

# Um método inexato de decomposição para minimizar a soma de duas funções convexas

Majela Pentón

UFBA

Novembro 2019

Problema geral de Otimização

Condições de otimalidade

Método do gradiente

Funções convexas

Funções convexas diferenciáveis

Funções convexas não diferenciáveis

Minimização da soma de duas funções convexas

Método do gradiente proximal inexato

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x)$$
$$\text{s.a. } x \in \mathbb{R}^n$$

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n$$

►  **$f$  função objetivo.**

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n$$

- ▶  $f$  **função objetivo**.
- ▶ O problema  $(P)$  é chamado de problema de **minimização irrestrita**.

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n$$

- ▶  $f$  **função objetivo**.
- ▶ O problema  $(P)$  é chamado de problema de **minimização irrestrita**.
- ▶  $x^*$  **mínimo global**:  $f(x^*) \leq f(x)$  para todo  $x \in \mathbb{R}^n$ ;

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n$$

- ▶  $f$  **função objetivo**.
- ▶ O problema  $(P)$  é chamado de problema de **minimização irrestrita**.
- ▶  $x^*$  **mínimo global**:  $f(x^*) \leq f(x)$  para todo  $x \in \mathbb{R}^n$ ;  
 $f^* = f(x^*)$  **valor ótimo** de  $f$ .

## Problema geral

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$(P) \quad \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n$$

- ▶  $f$  **função objetivo**.
- ▶ O problema  $(P)$  é chamado de problema de **minimização irrestrita**.
- ▶  $x^*$  **mínimo global**:  $f(x^*) \leq f(x)$  para todo  $x \in \mathbb{R}^n$ ;  
 $f^* = f(x^*)$  **valor ótimo** de  $f$ .
- ▶  $x^*$  **mínimo local**: se existe  $V$  vizinhança de  $x^*$  tal que  $f(x^*) \leq f(x)$  para todo  $x \in V$ .



## Teorema 1 (Condição necessária de primeira ordem)

*Se  $x^*$  é um mínimo local de  $f$  em  $\mathbb{R}^n$  e  $f$  é uma função diferenciável, então*


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

## Teorema 1 (Condição necessária de primeira ordem)

Se  $x^*$  é um mínimo local de  $f$  em  $\mathbb{R}^n$  e  $f$  é uma função diferenciável, então

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

**Não é suficiente**



$$f(x) = x^3$$


$$f'(0) = 0$$

## Teorema 1 (Condição necessária de primeira ordem)

Se  $x^*$  é um mínimo local de  $f$  em  $\mathbb{R}^n$  e  $f$  é uma função diferenciável, então

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

**Não é suficiente**



$$f(x) = x^3$$

$$f'(0) = 0$$

## Definição 1

Todo  $x$  tal que  $\nabla f(x) = 0$  é chamado de **ponto estacionário** do problema.

## Teorema 2 (Condição necessária de segunda ordem)

Se  $f$  é uma função duas vezes diferenciável e  $x^*$  é um *mínimo local* do problema, então  $x^*$  é um *ponto estacionário* ( $\nabla f(x^*) = 0$ ) e a matriz Hessiana de  $f$  no ponto  $x^*$  é *semidefinida positiva* ( $Hf(x^*) \succeq 0$ ).

## Teorema 2 (Condição necessária de segunda ordem)

Se  $f$  é uma função duas vezes diferenciável e  $x^*$  é um **mínimo local** do problema, então  $x^*$  é um **ponto estacionário** ( $\nabla f(x^*) = 0$ ) e a matriz Hessiana de  $f$  no ponto  $x^*$  é **semidefinida positiva** ( $Hf(x^*) \succeq 0$ ).

## Teorema 3 (Condição suficiente de segunda ordem)

Se  $f$  é uma função duas vezes diferenciável e  $x^*$  é um **ponto estacionário** ( $\nabla f(x^*) = 0$ ) tal que a Hessiana de  $f$  em  $x^*$  é **definida positiva** ( $Hf(x^*) \succ 0$ ), então  $x^*$  é um **mínimo local** de  $f$ .

Minimização irrestrita diferenciável:

$$\min f(x)$$

$$\text{s.a. } x \in \mathbb{R}^n$$

▶  $f$  é diferenciável no  $\mathbb{R}^n$ .

Minimização irrestrita diferenciável:

$$\begin{aligned} \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n \end{aligned}$$

►  $f$  é diferenciável no  $\mathbb{R}^n$ .

**Método do gradiente:** escolhe um ponto inicial  $x_0 \in \mathbb{R}^n$  e itera:

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k), \quad k = 0, 1, 2, \dots$$

Minimização irrestrita diferenciável:

$$\begin{aligned} \min f(x) \\ \text{s.a. } x \in \mathbb{R}^n \end{aligned}$$


- ▶  $f$  é diferenciável no  $\mathbb{R}^n$ .

**Método do gradiente:** escolhe um ponto inicial  $x_0 \in \mathbb{R}^n$  e itera:

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k), \quad k = 0, 1, 2, \dots$$


- ▶  $\alpha_k > 0$  é o **comprimento de passo**.






$x_0$


$x_0$




$$-\nabla f(x_0)$$




$$x_1 = x_0 - \alpha_0 \nabla f(x_0)$$




$$-\nabla f(x_1)$$



$$x_2 = x_1 - \alpha_1 \nabla f(x_1)$$



$$-\nabla f(x_2)$$



$$x_3 = x_2 - \alpha_2 \nabla f(x_2)$$

O método do gradiente é um método de descida: **o passo**  $\alpha_k$  é escolhido tal que  $f(x_{k+1}) \leq f(x_k)$



O método do gradiente é um método de descida: **o passo**  $\alpha_k$  é escolhido tal que  $f(x_{k+1}) \leq f(x_k)$

- ▶  $\alpha_k = \alpha$  constante para todo  $k$ .

O método do gradiente é um método de descida: **o passo**  $\alpha_k$  é escolhido tal que  $f(x_{k+1}) \leq f(x_k)$

- ▶  $\alpha_k = \alpha$  constante para todo  $k$ .
- ▶ busca linear de Armijo: com  $\sigma \in (0, 1)$

$$f(x_k - \alpha_k \nabla f(x_k)) \leq f(x_k) - \sigma \alpha_k \|\nabla f(x_k)\|^2.$$

O método do gradiente é um método de descida: o passo  $\alpha_k$  é escolhido tal que  $f(x_{k+1}) \leq f(x_k)$

- ▶  $\alpha_k = \alpha$  constante para todo  $k$ .
- ▶ busca linear de Armijo: com  $\sigma \in (0, 1)$

$$f(x_k - \alpha_k \nabla f(x_k)) \leq f(x_k) - \sigma \alpha_k \|\nabla f(x_k)\|^2.$$

- ▶ busca linear exata:  $\alpha_k = \arg \min_{\alpha} f(x_k - \alpha \nabla f(x_k))$ .

O método do gradiente é um método de descida: o **passo**  $\alpha_k$  é escolhido tal que  $f(x_{k+1}) \leq f(x_k)$

- ▶  $\alpha_k = \alpha$  constante para todo  $k$ .
- ▶ busca linear de Armijo: com  $\sigma \in (0, 1)$

$$f(x_k - \alpha_k \nabla f(x_k)) \leq f(x_k) - \sigma \alpha_k \|\nabla f(x_k)\|^2.$$

- ▶ busca linear exata:  $\alpha_k = \arg \min_{\alpha} f(x_k - \alpha \nabla f(x_k))$ .

## Convergência a um ponto estacionário

Sob hipóteses adequadas, temos que todo **ponto de acumulação** da sequência  $(x_k)$ , gerada pelo método do gradiente, é um **ponto estacionário do problema**.

Em geral, em otimização (não linear), o nosso objetivo é bastante moderado: encontrar apenas um mínimo local do problema. Mesmo assim, esse objetivo pode não ser alcançado com o método de gradiente.

Em geral, em otimização (não linear), o nosso objetivo é bastante moderado: encontrar apenas um mínimo local do problema. Mesmo assim, esse objetivo pode não ser alcançado com o método de gradiente.

### Exemplo 1

$$f(y, z) = \frac{1}{2}y^2 + \frac{1}{4}z^4 - \frac{1}{2}z^2$$

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

► Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .



$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .
- ▶ O ponto  $(0, 0)$  não é mínimo local nem máximo local

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .
- ▶ O ponto  $(0, 0)$  não é mínimo local nem máximo local

Ponto inicial:  $x_0 = (1, 0)$

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .
- ▶ O ponto  $(0, 0)$  não é mínimo local nem máximo local

Ponto inicial:  $x_0 = (1, 0)$

$$\Rightarrow \nabla f(x_0) = (1, 0) \quad \Rightarrow x_1 = (1, 0) - \alpha_k(1, 0) \quad \Rightarrow (x_1)_2 = 0.$$

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .
- ▶ O ponto  $(0, 0)$  não é mínimo local nem máximo local

Ponto inicial:  $x_0 = (1, 0)$

$$\Rightarrow \nabla f(x_0) = (1, 0) \quad \Rightarrow x_1 = (1, 0) - \alpha_k(1, 0) \quad \Rightarrow (x_1)_2 = 0.$$

Então  $(x_k)_2 = 0$  para todo  $k = 1, 2, \dots$

$$x = (y, z), \quad \nabla f(x) = (y, z^3 - z), \quad Hf(x) = \begin{pmatrix} 1 & 0 \\ 0 & 3z^2 - 1 \end{pmatrix}$$

- ▶ Pontos estacionários:  $(0, 0)$ ,  $(0, 1)$ ,  $(0, -1)$ .
- ▶ Mínimos locais:  $(0, 1)$  e  $(0, -1)$ .
- ▶ O ponto  $(0, 0)$  não é mínimo local nem máximo local

Ponto inicial:  $x_0 = (1, 0)$

$$\Rightarrow \nabla f(x_0) = (1, 0) \quad \Rightarrow x_1 = (1, 0) - \alpha_k(1, 0) \quad \Rightarrow (x_1)_2 = 0.$$

Então  $(x_k)_2 = 0$  para todo  $k = 1, 2, \dots$

O método converge para o ponto  $(0, 0)$  que **não é mínimo local**.

Só podemos garantir convergência a um **ponto estacionário** do problema.

- ▶ A condição necessária de otimalidade de primeira ordem é **fraca**.

# Funções convexas diferenciáveis

- ▶ A condição necessária de otimalidade de primeira ordem é **fraca**.
- ▶ Podemos tentar restringir a análise a um conjunto de funções diferenciáveis com propriedades '*boas*'.




- ▶ A condição necessária de otimalidade de primeira ordem é **fraca**.
- ▶ Podemos tentar restringir a análise a um conjunto de funções diferenciáveis com propriedades 'boas'.


## Definição 2 (Função convexa)

*Uma função  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  diferenciável é dita convexa no  $\mathbb{R}^n$  se*

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle$$

*para todo  $x, y \in \mathbb{R}^n$*





Equivalente a definição geral de funções convexas

### Definição 3

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

$$f(\theta x + (1 - \theta)y) \leq \theta f(x) + (1 - \theta)f(y)$$

para todo  $\theta \in [0, 1]$  e  $x, y \in \mathbb{R}^n$ .

## Condição suficiente de otimalidade

Se  $f$  é uma função convexa, diferenciável, e  $x^* \in \mathbb{R}^n$  é um ponto estacionário

## Condição suficiente de otimalidade

Se  $f$  é uma função convexa, diferenciável, e  $x^* \in \mathbb{R}^n$  é um ponto estacionário

$$\Rightarrow f(x) \geq f(x^*) + \langle \nabla f(x^*), y - x^* \rangle = f(x^*) \quad \forall x \in \mathbb{R}^n$$

## Condição suficiente de otimalidade

Se  $f$  é uma função convexa, diferenciável, e  $x^* \in \mathbb{R}^n$  é um ponto estacionário

$$\Rightarrow f(x) \geq f(x^*) + \langle \nabla f(x^*), y - x^* \rangle = f(x^*) \quad \forall x \in \mathbb{R}^n$$

então  $x^*$  é **mínimo global**.

## Condição suficiente de otimalidade

Se  $f$  é uma função convexa, diferenciável, e  $x^* \in \mathbb{R}^n$  é um ponto estacionário

$$\Rightarrow f(x) \geq f(x^*) + \langle \nabla f(x^*), y - x^* \rangle = f(x^*) \quad \forall x \in \mathbb{R}^n$$

então  $x^*$  é **mínimo global**.

Para funções convexas diferenciáveis a condição necessária de primeira ordem também é suficiente

## Problema de minimização convexa

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  diferenciável e convexa em  $\mathbb{R}^n$

$$\min f(x)$$

$$\text{s.a. } x \in \mathbb{R}^n$$



## Problema de minimização convexa

Seja  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  diferenciável e convexa em  $\mathbb{R}^n$

$$\min f(x)$$

$$\text{s.a. } x \in \mathbb{R}^n$$

## Convergência

- ▶ Se  $(x_k)$  é gerada pelo método do gradiente, então a sequência toda converge a uma solução global.

# Método do gradiente para funções convexas

Se  $\nabla f$  é  $L$ -Lipschitz contínuo:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \text{para todo } x, y \in \mathbb{R}^n$$

# Método do gradiente para funções convexas

Se  $\nabla f$  é  $L$ -Lipschitz contínuo:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \text{para todo } x, y \in \mathbb{R}^n$$

Método do gradiente:  $\alpha = \frac{1}{L}$

$$x_{k+1} = x_k - \alpha \nabla f(x_k) \quad k = 0, 1, 2, \dots$$

# Método do gradiente para funções convexas

Se  $\nabla f$  é  $L$ -Lipschitz contínuo:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \text{para todo } x, y \in \mathbb{R}^n$$

Método do gradiente:  $\alpha = \frac{1}{L}$

$$x_{k+1} = x_k - \alpha \nabla f(x_k) \quad k = 0, 1, 2, \dots$$

►  $f(x_k) - f^* \leq C/k$

# Método do gradiente para funções convexas

Se  $\nabla f$  é  $L$ -Lipschitz contínuo:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \text{para todo } x, y \in \mathbb{R}^n$$

Método do gradiente:  $\alpha = \frac{1}{L}$

$$x_{k+1} = x_k - \alpha \nabla f(x_k) \quad k = 0, 1, 2, \dots$$

- ▶  $f(x_k) - f^* \leq C/k$
- ▶ Dizemos que o método do gradiente tem **taxa de convergência**  $\mathcal{O}(1/k)$ . Ou seja, o # de iterações para obter uma  $\epsilon$ -**solução** (no sentido de  $f(x_k) - f^* \leq \epsilon$ ) é  $\mathcal{O}(1/\epsilon)$ .

# Método do gradiente para funções convexas

Se  $\nabla f$  é  $L$ -Lipschitz contínuo:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \text{para todo } x, y \in \mathbb{R}^n$$

Método do gradiente:  $\alpha = \frac{1}{L}$

$$x_{k+1} = x_k - \alpha \nabla f(x_k) \quad k = 0, 1, 2, \dots$$

- ▶  $f(x_k) - f^* \leq C/k$
- ▶ Dizemos que o método do gradiente tem **taxa de convergência**  $\mathcal{O}(1/k)$ . Ou seja, o # de iterações para obter uma  $\epsilon$ -**solução** (no sentido de  $f(x_k) - f^* \leq \epsilon$ ) é  $\mathcal{O}(1/\epsilon)$ .

**Prós:** Ideia simples, fácil implementação, usualmente as iterações são baratas.

**Contras:** Não pode ser aplicado a funções não diferenciáveis.

## Subgradiente de uma função convexa

Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, dizemos que  $v \in \mathbb{R}^n$  é um **subgradiente** de  $f$  no ponto  $x \in \mathbb{R}^n$  se


$$f(y) \geq f(x) + \langle v, y - x \rangle, \quad \forall y \in \mathbb{R}^n.$$

# Funções convexas não diferenciáveis

## Subgradiente de uma função convexa

Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, dizemos que  $v \in \mathbb{R}^n$  é um **subgradiente** de  $f$  no ponto  $x \in \mathbb{R}^n$  se

$$f(y) \geq f(x) + \langle v, y - x \rangle, \quad \forall y \in \mathbb{R}^n.$$






- ▶ O subgradiente sempre existe
- ▶ Se  $f$  é diferenciável em  $x$ , então  $v = \nabla f(x)$  é o único subgradiente de  $f$  em  $x$ .

- ▶ O subgradiente sempre existe
- ▶ Se  $f$  é diferenciável em  $x$ , então  $v = \nabla f(x)$  é o único subgradiente de  $f$  em  $x$ .



## Subdiferencial

O conjunto de todos os subgradientes de  $f$  em  $x$  se chama o **subdiferencial** de  $f$  em  $x$ , e é denotado por  $\partial f(x)$ .

Exemplo:



Exemplo:



$$\partial f(x) = \begin{cases} 1 & \text{se } x > 0 \\ [-1, 1] & \text{se } x = 0 \\ -1 & \text{se } x < 0 \end{cases}$$

## Teorema 4 (Condição de otimalidade)

*Se  $f$  é uma função convexa, então  $x^*$  é um mínimo de  $f$  se e somente se*

$$0 \in \partial f(x^*).$$

## Teorema 4 (Condição de otimalidade)

Se  $f$  é uma função convexa, então  $x^*$  é um mínimo de  $f$  se e somente se

$$0 \in \partial f(x^*).$$

Segue da definição que se  $v = 0$  é subgradiente:

$$f(y) \geq f(x^*) + \langle 0, y - x^* \rangle = f(x^*)$$

pegando  $v = 0 \in \partial f(x^*)$ .

## Teorema 4 (Condição de otimalidade)

Se  $f$  é uma função convexa, então  $x^*$  é um mínimo de  $f$  se e somente se

$$0 \in \partial f(x^*).$$

Segue da definição que se  $v = 0$  é subgradiente:

$$f(y) \geq f(x^*) + \langle 0, y - x^* \rangle = f(x^*)$$

pegando  $v = 0 \in \partial f(x^*)$ .

Observe a analogia com o caso diferenciável, onde

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

## Minimização irrestrita convexa

$$\min_{x \in \mathbb{R}^n} f(x)$$



## Minimização irrestrita convexa

$$\min_{x \in \mathbb{R}^n} f(x)$$

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa não diferenciável.

## Minimização irrestrita convexa

$$\min_{x \in \mathbb{R}^n} f(x)$$

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa não diferenciável.

**Método do subgradiente:** similar ao método do gradiente, mas substituindo gradientes por subgradientes.

## Minimização irrestrita convexa

$$\min_{x \in \mathbb{R}^n} f(x)$$

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa não diferenciável.

**Método do subgradiente:** similar ao método do gradiente, mas substituindo gradientes por subgradientes.

Escolha um ponto inicial  $x_0 \in \mathbb{R}^n$  e itera

$$x_{k+1} = x_k - \alpha_k v_k, \quad k = 0, 1, 2, \dots,$$

## Minimização irrestrita convexa

$$\min_{x \in \mathbb{R}^n} f(x)$$

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa não diferenciável.

**Método do subgradiente:** similar ao método do gradiente, mas substituindo gradientes por subgradientes.

Escolha um ponto inicial  $x_0 \in \mathbb{R}^n$  e itera

$$x_{k+1} = x_k - \alpha_k v_k, \quad k = 0, 1, 2, \dots,$$

- ▶  $v_k \in \partial f(x_k)$ ;
- ▶  $\alpha_k > 0$ .

## Observação:

- ▶ O método do subgradiente não é necessariamente um método de decida, logo guardamos em cada iteração o melhor iterado

$$f(x_k^{best}) = \min_{i=1,\dots,k} f(x_i).$$

## Observação:

- ▶ O método do subgradiente não é necessariamente um método de decida, logo guardamos em cada iteração o melhor iterado

$$f(x_k^{best}) = \min_{i=1,\dots,k} f(x_i).$$

## Escolhas do tamanho do passo

- ▶ Constante:  $\alpha_k = \alpha$  para todo  $k \in \mathbb{N}$ .

## Observação:

- ▶ O método do subgradiente não é necessariamente um método de decida, logo guardamos em cada iteração o melhor iterado

$$f(x_k^{best}) = \min_{i=1,\dots,k} f(x_i).$$

## Escolhas do tamanho do passo

- ▶ Constante:  $\alpha_k = \alpha$  para todo  $k \in \mathbb{N}$ .
- ▶ Quadrado somável, mas não somável:

$$\alpha_k > 0, \quad \sum_{k=0}^{\infty} \alpha_k^2 < \infty, \quad \sum_{k=0}^{\infty} \alpha_k = \infty.$$

## Observação:

- ▶ O método do subgradiente não é necessariamente um método de decida, logo guardamos em cada iteração o melhor iterado

$$f(x_k^{best}) = \min_{i=1, \dots, k} f(x_i).$$

## Escolhas do tamanho do passo

- ▶ Constante:  $\alpha_k = \alpha$  para todo  $k \in \mathbb{N}$ .
- ▶ Quadrado somável, mas não somável:

$$\alpha_k > 0, \quad \sum_{k=0}^{\infty} \alpha_k^2 < \infty, \quad \sum_{k=0}^{\infty} \alpha_k = \infty.$$

**Diferença com o método do gradiente:** as escolhas do passo são prefixadas, não calculadas em cada iteração.



## Resultados de convergência

▶ Passo constante:

Se  $f^* = -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se  $f^* > -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) \leq f^* + \alpha c^2/2$ .

## Resultados de convergência

- ▶ Passo constante:

Se  $f^* = -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se  $f^* > -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) \leq f^* + \alpha c^2/2$ .

- ▶ Quadrado somável, mas não somável:  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

## Resultados de convergência

- ▶ Passo constante:

Se  $f^* = -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se  $f^* > -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) \leq f^* + \alpha c^2/2$ .

- ▶ Quadrado somável, mas não somável:  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se existe solução do problema então  $x_k \rightarrow x^*$ , onde  $x^*$  é uma solução.

## Resultados de convergência

- ▶ Passo constante:

Se  $f^* = -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se  $f^* > -\infty$ , então  $\liminf_{k \rightarrow \infty} f(x_k) \leq f^* + \alpha c^2/2$ .

- ▶ Quadrado somável, mas não somável:  $\liminf_{k \rightarrow \infty} f(x_k) = f^*$ .

Se existe solução do problema então  $x_k \rightarrow x^*$ , onde  $x^*$  é uma solução.

## Taxa de convergência

O método do subgradiente tem taxa de convergência  $\mathcal{O}(1/\sqrt{k})$ .  
Ou seja, para obter  $f(x_k^{best}) - f^* \leq \epsilon$  é necessário  $\mathcal{O}(1/\epsilon^2)$  iterações.

**Prós:** Ampla aplicação: se podemos computar subgradientes, então podemos minimizar (quase) qualquer função convexa. Fácil implementação.

**Contras:** A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta.

**Prós:** Ampla aplicação: se podemos computar subgradientes, então podemos minimizar (quase) qualquer função convexa. Fácil implementação.

**Contras:** A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta.

Método do gradiente: para obter  $f(x_k) - f^* \leq 1/100 \Rightarrow 100$  iterações.

Método do subgradiente: para obter  $f(x_k^{best}) - f^* \leq 1/100 \Rightarrow 10000$  iterações.

**Prós:** Ampla aplicação: se podemos computar subgradientes, então podemos minimizar (quase) qualquer função convexa. Fácil implementação.

**Contras:** A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta.

Método do gradiente: para obter  $f(x_k) - f^* \leq 1/100 \Rightarrow 100$  iterações.

Método do subgradiente: para obter  $f(x_k^{best}) - f^* \leq 1/100 \Rightarrow 10000$  iterações.

Pode-se melhorar?

**Prós:** Ampla aplicação: se podemos computar subgradientes, então podemos minimizar (quase) qualquer função convexa. Fácil implementação.

**Contras:** A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta.

Método do gradiente: para obter  $f(x_k) - f^* \leq 1/100 \Rightarrow 100$  iterações.

Método do subgradiente: para obter  $f(x_k^{best}) - f^* \leq 1/100 \Rightarrow 10000$  iterações.

Pode-se melhorar? Em geral não!  
Mas considerando funções da forma

$$f(x) = h(x) + g(x)$$

onde  $h$  é convexa e diferenciável e  $g$  é convexa.

Para muitos problemas a taxa de convergência  $\mathcal{O}(1/k)$  do método do gradiente pode ser recuperada com um algoritmo simples.



# Minimização da soma de duas funções convexas

Minimizando a soma de duas funções

$$\min_{x \in \mathbb{R}^n} h(x) + g(x)$$

# Minimização da soma de duas funções convexas

## Minimizando a soma de duas funções

$$\min_{x \in \mathbb{R}^n} h(x) + g(x)$$

- ▶  $h, g : \mathbb{R}^n \rightarrow \mathbb{R}$  são funções convexas e  $h$  é diferenciável.

# Minimização da soma de duas funções convexas

## Minimizando a soma de duas funções

$$\min_{x \in \mathbb{R}^n} h(x) + g(x)$$

- ▶  $h, g : \mathbb{R}^n \rightarrow \mathbb{R}$  são funções convexas e  $h$  é diferenciável.

## Operador proximal

Dado  $\alpha > 0$ ,  $\text{prox}_{\alpha g} : \mathbb{R}^n \rightarrow \mathbb{R}^n$

$$\text{prox}_{\alpha g}(z) := \arg \min_{x \in \mathbb{R}^n} \alpha g(x) + \frac{1}{2} \|x - z\|^2.$$

Método do gradiente proximal: escolha  $x_0 \in \mathbb{R}^n$  e itera

$$x_{k+1} = \mathbf{prox}_{\alpha_k g}(x_k - \alpha_k \nabla h(x_k)), \quad k = 0, 1, \dots$$

▶  $\alpha_k > 0$ .

**Método do gradiente proximal:** escolha  $x_0 \in \mathbb{R}^n$  e itera

$$x_{k+1} = \mathbf{prox}_{\alpha_k g}(x_k - \alpha_k \nabla h(x_k)), \quad k = 0, 1, \dots$$

▶  $\alpha_k > 0$ .

Para  $f(x) = h(x) + g(x)$  supondo que

- ▶  $\nabla h$  é Lipschitz contínuo com  $L > 0$
- ▶  $\mathbf{prox}_{\alpha_k g}$  pode ser avaliado

e usando passo constante  $\alpha_k = 1/L$ , o método do gradiente proximal tem taxa de convergência  $\mathcal{O}(1/k)$ .

**Método do gradiente proximal:** escolha  $x_0 \in \mathbb{R}^n$  e itera

$$x_{k+1} = \mathbf{prox}_{\alpha_k g}(x_k - \alpha_k \nabla h(x_k)), \quad k = 0, 1, \dots$$

▶  $\alpha_k > 0$ .

Para  $f(x) = h(x) + g(x)$  supondo que

- ▶  $\nabla h$  é Lipschitz contínuo com  $L > 0$
- ▶  $\mathbf{prox}_{\alpha_k g}$  pode ser avaliado

e usando passo constante  $\alpha_k = 1/L$ , o método do gradiente proximal tem taxa de convergência  $\mathcal{O}(1/k)$ .

É recuperada a taxa de convergência do método do gradiente, mas tem o custo da avaliação do **prox**.

Para muitas funções  $g$ , importantes na prática, o  $\text{prox}_g$  tem **forma fechada**, mas

Para muitas funções  $g$ , importantes na prática, o  $\text{prox}_g$  tem forma fechada, mas e se não podemos avaliar  $\text{prox}$ ?



Para muitas funções  $g$ , importantes na prática, o  $\text{prox}_g$  tem **forma fechada**, mas **e se não podemos avaliar  $\text{prox}$ ?**

Avaliar  $\text{prox}_{\alpha g}(z) = \arg \min_{x \in \mathbb{R}^n} \alpha g(x) + 1/2 \|x - z\|^2$  é equivalente a resolver o **sistema proximal**: encontrar  $x, v \in \mathbb{R}^n$  tais que

$$\begin{cases} v \in \partial g(x), \\ \alpha v + x - z = 0. \end{cases} \quad (1)$$

Para muitas funções  $g$ , importantes na prática, o  $\text{prox}_g$  tem **forma fechada**, mas **e se não podemos avaliar prox?**

Avaliar  $\text{prox}_{\alpha g}(z) = \arg \min_{x \in \mathbb{R}^n} \alpha g(x) + 1/2 \|x - z\|^2$  é equivalente a resolver o **sistema proximal**: encontrar  $x, v \in \mathbb{R}^n$  tais que

$$\begin{cases} v \in \partial g(x), \\ \alpha v + x - z = 0. \end{cases} \quad (1)$$

### Soluções aproximadas:

- ▶ Dado  $r \geq 0$ , um ponto  $(x, v)$  é uma  **$r$ -solução aproximada** de (1) no ponto  $(\alpha, z)$  se  $v \in \partial g(x)$  e

$$\|\alpha v + x - z\| \leq r.$$

- ▶ Dado  $\sigma \in [0, 1)$  a tripla  $(x, v)$  é uma  **$\sigma$ -solução aproximada** de (1) no ponto  $(\alpha, z)$  se  $v \in \partial g(x)$

$$\|\alpha v + x - z\| \leq \sigma \|x - z\|.$$

**Método do gradiente proximal inexato:** similar ao método do gradiente proximal, mas avaliando o  $\text{prox}_g$  de forma inexata.

**Método do gradiente proximal inexato:** similar ao método do gradiente proximal, mas avaliando o  $\mathbf{prox}_g$  de forma inexata. Escolha  $x_0 \in \mathbb{R}^n$  e itera para  $k = 0, 1, 2, \dots$ .

- ▶  $y_k = x_k - \alpha_k \nabla h(x_k)$ ;
- ▶ calcule  $(\bar{x}_k, \bar{w}_k)$  solução aproximada de  $\mathbf{prox}_g$  em  $(\alpha_k, y_k)$ ;
- ▶  $x_{k+1} = y_k - \alpha_k \bar{w}_k$

**Método do gradiente proximal inexato:** similar ao método do gradiente proximal, mas avaliando o  $\mathbf{prox}_g$  de forma inexata. Escolha  $x_0 \in \mathbb{R}^n$  e itera para  $k = 0, 1, 2, \dots$

- ▶  $y_k = x_k - \alpha_k \nabla h(x_k)$ ;
- ▶ calcule  $(\bar{x}_k, \bar{w}_k)$  solução aproximada de  $\mathbf{prox}_g$  em  $(\alpha_k, y_k)$ ;
- ▶  $x_{k+1} = y_k - \alpha_k \bar{w}_k$

- ▶ **MGPI-A:**  $(\bar{x}_k, \bar{w}_k)$  é uma  $r_k$ -solução aproximada para todo  $k = 1, 2, \dots$ . Neste caso a sequência  $(r_k)$  deve ser fixada com antecedência.
- ▶ **MGPI-R:**  $(\bar{x}_k, \bar{w}_k)$  é uma  $\sigma$ -solução aproximada para todo  $k = 1, 2, \dots$ , com  $\sigma \in (0, 1)$  fixo.

# O problema de remoção de borrados com variação total



# O problema de remoção de borrados com variação total



# O problema de remoção de borrados com variação total



Para reconstruir uma imagem  $x \in \mathbb{R}^{N \times N}$  a partir de uma imagem borrada e/ou ruidosa  $b \in \mathbb{R}^{N \times N}$ , que descreve os dados obtidos, resolvemos o problema de minimização

$$\min_{x \in \mathbb{R}^{N \times N}} \frac{1}{2} \|Ax - b\|_F^2 + \tau \sum_{i,j=1}^N \|(\nabla x)_{i,j}\|_2.$$



- ▶  $A : \mathbb{R}^{N \times N} \rightarrow \mathbb{R}^{N \times N}$  é um operador linear que gera a imagem borrada;
- ▶  $\|\cdot\|_F$  é a norma de Frobenius para matrizes;
- ▶  $\tau > 0$  parâmetro de regularização;
- ▶  $\nabla : \mathbb{R}^{N \times N} \rightarrow \mathbb{R}^{N \times N} \times \mathbb{R}^{N \times N}$  é o gradiente discreto

$$(\nabla_1 x)_{ij} = x_{i+1,j} - x_{i,j} \quad \text{e} \quad (\nabla_2 x)_{ij} = x_{i,j+1} - x_{i,j};$$

- ▶  $\|\cdot\|_2$  é a norma Euclideana em  $\mathbb{R}^2$ .

Para resolver o problema consideramos:

- ▶  $h(x) = \frac{1}{2} \|Ax - b\|_F^2$ ;
- ▶  $g(x) = \tau \sum_{i,j=1}^N \|(\nabla x)_{i,j}\|_2$ ;
- ▶  $\alpha_k = 1/L$  com  $L = \|A^*A\|$ ;
- ▶  $x_0 = b$ ;
- ▶  $\tau = 10^{-4}$ .

Method	RelDiff	FuncVal	CPU time (s)
MGPI-R			
$\sigma = 0.9$	0.00009950	0.36002654	151
$\sigma = 0.5$	0.00009952	0.35995523	181
$\sigma = 0.1$	0.00009955	0.35987295	306
MGPI-A: $\sqrt{r_k} = 1/k^q$			
$q = 1.1$	0.00009956	0.35986216	336
$q = 1.5$	0.00009957	0.35985049	1039
$q = 1.9$	0.00009957	0.35987493	1423
MGPI-A: $\sqrt{r_k} = C/k^q$			
$q = 1.1$	0.00009956	0.35991933	137
$q = 1.5$	0.00009956	0.35986485	669
$q = 1.9$	0.00009956	0.35984404	1244

**Tabela:** Resultados numéricos.  $\text{RelDiff} = \|x_k - x_{k-1}\| / \|x_k\|$ . Critério de parada  $\text{RelDiff} < 10^{-4}$ .

- [1] Yu. Nesterov. Introductory Lectures on Convex Optimization. Kluwer, Boston (2004).
- [2] A. Izmailov, M. Solodov. Otimização, Volume 2: Métodos Computacionais. Rio de Janeiro, Brazil, Segunda Edição (2012).
- [3] Millán, R.D. and Machado, M.P. Inexact proximal  $\epsilon$ -subgradient methods for composite convex optimization problems. J Glob Optim (2019).  
<https://doi.org/10.1007/s10898-019-00808-8>