

# Otimização I: problemas restritos / métodos

→ gradiente:  $x^{k+1} = x^k - t_k \nabla f(x^k)$   
passo

• Newton:  $x^{k+1} = x^k - (\nabla^2 f(x^k))^{-1} \nabla f(x^k)$   
(caro computacionalmente)

• Quase-Newton:  $x^{k+1} = x^k - B_k \nabla f(x^k)$   
( $B_k$  é barata)

• gradiente espectral (?)

• gradientes conjugados

(minimização de quadráticas)

$$f(x) = \frac{1}{2} x^T A x - b^T x,$$


$A$  simétrica e definida positiva

→  $d^T A d > 0, \forall d \neq 0.$

$A$  simétrica e def. positiva  $\Rightarrow f$  (estruturadamente) convexa.

Funções convexas:

$$f(x_t) \leq t f(a) + (1-t) f(b)$$
$$t \in [0, 1]$$



## Funções convexas (definição)

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

$$f(ta + (1-t)b) \leq t f(a) + (1-t) f(b),$$

$\forall a, b \in \mathbb{R}^n$  e  $\forall t \in [0, 1]$ .

$f$  é estritamente convexa se a desigualdade é  $<$ .

---

TEO:  $f$  convexa.  $\nabla f(x^*) = 0 \Rightarrow x^*$  é minimizador de  $f$ .



---

Que é resolver  $\min_x f(x)$ ?

~~1) Ideal: encontrar um minimizador (global), isto é,  $x^*$  tal que~~

$$f(x^*) \leq f(x), \quad \forall x$$


~~2) minimizador local:  $\exists V(x^*)$  vizinhança de  $x^*$  tal que  $f(x^*) \leq f(x)$ ,  $\forall x \in V(x^*)$~~



$\bar{x}$  é min. local, mas não global!  
 $x^*$  é min. global

$\{x^k\}$  sequência gerada pelo método  
 $\lim_{k \rightarrow \infty} x^k = x^*$

$\|\nabla f(x^k)\| \leq \epsilon$



3) Expectativa na prática: sistema  $\tilde{m}$  encontrar  $x^*$  tal que  $\nabla f(x^*) = 0$   
 condição (necessária) de otimalidade de 1º ordem

# Problemas restritos

$$\min_x f(x)$$

sujeito a  $h(x) = 0$  )  $m$  restrições

$g(x) \leq 0$  )  $p$  restrições

$$f: \mathbb{R}^m \rightarrow \mathbb{R}, \quad h: \mathbb{R}^m \rightarrow \mathbb{R}^m, \quad g: \mathbb{R}^m \rightarrow \mathbb{R}^p$$

$\nabla f(x^*) = 0$  (não serve mais, pois não considera as restrições!)

→ KKT (Karush-Kuhn-Tucker)