

- 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 o problema ou programa de Optimização Não Linear

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

onde $f(x)$ é a **função objectivo**, $c_i(x) = 0, i \in \mathcal{E}$, as **restrições de igualdade** e $c_i(x) \geq 0, i \in \mathcal{I}$, as **restrições de desigualdade**.

A **região admissível** Ω é definida pelo conjunto de pontos que satisfazem todas as restrições

$$\Omega = \{x \in \mathbb{R}^n : c_i(x) = 0, i \in \mathcal{E} \quad c_i(x) \geq 0, i \in \mathcal{I}\}$$

Definição

Seja $x \in \Omega$.

Uma restrição $i \in \mathcal{I}$ diz-se activa em x se $c_i(x) = 0$.

O conjunto das restrições activas $\mathcal{A}(x)$ é constituído pelos índices de \mathcal{E} e pelos índices de \mathcal{I} das restrições activas em x , ou seja,

$$\mathcal{A}(x) = \mathcal{E} \cup \{i \in \mathcal{I} : c_i(x) = 0\}$$

Nota:

- Apenas as restrições activas são consideradas na caracterização da optimalidade local.

Exemplo:


$$\begin{array}{ll} \min_{x \in \mathbb{R}^2} & x_1 + x_2 \\ \text{sujeito a} & \ln(x_1) - x_2 \geq 0 \\ & x_2 \geq 0 \end{array}$$

De acordo com a notação anterior, temos

$$c_1(x) = \ln(x_1) - x_2 \quad \text{e} \quad c_2(x) = x_2$$

Assim,

$$\nabla c_1(x) = \begin{bmatrix} 1/x_1 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$



$$x_* = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

$$\mathcal{A}(x_*) = \{1, 2\}$$

Definição

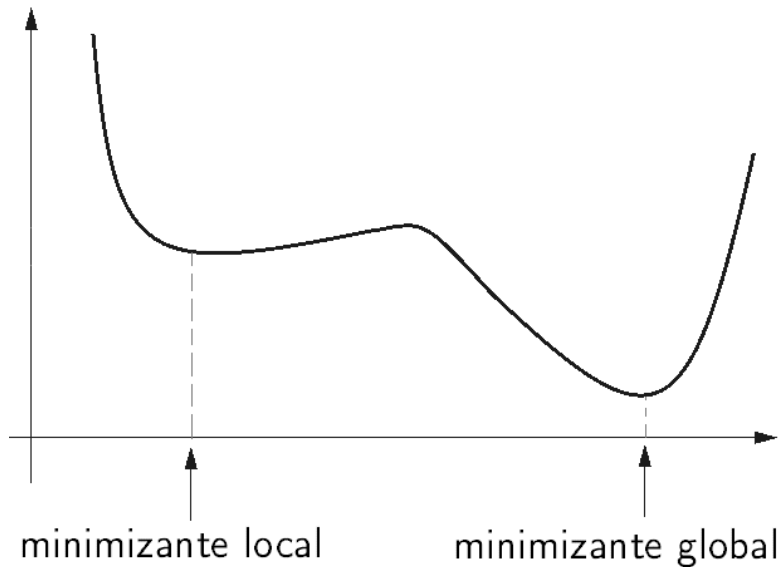
x_* diz-se um *minimizante local (estrito)* de f em Ω se existir uma vizinhança N de x_* tal que

$$f(x_*) \leq (<) f(x) \quad \forall x \in (N \cap \Omega) \setminus \{x_*\}$$

Definição

x_* diz-se um *minimizante global (estrito)* de f em Ω se

$$f(x_*) \leq (<) f(x) \quad \forall x \in \Omega \setminus \{x_*\}$$



Definição

Seja $x_* \in \Omega$. Diz-se que $\{z_k\}$ é uma sucessão admissível a aproximar-se de x_* se

$$z_k \longrightarrow x_* \quad \text{e} \quad z_k \in \Omega \quad \text{para } k \text{ suf. grande.}$$

Definição

Seja $x_* \in \Omega$. Um vector $d \in \Omega$ diz-se tangente a Ω em x_* se existir uma sucessão admissível $\{z_k\}$ a aproximar-se de x_* e uma sucessão $\{t_k\}$ em que $t_k > 0$ e $t_k \downarrow 0$ tais que

$$\lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k} = d$$


Definição

Seja $x_* \in \Omega$. O **cone tangente** é o conjunto de todas as direcções tangentes a Ω em x_* , ou seja,

$$T_\Omega(x_*) = \{d \in \mathbb{R}^n : d \text{ é tangente a } \Omega \text{ em } x_*\}$$

Considerando o exemplo anterior, temos


$$\begin{aligned} \min_{x \in \mathbb{R}^2} \quad & x_1 + x_2 \\ \text{sujeito a} \quad & \ln(x_1) - x_2 \geq 0 \\ & x_2 \geq 0 \end{aligned}$$



É possível, desde logo, provar uma condição necessária para otimização local utilizando $T_{\Omega}(x_*)$.


Em particular, utilizaremos o cone normal a Ω no ponto x_* (corresponde ao polar do cone tangente)

$$N_{\Omega}(x_*) = (T_{\Omega}(x_*))^{\circ} = \{v \in \mathbb{R}^n : v^{\top} d \leq 0, \quad \forall d \in T_{\Omega}(x_*)\}$$



Considerando o exemplo anterior, temos

$$\begin{aligned} \min_{x \in \mathbb{R}^2} \quad & x_1 + x_2 \\ \text{sujeito a} \quad & \ln(x_1) - x_2 \geq 0 \\ & x_2 \geq 0 \end{aligned}$$



Teorema

Seja $x_* \in \Omega$. Seja $f \in C^1(D)$, em que $x_* \in D$ (aberto).

Se x_* for um minimizante local de f em Ω , então

$$-\nabla f(x_*) \in N_{\Omega}(x_*)$$

Demonstração: Seja $d \in T_{\Omega}(x_*)$. Por definição de $T_{\Omega}(x_*)$, existe uma sucessão admissível $\{z_k\}$ a aproximar-se de x_* e uma sucessão $\{t_k\}$ em que $t_k > 0$ e $t_k \downarrow 0$ tais que

$$\lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k} = d$$

Este limite é equivalente a

$$z_k = x_* + t_k d + o(t_k)$$

Por sua vez, aplicando uma expansão de Taylor, temos

$$f(z_k) - f(x_*) = (z_k - x_*)^\top \nabla f(x_*) + o(\|z_k - x_*\|)$$

Como

$$z_k - x_* = t_k d + o(t_k)$$

então

$$(z_k - x_*)^\top \nabla f(x_*) = t_k d^\top \nabla f(x_*) + \nabla f(x_*)^\top o(t_k) = t_k d^\top \nabla f(x_*) + o(t_k)$$

Por outro lado, observe-se que

$$\begin{aligned}\frac{o(\|z_k - x_*\|)}{t_k} &= \frac{o(\|z_k - x_*\|)}{t_k} \frac{\|z_k - x_*\|}{\|z_k - x_*\|} \\ &= \underbrace{\frac{o(\|z_k - x_*\|)}{\|z_k - x_*\|}}_{\rightarrow 0} \underbrace{\frac{\|z_k - x_*\|}{t_k}}_{\rightarrow \|d\|}\end{aligned}$$

logo,

$$o(\|z_k - x_*\|) = o(t_k)$$

Assim, temos

$$f(z_k) - f(x_*) = (z_k - x_*)^\top \nabla f(x_*) + o(\|z_k - x_*\|) = t_k d^\top \nabla f(x_*) + o(t_k)$$

Como $f(z_k) \geq f(x_*)$ para k suf. grande, temos

$$t_k d^\top \nabla f(x_*) + o(t_k) \geq 0$$

Dividindo por t_k , vem

$$0 \leq \nabla f(x_*)^\top d + \frac{o(t_k)}{t_k}$$


Finalmente, tomando limites, vem

$$-\nabla f(x_*)^\top d \leq 0$$



No âmbito do exemplo anterior, a condição necessária do teorema é ilustrada do seguinte modo

$$\begin{array}{ll} \min_{x \in \mathbb{R}^2} & x_1 + x_2 \\ \text{sujeito a} & \ln(x_1) - x_2 \geq 0 \\ & x_2 \geq 0 \end{array}$$



Exercício:

- O que acontece quando temos $\Omega = \mathbb{R}^n$?

Note-se que quer a definição (geométrica) de $T_{\Omega}(x_*)$ quer o teorema anterior são válidos para qualquer Ω .

Como representar $T_{\Omega}(x_*)$ algebricamente e mais concretamente linearmente (caso em que Ω é definido na forma PNL)?

Tal representação é possível sob uma **qualificação de restrições**.

Esta é uma condição suficiente para que uma aproximação linear de Ω em x_* descreva bem as características geométricas essenciais de Ω numa vizinhança de x_* (resumidas por $T_{\Omega}(x_*)$).

Definição

Dado um ponto $x \in \Omega$ e o conjunto das restrições activas $\mathcal{A}(x)$, temos uma qualificação de restrições LICQ se o conjunto

$$\{\nabla c_i(x), i \in \mathcal{A}(x)\}$$

for linearmente independente.

Definição

Dado um ponto $x \in \Omega$ e o conjunto das restrições activas $\mathcal{A}(x)$, o cone de primeira ordem das direcções admissíveis é definido por

$$\mathcal{F}(x) = \left\{ d \in \mathbb{R}^n : \begin{array}{l} d^\top \nabla c_i(x) = 0, \quad \forall i \in \mathcal{E} \\ d^\top \nabla c_i(x) \geq 0, \quad \forall i \in \mathcal{I} \cap \mathcal{A}(x) \end{array} \right\}$$

Sob a qualificação de restrições LICQ

$\{\nabla c_i(x_*), i \in \mathcal{A}(x_*)\}$ linearmente independente,

tem-se que o cone de primeira ordem das direcções admissíveis

$$\mathcal{F}(x_*) = \left\{ d \in \mathbb{R}^n : \begin{array}{l} d^\top \nabla c_i(x_*) = 0, \quad \forall i \in \mathcal{E} \\ d^\top \nabla c_i(x_*) \geq 0, \quad \forall i \in \mathcal{I} \cap \mathcal{A}(x_*) \end{array} \right\}$$

é igual ao cone tangente $T_\Omega(x_*)$.

Teorema

Seja $x_* \in \Omega$. Sejam $c_i \in C^1(D)$, em que $x_* \in D$ (aberto).

Então temos que:

(i)

$$T_{\Omega}(x_*) \subseteq \mathcal{F}(x_*)$$

(ii)

$$\text{(sob LICQ)} \quad \mathcal{F}(x_*) \subseteq T_{\Omega}(x_*)$$

Demonstração: (i) Seja $d \in T_{\Omega}(x_*)$. Por definição de $T_{\Omega}(x_*)$, existe uma sucessão admissível $\{z_k\}$ a aproximar-se de x_* e uma sucessão $\{t_k\}$ em que $t_k > 0$ e $t_k \downarrow 0$, tais que

$$\lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k} = d$$

Este limite é equivalente a

$$z_k = x_* + t_k d + o(t_k)$$

Consideremos primeiro o caso em que $i \in \mathcal{E}$.

$$c_i(z_k) = \underbrace{c_i(x_*)}_{=0} + \underbrace{(z_k - x_*)^\top \nabla c_i(x_*)}_{t_k d^\top \nabla c_i(x_*) + o(t_k)} + \underbrace{o(\|z_k - x_*\|)}_{o(t_k)}$$

Como, para k suf. grande $c_i(z_k) = 0$, temos

$$0 = \nabla c_i(x_*)^\top d + \frac{o(t_k)}{t_k}$$

Tomando limites, temos

$$\nabla c_i(x_*)^\top d = 0$$

O caso em que $i \in \mathcal{I}$ prova-se de modo análogo.

(ii) Seja $d \in \mathcal{F}(x_*)$. Vamos construir uma sucessão $\{z_k\}$ a convergir para x_* .

$$\text{Seja } A = A(x_*) = \left[\nabla c_i(x_*)^\top \right]_{i \in \mathcal{A}(x_*)}$$

Seja $Z \in \mathbb{R}^{n \times (n-m)}$ uma matriz cujas colunas são uma base para o espaço nulo $\mathcal{N}(A)$ de A .

$$\text{Seja } c(z) = [c_i(z)]_{i \in \mathcal{A}(x_*)}$$

Considere-se

$$\begin{bmatrix} A \\ Z^\top \end{bmatrix}_{n-m}^m \quad \text{com} \quad m = |\mathcal{A}(x_*)|$$

Faça-se

$$R(z; t) = \begin{bmatrix} c(z) - tAd \\ Z^\top(z - x_* - td) \end{bmatrix}$$

Tem-se

$$R(x_*; 0) = 0 \quad \text{e} \quad \nabla_z R(x_*; 0) = \begin{bmatrix} A \\ Z^\top \end{bmatrix} \text{ não singular por construção de } Z.$$

Aplicando-se o teorema da função implícita (TFI) com

$$\{t_k\}, \quad t_k > 0 \quad \text{e} \quad t_k \longrightarrow 0$$

garante-se a existência de uma solução z_k para $R(z; t_k) = 0$ com

$$z_k \longrightarrow x_*$$

Verifica-se facilmente que z_k é admissível.

Prova-se, ainda, que $d = \lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k}$.



Exercício:

- Termine explicitamente a demonstração de (ii) do teorema anterior, mostrando que z_k é admissível e $d = \lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k}$.

Sugestão: Para provar que


$$d = \lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k}$$

comece por multiplicar por $\begin{bmatrix} A \\ Z^\top \end{bmatrix}^{-1}$ e depois mostre que

$$\lim_{k \rightarrow +\infty} \left(\frac{z_k - x_*}{\|z_k - x_*\|} - \frac{t_k}{\|z_k - x_*\|} d \right) = 0$$

Exemplo:

$$\Omega = \{x \in \mathbb{R}^2 : x_2 \leq x_1^3, x_2 \geq 0\}$$



Temos

$$\nabla c_1(x) = \begin{bmatrix} 3x_1^2 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Seja $x_* = 0$, então

$$\nabla c_1(x_*) = \begin{bmatrix} 0 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x_*) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Assim, temos que $\mathcal{A}(x_*) = \{1, 2\}$ e a qualificação de restrições LICQ não é satisfeita.

Temos ainda,

$$\begin{aligned}\mathcal{F}(x_*) &= \left\{ d \in \mathbb{R}^2 : \begin{bmatrix} 0 \\ -1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0, \quad \begin{bmatrix} 0 \\ 1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0 \right\} \\ &= \left\{ d \in \mathbb{R}^2 : d_2 = 0 \right\}\end{aligned}$$

e, por conseguinte, $\mathcal{F}(x_*) \not\subseteq T_\Omega(x_*)$.

Uma outra qualificação de restrições importante é

$$c_i, \quad i \in \mathcal{A}(x_*) \text{ são funções afim}$$


Neste caso prova-se, também, que $\mathcal{F}(x_*) \subseteq T_\Omega(x_*)$.

É importante notar que as restrições de qualificação **não são** condições necessárias para que $\mathcal{F}(x_*) = T_\Omega(x_*)$.

Veja-se o exemplo seguinte.

Exemplo:

$$\Omega = \{x \in \mathbb{R}^2 : x_2 \leq x_1^2, x_2 \geq -x_1^2\}$$



Temos

$$\nabla c_1(x) = \begin{bmatrix} 2x_1 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x) = \begin{bmatrix} 2x_1 \\ 1 \end{bmatrix}$$

Seja $x_* = 0$, então

$$\nabla c_1(x_*) = \begin{bmatrix} 0 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x_*) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Assim,

$$\begin{aligned}\mathcal{F}(x_*) &= \left\{ d \in \mathbb{R}^2 : \begin{bmatrix} 0 \\ -1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0, \quad \begin{bmatrix} 0 \\ 1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0 \right\} \\ &= \left\{ d \in \mathbb{R}^2 : d_2 = 0 \right\}\end{aligned}$$

Logo, neste exemplo, tem-se

$$\mathcal{F}(x_*) = T_\Omega(x_*)$$

Exercício:

- Sob a qualificação de restrições

$c_i, \quad i \in \mathcal{A}(x_*)$ são funções afim,

mostre que $\mathcal{F}(x_*) \subseteq T_{\Omega}(x_*)$.

- 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

Relativamente às condições necessárias de primeira ordem (CN1O), sabemos já que

$$-\nabla f(x_*) \in (T_\Omega(x_*))^\circ \underbrace{=}_{\text{sob LICQ}} (\mathcal{F}(x_*))^\circ$$

Importa agora calcular $(\mathcal{F}(x_*))^\circ$. Tal será conseguido através do conhecido Lema de Farkas.

Lema

Seja $g \in \mathbb{R}^n$ e $K = \{By + Cw : y \geq 0\} \subseteq \mathbb{R}^n$. Então

(i) ou


$$g \in K$$

(ii) ou

$$\exists d \in \mathbb{R}^n : \quad g^\top d < 0, \quad B^\top d \geq 0, \quad C^\top d = 0$$

Notas:

- K é um cone convexo e é fechado.
- O Lema de Farkas é um teorema de alternativa.



Demonstração: Começemos por mostrar que (i) e (ii) não podem acontecer simultaneamente.

Se $g \in K$, então $\exists y \geq 0, w : g = By + Cw$.

Se $\exists d \in \mathbb{R}^n : g^\top d < 0, \quad B^\top d \geq 0, \quad C^\top d = 0$, então temos

$$0 > d^\top g = d^\top By + d^\top Cw = \underbrace{(B^\top d)^\top}_{\geq 0} \underbrace{y}_{\geq 0} + \underbrace{(C^\top d)^\top}_{=0} w \geq 0!$$

Logo (i) e (ii) não podem acontecer simultaneamente.

Suponhamos então que $g \notin K$.

Uma vez que K é fechado e convexo e a função


$$f(s) = \|s - g\|^2$$

é contínua e uniformemente convexa, o problema

$$\begin{array}{ll} \min_{s \in \mathbb{R}^n} & \|s - g\|^2 \\ \text{sujeito a} & s \in K \end{array}$$

tem solução e esta é única (\hat{s}).

Seja d como na figura



Então, temos (pela figura...)

$$d^\top g = d^\top (\hat{s} - d) = \underbrace{d^\top \hat{s}}_{=0} - \underbrace{\|d\|^2}_{<0} < 0$$

Por outro lado, temos (pela figura...)

$$d^\top s \geq 0, \forall s \in K$$

Logo,

$$0 \leq d^\top (By + Cw), \quad \forall y \geq 0, w$$

Fazendo

$$w = 0 : (B^\top d)^\top y \geq 0, \quad \forall y \geq 0 \implies B^\top d \geq 0$$

$$y = 0 : (C^\top d)^\top w \geq 0, \quad \forall w \implies C^\top d = 0$$


Falta então provar que $d^\top \hat{s} = 0$ e $d^\top s \geq 0, \forall s \in K$.

Provemos que $d^\top \hat{s} = 0$.

Como $\hat{s} \in K$ e uma vez que K é um cone, então $\alpha \hat{s} \in K \quad \forall \alpha > 0$.

A função $h(\alpha) = \|\alpha \hat{s} - g\|^2$ tem como minimizante $\alpha = 1$. Assim,

$$h'(1) = ((2\hat{s}^\top \hat{s})\alpha - 2g^\top \hat{s})|_{\alpha=1} = 0 \iff \hat{s}^\top \hat{s} - g^\top \hat{s} = 0 \iff \underbrace{(\hat{s} - g)}_d^\top \hat{s} = 0$$



Por último provemos, analiticamente, que $d^\top s \geq 0, \forall s \in K$.

Uma vez que K é convexo e $\hat{s} \in K$, então

$$\theta s + (1 - \theta)\hat{s} \in K \quad \forall \theta \in [0, 1]$$

Assim, temos

$$\|\theta s + (1 - \theta)\hat{s} - g\|^2 = \|\hat{s} + \theta(s - \hat{s}) - g\|^2 \geq \|\hat{s} - g\|^2 \quad \forall \theta \in [0, 1]$$

Fazendo as contas, vem que

$$\theta^2 \|s - \hat{s}\|^2 + 2\theta(s - \hat{s})^\top (\hat{s} - g) \geq 0 \underbrace{\implies}_{\theta \rightarrow 0^+} (s - \hat{s})^\top d \geq 0 \implies s^\top d \geq 0$$



Sabemos, então, que se x_* for um minimizante local, temos

$$-\nabla f(x_*) \in (T_{\Omega}(x_*))^{\circ} \underbrace{=}_{\text{LICQ}} (\mathcal{F}(x_*))^{\circ}$$

Desta forma

$$d^{\top} \nabla f(x_*) \geq 0, \quad \forall d \in \mathcal{F}(x_*)$$

Recorde-se que

$$\mathcal{F}(x_*) = \left\{ d \in \mathbb{R}^n : \begin{array}{l} d^{\top} \nabla c_i(x_*) = 0, \quad \forall i \in \mathcal{E} \\ d^{\top} \nabla c_i(x_*) \geq 0, \quad \forall i \in \mathcal{I} \cap \mathcal{A}(x_*) \end{array} \right\}$$

Fazendo

$$B_* = (\nabla c_i(x_*))_{i \in \mathcal{I} \cap \mathcal{A}(x_*)}$$

$$C_* = (\nabla c_i(x_*))_{i \in \mathcal{E}}$$

vem, pelo Lema de Farkas,

$$\nabla f(x_*) \in K_* = \{B_* y + C_* w : y \geq 0\}$$

Surgem, assim, desta forma as condições necessárias de primeira ordem (CN1O) para o PNL, também conhecidas por condições de Karush-Kuhn-Tucker (KKT) de primeira ordem.

Seja

$$L(x, \lambda) = f(x) - \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i c_i(x)$$

a função Lagrangeana associada ao PNL (λ é o vector dos multiplicadores de Lagrange).

Observe-se que

$$\nabla_x L(x, \lambda) = \nabla f(x) - \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i \nabla c_i(x)$$

Teorema

Seja $x_* \in \Omega$.

Sejam $f, c_i \in C^1(D)$, em que $x_* \in D$ (aberto).

Suponhamos que a qualificação de restrições LICQ é satisfeita em x_* .

Se x_* for um minimizante local, então $\exists \lambda_*$:

$$\nabla_x L(x_*, \lambda_*) = 0, \quad (\text{dualidade})$$

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

$$c_i(x_*) \geq 0, \quad \forall i \in \mathcal{I} \quad (\text{admissibilidade})$$

$$\lambda_i^* \geq 0, \quad \forall i \in \mathcal{I} \quad (\text{n\~{a}o negatividade})$$

$$\lambda_i^* c_i(x_*) = 0, \quad \forall i \in \mathcal{I} \quad (\text{complementaridade})$$

Demonstração: Vimos que

$$\exists \lambda_i^*, i \in \mathcal{A}(x_*) \quad \text{e} \quad \lambda_i^* \geq 0, i \in \mathcal{I} \cap \mathcal{A}(x_*)$$

tais que

$$\nabla f(x_*) = \sum_{i \in \mathcal{A}(x_*)} \lambda_i^* \nabla c_i(x_*)$$

Defina-se λ_* do seguinte modo

$$\lambda_i^* = \begin{cases} \lambda_i, & i \in \mathcal{A}(x_*) \\ 0, & i \notin \mathcal{A}(x_*) \end{cases}$$

Mostremos, agora, que esta escolha de λ_* satisfaz as CN10-KKT.

Temos

$$\begin{aligned}\nabla_x L(x_*, \lambda_*) &= \nabla f(x_*) - \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i^* \nabla c_i(x_*) \\ &= \underbrace{\nabla f(x_*) - \sum_{i \in \mathcal{A}(x_*)} \lambda_i^* \nabla c_i(x_*)}_{= 0} - \sum_{i \notin \mathcal{A}(x_*)} \lambda_i^* \nabla c_i(x_*)\end{aligned}$$

Tendo em conta a definição de λ_* , vem

$$\nabla_x L(x_*, \lambda_*) = 0$$

dualidade ✓

Uma vez que $x_* \in \Omega$, vem

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

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

admissibilidade ✓

Temos

$$\lambda_i^* \geq 0, i \in \mathcal{A}(x_*) \quad \text{e} \quad \lambda_i^* = 0, i \notin \mathcal{A}(x_*)$$

Logo,

$$\lambda_i^* \geq 0, i \in \mathcal{I}$$

não negatividade ✓

Temos,

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

$$\lambda_i^* = 0, \quad \forall i \notin \mathcal{A}(x_*)$$

Assim,

$$\lambda_i^* c_i(x_*) = 0, \quad i \in \mathcal{I}$$

complementaridade ✓



Exemplo:

$$\begin{aligned} & \min_{x \in \mathbb{R}^2} f(x) \\ & \text{sujeito a } \ln(x_1) - x_2 \geq 0 \\ & \quad \quad \quad x_2 \geq 0 \end{aligned}$$

Temos

$$\nabla c_1(x) = \begin{bmatrix} 1/x_1 \\ -1 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Considerando $f(x) = x_1 + \frac{x_2^2}{3} + x_2$, temos $\nabla f(1, 0) = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

Assim, temos

$$\begin{bmatrix} 1 \\ 1 \end{bmatrix} = \lambda_1^* \begin{bmatrix} 1 \\ -1 \end{bmatrix} + \lambda_2^* \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$


Logo,

$$x_* = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \text{e} \quad \lambda_* = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \quad \text{satisfaz as CN1O-KKT.}$$


Considerando $f(x) = \frac{x_2^3}{3} + x_2$, temos $\nabla f(1,0) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$

Assim,

$$\begin{bmatrix} 0 \\ 1 \end{bmatrix} = \underbrace{0}_{\lambda_1^*} \begin{bmatrix} 1 \\ -1 \end{bmatrix} + \underbrace{1}_{\lambda_2^*} \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$




Notas:



- Sob LICQ, λ^* é único.

- Quando $\lambda_i^* > 0$, $\forall i \in \mathcal{I} \cap \mathcal{A}(x_*)$ tem-se complementaridade estrita. Nesse caso (e quando $\mathcal{E} = \emptyset$), $-\nabla f(x_*)$ está no *interior relativo* do cone normal $N_\Omega(x_*)$:



- Uma outra qualificação de restrições, muito conhecida, é a MFCQ (Mangasarian-Fromovitz)

$$\exists w \in \mathbb{R}^n : \begin{cases} \nabla c_i(x_*)^\top w > 0, & i \in \mathcal{A}(x_*) \cap \mathcal{I} \\ \nabla c_i(x_*)^\top w = 0, & i \in \mathcal{E} \end{cases}$$

e $\{\nabla c_i(x_*), i \in \mathcal{E}\}$ é linearmente independente.

Pode-se provar que MFCQ é equivalente a

$$\{\lambda_* : \lambda_* \text{ satisfaz as CN1O}\} \text{ é limitado.}$$

É óbvio, então, que LICQ \implies MFCQ.

- 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

Relativamente às condições necessárias de segunda ordem (CN2O), interessa-nos essencialmente estudar a curvatura da função Lagrangeana ao longo das direcções de indecisão, isto é, ao longo das direcções

$$v \in \mathcal{F}(x_*) \quad \text{para as quais} \quad \nabla f(x_*)^\top v = 0$$

Como

$$\nabla f(x_*)^\top v \stackrel{\text{CN1O}}{=} \sum_{i \in \mathcal{A}(x_*)} \lambda_i^* \nabla c_i(x_*)^\top v$$

há que considerar $\nabla c_i(x_*)^\top v = 0$, quando $i \in \mathcal{A}(x_*) \cap \mathcal{I}$ e $\lambda_i^* > 0$.

Definição

Considere-se

$$\mathcal{F}(x_*) = \left\{ d \in \mathbb{R}^n : \begin{array}{l} d^\top \nabla c_i(x_*) = 0, \quad \forall i \in \mathcal{E} \\ d^\top \nabla c_i(x_*) \geq 0, \quad \forall i \in \mathcal{I} \cap \mathcal{A}(x_*) \end{array} \right\}$$

Seja λ_* um vector de multiplicadores de Lagrange a satisfazer as KKT-CN1O.

O cone de criticalidade (de segunda ordem) é definido por

$$\mathcal{C}(x_*, \lambda_*) = \{v \in \mathcal{F}(x_*) : \nabla c_i(x_*)^\top v = 0, \forall i \in \mathcal{A}(x_*) \cap \mathcal{I} \text{ com } \lambda_i^* > 0\}$$

Teorema

Seja $x_* \in \Omega$ um minimizante local, em que a qualificação de restrições LICQ é satisfeita.

Sejam $f, c_i \in C^2(D)$, em que $x_* \in D$ (aberto).

Seja λ_* o vector dos multiplicadores de Lagrange a satisfazer as KKT-CN10.

Então

$$v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v \geq 0, \quad \forall v \in \mathcal{C}(x_*, \lambda_*)$$

Demonstração: Seja $v \in \mathcal{C}(x_*, \lambda_*) \subseteq \mathcal{F}(x_*) \underbrace{=}_{\text{LICQ}} T_{\Omega}(x_*)$

Por definição de $T_{\Omega}(x_*)$, existe uma sucessão admissível $\{z_k\}$ a aproximar-se de x_* e uma sucessão $\{t_k\}$ em que $t_k > 0$ e $t_k \downarrow 0$, tais que

$$\lim_{k \rightarrow +\infty} \frac{z_k - x_*}{t_k} = v$$

Este limite é equivalente a

$$z_k = x_* + t_k v + o(t_k)$$

Através de um raciocínio, utilizado anteriormente, sabemos que é possível escolher $\{t_k\}$ e $\{z_k\}$ tais que

$$c_i(z_k) = t_k \nabla c_i(x_*)^\top v, \quad \forall i \in \mathcal{A}(x_*)$$

Assim e tendo em conta a definição de função Lagrangeana, temos

$$\begin{aligned} L(z_k, \lambda_*) &= f(z_k) - \sum_{i \in \mathcal{A}(x_*)} \lambda_i^* c_i(z_k) \\ &= f(z_k) - t_k \underbrace{\sum_{i \in \mathcal{A}(x_*)} \lambda_i^* \nabla c_i(x_*)^\top v}_{= 0 \text{ (pois } v \in \mathcal{C}(x_*, \lambda_*)})} \\ &= f(z_k) \end{aligned}$$

Por outro lado, aplicando uma expansão de Taylor, temos

$$\begin{aligned}L(z_k, \lambda_*) &= L(x_*, \lambda_*) + (z_k - x_*)^\top \nabla_x L(x_*, \lambda_*) \\ &\quad + \frac{1}{2}(z_k - x_*)^\top \nabla_{xx}^2 L(x_*, \lambda_*)(z_k - x_*) + o(\|z_k - x_*\|^2)\end{aligned}$$

Pela complementaridade, temos

$$L(x_*, \lambda_*) = f(x_*) - \underbrace{\sum_{i \in \mathcal{A}(x_*)} \lambda_i^* c_i(x_*)}_{=0} = f(x_*)$$

Pela dualidade, temos

$$(z_k - x_*)^\top \nabla_x L(x_*, \lambda_*) = 0$$

Assim, temos

$$\begin{aligned} \underbrace{L(z_k, \lambda_*)}_{= f(z_k)} &= \underbrace{L(x_*, \lambda_*)}_{= f(x_*)} + \underbrace{(z_k - x_*)^\top \nabla_x L(x_*, \lambda_*)}_{= 0} \\ &+ \frac{1}{2} (z_k - x_*)^\top \nabla_{xx}^2 L(x_*, \lambda_*) (z_k - x_*) + o(\|z_k - x_*\|^2) \end{aligned}$$

Consequentemente,

$$f(z_k) = f(x_*) + \frac{1}{2} (z_k - x_*)^\top \nabla_{xx}^2 L(x_*, \lambda_*) (z_k - x_*) + o(\|z_k - x_*\|^2)$$

Uma vez que

$$z_k - x_* = t_k v + o(t_k)$$

vem

$$\begin{aligned} & (z_k - x_*)^\top \nabla_{xx}^2 L(x_*, \lambda_*) (z_k - x_*) + o(\|z_k - x_*\|^2) \\ &= t_k^2 v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v + 2v^\top \nabla_{xx}^2 L(x_*, \lambda_*) \underbrace{t_k o(t_k)}_{o(t_k^2)} + o(t_k^2) + o(t_k^2) \\ &= t_k^2 v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v + o(t_k^2) \end{aligned}$$

Assim

$$f(z_k) = f(x_*) + \frac{1}{2}t_k^2 v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v + o(t_k^2)$$

Uma vez que $f(z_k) \geq f(x_*)$ para k suficientemente grande, então

$$\frac{1}{2}t_k^2 v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v + o(t_k^2) \geq 0$$


Finalmente, dividindo por t_k^2 e tomando limites, vem

$$\frac{1}{2}v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v \geq 0 \iff v^\top \nabla_{xx}^2 L(x_*, \lambda_*) v \geq 0$$



Exemplo:

$$\begin{aligned} \min_{x \in \mathbb{R}^2} \quad & -0.1(x_1 - 4)^2 + x_2^2 \\ \text{sujeito a} \quad & x_1^2 + x_2^2 - 1 \geq 0 \\ & x_2 \geq 0 \end{aligned}$$



Temos $\mathcal{E} = \emptyset$ e $\mathcal{I} = \{1, 2\} = \mathcal{A}(x_*)$.

$$\nabla f(x) = \begin{bmatrix} -0.2(x_1 - 4) \\ 2x_2 \end{bmatrix}, \quad \nabla c_1(x) = \begin{bmatrix} 2x_1 \\ 2x_2 \end{bmatrix} \quad \text{e} \quad \nabla c_2(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}.$$

$$\nabla_x L(x_*, \lambda_*) = 0 \quad \iff \quad \begin{bmatrix} 0.6 \\ 0 \end{bmatrix} - \underbrace{\lambda_1^*}_{=0.3} \begin{bmatrix} 2 \\ 0 \end{bmatrix} - \underbrace{\lambda_2^*}_{=0} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = 0$$

Qualificação de restrições LICQ ✓

Dualidade ✓

Complementaridade ✓

Admissibilidade ✓

Não negatividade ✓

CN10 ✓

$$\begin{aligned}\mathcal{F}(x_*) &= \left\{ d \in \mathbb{R}^2 : \begin{bmatrix} 2 \\ 0 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0, \begin{bmatrix} 0 \\ 1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0 \right\} \\ &= \left\{ d \in \mathbb{R}^2 : d_1 \geq 0, d_2 \geq 0 \right\}\end{aligned}$$

$$\nabla_{xx}^2 L(x_*, \lambda_*) = \begin{bmatrix} -0.2 & 0 \\ 0 & 2 \end{bmatrix} - 0.3 \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} = \begin{bmatrix} -0.8 & 0 \\ 0 & 1.4 \end{bmatrix}$$

$$\begin{aligned}
\mathcal{C}(x_*, \lambda_*) &= \left\{ d \in \mathbb{R}^2 : \begin{bmatrix} 2 \\ 0 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} = 0, \begin{bmatrix} 0 \\ 1 \end{bmatrix}^\top \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \geq 0 \right\} \\
&= \left\{ d \in \mathbb{R}^2 : d_1 = 0, d_2 \geq 0 \right\}
\end{aligned}$$

Assim, temos

$$d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d = 1.4d_2^2 \geq 0, \forall d \in \mathcal{C}(x_*, \lambda_*)$$

CN2O ✓

As condições suficientes de segunda ordem (CS2O) baseiam-se, também, no cone $\mathcal{C}(x_*, \lambda_*)$.

Teorema

Seja $x_* \in \Omega$.

Sejam $f, c_i \in C^2(D)$, em que $x_* \in D$ (aberto).

Se, para todo o λ_* vector de multiplicadores de Lagrange a satisfazer as KKT-CN1O,

$$w^\top \nabla_{xx}^2 L(x_*, \lambda_*) w > 0 \quad \forall w \in \mathcal{C}(x_*, \lambda_*), w \neq 0$$

então

x_* é um minimizante local estrito.

Demonstração: Vamos provar que $f(z_k) > f(x_*)$ para toda a sucessão admissível $\{z_k\}$ a aproximar-se de x_* .

Se considerarmos todas as sucessões K para as quais

$$\lim_{\substack{k \rightarrow +\infty \\ k \in K}} \frac{z_k - x_*}{\|z_k - x_*\|} = d$$

cobrimos toda a sucessão $\{z_k\}$.

No caso em que $d \in \mathcal{C}(x_*, \lambda_*)$

(note que $d \in T_\Omega(x_*) \subseteq \mathcal{F}(x_*)$ e não é preciso qualificação de restrições),
utilizando a condição suficiente e a demonstração do último teorema, temos

$$\begin{aligned} f(z_k) \geq L(z_k, \lambda_*) &= L(x_*, \lambda_*) + \frac{1}{2}(z_k - x_*)^\top \nabla_{xx}^2 L(x_*, \lambda_*)(z_k - x_*) \\ &\quad + o(\|z_k - x_*\|^2) \\ &= f(x_*) + \frac{1}{2}\|z_k - x_*\|^2 \underbrace{d^\top \nabla_{xx}^2 L(x_*, \lambda_*)d}_{> 0} \\ &\quad + o(\|z_k - x_*\|^2) \end{aligned}$$

Vejamos que

$$\frac{1}{2} \|z_k - x_*\|^2 d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d + o(\|z_k - x_*\|^2) > 0$$

Sabemos que $\forall \varepsilon > 0$,

$$\left| \frac{o(\|z_k - x_*\|^2)}{\|z_k - x_*\|^2} \right| \leq \varepsilon \quad \text{para } k \text{ suf. grande}$$

Assim

$$-\varepsilon \|z_k - x_*\|^2 \leq o(\|z_k - x_*\|^2) \leq \varepsilon \|z_k - x_*\|^2$$

Fazendo $\varepsilon = \frac{1}{4}d^\top \nabla_{xx}^2 L(x_*, \lambda_*)d$, vem

$$\begin{aligned} -\frac{1}{4}d^\top \nabla_{xx}^2 L(x_*, \lambda_*)d \|z_k - x_*\|^2 &\leq o(\|z_k - x_*\|^2) \\ &\leq \frac{1}{4}d^\top \nabla_{xx}^2 L(x_*, \lambda_*)d \|z_k - x_*\|^2 \end{aligned}$$

Temos, então, o limite inferior

$$o(\|z_k - x_*\|^2) \geq -\frac{1}{4}d^\top \nabla_{xx}^2 L(x_*, \lambda_*)d \|z_k - x_*\|^2$$

Desta forma,

$$\frac{1}{2} \|z_k - x_*\|^2 d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d + o(\|z_k - x_*\|^2) >$$

$$\frac{1}{2} \|z_k - x_*\|^2 d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d - \frac{1}{4} \|z_k - x_*\|^2 d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d > 0$$

Assim, $f(z_k) > f(x_*)$ para k suficientemente grande.

No caso em $d \notin \mathcal{C}(x_*, \lambda_*)$ não pode ser aplicada a condição suficiente.

Porém, neste caso, sabemos que

$$\exists j \in \mathcal{A}(x_*) \cap \mathcal{I} : \quad \lambda_j^* > 0, \quad \nabla c_j(x_*)^\top d > 0$$

Para além disso,

$$\begin{aligned} L(z_k, \lambda_*) &= f(z_k) - \sum_{i \in \mathcal{A}(x_*)} \lambda_i^* c_i(z_k) \\ &\leq f(z_k) - \lambda_j^* c_j(z_k) \\ &= f(z_k) - \lambda_j^* \left(\overbrace{c_j(x_*)}^{=0} + \underbrace{(z_k - x_*)^\top \nabla c_j(x_*) + o(\|z_k - x_*\|)}_{\|z_k - x_*\| \underbrace{d^\top \nabla c_j(x_*)}_{>0} + o(\|z_k - x_*\|)} \right) \end{aligned}$$

Logo, usando $L(z_k, \lambda_*) = f(x_*) + o(\|z_k - x_*\|)$ (porquê?),

$$f(z_k) \geq f(x_*) + \|z_k - x_*\| \lambda_j^* d^\top \nabla c_j(x_*) + o(\|z_k - x_*\|)$$

Pelo mesmo raciocínio utilizado anteriormente, sabemos que

$$\|z_k - x_*\| \lambda_j^* d^\top \nabla c_j(x_*) + o(\|z_k - x_*\|) > 0$$

e, assim sendo, $f(z_k) > f(x_*)$ para k suficientemente grande.




Notas:

- As CS2O não necessitam de uma qualificação de restrições.
- Acha que a demonstração do último teorema é válida em espaços de dimensão infinita (espaços de Hilbert)? Ou seja, é utilizado, mesmo que implicitamente, algum argumento de compacidade na esfera unitária?

Exemplo:

Retomando o exemplo anterior,

$$\begin{array}{ll} \min_{x \in \mathbb{R}^2} & -0.1(x_1 - 4)^2 + x_2^2 \\ \text{sujeito a} & x_1^2 + x_2^2 - 1 \geq 0 \\ & x_2 \geq 0 \end{array}$$



$$d^\top \nabla_{xx}^2 L(x_*, \lambda_*) d = 1.4d_2^2 > 0, \quad \forall d \in \mathcal{C}(x_*, \lambda_*), d \neq 0$$

Logo x_* é um minimizante local estrito.

Note-se que não há um minimizante global, pois

$$\lim_{\substack{x \in \Omega \\ x_1 \rightarrow +\infty \\ x_2 = 0}} f(x) = -\infty$$

As condições de segunda ordem podem ser apresentadas de uma outra forma, mais fraca mas mais simples de verificar.

Sob complementaridade estrita, temos que

$$\begin{aligned}\mathcal{C}(x_*, \lambda_*) &= \{w \in \mathbb{R}^n : \nabla c_i(x_*)^\top w = 0, i \in \mathcal{A}(x_*)\} \\ &= \mathcal{N}(A(x_*)), \quad \text{em que } A(x_*) = [\nabla c_i(x_*)^\top]_{i \in \mathcal{A}(x_*)}\end{aligned}$$

ou, de modo equivalente,

$$\mathcal{C}(x_*, \lambda_*) = \{Zu : u \in \mathbb{R}^{|\mathcal{A}(x_*)|}\}$$

Deste modo, seja $w \in \mathcal{C}(x_*, \lambda_*)$ e Z uma matriz cujas colunas são uma base para $\mathcal{N}(A(x_*)) = \mathcal{C}(x_*, \lambda_*)$.

Então temos

$$w^\top \nabla_{xx}^2 L(x_*, \lambda_*) w = u^\top (Z^\top \nabla_{xx}^2 L(x_*, \lambda_*) Z) u$$

onde $Z^\top \nabla_{xx}^2 L(x_*, \lambda_*) Z$ é Hessiana projectada (ou reduzida) do Lagrangeano.

Assim, as CN2O podem ser apresentadas como no seguinte teorema.

Teorema

Seja $x_ \in \Omega$ um minimizante local, em que a qualificação de restrições LICQ é satisfeita.*

Sejam $f, c_i \in C^2(D)$, em que $x_ \in D$ (aberto).*

Seja λ_ o vector dos multiplicadores de Lagrange a satisfazer as KKT-CN1O (com complementaridade estrita).*

Seja Z uma matriz cujas colunas são uma base para $\mathcal{N}(A(x_))$.*

Então

$$Z^T \nabla_{xx}^2 L(x_*, \lambda_*) Z \text{ é PSD}$$

Por sua vez, as **CS2O** podem ser apresentadas como no seguinte teorema.

Teorema

Seja $x_ \in \Omega$*

Sejam $f, c_i \in C^2(D)$, em que $x_ \in D$ (aberto).*

Seja satisfeita a complementaridade estrita para todo o vector λ_ dos multiplicadores de Lagrange a satisfazer as KKT-CN1O.*

Seja Z uma matriz cujas colunas são uma base para $\mathcal{N}(A(x_))$.*

Se, para todo o λ_ vector de multiplicadores de Lagrange a satisfazer as KKT-CN1O,*

$$Z^\top \nabla_{xx}^2 L(x_*, \lambda_*) Z \text{ é PD}$$

então

x_ é um minimizante local estrito.*

Nota:

- No caso em que é verificada a qualificação de restrições LICQ, Z pode ser calculada na forma

$$\begin{aligned} A_{(n \times m)}^\top &= Q_{(n \times n)} \begin{bmatrix} R \\ 0 \end{bmatrix}_{(n \times m)} \\ &= \begin{bmatrix} Q_{1(n \times m)} & Q_{2(n \times (n-m))} \end{bmatrix} \begin{bmatrix} R \\ 0 \end{bmatrix} \end{aligned}$$

onde R é uma matriz não singular e triangular superior e $Q_2 = Z$.

Exercício:

- Mostre que se (x_*, λ_*) satisfaz as CN10 e

$$d^\top \nabla_{xx}^2 L(z, \lambda_*) d \geq 0, \quad \forall z, d \in \mathbb{R}^n$$

então x_* é um minimizante global.

Utilizando este resultado, resolva:

-

$$\begin{aligned} & \min_{x \in \mathbb{R}^n} \|x\|_2 \\ \text{sujeito a } & Ax = b \quad \text{em que } b \in \mathbb{R}^p, A \in \mathbb{R}^{p \times n} \text{ e } \text{car}(A) = p. \end{aligned}$$

-

$$\begin{aligned} & \min_{x \in \mathbb{R}^2} 3x_1^2 + 2x_2^2 \\ \text{sujeito a } & 25 - x_1^2 - x_2 \geq 0 \\ & -27 + 9x_1 - x_2^2 \geq 0 \end{aligned}$$

- 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

Para finalizar a teoria da Optimização ou Programação Não Linear, vamos estudar a **dualidade**.

A dualidade pode ser motivada através do seguinte **jogo**:

→ O jogador 1 escolhe a estratégia $x \in X$.

→ O jogador 2 escolhe a estratégia $y \in Y$.

Ambos os jogadores actuam de forma racional mas de modo independente um do outro.

O que um perde é igual ao que o outro ganha (**jogo de soma nula**).

(Suponhamos que o primeiro perde e o segundo ganha.)

→ O jogador 1 minimiza em X o pior cenário, dado por

$$\max_{y \in Y} F(x, y) \stackrel{\text{def}}{=} F_p(x) \quad (\text{função primal})$$

→ O jogador 2 maximiza em Y o pior cenário, dado por

$$\min_{x \in X} F(x, y) \stackrel{\text{def}}{=} F_d(y) \quad (\text{função dual})$$

Surgem, assim, os problemas

$$\text{PRIMAL} \quad \min_{x \in X} F_p(x)$$

$$\text{DUAL} \quad \max_{y \in Y} F_d(y)$$

Exemplo:

$$X = Y = \{1, 2\}, \quad F(i, j) = a_{ij}, \quad \text{em que} \quad A = \begin{bmatrix} 1 & 4 \\ 2 & -3 \end{bmatrix}.$$

$$\text{PRIMAL} \quad \min_{i \in \{1, 2\}} \max_{j \in \{1, 2\}} F(i, j) = \min_{i \in \{1, 2\}} \{4, 2\} = 2 \quad (i_* = 2)$$

$$\text{DUAL} \quad \max_{j \in \{1, 2\}} \min_{i \in \{1, 2\}} F(i, j) = \max_{j \in \{1, 2\}} \{1, -3\} = 1 \quad (j_* = 1)$$

Teorema (Dualidade Fraca)

$$F_d(y) \leq F_p(x), \forall x \in X, y \in Y$$

Demonstração:

$$F_d(y) = \min_{x' \in X} F(x', y) \leq F(x, y) \leq \max_{y' \in Y} F(x, y') = F_p(x)$$



A dualidade fraca implica:

$$\max_{y \in Y} F_d(y) \leq \min_{x \in X} F_p(x)$$

Teorema (Dualidade Forte)

$$\max_{y \in Y} F_d(y) = \min_{x \in X} F_p(x)$$

se e só se

$\exists (x_*, y_*) \in X \times Y$ (*ponto de sela*) :

$$F(x_*, y) \leq F(x_*, y_*) \leq F(x, y_*), \quad \forall (x, y) \in X \times Y$$

Exemplo:


No exemplo anterior não existe ponto de sela. Porém, se considerarmos

$$X = Y = \{1, 2\}, \quad F(i, j) = a_{ij}, \quad \text{em que} \quad A = \begin{bmatrix} 1 & 4 \\ 0 & -3 \end{bmatrix}.$$

O ponto $(i_*, j_*) = (2, 1) \in X \times Y$ é **ponto de sela**.

O zero é o maior na sua linha X .

O zero é o menor na sua coluna Y .



Neste caso, como

$$F(i, j) = a_{ij}, \quad \text{em que} \quad A = \begin{bmatrix} 1 & 4 \\ 0 & -3 \end{bmatrix}.$$

vem que

$$\text{PRIMAL} \quad \min_{i \in \{1,2\}} \max_{j \in \{1,2\}} F(i, j) = \min_{i \in \{1,2\}} \{4, 0\} = 0 \quad (i_* = 2)$$

$$\text{DUAL} \quad \max_{j \in \{1,2\}} \min_{i \in \{1,2\}} F(i, j) = \max_{j \in \{1,2\}} \{0, -3\} = 0 \quad (j_* = 1)$$

Analisemos, agora, a dualidade (Lagrangeana) em Optimização Não Linear, considerando

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

onde se pressupõe que $X = \mathbb{R}^n$.

Sejam

$$F(x, y) = L(x, \lambda) = f(x) - \sum_{i \in \mathcal{I}} \lambda_i c_i(x)$$

e

$$Y = \{\lambda \in \mathbb{R}^{|\mathcal{I}|} : \lambda \geq 0\}$$

A função primal toma a forma

$$\begin{aligned} L_p(x) &= \sup_{\lambda \geq 0} L(x, \lambda) \\ &= f(x) + \sup_{\lambda \geq 0} \sum_{i \in \mathcal{I}} \overbrace{(-\lambda_i)}^{\leq 0} c_i(x) \\ &= \begin{cases} f(x) & \text{se } x \in \Omega \\ +\infty & \text{se } x \notin \Omega \end{cases} \end{aligned}$$

Logo, o problema primal

$$\min_{x \in X} L_p(x) \iff \text{PNL}$$

Analisemos, agora, o problema dual.

A função dual é

$$L_d(\lambda) = \inf_{x \in X} L(x, \lambda) = q(\lambda)$$

e o seu domínio é

$$\mathcal{D} = \{\lambda : q(\lambda) > -\infty\}$$

Teorema

q é uma função côncava e \mathcal{D} é um conjunto convexo.

Demonstração:

$$L(x, \alpha \bar{\lambda} + (1 - \alpha) \bar{\bar{\lambda}}) = \alpha L(x, \bar{\lambda}) + (1 - \alpha) L(x, \bar{\bar{\lambda}}), \quad \forall \alpha \in [0, 1]$$

Logo,

$$q(\alpha \bar{\lambda} + (1 - \alpha) \bar{\bar{\lambda}}) \geq \alpha q(\bar{\lambda}) + (1 - \alpha) q(\bar{\bar{\lambda}})$$

Suponhamos, agora, que $\bar{\lambda}, \bar{\bar{\lambda}} \in \mathcal{D}$. A desigualdade anterior implica que

$$q(\alpha \bar{\lambda} + (1 - \alpha) \bar{\bar{\lambda}}) > -\infty$$

Logo, $\alpha \bar{\lambda} + (1 - \alpha) \bar{\bar{\lambda}} \in \mathcal{D}$.



Nota:

- O problema dual

$$\max_{\lambda \geq 0} L_d(\lambda)$$

é sempre convexo.

A dualidade fraca diz-nos que

$$q(\lambda) = L_d(\lambda) \leq L_p(x), \quad \forall \lambda \geq 0, x \in X = \mathbb{R}^n$$

Mas,

$$L_p(x) = \begin{cases} f(x) & \text{se } x \in \Omega \\ +\infty & \text{se } x \notin \Omega \end{cases}$$

Logo a dualidade fraca em Optimização Não Linear é dada por

$$q(\lambda) \leq f(x), \quad \forall \lambda \geq 0, x \in \Omega$$

No caso convexo, é possível relacionar os multiplicadores de Lagrange com a solução do problema dual.

Teorema

Sejam $f, -c_i \in C^1(\mathbb{R}^n)$ funções convexas em \mathbb{R}^n .

Então qualquer $\bar{\lambda}$, com $(\bar{x}, \bar{\lambda})$ a satisfazer as CN1O, é uma solução (global!) do problema dual.

Demonstração: Observemos que

(i) $L(\cdot, \bar{\lambda})$ é convexa, porque:

- $L(\cdot, \bar{\lambda}) = f(\cdot) - \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i c_i(\cdot)$
- $\lambda_i \geq 0, i \in \mathcal{I}$
- $f(\cdot)$ e $-c_i(\cdot)$ são convexas

(ii) $L(\cdot, \bar{\lambda}) \in C^1(\mathbb{R}^n)$

Logo,

$$\forall x \in \mathbb{R}^n : L(x, \bar{\lambda}) \geq L(\bar{x}, \bar{\lambda}) + \overbrace{\nabla_x L(\bar{x}, \bar{\lambda})^\top (x - \bar{x})}^{= 0 \text{ (CN1O)}} = L(\bar{x}, \bar{\lambda})$$

Assim, temos

$$q(\bar{\lambda}) = \inf_{x \in \mathbb{R}^n} L(x, \bar{\lambda}) = L(\bar{x}, \bar{\lambda}) \overset{\text{CN1O}}{=} f(\bar{x})$$

Mas, pela dualidade fraca,

$$q(\lambda) \leq f(\bar{x}), \forall \lambda \geq 0$$

Desta forma, $\bar{\lambda}$ é uma solução de $\sup_{\lambda \geq 0} q(\lambda)$.



Vimos, nesta demonstração, que em programação convexa ocorre dualidade forte:

$$q(\bar{\lambda}) = f(\bar{x}),$$

o que, aliás, mostra que \bar{x} é solução (global, claro) do primal.

Neste caso diz-se que o *gap* dual é nulo e que $(\bar{x}, \bar{\lambda})$ é um ponto de sela para o par primal–dual (no sentido de minimizar a função primal e maximizar a função dual).

Analisemos a aplicação à **Programação Linear**.

Considere-se o **PL**

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & c^\top x \\ \text{sujeito a} & Ax \geq b \end{array}$$

A função Lagrangeana é dada por

$$L(x, \lambda) = c^\top x - \lambda^\top (Ax - b)$$

A função dual é

$$\begin{aligned}q(\lambda) = L_d(\lambda) &= \inf_{x \in \mathbb{R}^n} \{c^\top x - \lambda^\top (Ax - b)\} \\ &= \inf_{x \in \mathbb{R}^n} \{(c - A^\top \lambda)^\top x\} + b^\top \lambda \\ &= \begin{cases} b^\top \lambda & \text{se } c - A^\top \lambda = 0 \\ -\infty & \text{caso contrário} \end{cases}\end{aligned}$$

Logo, o problema dual é equivalente a

$$\begin{aligned}&\max_{\lambda} \quad b^\top \lambda \\ &\text{sujeito a} \quad A^\top \lambda = c \\ &\quad \quad \quad \lambda \geq 0\end{aligned}$$

Prova-se, recorrendo ao resultado anterior, que o dual de um programa linear, escrito na **forma standard ou padrão**

$$\begin{array}{ll} \min_x & c^\top x \\ \text{sujeito a} & Ax = b \\ & x \geq 0 \end{array} \quad (\mathbf{P})$$

é dado por

$$\begin{array}{ll} \max_\lambda & b^\top \lambda \\ \text{sujeito a} & A^\top \lambda \leq c \end{array} \quad (\mathbf{D})$$

Exercício:

- Prove que o dual de um programa linear, escrito na forma standard ou padrão

$$\begin{aligned} \min_x \quad & c^\top x \\ \text{sujeito a} \quad & Ax = b \quad (\mathbf{P}) \\ & x \geq 0 \end{aligned}$$

é dado por

$$\begin{aligned} \max_{\lambda} \quad & b^\top \lambda \\ \text{sujeito a} \quad & A^\top \lambda \leq c \quad (\mathbf{D}) \end{aligned}$$

As CN10-KKT de (P) são

$$A^T \lambda + s = c$$

$$Ax = b$$

$$x \geq 0$$

$$s \geq 0$$

$$x^T s = 0$$

Seja (x_*, λ_*, s_*) a satisfazer as CN10-KKT.

Então, para qualquer x tal que $Ax = b$, $x \geq 0$, temos

$$\begin{aligned}c^\top x &= (A^\top \lambda_* + s_*)^\top x = b^\top \lambda_* + s_*^\top x \\ &\geq b^\top \lambda_* = (Ax_*)^\top \lambda_* = x_*^\top (c - s_*) \\ &= c^\top x_*\end{aligned}$$

Logo, estas condições são também **suficientes** para a optimização (global) do primal (P).

Exercício:

- Escreva as CN1O-KKT para (D). Verifique que são também suficientes para a otimização (global) de (D).

Analisemos a aplicação à **Programação Quadrática**.

No caso da programação quadrática estamos interessados em saber qual o dual do **PQ** **estritamente convexo**

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \quad & g^\top x + \frac{1}{2} x^\top H x \\ \text{sujeito a} \quad & Ax \geq b \end{aligned}$$

em que H é uma matriz simétrica e PD. A função dual é dada por

$$\inf_{x \in \mathbb{R}^n} L(x, \lambda) = \inf_{x \in \mathbb{R}^n} \left\{ g^\top x + \frac{1}{2} x^\top H x - \lambda^\top (Ax - b) \right\}$$

Como $L(\cdot, \lambda)$ é uma quadrática estritamente convexa, o ínfimo/mínimo é atingido em

$$Hx + g - A^\top \lambda = 0 \iff x = H^{-1}(A^\top \lambda - g)$$

Assim,

$$\begin{aligned} g^\top x + \frac{1}{2} x^\top Hx - \lambda^\top (Ax - b) &= \frac{1}{2} x^\top Hx + g^\top x - \lambda^\top Ax + b^\top \lambda \\ &= \frac{1}{2} x^\top Hx + (-A^\top \lambda + g)^\top x + b^\top \lambda \\ &= \frac{1}{2} x^\top Hx + (-Hx)^\top x + b^\top \lambda \\ &= -\frac{1}{2} x^\top Hx + b^\top \lambda \end{aligned}$$

Substituindo, na última expressão, por

$$x = H^{-1}(A^T \lambda - g)$$

temos

$$q(\lambda) = L_d(\lambda) = -\frac{1}{2}(A^T \lambda - g)^T H^{-1}(A^T \lambda - g) + b^T \lambda$$

O dual também é, assim, um PQ estritamente convexo.

No caso, mais geral, em que temos (com H matriz simétrica)

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \quad & g^\top x + \frac{1}{2} x^\top H x \\ \text{sujeito a} \quad & a_i^\top x = b_i, \quad i \in \mathcal{E} \\ & a_i^\top x \geq b_i, \quad i \in \mathcal{I} \end{aligned}$$

As CN1O-KKT são dadas por

$$\begin{aligned} Hx + g - \sum_{i \in \mathcal{A}(x)} \lambda_i a_i &= 0 && \text{(dualidade)} \\ a_i^\top x &= b_i, \quad i \in \mathcal{A}(x) && \text{(admissib., complem.)} \\ a_i^\top x &> b_i, \quad i \in \mathcal{I}, i \notin \mathcal{A}(x) && \text{(admissib., complem.)} \\ \lambda_i &\geq 0, \quad i \in \mathcal{A}(x) \cap \mathcal{I} && \text{(não negatividade)} \end{aligned}$$

Teorema

Seja $x_* \in \mathbb{R}^n$ a satisfazer as CN10-KKT, com multiplicadores λ_i^* , $i \in \mathcal{A}(x_*)$. Seja H PSD.

Então x_* é um minimizante global do PQ (ou seja, estas condições são suficientes para a optimalidade global).

Demonstração: Seja x um qualquer ponto admissível. Temos que

$$f(x) = f(x_*) + \underbrace{(x - x_*)^\top (Hx_* + g)}_{?} + \underbrace{\frac{1}{2}(x - x_*)^\top H(x - x_*)}_{\geq 0}$$

Porém,

$$(x - x_*)^\top (Hx_* + g) = \sum_{i \in \mathcal{E}} \lambda_i^* \underbrace{a_i^\top (x - x_*)}_{=0} + \sum_{i \in \mathcal{A}(x_*) \cap \mathcal{I}} \overbrace{\lambda_i^*}^{\geq 0} \underbrace{a_i^\top (x - x_*)}_{\geq 0} \geq 0$$

Logo, $f(x) \geq f(x_*)$. ■

Quando $\mathcal{I} = \emptyset$, ocorre um resultado mais forte.

Consideremos, então

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & g^\top x + \frac{1}{2} x^\top H x \\ \text{sujeito a} & Ax = b \end{array}$$

As CN1O são dadas por

$$\begin{cases} Hx_* + g - A^\top \lambda_* = 0 \\ Ax_* = b \end{cases}$$

Teorema

Seja $x_* \in \mathbb{R}^n$ a satisfazer as CN1O. Seja $Z^\top H Z$ PSD, em que Z é uma matriz cujas colunas são uma base para $\mathcal{N}(A)$.

Então x_* é um minimizante global do PQ (ou seja, estas condições são suficientes para a optimalidade global).

Demonstração: Seja x tal que $Ax = b$ (admissível).

Tem-se

$$\begin{aligned} f(x) &= f(x_*) + (x - x_*)^\top (Hx_* + g) + \frac{1}{2}(x - x_*)^\top H(x - x_*) \\ &= f(x_*) + \underbrace{(x - x_*)^\top (A^\top \lambda_*)}_{=0} + \frac{1}{2} \underbrace{(Zu)^\top H(Zu)}_{\geq 0} \end{aligned}$$

Logo, $f(x) \geq f(x_*)$.



As CN1O podem ser reescritas (mudando λ_* para $-\lambda_*$), do seguinte modo

$$\begin{cases} Hx_* + g + A^\top \lambda_* = 0 \\ Ax_* = b \end{cases} \iff \begin{bmatrix} H & A^\top \\ A & 0 \end{bmatrix} \begin{bmatrix} x_* \\ \lambda_* \end{bmatrix} = - \begin{bmatrix} g \\ -b \end{bmatrix}$$

Teorema

Seja $Z^T H Z$ PD, em que Z é uma matriz cujas colunas são uma base para $\mathcal{N}(A)$.

Seja $\text{car}(A) = \text{número de linhas de } A$.

A chamada matriz KKT

$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix}$$

é não singular.

Nota:

- Nas condições do último teorema, os multiplicadores são únicos.

Exercício:

- Prove o último teorema.