

# Resolução de problemas com apenas restrições lineares de igualdade

Marina Andretta

ICMC-USP

14 de outubro de 2014

# Problema com restrições lineares de igualdade

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

$$\begin{array}{ll} \text{Minimizar} & f(x) \\ \text{Sujeita a} & Ax = b, \end{array} \quad (1)$$

onde

- $x \in \mathbf{R}^n$ ,
- $A \in \mathbf{R}^{m \times n}$ ,  $b \in \mathbf{R}^m$ ,
- $f : \mathbf{R}^n \rightarrow \mathbf{R}$  função suave.

# Problema com restrições lineares de igualdade

Ao trabalhar com o problema (1), trataremos apenas do caso em que a matriz  $A$  possui linhas linearmente independentes.

Isso é razoável na prática, pois quando alguma linha de  $A$  depende linearmente de outra, ou a linha em questão pode ser eliminada sem nenhuma alteração da solução de (1) ou a região viável é vazia, não havendo solução para o problema.

# Problema com restrições lineares de igualdade

Vejamos algumas definições:

- $Z$  é uma matriz de  $\mathbb{R}^{n \times (n-m)}$  cujas **colunas formam uma base para núcleo** do espaço gerado pelas linhas da matriz  $A$ .
- $Y$  é uma matriz de  $\mathbb{R}^{n \times m}$  cujas **colunas formam uma base para a imagem** do espaço formado pelas linhas de  $A$ .

Note que  $AZ = 0$  e  $AY$  é não-singular.

# Problema com restrições lineares de igualdade

Uma vez escolhidas as matrizes  $Z$  e  $Y$ , todo vetor  $x$  em  $\mathbf{R}^n$  possui uma única representação da forma

$$x = Yx_y + Zx_z,$$

com  $x_y \in \mathbf{R}^m$  e  $x_z \in \mathbf{R}^{(n-m)}$ .

Em particular, tomando  $x^*$  solução de (1), temos

$$x^* = Yx_y^* + Zx_z^*.$$

# Problema com restrições lineares de igualdade

Como  $x^*$  é viável, vale que

$$Ax^* = A(Yx_y^* + Zx_z^*) = b.$$

Como  $AZ = 0$  e  $AY$  é não-singular, temos

$$x_y^* = (AY)^{-1}b,$$

# Problema com restrições lineares de igualdade

Assim, a **solução**  $x^*$  de (1) (assim como qualquer ponto viável de (1)) pode ser vista como a **soma de uma solução particular para o sistema linear**  $Ax = b$  (tomando, por exemplo,  $x_z^* = 0$ ) e de um ponto no núcleo do espaço gerado pelas linhas **de**  $A$ .

Desta forma, reduzimos o problema restrito original (1) a um **problema irrestrito de**  $n - m$  variáveis, dado por

$$\text{Minimizar } \bar{f}(x_z) = f(Y(AY)^{-1}b + Zx_z) = f(x). \quad (2)$$

# Problema com restrições lineares de igualdade

Note que o gradiente e a Hessiana de  $\bar{f}$  são dados por

$$\nabla \bar{f}(x_z) = Z^T \nabla f(x)$$

e

$$\nabla^2 \bar{f}(x_z) = Z^T \nabla^2 f(x) Z.$$



# Problema com restrições lineares de igualdade

Para resolver o problema (2), podemos usar **qualquer método para resolução de problemas irrestritos**.

Formularemos, então, um algoritmo para resolver (2) baseado em busca linear que gera uma sequência de pontos viáveis.

Para manter a viabilidade de cada ponto gerado pelo algoritmo, a cada iteração  $k$ , partimos de um ponto  $x_k$  viável e calculamos um passo  $p_k$  tal que

$$Ap_k = 0.$$

# Problema com restrições lineares de igualdade

Como  $x_k$  é viável e  $Ap_k = 0$ , temos

$$Ax_{k+1} = A(x_k + \alpha_k p_k) = Ax_k + \alpha_k Ap_k = Ax_k = b.$$

Ou seja, o ponto  $x_{k+1} = x_k + \alpha_k p_k$  é viável.

Note que

$$Ap_k = 0 \Leftrightarrow p_k = Zp_z,$$

para algum vetor  $p_z \in \mathbf{R}^{(n-m)}$ .

# Resolução de problemas com restrições lineares de igualdade

**Método de busca linear para minimização com restrições lineares de igualdade:** Dados uma matriz  $A \in \mathbf{R}^{m \times n}$ ,  $m < n$ , de posto  $m$ , um vetor  $b \in \mathbf{R}^m$ , um ponto inicial  $x_0$  viável e um escalar  $\epsilon > 0$ .

**Passo 1:** Faça  $k \leftarrow 0$ .

**Passo 2:** Calcule  $Z$  tal que  $AZ = 0$ .

**Passo 3:** Se  $\|Z^T \nabla f(x_k)\| \leq \epsilon$ , pare com  $x_k$  como solução.

**Passo 4:** Calcule uma direção de descida  $p_z \in \mathbf{R}^{(n-m)}$  e faça  $p_k \leftarrow Zp_z$ .

**Passo 5:** Faça  $x_{k+1} \leftarrow x_k + \alpha_k p_k$ ,  $\alpha_k$  satisfaz condições de Wolfe ou é calculado usando *backtracking* com Armijo.

**Passo 6:** Faça  $k \leftarrow k + 1$  e volte para o Passo 3.

# Cálculo da matriz $Z$

A primeira idéia para o cálculo da matriz  $Z$  é o uso da **fatoração LQ** da matriz  $A$ .

Nesta fatoração, que gasta  $O(nm^2)$  operações, temos uma **matriz ortogonal**  $Q \in \mathbb{R}^{n \times n}$  tal que

$$AQ = (L \ 0),$$

onde  $L \in \mathbb{R}^{m \times m}$  é **triangular inferior**.

Como estamos supondo que as linhas da matriz  $A$  são linearmente independentes, a matriz  $L$  é não-singular.

Escrevendo a matriz  $Q$  como  $Q = [Q_1; Q_2]$ , com  $Q_1 \in \mathbb{R}^{n \times m}$  e  $Q_2 \in \mathbb{R}^{n \times (n-m)}$ , temos que

$$AQ_1 = L \text{ e } AQ_2 = 0.$$

É fácil ver que as colunas de  $Q_1$  e  $Q_2$  formam, respectivamente, uma **base ortogonal para a imagem** e o **núcleo** do espaço gerado pelas linhas de  $A$ .

Assim, uma escolha natural para a **matriz  $Z$**  é  $Q_2$ .

Note que, usando, por exemplo, técnicas do tipo **Newton para calcular o passo  $p_z$**  (Passo 4), temos que

$$\text{cond}(Z^T \nabla^2 f(x_k) Z) \leq \text{cond}(\nabla^2 f(x_k)) (\text{cond}(Z))^2.$$

Assim, como este limitante é justo (pode valer a igualdade), quando o número de condição da matriz  $Z$  é grande, a matriz Hessiana projetada  $Z^T \nabla^2 f(x_k) Z$  poderia ser mal-condicionada mesmo quando a matriz Hessiana  $\nabla^2 f(x_k)$  é bem-condicionada.



# Cálculo da matriz $Z$

No entanto, utilizando a **fatoração LQ** para determinar  $Z$ , temos  **$\text{cond}(Z) = 1$** . Ou seja,

$$\text{cond}(Z^T \nabla^2 f(x_k) Z) \leq \text{cond}(\nabla^2 f(x_k)),$$

o que mostra que, neste caso, o condicionamento do problema (2) não é pior que o condicionamento do problema (1).

Portanto, uma grande **vantagem** do uso desta técnica é o fato de que esta escolha de  $Z$  **não piora o condicionamento do problema** de encontrar uma solução para (1).

# Cálculo da matriz $Z$

Para formar a matriz  $Q$  usando a fatoração LQ é necessário calcular o produto de transformações ortogonais usadas para triangularizar a matriz  $A$ .

Na implementação de métodos que usam a matriz  $Z$  somente em produtos matriz-vetor, pode não ser eficiente calcular a matriz  $Q$  (e, conseqüentemente,  $Z$ ) explicitamente, principalmente quando o número de restrições é pequeno.

Neste caso é mais interessante **armazenar as transformações ortogonais** de forma compacta e aplicá-las ao vetor apropriado para calcular o produto matriz-vetor sempre que necessário.

# Cálculo da matriz $Z$

Apesar das vantagens do uso da **fatoração LQ** para o cálculo da matriz  $Z$ , esta é uma operação **computacionalmente custosa**.

Uma **alternativa** é a técnica de **redução de variáveis**.

Tomando a matriz  $A$  com linhas linearmente independentes, podemos particioná-la em

$$A = (V \ U),$$

onde  $V \in \mathbf{R}^{m \times m}$  é não-singular e  $U \in \mathbf{R}^{m \times (n-m)}$ .

Usando esta partição de  $A$ , a matriz  $Z$  pode ser definida como

$$Z = \begin{pmatrix} -V^{-1}U \\ I \end{pmatrix},$$

onde  $I$  é a matriz identidade  $(n - m) \times (n - m)$ .

Note que

$$AZ = (V \quad U) \begin{pmatrix} -V^{-1}U \\ I \end{pmatrix} = -VV^{-1}U + U = 0,$$

como desejamos.

# Cálculo da matriz $Z$

Geralmente a matriz  $Z$ , tal como descrita acima, **não é armazenada explicitamente**.

Produtos matriz-vetor envolvendo  $Z$  e  $Z^T$  podem ser obtidos resolvendo sistemas lineares envolvendo  $V$  e  $V^T$ .

A grande **dificuldade** desta técnica é encontrar uma maneira eficiente de particionar  $A$  de forma que a matriz  $V$  **escolhida fique relativamente bem-condicionada**.