

# Convergência global de algoritmos de descida: um pouco além de Armijo, ângulo e proporcionalidade

**Douglas S. Gonçalves**

Department of Applied Mathematics  
University of Campinas (UNICAMP)

Campinas, Outubro, 2012

Partially supported by CNPq, FAPESP

## O problema

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  continuamente diferenciável

$$\begin{aligned} \min_x \quad & f(x) \\ \text{s.a} \quad & x \in \Omega = \mathbb{R}^n \end{aligned}$$

Solução  $x^*$

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

Algoritmos de Descida

$$x_{k+1} = x_k + t_k d_k$$

Dado um ponto inicial  $x^0$ , espera-se que

$$f(x_{k+1}) < f(x_k), \quad k = 0, 1, \dots,$$

## O problema

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  continuamente diferenciável

$$\begin{array}{ll} \min_x & f(x) \\ \text{s.a} & x \in \Omega = \mathbb{R}^n \end{array}$$

Solução  $x^*$

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

## Algoritmos de Descida

$$x_{k+1} = x_k + t_k d_k$$

Dado um ponto inicial  $x^0$ , espera-se que

$$f(x_{k+1}) < f(x_k), \quad k = 0, 1, \dots,$$


Direções de descida

$$\nabla f(x)^T d < 0$$

Expansão Taylor (Ordem 1)

$$f(x + t d) = f(x) + t \nabla f(x)^T d + o(t)$$

$\exists t > 0$  tal que  $f(x + t d) < f(x)$



Bertsekas, 1999

Métodos de direções de descida

$$x_{k+1} = x_k + t_k d_k,$$

onde  $\forall k, \nabla f(x_k)^T d_k < 0$

(se  $\nabla f(x_k) \neq 0$ )

$$f(x_k + t_k d_k) < f(x_k), \quad k = 0, 1, \dots$$


Direções de descida

$$\nabla f(x)^T d < 0$$

Expansão Taylor (Ordem 1)

$$f(x + t d) = f(x) + t \nabla f(x)^T d + o(t)$$

$\exists t > 0$  tal que  $f(x + t d) < f(x)$



Bertsekas, 1999

Métodos de direções de descida


$$x_{k+1} = x_k + t_k d_k,$$

onde  $\forall k, \nabla f(x_k)^T d_k < 0$

(se  $\nabla f(x_k) \neq 0$ )

$$f(x_k + t_k d_k) < f(x_k), \quad k = 0, 1, \dots$$

Decréscimo simples não é suficiente ...




Bertsekas, 1999

Precisamos de um **decréscimo substancial!**

Condição de Armijo

$$f(x_k + t_k d_k) \leq f(x_k) + \sigma t \nabla f(x_k)^T d_k, \quad \sigma \in (0, 1)$$

Decréscimo simples não é suficiente ...

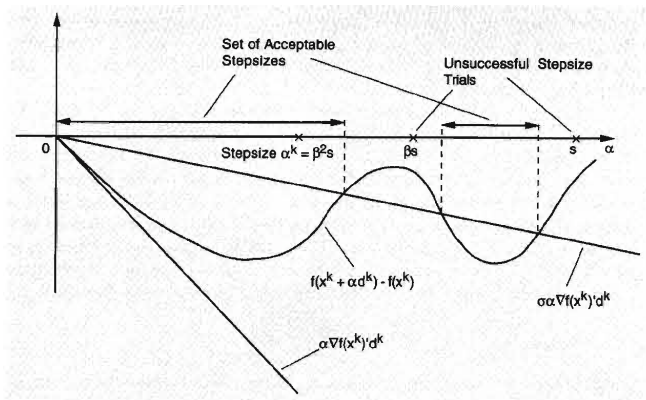


Bertsekas, 1999

Precisamos de um **decréscimo substancial!**

Condição de Armijo

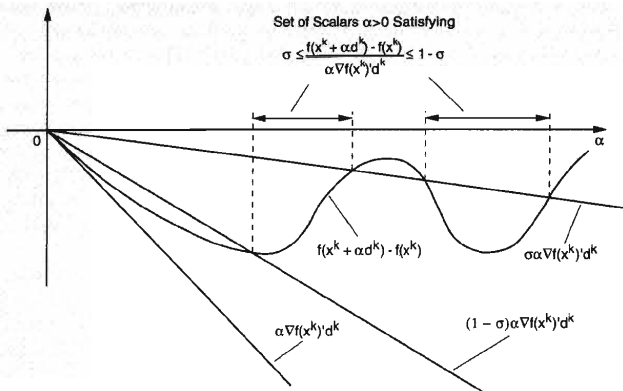
$$f(x_k + t_k d_k) \leq f(x_k) + \sigma t \nabla f(x_k)^T d_k, \quad \sigma \in (0, 1)$$



Bertsekas, 1999

$$\frac{f(x_k + t_k d_k) - f(x_k)}{t_k \nabla f(x_k)^T d_k} \geq \sigma$$






Bertsekas, 1999

$$\sigma \leq \frac{f(x_k + t_k d_k) - f(x_k)}{t_k \nabla f(x_k)^T d_k} \leq 1 - \sigma, \quad \sigma \in (0, \frac{1}{2})$$

# Wolfe


- 1  $f(x_k + t_k d_k) \leq f(x_k) + c_1 t_k \nabla f(x_k)^T d_k,$   $c_1 \in (0, 1)$
- 2  $\nabla f(x_k + t_k d_k)^T d_k \geq c_2 \nabla f(x_k)^T d_k,$   $c_2 \in (c_1, 1)$



Nocedal & Wright, 1999

## Proporcionalidade

Apenas Armijo não basta!



$$x_k = 1 + \frac{1}{2^k}, \quad t_k = 1$$

$$d_k = x_{k+1} - x_k, \quad \sigma = \frac{1}{2}$$

$$\left(1 + \frac{1}{2^{k+1}}\right)^2 < \left(1 + \frac{1}{2^k}\right)^2 - \frac{1}{2} \left(1 + \frac{1}{2^k}\right) \frac{1}{2^{k+1}}$$

- Às vezes passos pequenos são inevitáveis
- Devemos ao menos tentar passos grandes (sobretudo longe da solução)

$$\|d_k\| \geq \beta \|\nabla f(x_k)\|, \quad \beta > 0$$

# Ângulo

$$f(x_{k+1}) = f(x_k) + t_k \nabla f(x_k)^T d_k + o(t_k)$$

- Se  $\nabla f(x_k)^T d_k$  tem magnitude substancial, o progresso pode ser substancial
- Por outro lado, problemas à vista quando

$$\frac{-\nabla f(x_k)^T d_k}{\|\nabla f(x_k)\| \|d_k\|} = \cos \theta_k \rightarrow 0$$

## Exemplo

$$f(x) = \frac{1}{2} \|x\|_2^2, \quad \nabla f(x) = x$$

$$d_k = U_k(-x_k)$$

$$U_k = \begin{bmatrix} \cos \theta_k & -\sin \theta_k \\ \sin \theta_k & \cos \theta_k \end{bmatrix}, \quad \theta_k = \frac{\pi}{2} \left(1 - \frac{1}{k^2+1}\right), \quad \beta = 1.$$


Para  $\sigma \in (0, \frac{1}{2})$ , podemos mostrar que





$$\frac{1}{2} \|x_k - t U_k x_k\|^2 \leq \frac{1}{2} \|x_k\|^2 - \sigma t x_k^T U_k x_k$$

é satisfeita para

$$0 < t < \frac{x_k^T U_k x_k}{\|x_k\|^2} = \cos \theta_k$$

Usando  $t_k = \frac{x_k^T U_k x_k}{1 + \|x_k\|^2}$ ,  $x_0 = (2, 2)^T$





## Theorem (Nocedal & Wright, 1999, Zoutendijk, 1976)

Considere uma iteração do tipo  $x_{k+1} = x_k + t_k d_k$ , onde  $d_k$  é uma direção de descida e  $t_k$  satisfaz as *condições de Wolfe*. Suponha que  $f$  é *limitada inferiormente* e continuamente diferenciável em um aberto  $\mathcal{A}$  contendo o conjunto de nível  $\{x \mid f(x) \leq f(x^0)\}$ , onde  $x^0$  é o ponto inicial. Assuma também que o *gradiente* é *Lipschitz* em  $\mathcal{A}$ .

Então

$$\sum_{k \geq 0} \cos^2 \theta_k \|\nabla f(x_k)\|^2 < \infty.$$

Consequência

- $\cos^2 \theta_k \|\nabla f(x_k)\|^2 \rightarrow 0$
- Se  $\cos \theta_k \geq \delta > 0$ ,  $\forall k$  então  $\|\nabla f(x_k)\| \rightarrow 0$ .

## Theorem (Nocedal & Wright, 1999, Zoutendijk, 1976)

Considere uma iteração do tipo  $x_{k+1} = x_k + t_k d_k$ , onde  $d_k$  é uma direção de descida e  $t_k$  satisfaz as *condições de Wolfe*. Suponha que  $f$  é *limitada inferiormente* e continuamente diferenciável em um aberto  $\mathcal{A}$  contendo o conjunto de nível  $\{x \mid f(x) \leq f(x^0)\}$ , onde  $x^0$  é o ponto inicial. Assuma também que o *gradiente* é *Lipschitz* em  $\mathcal{A}$ .

Então

$$\sum_{k \geq 0} \cos^2 \theta_k \|\nabla f(x_k)\|^2 < \infty.$$

## Consequência

- $\cos^2 \theta_k \|\nabla f(x_k)\|^2 \rightarrow 0$
- Se  $\cos \theta_k \geq \delta > 0$ ,  $\forall k$  então  $\|\nabla f(x_k)\| \rightarrow 0$ .



## Gradient related

### Definição (Bertsekas, 1999)

Seja  $\{x_k, d_k\}$  uma sequência gerada por um algoritmo de descida. A sequência de direções  $\{d_k\}$  é dita *gradient related* se

para qualquer subsequência  $\{x_k\}_{k \in \mathcal{K}}$  que converge a um ponto não-estacionário, a subsequência correspondente de direções  $\{d_k\}_{k \in \mathcal{K}}$  é *limitada* e satisfaz

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T d_k < 0.$$

### Significado

A direção  $d_k$  não será “muito pequena” ou “muito grande” em relação a  $\nabla f(x_k)$  e que o ângulo entre  $d_k$  e  $\nabla f(x_k)$  não ficará tão próximo de  $90^\circ$ .

## Gradient related

### Definição (Bertsekas, 1999)

Seja  $\{x_k, d_k\}$  uma sequência gerada por um algoritmo de descida. A sequência de direções  $\{d_k\}$  é dita *gradient related* se

para qualquer subsequência  $\{x_k\}_{k \in \mathcal{K}}$  que converge a um ponto não-estacionário, a subsequência correspondente de direções  $\{d_k\}_{k \in \mathcal{K}}$  é *limitada* e satisfaz

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T d_k < 0.$$

### Significado

A direção  $d_k$  não será “muito pequena” ou “muito grande” em relação a  $\nabla f(x_k)$  e que o ângulo entre  $d_k$  e  $\nabla f(x_k)$  não ficará tão próximo de  $90^\circ$ .

## Proporcionalidade + Ângulo

- Proporcionalidade (condição  $\beta$ )

$$\|d_k\| \geq \beta \|\nabla f(x_k)\|, \quad \beta > 0$$

- Ângulo

$$\cos \theta_k = \frac{-\nabla f(x_k)^T d_k}{\|\nabla f(x_k)\| \|d_k\|} \geq \delta, \quad \delta \in (0, 1)$$

Seja  $\{x_k\}_{k \in \mathcal{K}}$ , convergindo a  $\bar{x}$  não estacionário.

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T d_k \leq -\delta \beta \|\nabla f(\bar{x})\|^2 < 0.$$

E se  $\{d_k\}$  é limitada então é gradient related.

## Proporcionalidade + Ângulo

- Proporcionalidade (condição  $\beta$ )

$$\|d_k\| \geq \beta \|\nabla f(x_k)\|, \quad \beta > 0$$

- Ângulo

$$\cos \theta_k = \frac{-\nabla f(x_k)^T d_k}{\|\nabla f(x_k)\| \|d_k\|} \geq \delta, \quad \delta \in (0, 1)$$

Seja  $\{x_k\}_{k \in \mathcal{K}}$ , convergindo a  $\bar{x}$  não estacionário.

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T d_k \leq -\delta \beta \|\nabla f(\bar{x})\|^2 < 0.$$

E se  $\{d_k\}$  é limitada então é gradient related.

## Exemplos

- ①  $d_k = -B_k^{-1}\nabla f(x_k)$ ,  $B_k$  simétrica e definida positiva

$$c_1 \|z\|^2 \leq z^T B_k z \leq c_2 \|z\|^2, \quad \forall z \in \mathbb{R}^n, \quad k = 0, 1, \dots,$$

para  $0 < c_1 < c_2$ . (“Autovalores limitados”)

- ② Para  $p_1 \geq 0, p_2 \geq 0$

$$c_1 \|\nabla f(x_k)\|^{p_1} \leq -\nabla f(x_k)^T d_k, \quad \|d_k\| \leq c_2 \|\nabla f(x_k)\|^{p_2}$$

- ③ Generalização de “autovalores limitados”

$$c_1 \|\nabla f(x_k)\|^{p_1} \|z\|^2 \leq z^T B_k z \leq c_2 \|\nabla f(x_k)\|^{p_2} \|z\|^2, \quad \forall z \in \mathbb{R}^n$$

# Convergência Global

## Theorem

Seja  $\{x_k\}$  uma sequência gerada por um algoritmo de descida. Assuma que  $\{d_k\}$  é *gradient related* e que  $t_k$  é escolhido de modo a satisfazer *Armijo*. Então todo ponto limite de  $\{x_k\}$  é estacionário.

## Proof.

- 1 Suponha que uma subsequência  $\{x_k\}_{k \in \mathcal{K}}$  convirja a  $\bar{x}$  não estacionário.
- 2 Usando a condição de Armijo e o fato de  $\{d_k\}$  ser gradient related, chegamos que  $\{t_k\}_{k \in \mathcal{K}} \rightarrow 0$ .
- 3 Como  $\{d_k\}_{\mathcal{K}}$  é limitada, existe  $\{d_k\}_{\bar{\mathcal{K}}}$  convergindo a  $\bar{d}$ .
- 4 Daí mostra-se que

$$0 \leq \nabla f(\bar{x})^T \bar{d},$$

que contradiz o fato de  $\{d_k\}$  ser gradient related.

# Convergência Global

## Theorem

Seja  $\{x_k\}$  uma sequência gerada por um algoritmo de descida. Assuma que  $\{d_k\}$  é *gradient related* e que  $t_k$  é escolhido de modo a satisfazer *Armijo*. Então todo ponto limite de  $\{x_k\}$  é estacionário.

## Proof.

- 1 Suponha que uma subsequência  $\{x_k\}_{k \in \mathcal{K}}$  convirja a  $\bar{x}$  não estacionário.
- 2 Usando a condição de Armijo e o fato de  $\{d_k\}$  ser gradient related, chegamos que  $\{t_k\}_{k \in \mathcal{K}} \rightarrow 0$ .
- 3 Como  $\{d_k\}_{\mathcal{K}}$  é limitada, existe  $\{d_k\}_{\bar{\mathcal{K}}}$  convergindo a  $\bar{d}$ .
- 4 Daí mostra-se que

$$0 \leq \nabla f(\bar{x})^T \bar{d},$$

que contradiz o fato de  $\{d_k\}$  ser gradient related.

# Iterações Híbridas

## Theorem

Seja  $\{x_k\}$  uma sequência tal que

$$f(x_{k+1}) \leq f(x_k), \quad k = 0, 1, \dots$$

Assuma que existe um conjunto infinito de índices  $\mathcal{K}$  tal que

$$x_{k+1} = x_k + t_k d_k, \quad \forall k \in \mathcal{K},$$

onde  $\{d_k\}_{\mathcal{K}}$  é gradient related e  $t_k$  é escolhido segundo Armijo. Então todo ponto limite de uma subsequência de  $\{x_k\}_{\mathcal{K}}$  é estacionário.

- Alternar iterações gradient-based e iterações heurísticas.



# Iterações Híbridas

## Theorem

Seja  $\{x_k\}$  uma sequência tal que

$$f(x_{k+1}) \leq f(x_k), \quad k = 0, 1, \dots$$

Assuma que existe um conjunto infinito de índices  $\mathcal{K}$  tal que

$$x_{k+1} = x_k + t_k d_k, \quad \forall k \in \mathcal{K},$$

onde  $\{d_k\}_{\mathcal{K}}$  é gradient related e  $t_k$  é escolhido segundo Armijo. Então todo ponto limite de uma subsequência de  $\{x_k\}_{\mathcal{K}}$  é estacionário.

- Alternar iterações **gradient-based** e iterações **heurísticas**.

# Teorema da Captura

## Theorem

Seja  $\{x_k\}$  uma sequência gerada por um algoritmo de descida e globalmente convergente. Assuma que existem  $s > 0$  e  $c > 0$  tais que  $\forall k$

$$t_k \leq s, \quad \|d_k\| \leq c \|\nabla f(x_k)\|.$$

Seja  $x_*$  um minimizador local estrito de  $f$ , o qual é o único ponto estacionário de  $f$  dentro de alguma bola aberta. Então existe um conjunto  $S$  contendo  $x_*$  tal que se  $x_{k_0} \in S$  para algum  $k_0 \geq 0$ , então  $x_k \in S$  para todo  $k \geq k_0$  e  $\{x_k\} \rightarrow x_*$ .

# Busca não-monótona

$$f(x_k + t d_k) \leq \max_{0 \leq j \leq \min\{k, M-1\}} f(x_{k-j}) + \sigma t \nabla f(x_k)^T d_k$$

Grippo, Lampariello, Lucidi, 1986

## Condições para convergência

- 1  $\{x \mid f(x) \leq f(x_0)\}$  é compacto
- 2 Existem  $c_1, c_2 > 0$  tais que

$$\nabla f(x_k)^T d_k \leq -c_1 \|\nabla f(x_k)\|^2,$$

$$\|d_k\| \leq c_2 \|\nabla f(x_k)\|.$$

## $\Omega$ convexo



$$\begin{aligned} \min_x \quad & f(x) \\ \text{s.a} \quad & x \in \Omega \subset \mathbb{R}^n \end{aligned}$$

$\Omega$  convexo e fechado

- 1 Se  $x_*$  é minimizador local de  $f$  em  $\Omega$ , então

$$\nabla f(x_*)^T (x - x_*) \geq 0, \quad \forall x \in \Omega$$

- 2 Se  $f$  é convexa em  $\Omega$ , então a condição anterior é também suficiente.



Bertsekas, 1999

## Métodos de direções factíveis

$$x_{k+1} = x_k + t_k d_k$$

$d_k$  é uma direção factível se existe  $\bar{t} > 0$  tal que

$$x_{k+1} = x_k + t d_k \in \Omega, \quad \forall t \in (0, \bar{t}]$$

Podemos expressar direções factíveis como

$$d_k = \bar{x}_k - x_k,$$

onde  $\bar{x}_k \in \Omega$ , e neste caso

$$x_{k+1} = x_k + t_k (\bar{x}_k - x_k), \quad t_k \in (0, 1].$$

# Convergência global

Se  $x_k$  é não estacionário, então

$$\exists \bar{x}_k \in \Omega, \quad \nabla f(x_k)^T (\bar{x}_k - x_k) < 0.$$

## Theorem

*Seja  $\{x_k\}$  uma sequência gerada por um algoritmo de direções factíveis  $x_{k+1} = x_k + t_k d_k$ . Assuma que  $\{d_k\}$  é gradient related e que  $t_k$  escolhido por Armijo. Então todo ponto limite de  $\{x_k\}$  é estacionário.*

## Gradiente condicional

Resolver o problema

$$\begin{aligned} \min_x \quad & \nabla f(x_k)^T (x - x_k) \\ \text{s.a} \quad & x \in \Omega, \end{aligned}$$

e obtendo uma solução  $\bar{x}_k$ , definir a direção

$$d_k = \bar{x}_k - x_k.$$

### Convergência

Suponha  $\Omega$  compacto. Seja  $\{x_k\}_{k \in \mathcal{K}}$  convergindo a  $\tilde{x}$  não estacionário.

$$\nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(x_k)(x - x_k), \quad \forall x \in \Omega,$$

tomando limites

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(\tilde{x})(x - \tilde{x}), \quad \forall x \in \Omega,$$

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \min_{x \in \Omega} \nabla f(\tilde{x})(x - \tilde{x}) < 0.$$

## Gradiente condicional

Resolver o problema

$$\begin{aligned} \min_x \quad & \nabla f(x_k)^T (x - x_k) \\ \text{s.a} \quad & x \in \Omega, \end{aligned}$$

e obtendo uma solução  $\bar{x}_k$ , definir a direção

$$d_k = \bar{x}_k - x_k.$$

### Convergência

Suponha  $\Omega$  compacto. Seja  $\{x_k\}_{k \in \mathcal{K}}$  convergindo a  $\tilde{x}$  não estacionário.

$$\nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(x_k)(x - x_k), \quad \forall x \in \Omega,$$

tomando limites

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(\tilde{x})(x - \tilde{x}), \quad \forall x \in \Omega,$$

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \min_{x \in \Omega} \nabla f(\tilde{x})(x - \tilde{x}) < 0.$$



## Gradiente condicional

Resolver o problema

$$\begin{aligned} \min_x \quad & \nabla f(x_k)^T (x - x_k) \\ \text{s.a} \quad & x \in \Omega, \end{aligned}$$

e obtendo uma solução  $\bar{x}_k$ , definir a direção

$$d_k = \bar{x}_k - x_k.$$

### Convergência

Suponha  $\Omega$  compacto. Seja  $\{x_k\}_{k \in \mathcal{K}}$  convergindo a  $\tilde{x}$  não estacionário.

$$\nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(x_k)(x - x_k), \quad \forall x \in \Omega,$$

tomando limites

$$\lim_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \nabla f(\tilde{x})(x - \tilde{x}), \quad \forall x \in \Omega,$$

$$\lim_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)(\bar{x}_k - x_k) \leq \min_{x \in \Omega} \nabla f(\tilde{x})(x - \tilde{x}) < 0.$$

## Gradiente projetado

$$x_{k+1} = x_k + t_k (\bar{x}_k - x_k),$$

onde

$$\bar{x}_k = \mathcal{P}_\Omega(x_k - s_k \nabla f(x_k))$$

$\mathcal{P}_\Omega(\cdot)$  denota a projeção em  $\Omega$ ,  $s_k > 0$   $t_k \in (0, 1]$ .

### Projection theorem

Seja  $\Omega \subset \mathbb{R}^n$  convexo, não vazio e fechado.

- 1  $\forall z \in \mathbb{R}^n$  existe um único  $x_* \in \Omega$  que minimiza  $\|z - x\|$  sobre  $\Omega$ .  $x_*$  é chamado de projeção de  $z$  em  $\Omega$  e denotado por  $\mathcal{P}_\Omega(z)$ .
- 2 Dado  $z \in \mathbb{R}^n$ ,  $x_* = \mathcal{P}_\Omega(z)$  se e somente se

$$(z - x_*)^T (x - x_*) \leq 0, \quad \forall x \in \Omega$$

- 3 A função  $\mathcal{P}_\Omega : \mathbb{R}^n \rightarrow \Omega$  é contínua e não-expansiva

$$\|\mathcal{P}_\Omega(x) - \mathcal{P}_\Omega(y)\| \leq \|x - y\|, \quad \forall x, y \in \mathbb{R}^n$$

## Gradiente projetado

$$x_{k+1} = x_k + t_k (\bar{x}_k - x_k),$$

onde

$$\bar{x}_k = \mathcal{P}_\Omega(x_k - s_k \nabla f(x_k))$$

$\mathcal{P}_\Omega(\cdot)$  denota a projeção em  $\Omega$ ,  $s_k > 0$   $t_k \in (0, 1]$ .

### Projection theorem

Seja  $\Omega \subset \mathbb{R}^n$  convexo, não vazio e fechado.

- 1  $\forall z \in \mathbb{R}^n$  existe um único  $x_* \in \Omega$  que minimiza  $\|z - x\|$  sobre  $\Omega$ .  $x_*$  é chamado de projeção de  $z$  em  $\Omega$  e denotado por  $\mathcal{P}_\Omega(z)$ .
- 2 Dado  $z \in \mathbb{R}^n$ ,  $x_* = \mathcal{P}_\Omega(z)$  se e somente se

$$(z - x_*)^T (x - x_*) \leq 0, \quad \forall x \in \Omega$$

- 3 A função  $\mathcal{P}_\Omega : \mathbb{R}^n \rightarrow \Omega$  é contínua e não-expansiva

$$\|\mathcal{P}_\Omega(x) - \mathcal{P}_\Omega(y)\| \leq \|x - y\|, \quad \forall x, y \in \mathbb{R}^n$$

## Convergência

Suponha que  $\{x_k\}_{k \in \mathcal{K}}$  converge a um ponto não estacionário  $\tilde{x}$ . A sequência de direções  $\{d_k\}_{k \in \mathcal{K}}$ ,  $d_k = \bar{x}_k - x_k$ , é limitada, já que  $\|\bar{x}_k - x_k\| \rightarrow \|\mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x})) - \tilde{x}\|$ . Como  $\bar{x}_k$  é solução do problema de projeção, temos que

$$(x_k - s\nabla f(x_k) - \bar{x}_k)^T (x - \bar{x}_k) \leq 0, \quad \forall x \in \Omega.$$

Em particular para  $x = x_k$

$$\nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|x_k - \bar{x}_k\|^2,$$

e tomando limites

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|\tilde{x} - \mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x}))\|^2 < 0.$$

FIM

## Convergência

Suponha que  $\{x_k\}_{k \in \mathcal{K}}$  converge a um ponto não estacionário  $\tilde{x}$ . A sequência de direções  $\{d_k\}_{k \in \mathcal{K}}$ ,  $d_k = \bar{x}_k - x_k$ , é limitada, já que  $\|\bar{x}_k - x_k\| \rightarrow \|\mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x})) - \tilde{x}\|$ . Como  $\bar{x}_k$  é solução do problema de projeção, temos que

$$(x_k - s\nabla f(x_k) - \bar{x}_k)^T (x - \bar{x}_k) \leq 0, \quad \forall x \in \Omega.$$

Em particular para  $x = x_k$

$$\nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|x_k - \bar{x}_k\|^2,$$

e tomando limites

$$\limsup_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|\tilde{x} - \mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x}))\|^2 < 0.$$

FIM

## Convergência

Suponha que  $\{x_k\}_{k \in \mathcal{K}}$  converge a um ponto não estacionário  $\tilde{x}$ . A sequência de direções  $\{d_k\}_{k \in \mathcal{K}}$ ,  $d_k = \bar{x}_k - x_k$ , é limitada, já que  $\|\bar{x}_k - x_k\| \rightarrow \|\mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x})) - \tilde{x}\|$ . Como  $\bar{x}_k$  é solução do problema de projeção, temos que

$$(x_k - s\nabla f(x_k) - \bar{x}_k)^T (x - \bar{x}_k) \leq 0, \quad \forall x \in \Omega.$$

Em particular para  $x = x_k$

$$\nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|x_k - \bar{x}_k\|^2,$$

e tomando limites

$$\lim_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|\tilde{x} - \mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x}))\|^2 < 0.$$

FIM

## Convergência

Suponha que  $\{x_k\}_{k \in \mathcal{K}}$  converge a um ponto não estacionário  $\tilde{x}$ . A sequência de direções  $\{d_k\}_{k \in \mathcal{K}}$ ,  $d_k = \bar{x}_k - x_k$ , é limitada, já que  $\|\bar{x}_k - x_k\| \rightarrow \|\mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x})) - \tilde{x}\|$ . Como  $\bar{x}_k$  é solução do problema de projeção, temos que

$$(x_k - s\nabla f(x_k) - \bar{x}_k)^T (x - \bar{x}_k) \leq 0, \quad \forall x \in \Omega.$$

Em particular para  $x = x_k$




$$\nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|x_k - \bar{x}_k\|^2,$$

e tomando limites

$$\lim_{k \rightarrow \infty} \sup_{k \in \mathcal{K}} \nabla f(x_k)^T (\bar{x}_k - x_k) \leq -\frac{1}{s} \|\tilde{x} - \mathcal{P}_\Omega(\tilde{x} - s\nabla f(\tilde{x}))\|^2 < 0.$$

FIM

# Referências

-  D. P. Bertsekas, *Nonlinear programming: 2nd edition*, Athena Scientific, 1999.
-  J. Nocedal & S. J. Wright, *Numerical Optimization*, Springer, 1999.
-  J. M. Martínez & S. A. Santos, *Métodos Computacionais de Otimização*, IMPA, 20<sup>o</sup> Colóquio Brasileiro de Matemática, Rio de Janeiro, SBM, 1995.