

# Métodos inerciais para resolver problemas de otimização convexa

Majela Pentón  
UFBA

Novembro, 2024

Minimização convexa e aplicações

Métodos do gradiente e do subgradiente

Métodos inerciais

## Minimização convexa

$$\min f(x)$$

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

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

# Minimização convexa

$$\min f(x)$$

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

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  função convexa
- ▶  $x^*$  solução do problema
- ▶  $f^* = f(x^*)$  valor ótimo

# Aplicações

## Aprendizado de máquina (machine learning)

Tem como objetivo principal tomar decisões ou fazer previsões baseado em dados

# Aplicações

## Aprendizado de máquina (machine learning)

Tem como objetivo principal tomar decisões ou fazer previsões baseado em dados

- ▶ Reconhecimento facial
- ▶ Processamento de linguagem (tradutor de Google)
- ▶ Sistemas de recomendação (Netflix, Amazon, ...)
- ▶ Predição de tumores
- ▶ Estimar preços
- ▶ Decidir se um empréstimo será aprovado ou não

## Mínimos quadrados $\ell_1$ -regularizado (Lasso)

O objetivo do problema é encontrar uma solução esparsa do sistema de equações  $Ax = b$ .

$$\begin{aligned} \min \quad & \frac{1}{2} \|Ax - b\|_2^2 + \mu \|x\|_1 \\ \text{s.a.} \quad & x \in \mathbb{R}^n \end{aligned}$$

## Mínimos quadrados $\ell_1$ -regularizado (Lasso)

O objetivo do problema é encontrar uma solução esparsa do sistema de equações  $Ax = b$ .

$$\begin{aligned} \min \quad & \frac{1}{2} \|Ax - b\|_2^2 + \mu \|x\|_1 \\ \text{s.a.} \quad & x \in \mathbb{R}^n \end{aligned}$$

- ▶  $A \in \mathbb{R}^{m \times n}$
- ▶  $b \in \mathbb{R}^m$
- ▶  $\mu > 0$

# Aplicações

## Processamento de imagens e sinais

- ▶ Remoção de ruído de imagens (modelo total variation)
- ▶ Remoção de borrados de imagens (deblurring)
- ▶ Compressed sensing

## Total variation

Para reconstruir uma imagem  $u \in \mathbb{R}^{m \times n}$  a partir de uma imagem borrada e/ou ruidosa  $b \in \mathbb{R}^{m \times n}$ , que descreve os dados obtidos, como solução do problema:

$$\min_{u \in \mathbb{R}^{m \times n}} \mu TV(u) + \frac{1}{2} \|u - b\|_F^2$$

## Total variation

Para reconstruir uma imagem  $u \in \mathbb{R}^{m \times n}$  a partir de uma imagem borrada e/ou ruidosa  $b \in \mathbb{R}^{m \times n}$ , que descreve os dados obtidos, como solução do problema:

$$\min_{u \in \mathbb{R}^{m \times n}} \mu TV(u) + \frac{1}{2} \|u - b\|_F^2$$



$$\min_{u \in \mathbb{R}^{m \times n}} \mu TV(u) + \frac{1}{2} \|u - b\|_F^2$$

- ▶  $\mu > 0$
- ▶  $\|\cdot\|_F$  é a norma de Frobenius para matrizes
- ▶  $TV$  é a norma de variação total

$$TV(u) = \|\nabla_1 u\|_1 + \|\nabla_2 u\|_1$$

onde

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

# Minimização convexa

- ▶ Todo mínimo local é global

# Minimização convexa

- ▶ Todo mínimo local é global
- ▶ Se a função é diferenciável, a condição necessária de primeira ordem é suficiente.

**Condição necessária de primeira ordem:** Se  $f$  é uma função diferenciável em  $\mathbb{R}^n$  e  $x^*$  é um mínimo local de  $f$  então

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

## Método do gradiente

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

## Método do gradiente

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


Gera uma sequência  $(f(x_k))_{k \in \mathbb{N}}$  tal que  $f(x_{k+1}) \leq f(x_k)$

## Método do gradiente

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

Gera uma sequência  $(f(x_k))_{k \in \mathbb{N}}$  tal que  $f(x_{k+1}) \leq f(x_k)$

- ▶ Escolher um ponto inicial  $x_0 \in \mathbb{R}^n$
- ▶ Iterar:  $x_{k+1} = x_k - \alpha \nabla f(x_k)$ ,  $k = 0, 1, \dots$
- ▶  $\alpha > 0$  é o **comprimento de passo** tal que  $f(x_{k+1}) \leq f(x_k)$ .



## Convergência

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, diferenciável e  $\nabla f$  é  $L$ -Lipschitz contínuo (com  $L > 0$ ) em  $\mathbb{R}^n$ :

- ▶ Se  $(x_k)_{k \in \mathbb{N}}$  é gerada pelo método do gradiente com passo  $\alpha = 1/L$ , então a sequência converge a uma solução global.

## Convergência

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, diferenciável e  $\nabla f$  é  $L$ -Lipschitz contínuo (com  $L > 0$ ) em  $\mathbb{R}^n$ :

- ▶ Se  $(x_k)_{k \in \mathbb{N}}$  é gerada pelo método do gradiente com passo  $\alpha = 1/L$ , então a sequência converge a uma solução global.

## $\epsilon$ -solução

Dado  $\epsilon > 0$ ,  $\bar{x}$  é uma  $\epsilon$ -solução se  $f(\bar{x}) - f^* \leq \epsilon$

## Convergência

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, diferenciável e  $\nabla f$  é  $L$ -Lipschitz contínuo (com  $L > 0$ ) em  $\mathbb{R}^n$ :

- ▶ Se  $(x_k)_{k \in \mathbb{N}}$  é gerada pelo método do gradiente com passo  $\alpha = 1/L$ , então a sequência converge a uma solução global.

## $\epsilon$ -solução

Dado  $\epsilon > 0$ ,  $\bar{x}$  é uma  $\epsilon$ -solução se  $f(\bar{x}) - f^* \leq \epsilon$

## Taxa de convergência

- ▶ O método do gradiente tem **taxa de convergência**  $\mathcal{O}(1/k)$ .  
Ou seja, o # de iterações para obter uma  $\epsilon$ -**solução** é  $\mathcal{O}(1/\epsilon)$ .



# Método do gradiente

## Vantagens:

- ▶ ideia simples
- ▶ fácil implementação
- ▶ usualmente as iterações são baratas

# Método do gradiente

## Vantagens:

- ▶ ideia simples
- ▶ fácil implementação
- ▶ usualmente as iterações são baratas

## Desvantagens:

- ▶ não pode ser aplicado a funções não diferenciáveis
  - $\frac{1}{2} \|Ax - b\|_2^2 + \mu \|x\|_1$
  - $\mu TV(u) + \frac{1}{2} \|u - b\|_F^2$

## Funções convexas não diferenciáveis


*Generalização da noção de derivada:* Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa,  $v \in \mathbb{R}^n$  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

Generalização da noção de derivada: Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa,  $v \in \mathbb{R}^n$  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

Generalização da noção de derivada: Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa,  $v \in \mathbb{R}^n$  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.

## Funções convexas não diferenciáveis

Generalização da noção de derivada: Se  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa,  $v \in \mathbb{R}^n$  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.
- ▶ *Condição de otimalidade:*  $x^*$  é um mínimo de  $f$  se e somente se  $0$  é um subgradiente de  $f$  em  $x^*$ .

## Método do subgradiente

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

## Método do subgradiente

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

Gera uma sequência  $(x_k)_{k \in \mathbb{N}}$

- ▶ Escolher um ponto inicial  $x_0 \in \mathbb{R}^n$
- ▶ Iterar:  $x_{k+1} = x_k - \alpha v_k$ ,  $k = 0, 1, 2, \dots$ ,  
 $v_k$  é subgradiente de  $f$  em  $x_k$
- ▶  $\alpha > 0$  é o comprimento do passo.

## Método do subgradiente

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

Gera uma sequência  $(x_k)_{k \in \mathbb{N}}$

- ▶ Escolher um ponto inicial  $x_0 \in \mathbb{R}^n$
- ▶ Iterar:  $x_{k+1} = x_k - \alpha v_k$ ,  $k = 0, 1, 2, \dots$ ,  
 $v_k$  é subgradiente de  $f$  em  $x_k$
- ▶  $\alpha > 0$  é o comprimento do passo.
- ▶ O método é similar ao método do gradiente, mas substituindo gradientes por subgradientes.

## Taxa de convergência

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

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

## Taxa de convergência

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

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

- 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.

- ▶ A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta!

- ▶ A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta!

Pode-se melhorar?

- ▶ A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta!

Pode-se melhorar? **Em geral não!** [Nes04]

- ▶ A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta!

Pode-se melhorar? **Em geral não!** [Nes04]

$$\frac{1}{2} \|Ax - b\|_2^2 + \mu \|x\|_1$$

- ▶ A taxa de convergência  $\mathcal{O}(1/\sqrt{k})$  é muito lenta!

Pode-se melhorar? **Em geral não!** [Nes04]

$$\frac{1}{2} \|Ax - b\|_2^2 + \mu \|x\|_1$$

Considerando funções da forma

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

onde  $h$  é convexa e diferenciável e  $g$  é convexa, a taxa de convergência  $\mathcal{O}(1/k)$  do método do gradiente pode ser recuperada com um algoritmo simples.

## Operador proximal

Se  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, dado  $\alpha > 0$  definimos

$\mathbf{prox}_{\alpha g} : \mathbb{R}^n \rightarrow \mathbb{R}^n$

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

## Operador proximal

Se  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, dado  $\alpha > 0$  definimos

$\mathbf{prox}_{\alpha g} : \mathbb{R}^n \rightarrow \mathbb{R}^n$

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

- Se  $C$  é um conjunto convexo e fechado e  $g = \delta_C$ , então

$$\mathbf{prox}_g(z) = P_C(z)$$

## Operador proximal

Se  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa, dado  $\alpha > 0$  definimos  $\mathbf{prox}_{\alpha g} : \mathbb{R}^n \rightarrow \mathbb{R}^n$

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

- Se  $C$  é um conjunto convexo e fechado e  $g = \delta_C$ , então

$$\mathbf{prox}_g(z) = P_C(z)$$

- Se  $g(z) = \alpha \|z\|_1$ , então

$$\mathbf{prox}_g(z) = \mathbf{shrink}(z, \alpha),$$

onde  $\mathbf{shrink}(z, \alpha)_i := \max\{|z_i| - \alpha, 0\} \text{sign}(z_i)$ .

## Método do gradiente proximal

- ▶  $f(x) = h(x) + g(x)$  é tal que  $h, g$  são convexas e  $h$  é diferenciável com gradiente  $L$ -Lipschitz contínuo.

## Método do gradiente proximal

- ▶  $f(x) = h(x) + g(x)$  é tal que  $h, g$  são convexas e  $h$  é diferenciável com gradiente  $L$ -Lipschitz contínuo.

Gera uma sequência  $(x_k)_{k \in \mathbb{N}}$

- ▶ Escolher um ponto inicial  $x_0 \in \mathbb{R}^n$
- ▶ Iterar:  $x_{k+1} = \mathbf{prox}_{\alpha g}(x_k - \alpha \nabla h(x_k))$ ,  $k = 0, 1, 2, \dots$ ,
- ▶  $\alpha > 0$  é o comprimento do passo.

## Método do gradiente proximal

- ▶  $f(x) = h(x) + g(x)$  é tal que  $h, g$  são convexas e  $h$  é diferenciável com gradiente  $L$ -Lipschitz contínuo.

Gera uma sequência  $(x_k)_{k \in \mathbb{N}}$

- ▶ Escolher um ponto inicial  $x_0 \in \mathbb{R}^n$
- ▶ Iterar:  $x_{k+1} = \mathbf{prox}_{\alpha g}(x_k - \alpha \nabla h(x_k))$ ,  $k = 0, 1, 2, \dots$ ,
- ▶  $\alpha > 0$  é o comprimento do passo.

### Taxa de convergência

- ▶ Se  $\alpha \leq 1/L$ , o método do gradiente proximal tem taxa de convergência  $\mathcal{O}(1/k)$  ([BeT09], [MoS10]).

É recuperada a taxa de convergência do método do gradiente!

Podemos fazer melhor?

## Podemos fazer melhor?

Em [Nes04], foi provado que  $\mathcal{O}(1/k^2)$  é uma cota inferior para a taxa de convergência de métodos que têm apenas informação sobre o gradiente em iterações consecutivas:

$$x_k \in x_0 + \text{Lin}\{\nabla f(x_0), \dots, \nabla f(x_{k-1})\}.$$

## Podemos fazer melhor?

Em [Nes04], foi provado que  $\mathcal{O}(1/k^2)$  é uma cota inferior para a taxa de convergência de métodos que têm apenas informação sobre o gradiente em iterações consecutivas:

$$x_k \in x_0 + \text{Lin}\{\nabla f(x_0), \dots, \nabla f(x_{k-1})\}.$$

- ▶ Existe método ótimo?

## Podemos fazer melhor?

Em [Nes04], foi provado que  $\mathcal{O}(1/k^2)$  é uma cota inferior para a taxa de convergência de métodos que têm apenas informação sobre o gradiente em iterações consecutivas:

$$x_k \in x_0 + \text{Lin}\{\nabla f(x_0), \dots, \nabla f(x_{k-1})\}.$$

- ▶ Existe método ótimo?

Sim! Os métodos do gradiente e do gradiente proximal podem ser acelerados para obter a taxa de convergência  $\mathcal{O}(1/k^2)$ .

## Método do gradiente acelerado

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa diferenciável com gradiente  $L$ -Lipschitz contínuo.

[Nes83], [Nes04]

- ▶ Escolher ponto inicial  $x_0 = x_{-1} \in \mathbb{R}^n$  e  $t_1 = 1$
- ▶ Iterar:

- $$t_{k+1} = \frac{1 + \sqrt{4t_k^2 + 1}}{2}$$
- $$y_k = x_k + \frac{t_k - 1}{t_{k+1}}(x_k - x_{k-1})$$
- $$x_{k+1} = y_k - \frac{1}{L} \nabla f(y_k)$$

## Método do gradiente acelerado

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função convexa diferenciável com gradiente  $L$ -Lipschitz contínuo.

[Nes83], [Nes04]

- ▶ Escolher ponto inicial  $x_0 = x_{-1} \in \mathbb{R}^n$  e  $t_1 = 1$
- ▶ Iterar:

- $t_{k+1} = \frac{1 + \sqrt{4t_k^2 + 1}}{2}$
- $y_k = x_k + \frac{t_k - 1}{t_{k+1}}(x_k - x_{k-1})$
- $x_{k+1} = y_k - \frac{1}{L}\nabla f(y_k)$

- ▶  $f(x_k) - f^* = \mathcal{O}(1/k^2)$

## Método do gradiente proximal acelerado

- ▶  $f(x) = h(x) + g(x)$  é tal que  $h, g$  são convexas e  $h$  é diferenciável com gradiente  $L$ -Lipschitz contínuo.

[BeT09] (FISTA)

## Método do gradiente proximal acelerado

- ▶  $f(x) = h(x) + g(x)$  é tal que  $h, g$  são convexas e  $h$  é diferenciável com gradiente  $L$ -Lipschitz contínuo.

[BeT09] (FISTA)

- ▶ Escolher ponto inicial  $x_0 = x_{-1} \in \mathbb{R}^n$  e  $t_1 = 1$

▶ Iterar:

- $t_{k+1} = \frac{1 + \sqrt{4t_k^2 + 1}}{2}$
- $y_k = x_k + \frac{t_k - 1}{t_{k+1}}(x_k - x_{k-1})$
- $x_{k+1} = \mathbf{prox}_{1/Lg}(y_k - \frac{1}{L}\nabla h(y_k))$

- ▶  $f(x_k) - f^* = \mathcal{O}(1/k^2)$

## Métodos inerciais

$$\begin{cases} y_k = x_k + \lambda_k(x_k - x_{k-1}) \\ x_{k+1} = \mathbf{prox}_{\alpha g}(y_k - \alpha \nabla h(y_k)) \end{cases}$$

- ▶  $\alpha \in (0, 1/L]$  e  $\lambda_k \geq 0$

## Métodos inerciais

$$\begin{cases} y_k = x_k + \lambda_k(x_k - x_{k-1}) \\ x_{k+1} = \mathbf{prox}_{\alpha g}(y_k - \alpha \nabla h(y_k)) \end{cases}$$

- ▶  $\alpha \in (0, 1/L]$  e  $\lambda_k \geq 0$
- ▶ FISTA (e o método do gradiente acelerado) corresponde a escolha

$$\lambda_k = \frac{t_k - 1}{t_{k+1}} \quad \text{com} \quad t_{k+1} = \frac{1 + \sqrt{4t_k^2 + 1}}{2}$$

## Métodos inerciais

$$\begin{cases} y_k = x_k + \lambda_k(x_k - x_{k-1}) \\ x_{k+1} = \mathbf{prox}_{\alpha g}(y_k - \alpha \nabla h(y_k)) \end{cases}$$

- ▶  $\alpha \in (0, 1/L]$  e  $\lambda_k \geq 0$
- ▶ FISTA (e o método do gradiente acelerado) corresponde a escolha

$$\lambda_k = \frac{t_k - 1}{t_{k+1}} \quad \text{com} \quad t_{k+1} = \frac{1 + \sqrt{4t_k^2 + 1}}{2}$$

- ▶ Outras escolhas da sequência de parâmetros inerciais  $(\lambda_k)_{k \in \mathbb{N}}$  permite melhorar a velocidade de convergência do método e obter propriedades de convergência de  $(x_k)_{k \in \mathbb{N}}$ .

[AtC18], [AtC16]

►  $\lambda_k = 1 - \frac{\lambda}{k}$

[AtC18], [AtC16]

▶  $\lambda_k = 1 - \frac{\lambda}{k}$

- Se  $\lambda > 3$ , então

$$f(x_k) - f^* = o(1/k^2)$$

e a sequência  $(x_k)_{k \in \mathbb{N}}$  converge [CaF11].

[AtC18], [AtC16]

▶  $\lambda_k = 1 - \frac{\lambda}{k}$

- Se  $\lambda > 3$ , então

$$f(x_k) - f^* = o(1/k^2)$$

e a sequência  $(x_k)_{k \in \mathbb{N}}$  converge [CaF11].

- Se  $\lambda = 3$ , a sequência  $\lambda_k$  se comporta similar a sequência de parâmetros inerciais de FISTA e a taxa de convergência é  $\mathcal{O}(1/k^2)$ .

[AtC18], [AtC16]

▶  $\lambda_k = 1 - \frac{\lambda}{k}$

- Se  $\lambda > 3$ , então

$$f(x_k) - f^* = o(1/k^2)$$

e a sequência  $(x_k)_{k \in \mathbb{N}}$  converge [CaF11].

- Se  $\lambda = 3$ , a sequência  $\lambda_k$  se comporta similar a sequência de parâmetros inerciais de FISTA e a taxa de convergência é  $\mathcal{O}(1/k^2)$ .
- A convergência da sequência  $(x_k)_{k \in \mathbb{N}}$  gerada por FISTA é um problema em aberto.

## “Inexact proximal $\epsilon$ -subgradient methods for composite convex optimization problems” (with R.D. Millan)

- ▶ Método do gradiente proximal acelerado com cálculo aproximado do operador proximal.

## “Inexact proximal $\epsilon$ -subgradient methods for composite convex optimization problems” (with R.D. Millan)

- ▶ Método do gradiente proximal acelerado com cálculo aproximado do operador proximal.
  - erro relativo ([Bel20])
  - erro absoluto e aproximação do gradiente [Sch11]
  - erro absoluto [Vil13]

“An inertial projective splitting method for the sum of two maximal monotone operators.”

- ▶ Métodos de decomposição inerciais para resolver problemas de inclusão monótona.

“An inertial projective splitting method for the sum of two maximal monotone operators.”

- ▶ Métodos de decomposição inerciais para resolver problemas de inclusão monótona.
  - cálculo aproximado dos subproblemas proximais com erro relativo
  - convergência da sequência gerada pelo método
  - taxa de convergência para soluções aproximadas do problema de inclusão monótona
  - quando aplicado a otimização convexa, qual é a taxa de convergência dos valores funcionais?

Obrigada!

# Referências:

[AtC18] H. Attouch, and A. Cabot. Convergence rates of inertial Forward-backward algorithms. *Siam J. Optim.*, 28 (2018), 849–874.

[AtP16] H. Attouch and J. Peypouquet. The rate of convergence of Nesterov’s accelerated forward-backward method is actually faster than  $\frac{1}{k^2}$ . *SIAM J. Optim.*, 26 (2016), 1824–1834.

[Bel20] Bello Cruz, Y.; Gonçalves, M.L.N.; Krislock, N.: On inexact accelerated proximal gradient methods with relative error rules, (2020)

[CaF11] A. Cabot and P. Frankel, Asymptotics for some proximal-like method involving inertia and memory aspects, *Set Valued Var. Anal.*, 19 (2011), 59–74.

# Referências:

[MiM19] R.D. Millán and M.P. Machado. Inexact proximal  $\epsilon$ -subgradient methods for composite convex optimization problems. J Glob Optim (2019).

<https://doi.org/10.1007/s10898-019-00808-8>

[Mac23] M. P. Machado. An inertial projective splitting method for the sum of two maximal monotone operators (2023).

[Nes83] Nesterov, Y.: A method of solving a convex programming problem with convergence rate  $O(1/k^2)$ . Sov.Math. Dokl.27, 372–376 (1983)

[Nes04] Nesterov, Y.: Introductory Lectures on Convex Optimization. Kluwer, Boston, 2004

[Sch11] Schmidt, M., Le Roux, N., Bach, F.: Convergence rates of inexact proximal-gradient methods for convex optimization. In: NIPS'11—25th Annual Conference on Neural Information Processing Systems(Grenada, Spain, Dec. 2011)

[Vil13] S. Villa, S. Salzo, L. Baldassarre and A. Verri. Accelerated and inexact forward-backward algorithms. JSIAM J. Optim., 23(3) (2013), 1607–1633.