


# Condições Karush-Kuhn-Tucker (KKT)

EXEMPLO:

minimizar  $f(x) = (x_1 - 2)^2 + (x_2 - 1)^2$

sujeito a  $g_1(x) = x_1 + x_2 - 2 \leq 0 \quad \checkmark$

$g_2(x) = x_1^2 - x_2 \leq 0 \quad \checkmark$




$$g_1(0,0) = -2 \leq 0.$$

$$g_2(0,2) = 0 - 2 \leq 0$$

$$\nabla f(x_1, x_2) = \begin{bmatrix} 2(x_1 - 2) \\ 2(x_2 - 1) \end{bmatrix}$$

$$\nabla f(1,1) = \begin{bmatrix} -2 \\ 0 \end{bmatrix}$$

Obs: ao tentar caminhar na direção  $-\nabla f(1,1)$  a partir de  $(1,1)$ , perdemos viabilidade.  $(1,1)$  é minimizador global deste problema

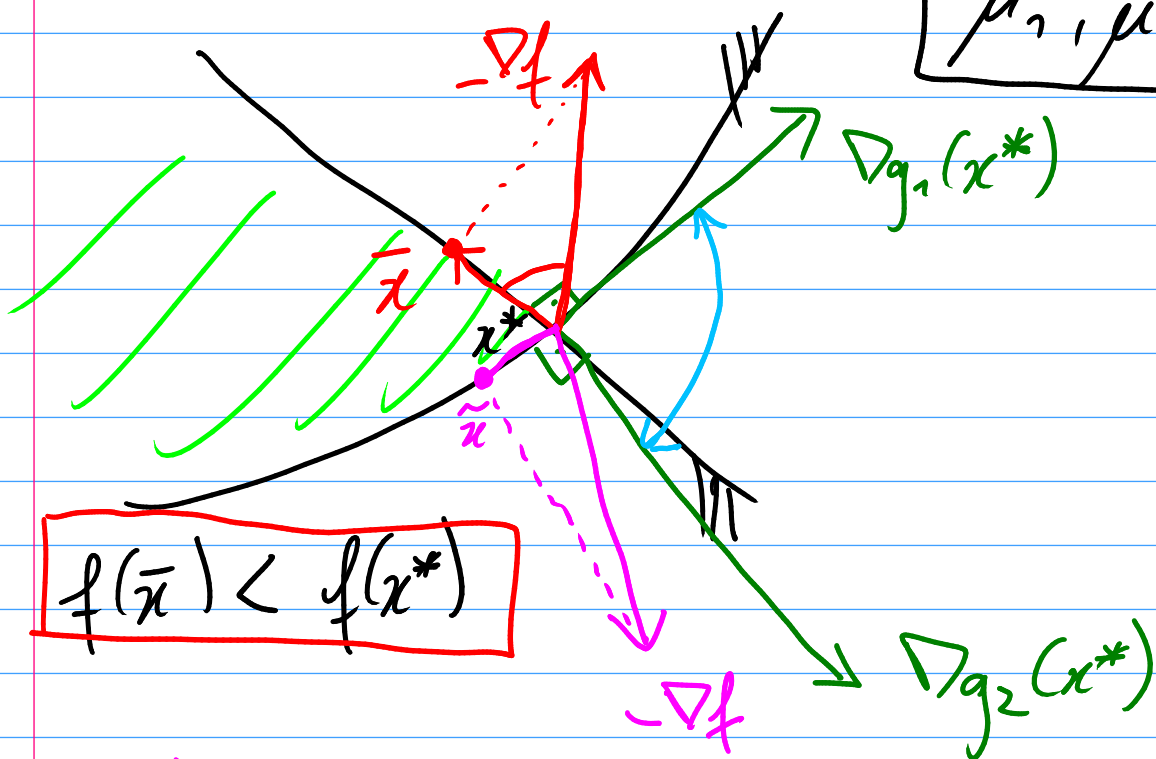


$$-\nabla f(x^*) = \mu_1 \nabla g_1(x^*) + \mu_2 \nabla g_2(x^*) \quad ,$$

$$\mu_1, \mu_2 \geq 0$$

$$(*) \quad \nabla f(x^*) + \mu_1 \nabla g_1(x^*) + \mu_2 \nabla g_2(x^*) = 0,$$

$$\mu_1, \mu_2 \geq 0$$



$$f(\bar{x}) < f(x^*)$$

$$f(\tilde{x}) < f(x^*)$$

$(\bar{x}$  e  $\tilde{x}$  são máximos  
↓

$x^*$  não é minimizador local)

Obs: se não há restrições, (\*) resume-se à

$$\nabla f(x^*) = 0$$

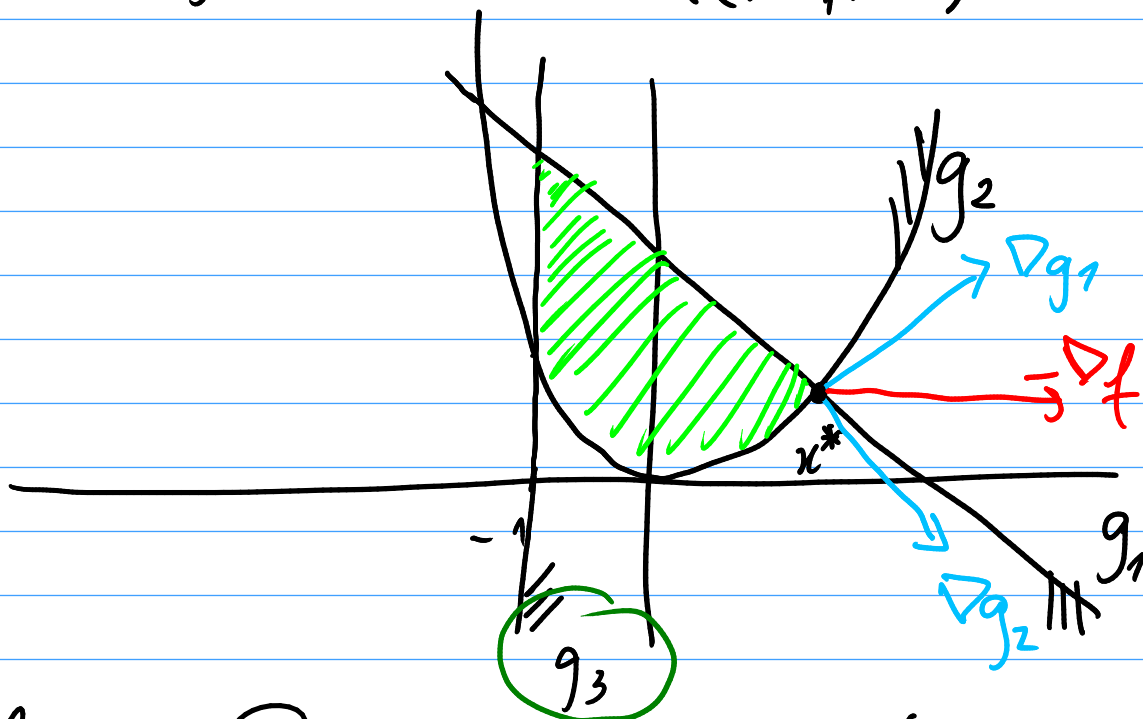
(coerente com minimização sem restrições).

minimizar  $f(x) = (x_1 - 2)^2 + (x_2 - 1)^2$

sujeito a  $g_1(x) = x_1 + x_2 - 2 \leq 0$

$g_2(x) = x_1^2 - x_2 \leq 0.$

$g_3(x) = -x_1 \leq 1 \quad (\Leftrightarrow x_1 \geq -1)$



Definição: Dizemos que uma restrição

$g(x) \leq 0$   
é ativa no ponto  $x^*$  se  $g(x^*) = 0$ .

Caso  $g(x^*) < 0$ , então  $g$  é  
inativa em  $x^*$ .

Como incluir  $g_3$  (inativa em  $x^*$ ) na expressão  
(\*) ?  
0

$$\nabla f(x^*) + \mu_1 \nabla g_1(x^*) + \mu_2 \nabla g_2(x^*) + \mu_3 \nabla g_3(x^*) = 0$$

$$\mu_1, \mu_2, \mu_3 \geq 0$$

complementaridade  $(\mu_i g_i(x^*) = 0, i=1, 2, 3)$

$\rightarrow \mu_i = 0$  caso  $g_i(x^*) < 0$  (inativa)

Se  $g_i(x^*) = 0$  (ativa),  $\mu_i$  é livre!

Considerando restrições de igualdade

$$\min_x f(x)$$

$$\text{s.a. } h(x) = 0, g(x) \leq 0.$$

Karush-Kuhn-Tucker (KKT)

Def.:  $x^*$  é ponto KKT se é viável (i.e.,  $h(x^*) = 0$  e  $g(x^*) \leq 0$ ) e existem  $\lambda_1, \dots, \lambda_m$  e  $\mu_1, \dots, \mu_p$  tais que

$$\nabla f(x^*) + \sum_{i=1}^m \lambda_i \nabla h_i(x^*) + \sum_{j=1}^p \mu_j \nabla g_j(x^*) = 0,$$



$$\mu_1, \dots, \mu_p \geq 0$$

$$\mu_j g_j(x^*) = 0, \quad \forall j.$$

"Todo ponto KKT é candidato à minimizador".

Obs.: se  $h \equiv 0$  e  $g \equiv 0$  então KKT resume-se a  $\nabla f(x^*) = 0$ . ✓

- $\lambda_i$ 's não tem sinal.



- Nem todo minimizador é ponto KKT!

$$\min_x x$$

$$\text{s.a. } x^2 \leq 0$$

Claro que  $x^* = 0$ .

KKT (para  $x^*$ ):  $f'(x^*) + \mu g'(x^*) = 0$ ,

$\mu \geq 0$   
 $\mu g(x^*) = 0$

$1 + \mu(2.0) = 0$  ~~X~~  
falha  $\forall \mu \geq 0$ .

Problema:  $g'(x^*) = 0$  !!!

(ou  $\exists \nabla g_j(x^*)$ ;  $g_j$  ativa e é L.D.).

• Def:  $x^*$  é regular se

$\nabla h_i(x^*)$ ,  $i = 1, \dots, m$ ,

$\nabla g_j(x^*)$ ,  $j$  tq  $g_j(x^*) = 0$  (ativas)

formam um conjunto linearmente independente.

• Teorema: se  $x^*$  é minimizador local e regular então  $x^*$  é KKT.

(condição necessária de otimalidade - CNO - de 1ª ordem)

Prova: depois, usando método de penalidade externa.


- $\lambda$  e  $\mu$  são chamados de multiplicadores de Lagrange

- Em problemas convexos (a definir), vale que: se  $x^*$  é KKT então  $x^*$  é minimizador global.

Em problemas não convexos, não vale em geral!

↳ KKT apenas fornece candidatos a minimizador (tal como  $\nabla f = 0$  na otimização irrestrita)

minimizar  $f(x) = (x_1 - 2)^2 + (x_2 - 1)^2$   
 sujeito a  $g_1(x) = x_1 + x_2 - 2 \leq 0$   
 $g_2(x) = x_1^2 - x_2 \leq 0$ .



KKT:

$$\nabla f(x) + \mu_1 \nabla g_1(x) + \mu_2 \nabla g_2(x) = 0$$

$$\mu_1, \mu_2 \geq 0$$

$$\mu_1 g_1(x) = 0, \mu_2 g_2(x) = 0.$$

$x$  viável!

$$(*) \begin{bmatrix} 2(x_1 - 2) \\ 2(x_2 - 1) \end{bmatrix} + \mu_1 \begin{bmatrix} 1 \\ 1 \end{bmatrix} + \mu_2 \begin{bmatrix} 2x_1 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \quad x \text{ viável.}$$

$$\mu_1, \mu_2 \geq 0$$

$$\mu_1(x_1 + x_2 - 2) = 0$$

$$\mu_2(x_1^2 - x_2) = 0.$$

Caso 1:  $\mu_1 = \mu_2 = 0$ .

Neste caso,  $2(x_1 - 2) = 2(x_2 - 1) = 0 \Rightarrow (x_1, x_2) = (2, 1)$ . Veja que  $g_1(2, 1) = 1 \neq 0$ , ou seja,  $(2, 1)$  não é viável. Logo não pode ser  $\mu_1 = \mu_2 = 0$ .

Caso 2:  $\mu_1 > 0$  e  $\mu_2 = 0$

Não é possível (exercício)

Caso 3:  $\mu_1 = 0$  e  $\mu_2 > 0$

Não é possível (exercício)

Caso 4:  $\mu_1 > 0$  e  $\mu_2 > 0$

Neste caso, as condições de complementaridade dizem que ambas restrições  $g_1(x) \leq 0$  e  $g_2(x) \leq 0$  são ativas, isto é,

$$g_1(x) = x_1 + x_2 - 2 = 0 \quad \text{e} \quad g_2(x) = x_1^2 - x_2 = 0$$



Assim, resolvemos o sistema

$$\begin{cases} x_1 + x_2 - 2 = 0 & (1) \\ x_1^2 - x_2 = 0 & (2) \end{cases}$$

Substituindo (2) em (1), obtemos

$$x_1^2 + x_1 - 2 = 0. \text{ Daí } x_1 = 1 \text{ ou}$$

$x_1 = -2$ . As possibilidades de pontos KKT são portanto  $(1, 1)$  e  $(-2, 4)$ .

Agora, verificamos se cada ponto é de fato KKT. Eles são viáveis. Faltava verificar (\*):

$$\begin{bmatrix} 2(x_1 - 2) \\ 2(x_2 - 1) \end{bmatrix} + \mu_1 \begin{bmatrix} 1 \\ 1 \end{bmatrix} + \mu_2 \begin{bmatrix} 2x_1 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\checkmark \underline{(1, 1)}: \begin{bmatrix} 2(1-2) \\ 2(1-1) \end{bmatrix} + \mu_1 \begin{bmatrix} 1 \\ 1 \end{bmatrix} + \mu_2 \begin{bmatrix} 2 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\Rightarrow \begin{cases} \mu_1 + 2\mu_2 = 2 \\ \mu_1 - \mu_2 = 0 \end{cases} \Rightarrow \mu_1 = \mu_2 = \frac{2}{3} > 0.$$

$$\underline{(-2, 4)}: \begin{bmatrix} 2(-2-2) \\ 2(4-1) \end{bmatrix} + \mu_1 \begin{bmatrix} 1 \\ 1 \end{bmatrix} + \mu_2 \begin{bmatrix} -4 \\ -1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\Rightarrow \begin{cases} \mu_1 - 4\mu_2 = 8 \\ \mu_1 - \mu_2 = -6 \end{cases} \text{ Daí } -3\mu_2 = 14 \Rightarrow \mu_2 = -\frac{14}{3},$$

o que é proibido visto que  $\mu_2 \geq 0$ .  
Logo  $(-2, 4)$  não é KKT.

O único ponto KKT, e minimizador,  
é  $(1, 1)$

Relembrando...

- KKT fornece candidatos a minimizadores
- Nem todo minimizador é KKT. Por exemplo,

$$\min x \text{ s.a. } x^2 \leq 0.$$

não  
regular

$x^* = 0$  é o (único) minimizador, porém KKT não vale:  $1 + \mu(2x^*) = 0$  é impossível para qualquer  $\mu \geq 0$ !

Veja que o gradiente de  $g$  se anula em  $x^*$ .  $\rightarrow$  Os gradientes das restrições ativas são L.D.

- $x^*$  ponto viável é regular se

$\nabla h_i(x^*), \forall i, \nabla g_j(x^*), j: g_j(x^*) = 0$   
formam um conjunto L.I.

hip. sobre as restrições

- TEO: se  $x^*$  é minimizador regular então  $x^*$  é KKT.

Optimização irrestrita:  $x^*$  é min.  $\Rightarrow \nabla f(x^*) = 0$ .

→ prova através do método de penalidade externa.



Algoritmos  
busca anular  
 $\nabla f(x)$   
(otim. irrestrita)

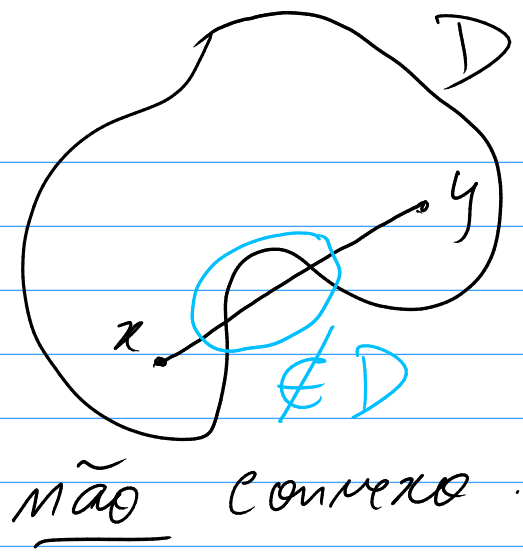
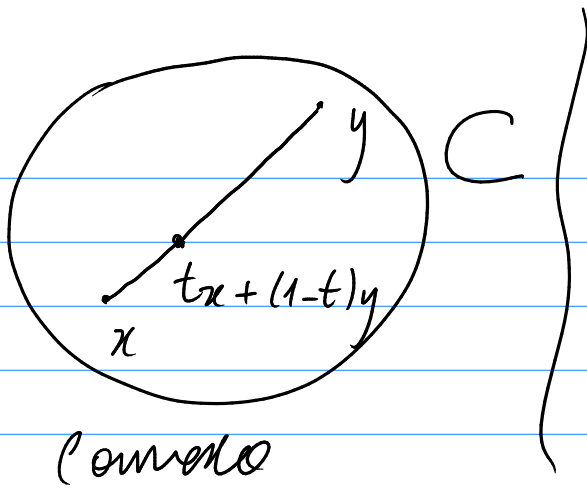
- Optimização restrita:

Algoritmos buscam satisfazer KKT.

Problemas de otimização convexos

Def: Um conjunto  $C \subset \mathbb{R}^n$  é convexo se dados  $x, y \in C$  e  $t \in [0, 1]$ , temos  $tx + (1-t)y \in C$ .

"o segmento de  $x$  a  $y$  está contido em  $C$ "



Exemplos:

1)  $\mathbb{R}^m$  é convexo.


2)  $[a, b]$ ,  $[a, b] \times [c, d]$ ,  $\prod_{i=1}^m [a_i, b_i]$   
são convexos.

3)  $\{x \in \mathbb{R}^m; Ax = b, Cx \leq d\}$  é convexo (conjunto viável de PL's)

4)  $C_1, \dots, C_p$  convexos  $\Rightarrow \bigcap_{i=1}^p C_i$  é convexo. (prove!)

5)  $[1, 2]$  e  $[3, 4]$ . Então

$[1, 2] \cup [3, 4]$  não é convexo




Def: Seja  $C \subset \mathbb{R}^n$  conjunto convexo.

A função  $f: C \rightarrow \mathbb{R}$  é convexa

se

$$f(\underline{tx + (1-t)y}) \leq t f(x) + (1-t) f(y),$$
$$\forall x, y \in C \text{ e } \forall t \in [0, 1]$$



"O gráfico de  $f$  está abaixo das cordas que ligam pontos de seu gráfico".

Exemplos:

1)  $f(x) = c$ ,  $c$  constante é convexa.

2)  $f(x) = c^t x$  é convexa (F.O. dos PL's)

3)  $f(x) = \frac{1}{2} x^t A x + b^t x + c$ , onde

$A$  é simétrica e definida positiva (função quadrática).

$$f: \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = \frac{1}{2}x^2 + x.$$

$$f: \mathbb{R}^2 \rightarrow \mathbb{R}, \quad f(x) = \frac{1}{2} [x_1, x_2] \begin{bmatrix} 2 & 0 \\ 0 & 3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$\hookrightarrow f(x) = \frac{1}{2} [2x_1, 3x_2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$f(x) = \frac{1}{2} (2x_1^2 + 3x_2^2)$$

## Problemas convexos

$\min f(x)$  s.a.  $h(x) = 0, g(x) \leq 0$   
é um problema convexo se:

(i)  $f$  é convexa

(ii)  $g_j$  são convexas,  $\forall j$

(iii)  $h_i$  são afins,  $\forall i$

( $\Leftrightarrow h_i$  e  $-h_i$  são convexas)

## Interesse em convexidade:

Em problemas convexos,

(1)  $x^*$  minimizador local  $\Rightarrow x^*$  é min global

✓ (2)  $x^*$  é KKT  $\Rightarrow x^*$  é minimizador global.

# Condições de Karush-Kuhn-Tucker (KKT) (problemas convexos)

$$P: \min f(x) \text{ s.a. } h(x) = 0, g(x) \leq 0$$

$$f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ convexa}$$

$$g_j: \mathbb{R}^n \rightarrow \mathbb{R} \text{ convexas, } \forall j = 1, \dots, p$$


$$h_i: \mathbb{R}^n \rightarrow \mathbb{R} \text{ afins, } \forall i = 1, \dots, m$$

$$\hookrightarrow h(x) = Ax - b$$

→ KKT é suficiente para otimalidade em problemas convexos.

Teorema: Seja  $C \subset \mathbb{R}^n$  um conjunto convexo e  $f: C \rightarrow \mathbb{R}$  uma função diferenciável. Então  $f$  é convexa se, e somente se,

$$f(y) \geq f(x) + \nabla f(x)^t (y - x), \forall x, y \in C.$$



Teorema: Seja  $x^*$  um ponto KKT do problema convexo  $P$ . Então  $x^*$  é minimizador global de  $P$ .

Prova: Como  $x^*$  é KKT, existem  $\lambda \in \mathbb{R}^m$  e  $\mu \in \mathbb{R}^p$  tais que

- $x^*$  é viável ( $h(x^*)=0$ ,  $g(x^*) \leq 0$ )
- $\nabla f(x^*) + \sum_{i=1}^m \lambda_i \nabla h_i(x^*) + \sum_{j=1}^p \mu_j \nabla g_j(x^*) = 0$

- $\mu_j \geq 0$ ,  $\forall j$

- $\mu_j g_j(x^*) = 0$ ,  $\forall j$ .

Dado qualquer  $y$  viável, multiplicamos o item por  $(y - x^*)$ , obtendo

$$(1) \quad \nabla f(x^*)^t (y - x^*) + \sum_{i=1}^m \lambda_i \nabla h_i(x^*)^t (y - x^*) + \sum_{j=1}^p \mu_j \nabla g_j(x^*)^t (y - x^*) = 0$$

Usando o teorema anterior com  $x = x^*$ , temos

$$(1) \leq f(y) - f(x^*) + \sum_{i=1}^m \lambda_i (h_i(y) - h_i(x^*)) + \sum_{j=1}^p \mu_j (g_j(y) - g_j(x^*))$$



Como  $h_i(x) = a_i^t x - b_i$ , note que  
 $\nabla h_i(x^*)^t (y - x^*) = h_i(y) - h_i(x^*)$ .

De fato,  $a_i^t (y - x^*) = a_i^t y - b_i - (a_i^t x^* - b_i)$   
 $= h_i(y) - h_i(x^*)$ .

Como  $x^*$  e  $y$  são viáveis, temos

$$(1) \leq f(y) - f(x^*) + \sum_{j=1}^p \underbrace{\mu_j g_j(y)}_{\leq 0} \quad (\mu_j g_j(x^*) = 0 \quad \forall j)$$

$$\Rightarrow 0 \leq f(y) - f(x^*) \Rightarrow f(y) \geq f(x^*).$$

Como  $y$  é arbitrário ( $f(y) \geq f(x^*) \quad \forall y$  viável),  
concluímos que  $x^*$  é minimizador global de  $f$ .  $\blacksquare$