

- 1 Métodos numéricos para optimização não linear sem restrições
  - Métodos de procura directa
  - Métodos de procura unidireccional (geral)
  - Métodos de procura unidireccional (descida máxima, Newton)
  - Métodos de região de confiança
- 2 Teoria da optimização não linear com restrições
  - Introdução e qualificações de restrições
  - Condições de primeira ordem
  - Condições de segunda ordem
  - Teoria da dualidade
- 3 Métodos numéricos para optimização não linear com restrições
  - **Método da penalização quadrática**
  - Método do Lagrangeano aumentado
  - Programação Sequencial Quadrática (SQP)
  - Métodos de pontos interiores

Os métodos de penalização para **otimização com restrições** resolvem o problema original por uma sucessão de subproblemas.

Cada subproblema envolve a minimização de uma função de penalização.

A mais simples **função de penalização** é a **função de penalização quadrática**.

Consideremos um PNL com  $\mathcal{I} = \emptyset$

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \end{array}$$

$P_{\mathcal{E}}$

e a seguinte função de penalização quadrática

$$Q(x; \mu) = f(x) + \frac{\mu}{2} \sum_{i \in \mathcal{E}} (c_i(x))^2$$

em que  $\mu > 0$  é o parâmetro da penalização.

Ao aumentar-se  $\mu$ , penaliza-se a violação das restrições.

## Exemplo:

Consideremos o problema

$$\begin{array}{ll} \min_{(x_1, x_2)} & x_1 + x_2 \\ \text{sujeito a} & x_1^2 + x_2^2 - 2 = 0 \end{array}$$

em que  $x_* = (-1, -1)^\top$  é a solução.

A função de penalização quadrática é dada por

$$Q(x; \mu) = x_1 + x_2 + \frac{\mu}{2}(x_1^2 + x_2^2 - 2)^2$$

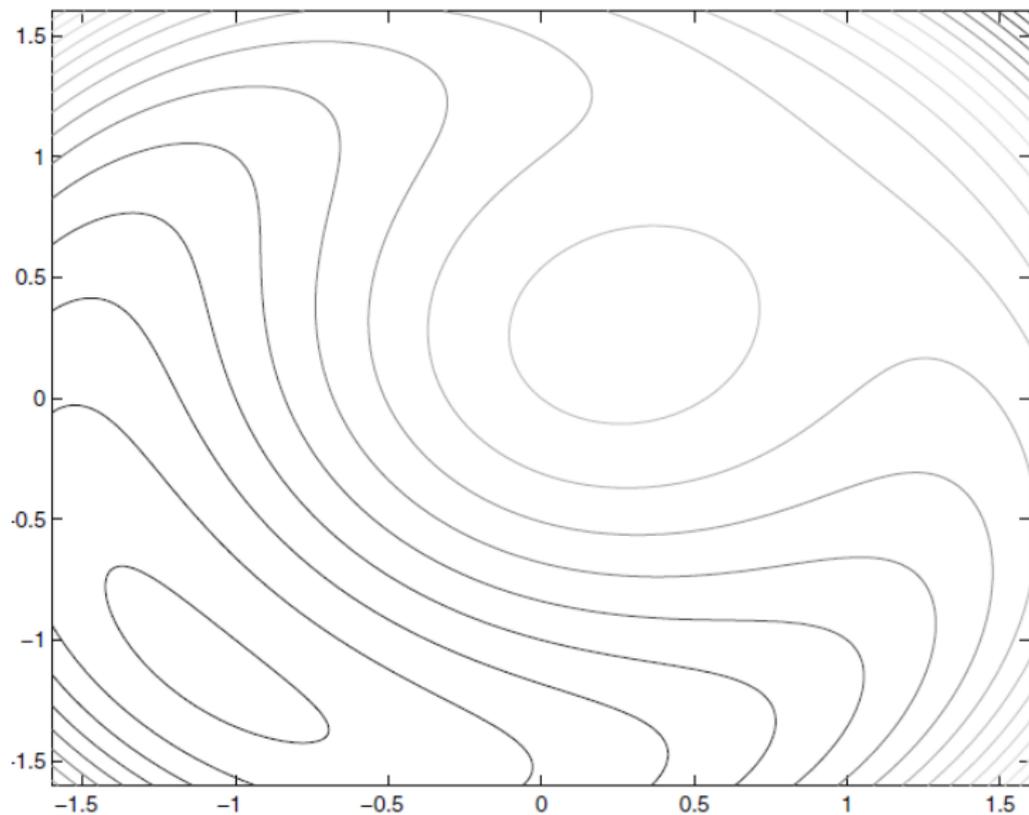


Figure: curvas de nível de  $Q(x; 1)$

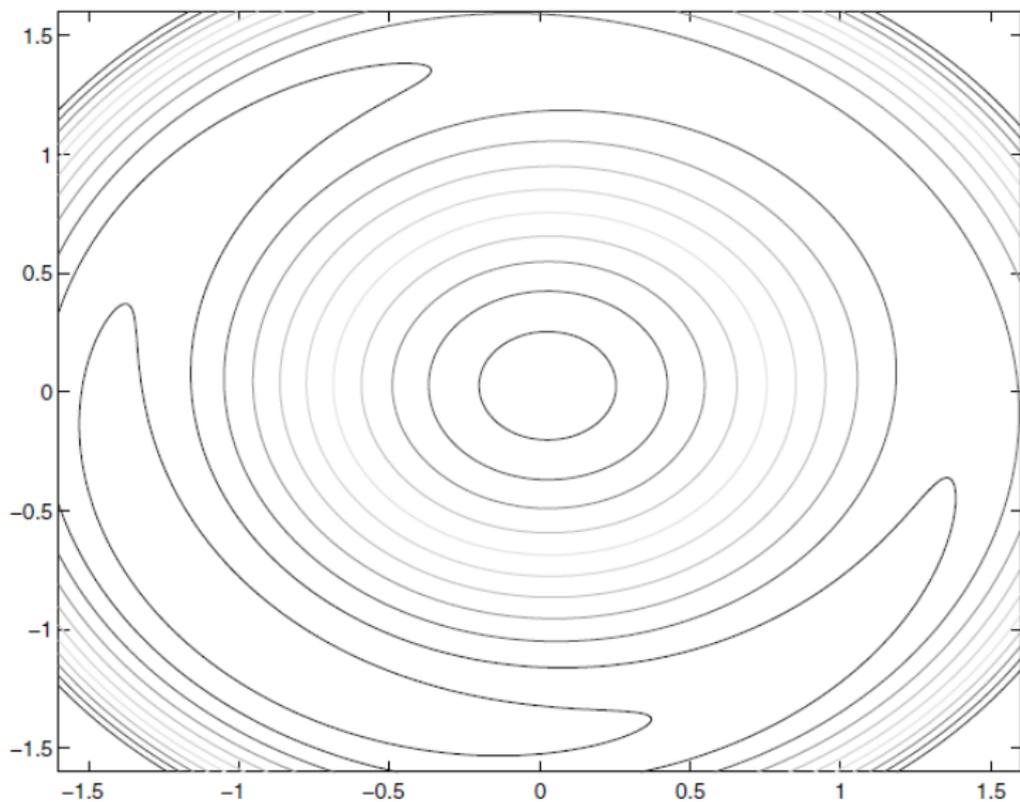


Figure: curvas de nível de  $Q(x; 10)$

## Algoritmo (Método da penalização quadrática)

### Inicialização

Dado  $\mu_0 > 0$ ,  $x_0 = x_0^s$  um ponto inicial e  $\{\tau_k\}$  em que  $\tau_k \geq 0$  e  $\tau_k \downarrow 0$ .

Para  $k = 0, 1, 2, \dots$

- 1 Minimizar  $Q(\cdot; \mu_k)$  partindo de  $x_k^s$  e terminando quando  $\|\nabla_x Q(\cdot; \mu_k)\| \leq \tau_k$  (resultado em  $x_k$ ).
- 2 Escolher  $\mu_{k+1} > \mu_k$ .
- 3 Escolher  $x_{k+1}^s$  (e.g.  $x_{k+1}^s = x_k$ ).

## Teorema

Seja  $x_k$  um minimizante global de  $Q(\cdot; \mu_k)$  e  $\{\mu_k\}$  em que  $\mu_k \geq 0$  e  $\mu_k \uparrow +\infty$ .

Então qualquer ponto de acumulação  $x_*$  de  $\{x_k\}$  é um minimizante global de  $P_{\mathcal{E}}$ .

**Demonstração:** Seja  $\bar{x}$  um minimizante global de  $P_{\mathcal{E}}$ , ou seja,

$$f(\bar{x}) \leq f(x) \quad \forall x : c_i(x) = 0, i \in \mathcal{E}$$

Uma vez que  $x_k$  minimiza  $Q(\cdot; \mu_k) \forall k$ , temos

$$Q(x_k; \mu_k) \leq Q(\bar{x}; \mu_k)$$

Logo,

$$f(x_k) + \frac{\mu_k}{2} \sum_{i \in \mathcal{E}} c_i^2(x_k) \leq f(\bar{x}) + \underbrace{\frac{\mu_k}{2} \sum_{i \in \mathcal{E}} c_i^2(\bar{x})}_{=0} = f(\bar{x})$$

$\Downarrow$

$$\sum_{i \in \mathcal{E}} c_i^2(x_k) \leq \frac{2}{\mu_k} [f(\bar{x}) - f(x_k)]$$

Suponhamos, agora, que  $x_*$  é um ponto de acumulação de  $\{x_k\}$ .

Assim, existe uma subsucessão  $K$  tal que

$$\lim_{k \in K} x_k = x_*$$

Por sua vez (atenção...),

$$\sum_{i \in \mathcal{E}} c_i^2(x_*) = \lim_{k \in K} \sum_{i \in \mathcal{E}} c_i^2(x_k) \leq \lim_{k \in K} \frac{2}{\mu_k} [f(\bar{x}) - f(x_k)] \underbrace{=}_{\mu_k \uparrow +\infty} 0$$

Temos, então, que

$$c_i(x_*) = 0, \quad \forall i \in \mathcal{E}$$

e, desta forma,  $x_*$  é admissível.

Vimos já que

$$(f(x_k) \leq) f(x_k) + \frac{\mu_k}{2} \sum_{i \in \mathcal{E}} c_i^2(x_k) \leq f(\bar{x}) + \frac{\mu_k}{2} \sum_{i \in \mathcal{E}} c_i^2(\bar{x}) = f(\bar{x})$$

Tomando limites, temos

$$f(x_*) \leq f(\bar{x})$$

Assim,  $x_*$  é um minimizante global. ■

Este resultado é pouco prático.

Supõe a minimização global de  $Q(\cdot; \mu_k)$  em  $x$ .

O resultado seguinte apenas requer de  $x_k$  uma estacionaridade aproximada.

## Teorema

Sejam  $f$  e  $c_i$ ,  $i \in \mathcal{E}$ , funções continuamente diferenciáveis.

Seja  $\{\tau_k\}$  em que  $\tau_k \geq 0$  e  $\tau_k \downarrow 0$ .

Seja  $\{\mu_k\}$  em que  $\mu_k \geq 0$  e  $\mu_k \uparrow +\infty$ .

Seja  $x_*$  um ponto de acumulação de  $\{x_k\}$   $\left( \exists K : \lim_{k \in K} x_k = x_* \right)$ .

(i) Se  $x_*$  for não admissível ele é um ponto estacionário do problema

$$\min \|c(x)\|^2$$

(ii) Se  $x_*$  verificar LICQ, então satisfaz as CN10-KKT e

$$\lim_{k \in K} -\mu_k c_i(x_k) = \lambda_i^*, \quad \forall i \in \mathcal{E}$$

**Demonstração:** (i) Começemos por observar que

$$\nabla_x Q(x_k; \mu_k) = \nabla f(x_k) + \sum_{i \in \mathcal{E}} \mu_k c_i(x_k) \nabla c_i(x_k)$$

Assim, vem

$$\|\nabla_x Q(x_k; \mu_k)\| \leq \tau_k \iff$$

$$\left\| \nabla f(x_k) + \sum_{i \in \mathcal{E}} \mu_k c_i(x_k) \nabla c_i(x_k) \right\| \leq \tau_k \implies$$

$$\left\| \sum_{i \in \mathcal{E}} c_i(x_k) \nabla c_i(x_k) \right\| \leq \frac{1}{\mu_k} (\tau_k + \|\nabla f(x_k)\|)$$

Logo, tomando limites, vem que

$$\sum_{i \in \mathcal{E}} c_i(x_*) \nabla c_i(x_*) = 0$$

e temos que  $x_*$  é um ponto estacionário da função  $\|c(x)\|^2$ .

(ii) Seja  $A(x) = \left[ \nabla c_i(x)^\top \right]_{i \in \mathcal{E}}$ .

Seja  $\lambda_k = -\mu_k c(x_k)$ , em que  $c(x) = [c_i(x)]_{i \in \mathcal{E}}$ .

Assim, temos

$$A(x_k)^\top \lambda_k = \nabla f(x_k) - \nabla_x Q(x_k; \mu_k)$$

com  $\|\nabla_x Q(x_k; \mu_k)\| \leq \tau_k$ .

Uma vez que, para  $k$  suf. grande, temos  $\text{car}(A(x_k)) = |\mathcal{E}|$ , então  $A(x_k)A(x_k)^\top$  é não-singular.

Multiplicando

$$A(x_k)^\top \lambda_k = \nabla f(x_k) - \nabla_x Q(x_k; \mu_k)$$

por  $A(x_k)$ , vem

$$A(x_k)A(x_k)^\top \lambda_k = A(x_k) [\nabla f(x_k) - \nabla_x Q(x_k; \mu_k)]$$

Logo,

$$\lambda_k = \left[ A(x_k)A(x_k)^\top \right]^{-1} A(x_k) [\nabla f(x_k) - \nabla_x Q(x_k; \mu_k)]$$

Tomando limites, vem

$$\lim_{k \in K} \lambda_k = \left[ A(x_*)A(x_*)^\top \right]^{-1} A(x_*) \nabla f(x_*) \stackrel{\text{def}}{=} \lambda_*$$

Por outro lado, tomando limites em

$$A(x_k)^\top \lambda_k = \nabla f(x_k) - \nabla_x Q(x_k; \mu_k)$$

vem que

$$A(x_*)^\top \lambda_* = \nabla f(x_*) \iff \nabla f(x_*) - A(x_*)^\top \lambda_* = 0$$

Logo,  $x_*$  satisfaz as CN10-KKT.



## Notas:

- 1 A Hessiana da função de penalização

$$\nabla_{xx}^2 Q(x; \mu_k) = \nabla^2 f(x) + \sum_{i \in \mathcal{E}} \mu_k c_i(x) \nabla^2 c_i(x) + \mu_k A(x)^\top A(x)$$

é mal condicionada para  $\mu_k$  suf. grande, o que dificultará a aplicação do método de Newton (ou métodos nele baseados).

De facto, quando  $x$  está próximo de  $x_*$

$$\nabla_{xx}^2 Q(x; \mu_k) \approx \nabla_{xx}^2 L(x, \lambda_*) + \mu_k A(x)^\top A(x)$$

e o segundo termo torna-se (com  $\mu_k$  suf. grande) arbitrariamente mal condicionado.

Porém, o sistema de Newton

$$\nabla_{xx}^2 Q(x; \mu_k) p = -\nabla_x Q(x; \mu_k)$$

é equivalente a

$$\begin{bmatrix} \nabla^2 f(x) + \sum_{i \in \mathcal{E}} \mu_k c_i(x) \nabla^2 c_i(x) & A(x) \\ A(x)^\top & -\frac{1}{\mu_k} I \end{bmatrix} \begin{bmatrix} p \\ \zeta \end{bmatrix} = \begin{bmatrix} -\nabla_x Q(x; \mu_k) \\ 0 \end{bmatrix}$$

A matriz,  $2 \times 2$  por blocos, deste sistema é, em princípio, bem condicionada quando  $x$  está próximo de  $x_*$  e  $\mu_k$  é suf. grande (sob LICQ e CS20) — ver final do capítulo anterior...

No entanto, note-se que o método de Newton pode, mesmo assim, ser lento (pois a sua região de convergência local pode ser muito pequena).

- 2 Na presença de restrições de desigualdade pode considerar-se a função de penalidade quadrática

$$Q(x; \mu) = f(x) + \frac{\mu}{2} \sum_{i \in \mathcal{E}} (c_i(x))^2 + \frac{\mu}{2} \sum_{i \in \mathcal{I}} ([c_i(x)]^-)^2$$

em que  $[y]^- = \max(-y, 0)$ .

Observe-se que esta função apresenta uma ordem de suavidade a menos que o PNL original, pois tem uma derivada de segunda ordem descontínua.

- 1 Métodos numéricos para optimização não linear sem restrições
  - Métodos de procura directa
  - Métodos de procura unidireccional (geral)
  - Métodos de procura unidireccional (descida máxima, Newton)
  - Métodos de região de confiança
- 2 Teoria da optimização não linear com restrições
  - Introdução e qualificações de restrições
  - Condições de primeira ordem
  - Condições de segunda ordem
  - Teoria da dualidade
- 3 Métodos numéricos para optimização não linear com restrições
  - Método da penalização quadrática
  - **Método do Lagrangeano aumentado**
  - Programação Sequencial Quadrática (SQP)
  - Métodos de pontos interiores

Consideremos um PNL com  $\mathcal{I} = \emptyset$

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \end{array} \quad P_{\mathcal{E}}$$

O **método do Lagrangeano aumentado** (também conhecido por **método dos multiplicadores**) está relacionado com o **método da penalização quadrática**.

Pretende evitar o mau condicionamento quando  $\mu_k$  se torna grande, forçando as restrições a serem satisfeitas mais rapidamente.

Introduz, explicitamente, uma aproximação para os multiplicadores, na função a minimizar (**função Lagrangeana aumentada**).

Conhece-se já a aproximação

$$\lambda_i^* \approx -c_i(x_k)\mu_k, \quad \forall i \in \mathcal{E}$$

para os multiplicadores.

Define-se, assim, a função Lagrangeana aumentada

$$L_A(x; \lambda, \mu) \stackrel{\text{def}}{=} f(x) - \sum_{i \in \mathcal{E}} \lambda_i c_i(x) + \frac{\mu}{2} \sum_{i \in \mathcal{E}} (c_i(x))^2$$

## Exemplo:

Consideremos o problema

$$\begin{array}{ll} \min_{(x_1, x_2)} & x_1 + x_2 \\ \text{sujeito a} & x_1^2 + x_2^2 - 2 = 0 \end{array}$$

em que  $x_* = (-1, -1)^\top$  é a solução do problema (único minimizante local).

A função Lagrangeana aumentada é dada por

$$L_A(x; \lambda, \mu) = x_1 + x_2 - \lambda (x_1^2 + x_2^2 - 2) + \frac{\mu}{2} (x_1^2 + x_2^2 - 2)^2$$

Observe-se que  $\lambda_* = -0.5$  é o multiplicador associado a  $x_*$  (CN10).

Seja  $x_k$  um minimizante, aproximado, para  $L_A(x; \lambda^k, \mu_k)$ . Assim, temos

$$\begin{aligned}\nabla_x L_A(x_k; \lambda^k, \mu_k) &= \nabla f(x_k) - \sum_{i \in \mathcal{E}} \left( \lambda_i^k - \mu_k c_i(x_k) \right) \nabla c_i(x_k) \\ &= 0\end{aligned}$$

Comparando esta última expressão com

$$\nabla_x L(x_k, \lambda^{\text{ideal}}) = \nabla f(x_k) - \sum_{i \in \mathcal{E}} \lambda^{\text{ideal}} \nabla c_i(x_k) = 0$$

facilmente se deduz uma fórmula para melhorar a aproximação actual  $\lambda^k$

$$\lambda_i^{k+1} = \lambda_i^k - \mu_k c_i(x_k), \quad \forall i \in \mathcal{E}$$

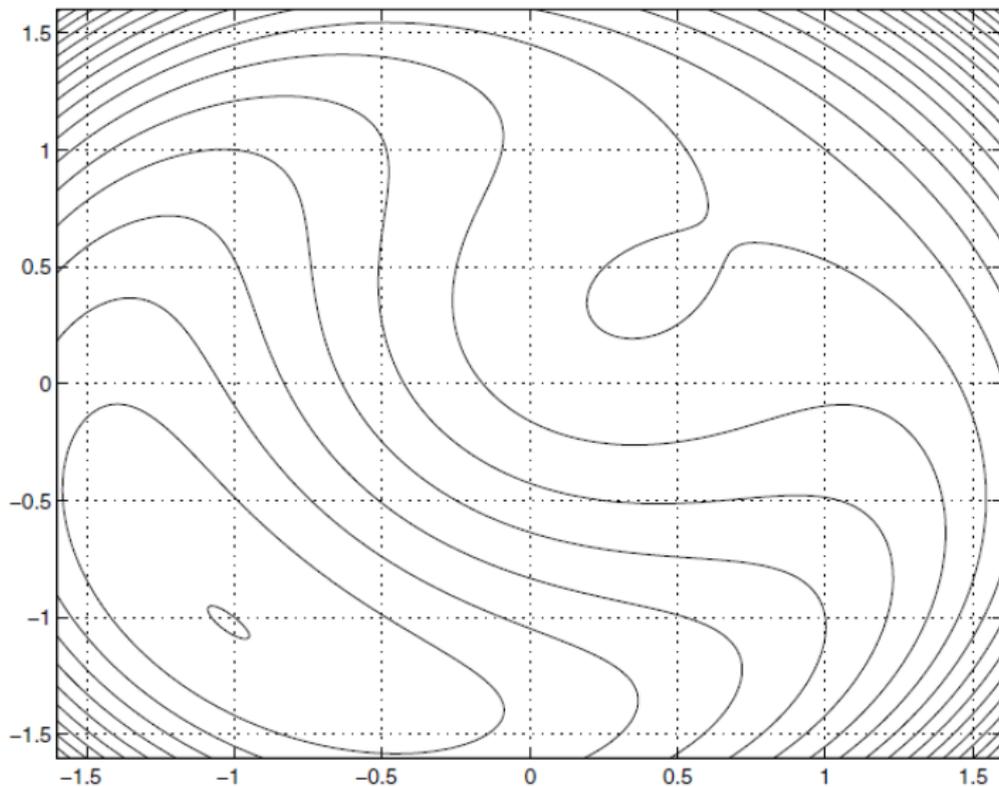


Figure: curvas de nível de  $L_A(x; -0.4, 1)$

## Algoritmo (Método do Lagrangeano aumentado)

### Inicialização

Dados  $x_0 = x_0^s$ ,  $\lambda^0$  pontos iniciais e  $\mu_0 > 0$ ,  $\{\tau_k\}$  em que  $\tau_k \geq 0$  e  $\tau_k \downarrow 0$ .

Para  $k = 0, 1, 2, \dots$

- 1 Minimizar  $L_A(\cdot; \lambda^k, \mu_k)$  partindo de  $x_k^s$  e terminando quando  $\|\nabla_x L_A(x_k; \lambda^k, \mu_k)\| \leq \tau_k$  (resultado em  $x_k$ ).
- 2 Actualizar  $\lambda^{k+1}$ .
- 3 Escolher  $\mu_{k+1} \geq \mu_k$ .
- 4 Escolher  $x_{k+1}^s$  (e.g.  $x_{k+1}^s = x_k$ ).

## Teorema

Seja  $x_*$  um minimizante local de  $P_{\mathcal{E}}$  a satisfazer LICQ (e numa vizinhança do qual todas as funções são duas vezes continuamente diferenciáveis).

Seja  $\lambda_*$  a satisfazer as CS2O.

Então

$\exists \bar{\mu}, \forall \mu \geq \bar{\mu} : x_*$  é um minimizante local estrito de  $L_A(x; \lambda_*, \mu)$ .

## Notas:

- 1 Conhecendo  $\lambda_*$ , a função Lagrangeana aumentada é uma função de penalização “exacta” (no sentido em que não é necessário fazer  $\mu$  tender para  $+\infty$ ).
- 2 Existirá menos mal condicionamento (pois não será preciso aumentar muito  $\mu$ ) e como tal a escolha de  $x_{k+1}^s$  é menos crítica.

## Teorema

Nas hipóteses do teorema anterior, existem escalares  $\delta$  e  $M$  positivos tais que:

(A) Se  $\frac{\|\lambda^k - \lambda_*\|}{\mu_k} \leq \delta$  e  $\mu_k \geq \bar{\mu}$ , então o subproblema

$$\min_{x \in \mathbb{R}^n} L_A(x; \lambda^k, \mu_k)$$

tem um minimizante local estrito ( $x_k$ ) suf. perto de  $x_*$  (onde as CS20 do subproblema são satisfeitas). Além disso, temos

$$\|x_k - x_*\| \leq \frac{M}{\mu_k} \|\lambda^k - \lambda_*\|$$

(B) Nas condições de (A)

$$\|\lambda^{k+1} - \lambda_*\| \leq \frac{M}{\mu_k} \|\lambda^k - \lambda_*\|$$

## Notas:

- 1 Neste teorema considera-se o cenário mais realista em que  $\lambda^k \neq \lambda_*$ .
- 2 O método do Lagrangeano aumentado dá-nos duas possibilidades de aproximar  $x_k$  de  $x_*$  (aumentar  $\mu_k$  ou aproximar  $\lambda^k$  de  $\lambda_*$ ).
- 3 (B) garante-nos uma taxa de convergência local **linear** para  $\{\lambda^k\}$ , quando  $\mu_k$  for suf. grande.
- 4 (A) diz-nos, também, que o subproblema do algoritmo satisfaz localmente (perto de  $x_*$ ) as CS2O.

- 1 Métodos numéricos para optimização não linear sem restrições
  - Métodos de procura directa
  - Métodos de procura unidireccional (geral)
  - Métodos de procura unidireccional (descida máxima, Newton)
  - Métodos de região de confiança
- 2 Teoria da optimização não linear com restrições
  - Introdução e qualificações de restrições
  - Condições de primeira ordem
  - Condições de segunda ordem
  - Teoria da dualidade
- 3 Métodos numéricos para optimização não linear com restrições
  - Método da penalização quadrática
  - Método do Lagrangeano aumentado
  - Programação Sequencial Quadrática (SQP)
  - Métodos de pontos interiores

Consideremos um PNL com  $\mathcal{I} = \emptyset$

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \end{array}$$

$P_{\mathcal{E}}$

Seja  $c(x) = [c_i(x)]_{i \in \mathcal{E}}$  e  $A(x) = [\nabla c_i(x)^{\top}]_{i \in \mathcal{E}}$ .

Sabemos que a função Lagrangeana associada a  $P_{\mathcal{E}}$  é dada por

$$L(x, \lambda) = f(x) - \lambda^{\top} c(x)$$

As CN1O-KKT para  $P_{\mathcal{E}}$  consistem num sistema de equações não lineares  $F(x, \lambda) = 0$ , em que  $F : \mathbb{R}^{n+m} \rightarrow \mathbb{R}^{n+m}$ ,

$$F(x, \lambda) = \begin{bmatrix} \nabla f(x) - A(x)^{\top} \lambda \\ c(x) \end{bmatrix} = 0$$

O Jacobiano, em relação a  $x$  e a  $\lambda$ , deste sistema é dado por

$$F'(x, \lambda) = \begin{bmatrix} \nabla_{xx}^2 L(x, \lambda) & -A(x)^{\top} \\ A(x) & 0 \end{bmatrix}$$

Assim, a aplicação do método de Newton resulta em

$$\begin{bmatrix} x_{k+1} \\ \lambda_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ \lambda_k \end{bmatrix} + \begin{bmatrix} p_k \\ \Delta\lambda_k \end{bmatrix}$$

em que  $p_k$  e  $\Delta\lambda_k$  são a solução do sistema (Newton-KKT) de equações lineares

$$\underbrace{\begin{bmatrix} \nabla_{xx}^2 L(x_k, \lambda_k) & -A(x_k)^\top \\ A(x_k) & 0 \end{bmatrix}}_{F'(x_k, \lambda_k)} \begin{bmatrix} p_k \\ \Delta\lambda_k \end{bmatrix} = \underbrace{\begin{bmatrix} -\nabla f(x_k) + A(x_k)^\top \lambda_k \\ -c(x_k) \end{bmatrix}}_{-F(x_k, \lambda_k)}$$

## Notas:

- 1 Observe-se que  $F'(x, \lambda)$  é não-singular se  $\text{car}(A(x)) = m$  e  $\nabla_{xx}^2 L(x, \lambda)$  for DP para todo o  $d \neq 0$  tal que  $A(x)d = 0$  — ver final do capítulo anterior...
- 2 Sob estas condições em  $(x_*, \lambda_*)$ , o método de Newton apresenta uma taxa de convergência local quadrática.

Existe uma forma alternativa de se chegar ao mesmo sistema linear. Essa forma consiste em considerar o seguinte problema quadrático (PQ)

$$\begin{aligned} \min_p \quad & f(x_k) + \nabla f(x_k)^\top p + \frac{1}{2} p^\top \nabla_{xx}^2 L(x_k, \lambda_k) p \\ \text{sujeito a} \quad & A(x_k) p + c(x_k) = 0 \end{aligned}$$

ou seja, tomando um modelo quadrático de  $f$  (com a curvatura dada pelo Lagrangeano) e linearizando as restrições.

De facto sob as hipóteses da nota 1, o PQ anterior tem solução única  $(x_k, l_k)$  tal que

$$\begin{aligned} \nabla_{xx}^2 L(x_k, \lambda_k) p_k + \nabla f(x_k) - A(x_k)^\top l_k &= 0 \\ A(x_k) p_k + c(x_k) &= 0 \end{aligned}$$

Desta forma,  $(p_k, \lambda_{k+1})$ , em que  $\lambda_{k+1} = l_k$ , satisfaz

$$\begin{bmatrix} \nabla_{xx}^2 L(x_k, \lambda_k) & -A(x_k)^\top \\ A(x_k) & 0 \end{bmatrix} \begin{bmatrix} p_k \\ \lambda_{k+1} \end{bmatrix} = \begin{bmatrix} -\nabla f(x_k) \\ -c(x_k) \end{bmatrix}$$

e tem-se que  $\lambda_{k+1}$  é, de facto, igual a  $\lambda_k + \Delta\lambda_k$ .

Ambas as abordagens são úteis:

- a abordagem pela programação sequencial quadrática (SQP) permite algoritmos práticos neste e noutros cenários,
- Newton facilita a análise local.

## Algoritmo (Método SQP (local))

### Inicialização

Sejam  $(x_0, \lambda_0)$ .

Para  $k = 0, 1, 2, \dots$

- 1 Calcular os valores de  $f(x_k)$ ,  $\nabla f(x_k)$ ,  $\nabla_{xx}^2 L(x_k, \lambda_k)$ ,  $c(x_k)$  e  $A(x_k)$ .
- 2 Resolver o PQ para obter  $p_k$  e  $l_k$ .
- 3 Fazer  $x_{k+1} = x_k + p_k$  e  $\lambda_{k+1} = l_k$ .

## Notas:

- 3 Observe-se que

$$\begin{aligned} & L(x_k, \lambda_k) + \nabla_x L(x_k, \lambda_k)^\top p \\ = & f(x_k) - \lambda_k^\top c(x_k) + \nabla f(x_k)^\top p - \underbrace{\left( A(x_k)^\top \lambda_k \right)^\top p}_{= -\lambda_k^\top c(x_k) \text{ (se } A(x_k)p_k = -c(x_k))} \\ = & f(x_k) + \nabla f(x_k)^\top p \end{aligned}$$

e, assim sendo, a função objectivo do PQ poderia ter sido escrita como um modelo quadrático do Lagrangeano.

Consideremos, agora, o caso em que temos restrições de desigualdade

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \\ & c_i(x) \geq 0, \quad i \in \mathcal{I} \end{array} \quad \text{PNL}$$

Linearizando as restrições, o PQ tem a forma

$$\begin{array}{ll} \min_p & f(x_k) + \nabla f(x_k)^\top p + \frac{1}{2} p^\top \nabla_{xx}^2 L(x_k, \lambda_k) p \\ \text{sujeito a} & \nabla c_i(x_k)^\top p + c_i(x_k) = 0, \quad i \in \mathcal{E} \\ & \nabla c_i(x_k)^\top p + c_i(x_k) \geq 0, \quad i \in \mathcal{I} \end{array} \quad \text{IPQ}$$

A versão local do método SQP seria fácil de esquematizar.

As restrições activas do IPQ podem constituir uma aproximação das restrições activas do PNL.

O resultado seguinte valida localmente esta aproximação.

### Teorema

*Seja  $(x_*, \lambda_*)$  a satisfazer LICQ, CS2O e complementaridade estrita.*

*Então,*

*se  $(x_k, \lambda_k)$  estiver suf. próximo de  $(x_*, \lambda_*)$ ,*

*há uma solução local do IPQ cujo conjunto das restrições activas  $\mathcal{A}(x_k)$  coincide com  $\mathcal{A}(x_*)$ .*

↓  
PNL

↓  
IPQ

Desta forma, o método SQP baseado em IPQ pode ser visto, localmente e a partir de uma certa ordem, como um método de Newton aplicado a

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \\ & c_i(x) = 0, \quad i \in \mathcal{I} \cap \mathcal{A}(x_*) \end{array}$$

As estratégias de procura unidireccional e regiões de confiança podem ser utilizadas para globalizar os métodos SQP.

Porém, coloca-se a questão de como avaliar o passo nas CW (no caso da procura unidireccional) e decréscimos previstos e actuais (no caso das regiões de confiança).

Surgem, assim, as **funções mérito**.

A título ilustrativo, reformula-se primeiro o PNL do seguinte modo:

- substituindo  $c_{\mathcal{I}}(x) \geq 0$  por  $c_{\mathcal{I}}(x) - s = 0$ ,  $s \geq 0$ ,
- fazendo  $c(x, s) = \begin{bmatrix} c_{\mathcal{E}}(x) \\ c_{\mathcal{I}}(x) - s \end{bmatrix}$ ,
- definindo  $x = \begin{bmatrix} x \\ s \end{bmatrix}$ .

Chega-se, assim, a

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \text{ novo} \\ & x \geq 0 \end{array}$$

PNL2

Considera-se, então, a função mérito  $\ell_1$

$$\phi_1(x; \mu) = f(x) + \mu \|c(x)\|_1$$

(ignorando as restrições  $x \geq 0$ ).

A CDS, por exemplo, assumiria a forma

$$\phi_1(x_k + \alpha_k p_k; \mu_k) \leq \phi_1(x_k; \mu_k) + \eta \alpha_k D(\phi_1(x_k; \mu_k); p_k), \quad \eta \in (0, 1)$$

onde  $D(\phi_1(x_k; \mu_k); p_k)$  é a derivada direccional de  $\phi_1$  em  $x_k$  ao longo de  $p_k$ .

Quando é que esta derivada é **negativa**?

## Teorema

Seja  $(p_k, \lambda_{k+1})$  o passo de SQP (PQ e não IPQ).

Então a derivada direccional de  $\phi_1$  em  $x_k$ , ao longo de  $p_k$ , satisfaz

$$D(\phi_1(x_k; \mu_k); p_k) = \nabla f(x_k)^\top p_k - \mu_k \|c(x_k)\|_1$$

e

$$D(\phi_1(x_k; \mu_k); p_k) \leq -p_k^\top \nabla_{xx}^2 L(x_k, \lambda_k) p_k - (\mu_k - \|\lambda_{k+1}\|_\infty) \|c(x_k)\|_1$$

Logo, se  $p_k \neq 0$  e  $\nabla_{xx}^2 L(x_k, \lambda_k)$  for DP,  $p_k$  é direcção de descida para  $\phi_1$  se  $\mu_k > \|\lambda_{k+1}\|_\infty$ .

(Bastaria, aliás, que a Hessiana reduzida  $Z_k^\top \nabla_{xx}^2 L(x_k, \lambda_k) Z_k$  fosse DP.)

- 1 Métodos numéricos para optimização não linear sem restrições
  - Métodos de procura directa
  - Métodos de procura unidireccional (geral)
  - Métodos de procura unidireccional (descida máxima, Newton)
  - Métodos de região de confiança
- 2 Teoria da optimização não linear com restrições
  - Introdução e qualificações de restrições
  - Condições de primeira ordem
  - Condições de segunda ordem
  - Teoria da dualidade
- 3 Métodos numéricos para optimização não linear com restrições
  - Método da penalização quadrática
  - Método do Lagrangeano aumentado
  - Programação Sequencial Quadrática (SQP)
  - Métodos de pontos interiores

Os métodos de pontos interiores podem ser vistos como métodos de continuação ou de homotopia.

Consideremos o problema

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0 \quad i \in \mathcal{E} \text{ novo} \\ & x \geq 0 \end{array}$$

PNL2

Sendo  $e = (1, \dots, 1)^\top$  e  $\mathcal{X} = \text{diag}(x)$ , as CN1O-KKT do PNL2 são dadas por

$$\left. \begin{aligned} \nabla f(x) - A(x)^\top y - z &= 0 \\ \mathcal{X}z &= \mu e \\ c(x) &= 0 \end{aligned} \right\} (1)$$

com  $x \geq 0$  e  $z \geq 0$ , quando  $\mu = 0$ .

Este tipo de método consiste em resolver o sistema de equações não lineares (1), por uma sucessão  $\{\mu_k\}$  a convergir para zero, mantendo  $x, z > 0$ .

Tal estratégia encontra-se, localmente, bem justificada pelo teorema seguinte.

## Teorema

*Seja  $(x_*, \lambda_*, z_*)$  uma solução do PNL2 que satisfaz LICQ, CS2O e complementaridade estrita.*

*Então,*

*para  $\mu$  suf. pequeno, o sistema (1) tem solução única  $(x(\mu), y(\mu), z(\mu))$   
perto de  $(x_*, y_*, z_*)$*

e

$$\lim_{\mu \rightarrow 0} (x(\mu), y(\mu), z(\mu)) = (x_*, y_*, z_*)$$

A trajetória descrita por estes pontos chama-se **caminho central primal-dual**.

Tem existência apenas **local em PNL** mas existe **globalmente em PL**.

Uma outra forma de desenvolver métodos de pontos interiores para PNL, consiste em considerar o **problema de barreira** (primal-dual)

$$\begin{aligned} \min \quad & f(x) - \mu \sum_{i=1}^n \log(x_i) \\ \text{sujeito a} \quad & c(x) = 0 \end{aligned}$$

com  $\mu > 0$ .

O método de barreira consiste em resolver, aproximadamente, uma sucessão de problemas de barreira para  $\{\mu_k\}$  em que  $\mu_k \rightarrow 0$ , mantendo  $x$  positivo.

## Exercícios:

- Escreva as CN1O para o problema de barreira e mostre que são equivalentes a (1), supondo  $\mu > 0$  e  $x > 0$ .
- Prove que o caminho central primal dual existe apenas localmente em PNL, mas existe globalmente em PL.

Existe, também, o **método de barreira primal**, baseado na formulação

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f(x) \\ \text{sujeito a} & c_i(x) = 0, \quad i \in \mathcal{E} \\ & c_i(x) \geq 0, \quad i \in \mathcal{I} \end{array}$$

PNL

Neste caso, considera-se o problema de barreira

$$\min_{x \in \mathbb{R}^n} f(x) - \mu \sum_{i \in \mathcal{I}} \log(c_i(x)) \quad (\mathcal{E} = \emptyset)$$

Uma das dificuldades desta abordagem é encontrar um ponto inicial estritamente admissível ( $c_{\mathcal{I}} > 0$ ).