin \Omega$ , calcula-se o escalar  $\alpha_{\max}$  que faz com que  $x_k + \alpha_{\max}$  fique na borda de  $\Omega$ .
- Se a função  $\bar{f}$  tem **decréscimo simples** neste ponto, ele é tomado como  $x_{k+1}$ .
- Se o ponto na borda não produz decréscimo da função, **diminui-se o raio da região de confiança** de modo que a solução do subproblema de regiões de confiança gere  $x_k + p_k \in \Omega$ .

# Minimização na face com regiões de confiança



# Minimização na face com regiões de confiança

Além disso, para garantir convergência deste método de restrições ativas, quando um ponto está muito próximo da borda de  $\Omega$ , não se deve usar uma iteração de regiões de confiança.

Neste caso, utilizamos uma iteração do método de SPG para resolver o seguinte problema

$$\begin{array}{ll} \text{Minimizar} & f(x) \\ \text{Sujeita a} & x \in F_I. \end{array}$$

# Minimização na face com regiões de confiança

**Iteração do algoritmo “irrestrito” com regiões de confiança:** Seja  $k$  a iteração atual. Dados  $x_k$  viável,  $\epsilon > 0$ ,  $\Delta_{\min} > 0$ ,  $\Delta_k \geq \Delta_{\min}$  e  $\sigma > 0$ .

**Passo 1:** Se  $\|\nabla\bar{f}(x_k)\| \leq \epsilon$  então pare com  $x_k$  minimizador na face.

**Passo 2:** Calcule  $\Delta_{borda}$  a distância de  $x_k$  à borda da face.

**Passo 3:** Se  $\Delta_{borda} < 2\Delta_{\min}$  então

faça uma iteração de SPG restrito a  $F_l$  (face atual) para calcular  $x_{k+1}$  e pare.

**Passo 4:** Calcule  $p_k$  uma solução aproximada de

$$\begin{array}{ll} \text{Minimizar} & \varphi(w) \equiv \frac{1}{2}w^T \nabla^2 \bar{f}(x_k)w + (\nabla \bar{f}(x_k))^T w \\ \text{sujeita a} & \|w\| \leq \Delta_k. \end{array}$$

**Passo 5:** Se  $\varphi(p_k) = 0$  então pare com  $x_k$  minimizador na face.



**Passo 6:** Calcule

$$\alpha_{\max} = \max\{\alpha \in [0, 1] \mid [x_k, x_k + \alpha p_k] \subset \Omega\}.$$

**Passo 7:** Se  $\alpha_{\max} < 1$  e  $\bar{f}(x_k + \alpha_{\max} p_k) < \bar{f}(x_k)$  então  
faça  $x_{k+1} = x_k + \alpha_{\max} p_k$  e pare.

**Passo 8:** Se  $\alpha_{\max} < 1$  e  $\bar{f}(x_k + \alpha_{\max} p_k) \geq \bar{f}(x_k)$  então  
faça  $\Delta_k = 0.9\Delta_{\text{borda}}$  e volte para o Passo 4.

**Passo 9:** Se  $\frac{\bar{f}(x_k + p_k) - \bar{f}(x_k)}{\varphi(p_k)} \leq 0.1$  então  
escolha  $\Delta_k = \Delta \in [0.1\|p_k\|, 0.9\|p_k\|]$  e volte para o Passo 4.

**Passo 10:** Faça  $x_{k+1} \leftarrow x_k + p_k$  e escolha  $\Delta_{k+1} \geq \Delta_{\min}$ .