

---

# OPTIMIZACIÓN

Primer Cuatrimestre 2018

---

## Práctica N° 2: Métodos de descenso.

### Algoritmos y convergencia

**Ejercicio 1** Dada una constante  $b \in \mathbb{R}$ , considerar la función punto a conjunto dada por:

$$f(x) = \{y \in \mathbb{R}^n : y^t x \leq b\}, \quad \forall x \in \mathbb{R}^n.$$

¿f es cerrada?

**Ejercicio 2** Sean  $f : X \rightarrow Y$  y  $g : Y \rightarrow Z$  dos funciones punto a conjunto. Probar que si  $f$  es cerrada en el punto  $x$ ,  $g$  es cerrada en el conjunto  $f(x)$  e  $Y$  es compacto, entonces  $g \circ f$  es cerrada en  $x$ .

**Ejercicio 3** Sean  $f : X \rightarrow Y$  punto a punto y  $g : Y \rightarrow Z$  punto a conjunto. Probar que si  $f$  es continua en el punto  $x$  y  $g$  es cerrada en el punto  $f(x)$ , entonces  $g \circ f$  es cerrada en  $x$ .

**Ejercicio 4** Mostrar que si  $A$  es una aplicación punto a punto continua, en el Teorema de Convergencia Global puede eliminarse la hipótesis de que los puntos  $x_k$  caigan sobre un compacto.

**Ejercicio 5 (Orden de Convergencia)** Sea  $\{e_k\}$  una sucesión de números no negativos convergente a 0. Decimos que  $\{e_k\}$  converge *linealmente* (o geométricamente) si existen  $q > 0$  y  $\beta \in (0, 1)$  tales que

$$e_k \leq q\beta^k, \quad \forall k \geq 0.$$

Decimos que  $\{e_k\}$  converge *superlinealmente* si para todo  $\beta \in (0, 1)$  existe  $q > 0$  tal que  $e_k \leq q\beta^k$ . Finalmente, dado  $p > 1$ , decimos que  $\{e_k\}$  converge *al menos superlinealmente con orden p* si existen  $q > 0$  y  $\beta \in (0, 1)$  tales que  $e_k \leq q\beta^{p^k}$  para todo  $k \geq 0$ .

a. Verificar que si para algún  $\beta \in (0, 1)$  vale que

$$\limsup_{k \rightarrow \infty} \frac{e_{k+1}}{e_k} = \beta,$$

entonces  $\{e_k\}$  converge linealmente.

b. Mostrar que si

$$\limsup_{k \rightarrow \infty} \frac{e_{k+1}}{e_k} = 0,$$

entonces  $\{e_k\}$  converge superlinealmente.

c. Verificar que si  $\{e_k\}$  converge superlinealmente con orden  $p > 1$ , entonces, efectivamente, converge superlinealmente.

d. Mostrar que si

$$\limsup_{k \rightarrow \infty} \frac{e_{k+1}}{e_k^p} = \beta,$$

entonces  $\{e_k\}$  converge superlinealmente con orden  $p$ .

### Métodos de descenso

**Ejercicio 6** Sea  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ . El algoritmo de descenso genérico consiste en, dado  $x_k \in \mathbb{R}^n$ , dar una dirección  $d_k$  y un paso  $t_k > 0$  tal que  $f(x_k + t_k d_k) < f(x_k)$ , y tomar  $x_{k+1} = x_k + t_k d_k$ .

- Probar que si  $f$  es diferenciable en  $x_k$  y  $\nabla f(x_k) \cdot d_k < 0$ , entonces  $d_k$  es una dirección de descenso.
- Concluir que  $-\nabla f(x_k)$  es una dirección de descenso.

**Ejercicio 7 (Descenso más rápido)** Sea  $f$  de clase  $C^1$  en  $\mathbb{R}^n$ .

- Mostrar que la dirección de  $-\nabla f(x_k)$  es la de máximo descenso. Es decir, mostrar que la pendiente de  $\phi(t) := f(x_k + td)$  en  $t = 0$  se minimiza entre todas las direcciones  $d$  de norma 1 en  $d^* = -\frac{\nabla f(x_k)}{\|\nabla f(x_k)\|}$ .
- (Efecto zigzag)** Dada la sucesión  $(x_k)_{k \geq 1}$  generada por el método del descenso más rápido con búsqueda lineal óptima, mostrar que las direcciones entre iteraciones consecutivas son ortogonales.

**Ejercicio 8** Sea  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  una función cuadrática, y sea  $d_k$  una dirección de descenso en el punto  $x_k$ . Probar que el paso óptimo está dado por:

$$t_k = -\frac{d_k^t \nabla f(x_k)}{d_k^t H f(x_k) d_k}.$$

**Ejercicio 9** Una función  $f : \mathbb{R} \rightarrow \mathbb{R}$  se dice *unimodal* en el intervalo  $[a, b]$  si existe  $x^* \in (a, b)$  tal que  $f$  es estrictamente decreciente en  $(a, x^*)$  y estrictamente creciente en  $(x^*, b)$ . Probar que si  $f$  es unimodal y continua en  $[a, b]$  entonces tiene un único mínimo en  $[a, b]$ . Probar además que dados  $\alpha, \beta$  tales que  $a < \alpha < \beta < b$  vale que:

- Si  $f(\alpha) \leq f(\beta)$ , entonces  $f$  es unimodal en  $[a, \beta]$ ,
- Si  $f(\alpha) \geq f(\beta)$ , entonces  $f$  es unimodal en  $[\alpha, b]$ .

**Ejercicio 10** Implementar un algoritmo que reciba como entrada una función  $f$ , un intervalo  $[a, b]$ , y una tolerancia  $\delta$  y calcule el mínimo de  $f$  en  $[a, b]$  con error menor o igual que  $\delta$ , mediante el algoritmo de búsqueda por la razón dorada.

**Ejercicio 11** Dada  $\delta > 0$ , sea la función punto a conjunto  $\mathbf{S}^\delta$  definida como

$$\mathbf{S}^\delta(x, d) = \left\{ y : y = x + \alpha d, \quad 0 \leq \alpha \leq \delta; \quad f(y) = \min_{0 \leq \beta \leq \delta} f(x + \beta d) \right\}.$$

Explicar lo que hace  $\mathbf{S}^\delta$  y probar que si  $f$  es continua entonces  $\mathbf{S}^\delta(x, d)$  es cerrada en  $(x, d)$ . ¿Por qué es importante este resultado?

**Ejercicio 12** Sea  $\varepsilon > 0$ , sea la función punto a conjunto  $\mathbf{S}^\varepsilon$  definida como

$$\mathbf{S}^\varepsilon(x, d) = \left\{ y : y = x + \alpha d, \quad 0 \leq \alpha; \quad f(y) \leq \min_{0 \leq \beta} f(x + \beta d) + \varepsilon \right\}.$$

Explicar lo que hace  $\mathbf{S}^\varepsilon$  y probar que si  $f$  es continua y  $d \neq 0$  entonces  $\mathbf{S}^\varepsilon(x, d)$  es cerrada en  $(x, d)$ . ¿Por qué es importante este resultado?

**Ejercicio 13** Implementar un algoritmo que reciba como datos una función  $f$ , un punto  $x_k$  y una dirección  $d_k$  y aplique la condición de Armijo para determinar el paso del descenso, devolviendo el correspondiente  $x_{k+1}$ .

**Ejercicio 14** Implementar un programa similar al del ejercicio anterior, pero utilizando la condición de Goldstein.

**Ejercicio 15** Probar que la condición de Goldstein determina un algoritmo de búsqueda cerrado.

**Ejercicio 16** Sea  $Q \in \mathbb{R}^{n \times n}$  definida positiva y sean  $v_1, \dots, v_n$  vectores l.i. Mostrar que el método de Gram-Schmidt puede ser usado para generar una secuencia de direcciones  $Q$ -ortogonales desde los  $v_i$ . Específicamente, muestre que

$$d_1 = v_1; \quad d_{k+1} = v_{k+1} - \sum_{i=1}^k \frac{v_{k+1}^t Q d_i}{d_i^t Q d_i} d_i$$

forma un conjunto  $Q$ -ortogonal.

**Ejercicio 17** Sea  $f(x) = \frac{1}{2}x^t Q x - b^t x$  con  $Q$  simétrica DP. Sea  $x_1$  un minimizante de  $f$  en un subespacio  $S_1$  que contiene al vector  $d$  y sea  $x_2$  un minimizante de  $f$  en un subespacio  $S_2$  que contiene a  $d$ . Mostrar que  $\bar{x} = x_1 - x_2$  es  $Q$ -ortogonal a  $d$ .

**Ejercicio 18** Implementar el método del Gradiente Conjugado para minimizar una función cuadrática  $f(x) = \frac{1}{2}x^t Q x - b^t x$ :

(1) A partir de un  $x_0$  tomar  $d_0 = -g_0 = b - Qx_0$

(2) Para  $k = 0, 1, \dots, n - 1$  hacer:

(a) Hacer  $x_{k+1} = x_k + \alpha_k d_k$  con

$$\alpha_k = \frac{-g_k^t d_k}{d_k^t Q d_k}, \quad g_k = Qx_k - b.$$

(b) Hacer  $d_{k+1} = -g_{k+1} + \beta_k d_k$  con

$$\beta_k = \frac{g_{k+1}^t Q d_k}{d_k^t Q d_k}.$$

**Ejercicio 19** Dada  $f(x) = \frac{1}{2}x^t Q x - b^t x$  con  $Q$  simétrica definida positiva, si definimos  $\mathcal{B}_k = \langle d_0, \dots, d_{k-1} \rangle$  el subespacio generado por las primeras  $k$  direcciones conjugadas, mostrar que el método de las direcciones conjugadas, en cada  $x_k$  minimiza la función objetivo tanto en la recta  $L : x_{k-1} + \alpha d_{k-1} : \alpha \in \mathbb{R}$ , como en la variedad lineal  $x_0 + \mathcal{B}_k$ .

**Ejercicio 20** Implementar el siguiente algoritmo que generaliza el del gradiente conjugado a funciones no cuadráticas:

(1) A partir de un  $x_0$  tomar  $g_0 = \nabla f(x_0)^T$  y hacer  $d_0 = -g_0$ .

(2) Para  $k = 0, 1, \dots, n - 1$  hacer:

(a) Hacer  $x_{k+1} = x_k + \alpha_k d_k$  con  $\alpha_k = \frac{-g_k^T d_k}{d_k^T H f(x_k) d_k}$ .

(b) Hacer  $g_{k+1} = \nabla f(x_{k+1})^T$ .

(c) Si  $k \neq n - 1$ , hacer  $d_{k+1} = -g_{k+1} + \beta_k d_k$  con

$$\beta_k = \frac{g_{k+1}^T H f(x_k) d_k}{d_k^T H f(x_k) d_k}.$$

y repetir (a).

(3) Hacer  $x_0 = x_n$  y volver a (1).