

# Subgradienles / subdiferencial

⌊

$$P: \min_x c^t x \quad \text{s.a.} \quad Ax = b, \quad Dx \leq e, \quad x \in \mathbb{Z}_+^m.$$

$$P(u) : \min_x \underbrace{c^t x + u^t (Ax - b)}_{L(x, u)} \quad \text{s.a.} \quad Dx \leq e, \quad x \in \mathbb{Z}_+^m$$

$$L^*(u) = \min_x \{ c^t x + u^t (Ax - b) \}; \quad Dx \leq e, \quad x \in \mathbb{Z}_+^m$$

Objetivos: resolver  $D: \max_u L^*(u)$ .

Como  $L^*: \mathbb{R}^m \rightarrow \mathbb{R}$  é? ( $m = n^\circ$  de restrições dualizadas) (2)

Exemplo:  $P: \min_x x_1 + 2x_2 + 3x_3$

$$\text{s.a. } x_1 + x_2 + x_3 = 1$$

$$x \in \{0, 1\}^3$$

Dualizando  $\sum_1^3 x_i = 1$ , obtemos

$$P(u) = \min_x (1+u)x_1 + (2+u)x_2 + (3+u)x_3 - u$$

$$\text{s.a. } x \in \{0, 1\}^3.$$


Resolvendo  $P(u)$ :

3

- $u \leq -3 \Rightarrow \kappa_1 = \kappa_2 = \kappa_3 = 1$
- $-3 < u \leq -2 \Rightarrow \kappa_1 = \kappa_2 = 1, \kappa_3 = 0$
- $-2 < u \leq -1 \Rightarrow \kappa_1 = 1, \kappa_2 = \kappa_3 = 0$
- $u > -1 \Rightarrow \kappa_1 = \kappa_2 = \kappa_3 = 0$ .

Assim,

$$L^*(u) = \begin{cases} 6 + 2u & , \quad u \leq -3 \\ 3 + u & , \quad -3 < u \leq -2 \\ 1 & , \quad -2 < u \leq -1 \\ -u & , \quad u > -1 \end{cases}$$



$L^*$  não é diferenciável  $\forall u$ !



Em geral,  $L^*$  não é diferenciável, 5  
o que impede o uso de métodos que dependam de gradientes para resolver  
 $D: \max_u L^*(u)$ .

Porém, nem tudo está perdido:

Teorema:  $L^*$  é côncava, isto é,  
 $-L^*$  é convexa.

Prova: Seja  $X = \{x; Dx \leq e, x \in \mathbb{Z}_+^m\}$ . (6)

Dados  $u, \tilde{u} \in \mathbb{R}^m$  e  $t \in [0, 1]$  temos

$$-L^*((1-t)u + t\tilde{u}) = -\min_x \{c^t x + [(1-t)u + t\tilde{u}]^t (Ax - b); x \in X\}$$

$$= -\min_x \{ (1-t) [c^t x + u^t (Ax - b)] + t [c^t x + \tilde{u}^t (Ax - b)] ; x \in X \}$$

$$\leq -[(1-t) \min_x \{c^t x + u^t (Ax - b); x \in X\}]$$

$$+ t \min_x \{ c^t x + \tilde{u}^t (Ax - b) ; x \in X \} \quad [7]$$

$$= (1-t)(-L^*(u)) + t(-L^*(\tilde{u})) \quad \blacksquare$$

Assim,  $D: \max_u L^*(u)$  é um problema de maximização de uma função côncava.

Para manter o padrão, note que isso é o mesmo que minimizar a função convexa  $-L^*$   $\rightarrow$   $D: -\min_u -L^*(u)$  (problema convexo).

• Como no exemplo, em geral  $L^*$  é o  $L$  mínimo entre funções afins.

Para ver isto, suponha por simplicidade que  $X = \{x; Dx \leq e, x \in \mathbb{Z}_+^n\}$  seja finito.

Assim,  $X = \{x^1, x^2, \dots, x^q\}$  e logo

$$L^*(u) = \min_{j=1, \dots, q} \{c^t x^j + u^t (A x^j - b)\}.$$

Neste caso, o problema  $D$  fica



$$D: \max_u \min_{j=1, \dots, q} \{ c^t x^j + u^t (A x^j - b) \}$$

(9)

que equivale à

$$D: \max_z$$

$z$

s.a.

$$z \leq c^t x^j + u^t (A x^j - b), \quad j=1, \dots, q$$

$$u \in \mathbb{R}^m, \quad z \in \mathbb{R}.$$

Il s'agit d'un problème de programmation linéaire en variables mixtes (PLM) car les variables  $x^j$  sont continues et les variables  $u$  sont continues.

Este PL sugere resolver D via geração <sup>(10)</sup>  
de linhas ou planos de corte, pois poderíamos  
resolver uma sequência de PL's inserindo  
restrições do tipo  $z \leq c^t \tilde{x} + u^t (A \tilde{x} - b)$ , com  
 $\tilde{x}$  precisamente calculado. (planos de corte foi  
visto em "Otimização II").

Porém não queremos (e não precisamos)  
acumular restrições em grandes PL's...

↳ Vamos imitar o metodo do gradiente!

Sabemos que para uma função convexa <sup>11</sup>  
diferenciável  $f$ , a condição de otimalidade de 1ª ordem é necessária e suficiente:

$$\nabla f(x^*) = 0 \iff x^* \text{ minimiza } f.$$

Porém,  $-L^*$  não é diferenciável...

Como contornar?

↳ subgradientes!


# Subgradiente (de funções convexas)

12

Considere  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  convexa, não  
necessariamente diferenciável.

Sabemos ("Otimização I") que  
 $f$  diferenciável é convexa  
se, e somente se,

$f(y) \geq f(x) + \nabla f(x)^t (y-x)$ ,  
 $\forall x, y$  (graf  $f$  acima das tangentes)



• O subgradiente imita o papel de  $\nabla f$  nessa desigualdade: (13)

Definição: o vetor  $g \in \mathbb{R}^n$  é subgradiente de  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  no ponto  $x$  se

$$f(y) \geq f(x) + g^t(y-x), \quad \forall y.$$


Chamamos o conjunto dos subgradientes de  $f$  em  $x$  de subdiferencial, e o denotamos por  $\partial f(x)$ .

# Interpretação geométrica

Tomemos  $x$  e  $g \in \partial f(x)$  subgradiente.  
Dado  $y \neq x$ , considere o vetor  $v$  que  
liga  $(x, f(x))$  a  $(y, f(y))$ .

$$v = (y - x, f(y) - f(x)).$$

Dado  $t > 0$ , consideramos  
ainda a semireta  $tv$ .




Exemplos

$$\langle (g, -1); t v \rangle = t \underbrace{(g^t (y-x) - f(y) + f(x))}_{\leq 0} \leq 0$$

Ora seja,  $t v$  faz um ângulo  $\geq 90^\circ$  com  $g$ ,  $\forall t > 0$ .

reta com normal  $(g, -1)$



Assim, " $g$  está associado à inclinação das retas que estão entre as tangentes à graf  $f$ ". (16)

Em outras palavras, graf  $f$  está acima das retas  $l(y) = f(x) + g^+(y-x)$ .

Na figura,  $\partial f(x)$  está relacionado com o cone na "quina" do gráfico de  $f$ .

A interpretação geométrica usual é via epígrafo de  $f$  (ver livro Bertsekas).



# Propriedades dos subgradientes / subdiferenciais.

17

1) Se  $f$  é diferenciável em  $x$  então

$$\partial f(x) = \{ \nabla f(x) \}.$$

(subgradiente generaliza gradiente).

De fato, é claro que  $g = \nabla f(x)$  é um subgradiente. E ele é único, pois neste só há uma tangente ao gráfico de  $f$  em  $x$ , aquela com normal  $(\nabla f(x), -1)$ .

2) Se  $f$  é convexa, então  $\partial f(x) \neq \emptyset$  12  
 $\forall x \in \mathbb{R}^n$ . (pense na interpretação geométrica para se convencer disso).

↳ Assim, um método que só use subgradientes estará bem definido para  $f$  convexa, mesmo  $f$  não sendo diferenciável.

3) Se  $f$  é concava, também

$\partial f(x) \neq \emptyset, \forall x \in \mathbb{R}^n$ . Assim,  $L^*$  admite  
subgradientes  $\forall u$  !!!

Exercício: mostre que  $\partial f(x) \neq \emptyset$  quando  
 $f$  é conca~~va~~va, lembrando que neste caso  
 $-f$  é convexa.

4) Se  $f$  é convexa,  $\partial f(x)$  é conjunto convexo. De fato, se  $g, h \in \partial f(x)$  e  $t \in [0, 1]$ , então

$$\begin{aligned} & f(x) + [(1-t)g + th]^t (y-x) \\ &= (1-t)[f(x) + g^t(y-x)] + t[f(x) + h^t(y-x)] \\ &\leq (1-t)f(y) + tf(y) = f(y). \\ &\Rightarrow (1-t)g + th \in \partial f(x). \end{aligned}$$

5) Se  $f$  é convexa,  $\partial f(x)$  é conjunto  $\mathbb{R}^n$  fechado. De fato, seja  $\{g_k\} \subset \partial f(x)$  uma sequência de subgradientes em  $x$ .

com  $\lim_{k \rightarrow \infty} g_k = g_*$ . Dado  $y$ , temos  
 $f(y) \geq f(x) + g_k^t (y - x)$ ,  $\forall k$ .


Fazendo  $k \rightarrow \infty$  obtemos

$$f(y) \geq f(x) + g_*^t (y - x), \forall y \Rightarrow g_* \in \partial f(x)$$

Obs: mais,  $\partial f(x)$  é compacto. ▀

Exemplos:

1)  $f(x) = |x|$ .



$f$  é diferenciável em  $x \neq 0$ . Logo

$$\partial f(x) = \{ f'(x) \}, \quad x \neq 0.$$

$\partial f(0)$ :  $f(y) \geq f(0) + g(y-0), \forall y \Leftrightarrow |y| \geq gy, \forall y$

$\Leftrightarrow -1 \leq g \leq 1$ . Assim

$$\partial |x| = \begin{cases} -1, & x < 0 \\ [-1, 1], & x = 0 \\ 1, & x > 0 \end{cases} //$$

2)  $a, b: \mathbb{R} \rightarrow \mathbb{R}$  convexas e diferenciáveis. (23)


$f(x) = \max\{a(x), b(x)\}$  é convexa (verifique).

Então

- $b(x) < a(x) = f(x)$   
 $\Rightarrow \partial f(x) = \{a'(x)\}$

- $a(x) < b(x) = f(x)$   
 $\Rightarrow \partial f(x) = \{b'(x)\}$

- $a(x) = b(x) = f(x) \Rightarrow \partial f(x) = \{(1-t)a'(x) + tb'(x); t \in [0, 1]\}$



Note que  $|x| = \max\{-x, x\}$  24  
(compare os dois exemplos anteriores). //

---

3) Em geral, se  $f_i: \mathbb{R}^m \rightarrow \mathbb{R}$ ,  $i=1, \dots, p$ ,  
são convexas e diferenciáveis, então

$$f(x) = \max\{f_1(x), \dots, f_p(x)\}$$

é convexa, e

$$\partial f(x) = \text{conv}\{\nabla f_i(x) ; i \text{ tal que } f_i(x) = f(x)\}$$

(fecho convexo dos gradientes das máximas  $f_i$ 's)



Lembre-se, supondo  $X = \{x; Dx \leq e$ , (25)  
 $x \in \mathbb{Z}_+^m$   $\{ = \{x^1, \dots, x^q\}$  finito, temos

$$L^*(u) = \min_{j=1, \dots, q} \{ c^t x^j + u^t (A x^j - b) \}.$$

Logo, subgradientes de  $L^*$  têm relação com os gradientes das funções afins, dado que

$$-L^*(u) = \max_{j=1, \dots, q} \{ -c^t x^j - u^t (A x^j - b) \}.$$