

# Sistemas dinámicos y algoritmos en optimización convexa

**Juan PEYPOUQUET**

Universidad Técnica Federico Santa María

Universidad de La Habana

La Habana, 16 al 20 de noviembre de 2015

# CLASE I

## Aspectos generales

## Funciones en los reales extendidos

Consideraremos funciones definidas en un conjunto  $X$  con valores en los **reales extendidos**  $\mathbb{R} \cup \{+\infty\}$  y escribiremos

$$\text{dom}(f) = \{x \in \mathbb{R}^N : f(x) < +\infty\}.$$

### Ejemplo

*La función indicatriz de un conjunto  $C$  es*

$$\delta_C(x) = \begin{cases} 0 & \text{si } x \in C \\ +\infty & \text{si } x \notin C \end{cases}$$

# Problemas de optimización

Estudiaremos el problema de existencia, caracterización y aproximación numérica de los puntos donde una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  alcanza su menor valor:

El valor del problema es

$$\min(f) = \min\{f(x) : x \in \mathbb{R}^N\}.$$

El conjunto de soluciones es

$$\operatorname{argmin}(f) = \{x \in \mathbb{R}^N : f(x) = \min(f)\}.$$

# Problemas de optimización

Estudiaremos el problema de existencia, caracterización y aproximación numérica de los puntos donde una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  alcanza su menor valor:

El **valor** del problema es

$$\min(f) = \min\{f(x) : x \in \mathbb{R}^N\}.$$

El conjunto de soluciones es

$$\operatorname{argmin}(f) = \{x \in \mathbb{R}^N : f(x) = \min(f)\}.$$

# Problemas de optimización

Estudiaremos el problema de existencia, caracterización y aproximación numérica de los puntos donde una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  alcanza su menor valor:

El **valor** del problema es

$$\min(f) = \min\{f(x) : x \in \mathbb{R}^N\}.$$

El **conjunto de soluciones** es

$$\operatorname{argmin}(f) = \{x \in \mathbb{R}^N : f(x) = \min(f)\}.$$

# Semicontinuidad inferior

Una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **inferiormente semicontinua** si para cada  $x \in \text{dom}(f)$  y cada  $\varepsilon > 0$  existe  $\delta > 0$  tal que  $\|x - y\| < \delta \Rightarrow f(y) > f(x) - \varepsilon$ .

## Ejemplo

*Toda función continua es inferiormente semicontinua.*

*Si  $C$  es cerrado,  $\delta_C$  es inferiormente semicontinua.*

## Semicontinuidad inferior

Una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **inferiormente semicontinua** si para cada  $x \in \text{dom}(f)$  y cada  $\varepsilon > 0$  existe  $\delta > 0$  tal que  $\|x - y\| < \delta \Rightarrow f(y) > f(x) - \varepsilon$ .

### Ejemplo

*Toda función continua es inferiormente semicontinua.  
Si  $C$  es cerrado,  $\delta_C$  es inferiormente semicontinua.*



# Coercividad

Diremos que  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **coerciva** si

$$\lim_{\|x\| \rightarrow +\infty} f(x) = +\infty.$$

Es decir, si para cada  $\gamma \in \mathbb{R}$  el conjunto de subnivel  $\gamma$  de  $f$ :

$$[f \leq \gamma] = \{x \in \mathbb{R}^N : f(x) \leq \gamma\}$$

es acotado.

Ejemplo

*Si  $C$  es acotado,  $\delta_C$  es coerciva.*

# Coercividad

Diremos que  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **coerciva** si

$$\lim_{\|x\| \rightarrow +\infty} f(x) = +\infty.$$

Es decir, si para cada  $\gamma \in \mathbb{R}$  el **conjunto de subnivel  $\gamma$**  de  $f$ :

$$[f \leq \gamma] = \{x \in \mathbb{R}^N : f(x) \leq \gamma\}$$

es acotado.

Ejemplo

*Si  $C$  es acotado,  $\delta_C$  es coerciva.*

# Coercividad

Diremos que  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **coerciva** si

$$\lim_{\|x\| \rightarrow +\infty} f(x) = +\infty.$$

Es decir, si para cada  $\gamma \in \mathbb{R}$  el **conjunto de subnivel  $\gamma$**  de  $f$ :

$$[f \leq \gamma] = \{x \in \mathbb{R}^N : f(x) \leq \gamma\}$$

es acotado.

## Ejemplo

*Si  $C$  es acotado,  $\delta_C$  es coerciva.*

# Existencia de minimizadores

## Teorema

*Si  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es inferiormente semicontinua y coerciva, entonces*

$$\operatorname{argmin}(f) \neq \emptyset.$$

## Corolario

*Si  $f : C \subset \mathbb{R}^N \rightarrow \mathbb{R}$  es semicontinua y  $C$  es compacto, entonces*



$$\operatorname{argmin}(f) \neq \emptyset.$$

# Conjuntos convexos

Un subconjunto  $C$  de  $\mathbb{R}^N$  es **convexo** si para cada  $x, y \in C$ , el segmento que une  $x$  con  $y$ :

$$\text{seg}[x, y] = \{\lambda x + (1 - \lambda)y : \lambda \in [0, 1]\}$$

está contenido en  $C$ .



# Condición necesaria de optimalidad

## Teorema

Sea  $f : \mathbb{R}^N \rightarrow \mathbb{R}$  y sea  $C \subset \mathbb{R}^N$  un conjunto convexo. Si  $f(x^*) \leq f(x)$  para todo  $x \in C$  y  $f$  es diferenciable en  $x^*$ , entonces

$$\nabla f(x^*) \cdot (x - x^*) \geq 0$$

para todo  $x \in C$ . Si, además,  $x^* \in \text{int}(C)$ , entonces  $\nabla f(x^*) = 0$ .

# Funciones convexas

Una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **convexa** si para cada  $x, y \in \mathbb{R}^N$  y cada  $\lambda \in (0, 1)$  se cumple

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

Esto es equivalente a que el epígrafo de  $f$ :

$$\text{epi}(f) = \{(x, z) \in X \times \mathbb{R} : f(x) \leq z\}$$

sea convexo.

Lo anterior implica que el conjunto  $[f \leq \gamma]$  es convexo para cada  $\gamma$  (pero no es equivalente!).

# Funciones convexas

Una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **convexa** si para cada  $x, y \in \mathbb{R}^N$  y cada  $\lambda \in (0, 1)$  se cumple

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

Esto es equivalente a que el **epígrafo** de  $f$ :

$$\text{epi}(f) = \{(x, z) \in X \times \mathbb{R} : f(x) \leq z\}$$

sea convexo.

Lo anterior implica que el conjunto  $[f \leq \gamma]$  es convexo para cada  $\gamma$  (pero no es equivalente!).



# Funciones convexas

Una función  $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$  es **convexa** si para cada  $x, y \in \mathbb{R}^N$  y cada  $\lambda \in (0, 1)$  se cumple

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

Esto es equivalente a que el **epígrafo** de  $f$ :

$$\text{epi}(f) = \{(x, z) \in X \times \mathbb{R} : f(x) \leq z\}$$

sea convexo.

Lo anterior implica que el conjunto  $[f \leq \gamma]$  es convexo para cada  $\gamma$  (pero no es equivalente!).

# Propiedades del gradiente

Sea  $f : \mathbb{R}^N \rightarrow \mathbb{R}$  convexa y diferenciable. Entonces

- 1 Se cumple la **desigualdad del gradiente**:

$$f(y) \geq f(x) + \nabla f(x) \cdot (y - x).$$

- 2 El gradiente es **monótono**:

$$(\nabla f(x) - \nabla f(y)) \cdot (x - y) \geq 0.$$

# Propiedades del gradiente

Sea  $f : \mathbb{R}^N \rightarrow \mathbb{R}$  convexa y diferenciable. Son equivalentes:

- ①  $\nabla f$  es **Lipschitz-continuo** con constante  $L$ :

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\|.$$

- ② Se cumple la **desigualdad de descenso**:

$$f(y) \leq f(x) + \nabla f(x) \cdot (y - x) + \frac{L}{2}\|x - y\|^2.$$

- ③  $\nabla f$  es **cocoercivo** con constante  $1/L$ :


$$(\nabla f(x) - \nabla f(y)) \cdot (x - y) \geq \frac{1}{L}\|\nabla f(x) - \nabla f(y)\|^2.$$

# CLASE II

## Métodos básicos de descenso

# Dinámica del máximo descenso

Ecuación diferencial  $\dot{x}(t) = -\nabla f(x(t))$ ,  $x(0) = x_0$



# Dinámica del máximo descenso

La función  $t \mapsto f(x(t))$  es decreciente:

$$\frac{d}{dt}f(x(t)) = \nabla f(x(t)) \cdot \dot{x}(t) = -\|\nabla f(x(t))\|^2 = -\|\dot{x}(t)\|^2 \leq 0.$$

Anclaje al conjunto de soluciones: Si  $x^* \in S$ , entonces

$$\frac{d}{dt}\|x(t) - x^*\|^2 \leq 0.$$

# Dinámica del máximo descenso

La función  $t \mapsto f(x(t))$  es decreciente:

$$\frac{d}{dt}f(x(t)) = \nabla f(x(t)) \cdot \dot{x}(t) = -\|\nabla f(x(t))\|^2 = -\|\dot{x}(t)\|^2 \leq 0.$$

Anclaje al conjunto de soluciones: Si  $x^* \in \mathcal{S}$ , entonces

$$\frac{d}{dt}\|x(t) - x^*\|^2 \leq 0.$$

# Dinámica del máximo descenso

**Minimización:** Si  $x^* \in S$ , entonces

$$f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}.$$

Aproximación de las soluciones: Si  $S \neq \emptyset$ , entonces

$$\lim_{t \rightarrow +\infty} x(t)$$

existe y pertenece a  $S$ .



# Dinámica del máximo descenso

Minimización: Si  $x^* \in S$ , entonces

$$f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}.$$

Aproximación de las soluciones: Si  $S \neq \emptyset$ , entonces

$$\lim_{t \rightarrow +\infty} x(t)$$

existe y pertenece a  $S$ .

# Método del gradiente

Para aproximar las soluciones de la ecuación

$$\dot{x}(t) = -\nabla f(x(t)),$$

hacemos una discretización explícita en diferencias finitas:

$$\frac{x_{k+1} - x_k}{\lambda} = -\nabla f(x_k).$$

En otras palabras,

$$x_{k+1} = x_k - \lambda \nabla f(x_k).$$

# Método del gradiente

Para aproximar las soluciones de la ecuación

$$\dot{x}(t) = -\nabla f(x(t)),$$

hacemos una discretización explícita en diferencias finitas:


$$\frac{x_{k+1} - x_k}{\lambda} = -\nabla f(x_k).$$

En otras palabras,

$$x_{k+1} = x_k - \lambda \nabla f(x_k).$$

# Método del gradiente

$$x_{k+1} = x_k - \lambda \nabla f(x_k)$$



# Puede salir bien o mal

## Ejemplo

Sean  $f(x) = x^2$  y  $x_0 = 1$ . Entonces

$$x_k = (1 - 2\lambda)^k.$$

En particular,

- 1 Si  $\lambda > 1$ ,  $\lim_{k \rightarrow +\infty} |x_k| = +\infty$ ;
- 2 Si  $\lambda = 1$ ,  $x_k = (-1)^k$ ,  $|x_k| \equiv 1$  pero  $\nexists \lim_{k \rightarrow +\infty} x_k$ ; y
- 3 Si  $\lambda < 1$ ,  $\lim_{k \rightarrow +\infty} x_k = 0$ .

# Puede salir bien o mal

## Ejemplo

Sean  $f(x) = x^2$  y  $x_0 = 1$ . Entonces

$$x_k = (1 - 2\lambda)^k.$$

En particular,

- 1 Si  $\lambda > 1$ ,  $\lim_{k \rightarrow +\infty} |x_k| = +\infty$ ;
- 2 Si  $\lambda = 1$ ,  $x_k = (-1)^k$ ,  $|x_k| \equiv 1$  pero  $\nexists \lim_{k \rightarrow +\infty} x_k$ ; y
- 3 Si  $\lambda < 1$ ,  $\lim_{k \rightarrow +\infty} x_k = 0$ .

# Puede salir bien o mal

## Ejemplo

Sean  $f(x) = x^2$  y  $x_0 = 1$ . Entonces

$$x_k = (1 - 2\lambda)^k.$$

En particular,

- 1 Si  $\lambda > 1$ ,  $\lim_{k \rightarrow +\infty} |x_k| = +\infty$ ;
- 2 Si  $\lambda = 1$ ,  $x_k = (-1)^k$ ,  $|x_k| \equiv 1$  pero  $\nexists \lim_{k \rightarrow +\infty} x_k$ ; y
- 3 Si  $\lambda < 1$ ,  $\lim_{k \rightarrow +\infty} x_k = 0$ .

# Puede salir bien o mal

## Ejemplo

Sean  $f(x) = x^2$  y  $x_0 = 1$ . Entonces

$$x_k = (1 - 2\lambda)^k.$$

En particular,

- 1 Si  $\lambda > 1$ ,  $\lim_{k \rightarrow +\infty} |x_k| = +\infty$ ;
- 2 Si  $\lambda = 1$ ,  $x_k = (-1)^k$ ,  $|x_k| \equiv 1$  pero  $\nexists \lim_{k \rightarrow +\infty} x_k$ ; y
- 3 Si  $\lambda < 1$ ,  $\lim_{k \rightarrow +\infty} x_k = 0$ .



# Convergencia

Supongamos que  $\nabla f$  es Lipschitz-continuo con constante  $L$  y

$$\lambda L < 2.$$

Recordemos que se tiene la desigualdad del descenso:

$$f(y) \leq f(x) + \nabla f(x) \cdot (y - x) + \frac{L}{2} \|x - y\|^2$$

y la cocoercividad:

$$(\nabla f(x) - \nabla f(y)) \cdot (x - y) \geq \frac{1}{L} \|\nabla f(x) - \nabla f(y)\|^2.$$

# Convergencia

Supongamos que  $\nabla f$  es Lipschitz-continuo con constante  $L$  y

$$\lambda L < 2.$$

Recordemos que se tiene la **desigualdad del descenso**:

$$f(y) \leq f(x) + \nabla f(x) \cdot (y - x) + \frac{L}{2} \|x - y\|^2$$

y la **cocoercividad**:

$$(\nabla f(x) - \nabla f(y)) \cdot (x - y) \geq \frac{1}{L} \|\nabla f(x) - \nabla f(y)\|^2.$$

# Convergencia

La sucesión  $f(x_k)$  es decreciente:

$$f(x_{k+1}) \leq f(x_k).$$

Anclaje al conjunto de soluciones: Si  $x^* \in S$ , entonces

$$\|x_{k+1} - x^*\|^2 + \delta \|x_{k+1} - x_k\|^2 \leq \|x_k - x^*\|^2.$$

# Convergencia

La sucesión  $f(x_k)$  es decreciente:

$$f(x_{k+1}) \leq f(x_k).$$

Anclaje al conjunto de soluciones: Si  $x^* \in S$ , entonces

$$\|x_{k+1} - x^*\|^2 + \delta \|x_{k+1} - x_k\|^2 \leq \|x_k - x^*\|^2.$$

# Convergencia

**Minimización:** Si  $S \neq \emptyset$ , entonces

$$f(x_k) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{\lambda(2 - \lambda L)k}.$$

**Convergencia:** Si  $S \neq \emptyset$ , entonces

$$\lim_{k \rightarrow +\infty} x_k$$

existe y pertenece a  $S$ .

# Convergencia

**Minimización:** Si  $S \neq \emptyset$ , entonces

$$f(x_k) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{\lambda(2 - \lambda L)k}.$$

**Convergencia:** Si  $S \neq \emptyset$ , entonces

$$\lim_{k \rightarrow +\infty} x_k$$

existe y pertenece a  $S$ .

# CLASE III

## Optimización no diferenciable

# Optimización no diferenciable

El **algoritmo proximal** se define de la siguiente forma: dados  $z_k \in \mathbb{R}^N$  y  $\lambda > 0$ , escogemos  $z_{k+1}$  como la única solución del problema

$$\operatorname{argmin} \left\{ f(z) + \frac{1}{2\lambda} \|z - z_k\|^2 \right\}.$$

## Observación

- *Está bien definido.*
- *No es necesario que  $f$  sea diferenciable.*



## Optimización no diferenciable

El **algoritmo proximal** se define de la siguiente forma: dados  $z_k \in \mathbb{R}^N$  y  $\lambda > 0$ , escogemos  $z_{k+1}$  como la única solución del problema

$$\operatorname{argmin} \left\{ f(z) + \frac{1}{2\lambda} \|z - z_k\|^2 \right\}.$$

### Observación

- *Está bien definido.*
- *No es necesario que  $f$  sea diferenciable.*

## Relación con los métodos anteriores

Dinámica del máximo descenso:

$$\dot{x}(t) = -\nabla f(x(t))$$

Método del gradiente:

$$\frac{x_{k+1} - x_k}{\lambda} = -\nabla f(x_k) \quad \Leftrightarrow \quad x_{k+1} = x_k - \lambda \nabla f(x_k).$$

Algoritmo proximal (si  $f$  es diferenciable):

$$\frac{z_{k+1} - z_k}{\lambda} = -\nabla f(z_{k+1}) \quad \Leftrightarrow \quad z_{k+1} + \lambda \nabla f(z_{k+1}) = z_k.$$


# Comparación geométrica

Gradiente

$$x_{k+1} = x_k - \lambda \nabla f(x_k)$$

Proximal

$$z_{k+1} + \lambda \nabla f(z_{k+1}) = z_k$$



# Lo bueno y lo malo

## Método del gradiente

- + Fácil implementación (fórmula explícita).
- Se necesita  $f$  diferenciable con  $\nabla f$  Lipschitz-continuo para tener convergencia. Hay que escoger bien el paso  $\lambda$ .

## Algoritmo proximal

- + Garantía de convergencia aunque  $f$  no sea diferenciable, y sin importar el paso.
- La implementación puede ser más difícil (la fórmula es implícita).

# Lo bueno y lo malo

## Método del gradiente

- + Fácil implementación (fórmula explícita).
- Se necesita  $f$  diferenciable con  $\nabla f$  Lipschitz-continuo para tener convergencia. Hay que escoger bien el paso  $\lambda$ .

## Algoritmo proximal

- + Garantía de convergencia aunque  $f$  no sea diferenciable, y sin importar el paso.
- La implementación puede ser más difícil (la fórmula es implícita).

## Ejemplos

## Ejemplo

En  $\mathbb{R}^N$ ,  $f(x) = \delta_C(x)$ :

$$z_k = \text{proy}_C(z_0)$$

para todo  $k \geq 1$ .

## Ejemplo

En  $\mathbb{R}$ ,  $f(x) = |x|$ :

$$z_{k+1} = \begin{cases} z_k - \lambda & \text{si } z_k > \lambda \\ z_k + \lambda & \text{si } z_k < -\lambda \\ 0 & \text{si } z_k \in [-\lambda, \lambda]. \end{cases}$$

## Ejemplos

## Ejemplo

En  $\mathbb{R}^N$ ,  $f(x) = \delta_C(x)$ :

$$z_k = \text{proy}_C(z_0)$$

para todo  $k \geq 1$ .

## Ejemplo

En  $\mathbb{R}$ ,  $f(x) = |x|$ :

$$z_{k+1} = \begin{cases} z_k - \lambda & \text{si } z_k > \lambda \\ z_k + \lambda & \text{si } z_k < -\lambda \\ 0 & \text{si } z_k \in [-\lambda, \lambda]. \end{cases}$$

# Convergencia

La sucesión  $f(z_k)$  es decreciente:

$$f(z_{k+1}) \leq f(z_k).$$

Anclaje al conjunto de soluciones: Si  $x^* \in S$ , entonces

$$\|z_{k+1} - x^*\| \leq \|z_k - x^*\|.$$



# Convergencia

La sucesión  $f(z_k)$  es decreciente:

$$f(z_{k+1}) \leq f(z_k).$$

Anclaje al conjunto de soluciones: Si  $x^* \in S$ , entonces

$$\|z_{k+1} - x^*\| \leq \|z_k - x^*\|.$$

# Convergencia

**Minimización:** Si  $S \neq \emptyset$ , entonces

$$f(z_k) - \min(f) \leq \frac{\text{dist}(z_0, S)^2}{2\lambda k}.$$

**Convergencia:** Si  $S \neq \emptyset$ , entonces

$$\lim_{k \rightarrow +\infty} z_k$$

existe y pertenece a  $S$ .

# Convergencia

**Minimización:** Si  $S \neq \emptyset$ , entonces

$$f(z_k) - \min(f) \leq \frac{\text{dist}(z_0, S)^2}{2\lambda k}.$$

**Convergencia:** Si  $S \neq \emptyset$ , entonces

$$\lim_{k \rightarrow +\infty} z_k$$

existe y pertenece a  $S$ .

## El subdiferencial

Sabemos que si  $f : \mathbb{R}^N \rightarrow \mathbb{R}$  es convexa y diferenciable, entonces

$$f(y) \geq f(x) + \nabla f(x) \cdot (y - x).$$

Diremos que  $v \in \mathbb{R}^N$  es un **subgradiente** de  $f$  en  $x$  si

$$f(y) \geq f(x) + v \cdot (y - x)$$

para todo  $y \in \mathbb{R}^N$ . El **subdiferencial** de  $f$  en  $x$  es el conjunto de todos los subgradientes:

$$\partial f(x) = \{v \in \mathbb{R}^N : f(y) \geq f(x) + v \cdot (y - x) \text{ para todo } y \in \mathbb{R}^N\}$$

# Algunas propiedades

Caracterización de las soluciones:

$$x^* \in \operatorname{argmin}(f) \quad \iff \quad 0 \in \partial f(x^*)$$

Monotonía: Si  $\hat{x} \in \partial f(x)$  y  $\hat{y} \in \partial f(y)$ , entonces

$$(\hat{x} - \hat{y}) \cdot (x - y) \geq 0$$

# Algunas propiedades

Caracterización de las soluciones:

$$x^* \in \operatorname{argmin}(f) \quad \iff \quad 0 \in \partial f(x^*)$$

**Monotonía:** Si  $\hat{x} \in \partial f(x)$  y  $\hat{y} \in \partial f(y)$ , entonces

$$(\hat{x} - \hat{y}) \cdot (x - y) \geq 0$$

# Ejemplos

## Ejemplo

Si  $f$  es diferenciable, entonces  $\partial f(x) = \{\nabla f(x)\}$ .

## Ejemplo

En  $\mathbb{R}$ , si  $f(x) = |x|$ :

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

# Ejemplos

## Ejemplo

Si  $f$  es diferenciable, entonces  $\partial f(x) = \{\nabla f(x)\}$ .

## Ejemplo

En  $\mathbb{R}$ , si  $f(x) = |x|$ :

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



## CLASE IV

### Combinando funciones diferenciables y no diferenciables

## Tenemos dos métodos básicos

Método del gradiente (para  $g$  diferenciable):

$$x_{k+1} = \text{Grad}_{\lambda g}(x_k) = x_k - \lambda \nabla g(x_k)$$

Algoritmo proximal (para  $h$  cualquiera):

$$z_{k+1} = \text{Prox}_{\lambda h}(z_k) = \operatorname{argmin} \left\{ h(z) + \frac{1}{2\lambda} \|z - z_k\|^2 \right\}$$

## Estructura mixta

Queremos minimizar  $f = g + h$ , donde  $g$  es diferenciable pero  $h$  no.

### Ejemplo

*El problema con restricciones*

$$\min\{g(x) : x \in C\}$$

*es equivalente a*

$$\min\{g(x) + \delta_C(x) : x \in \mathbb{R}^N\}.$$

## Estructura mixta

Queremos minimizar  $f = g + h$ , donde  $g$  es diferenciable pero  $h$  no.

### Ejemplo

*El problema con restricciones*

$$\min\{g(x) : x \in C\}$$

*es equivalente a*

$$\min\{g(x) + \delta_C(x) : x \in \mathbb{R}^N\}.$$

## Estructura mixta

Queremos minimizar  $f = g + h$ , donde  $g$  es diferenciable pero  $h$  no.

### Ejemplo

Sean  $\mu > 0$ ,  $b \in \mathbb{R}^M$  y  $A$  una matriz de tamaño  $M \times N$ .  
 Considere las funciones  $g, h : \mathbb{R}^N \rightarrow \mathbb{R}$  definidas por

$$g(x) = \mu \sum_{n=1}^N |x_n| \quad y \quad h(x) = \frac{1}{2} \|Ax - b\|^2$$

La función  $f = g + h$  aparece en procesamiento de imágenes y compresión datos, entre otros.

# Estrategia

Usar método del gradiente para la parte diferenciable y algoritmo proximal para la parte no diferenciable:

Método gradiente-proximal:

$$x_{k+1} = T_\lambda(x_k) = \text{Prox}_{\lambda h}(\text{Grad}_{\lambda g}(x_k))$$

Caso  $h = 0$ : gradiente

Caso  $h = \delta_C$ : gradiente proyectado  $x_{k+1} = \text{Proy}_C(\text{Grad}_{\lambda g}(x_k))$

Caso  $g = 0$ : proximal

# Una propiedad fundamental

## Proposición

Si  $\nabla g$  es Lipschitz-continuo con constante  $L$  y  $\lambda L \leq 1$ , entonces

$$f(T_\lambda(x)) + \frac{\|y - T_\lambda(x)\|^2}{2\lambda} \leq f(y) + \frac{\|y - x\|^2}{2\lambda}.$$

# Principales consecuencias

## Proposición

- *Decrecimiento:*  $f(x_{k+1}) + \frac{1}{2\lambda} \|x_{k+1} - x_k\|^2 \leq f(x_k)$
- *Anclaje:* Si  $x^* \in S$ ,  $\|x_{k+1} - x^*\| \leq \|x_k - x^*\|$
- *Minimización:* Si  $S \neq \emptyset$ ,  $f(x_k) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2\lambda k}$
- *Convergencia:* Si  $S \neq \emptyset$ ,  $\lim_{k \rightarrow +\infty} x_k$  existe y está en  $S$ .




# CLASE V

## Aceleración


# Aceleración

La idea es la siguiente: En lugar de hacer esto:




# Aceleración

Probemos mejor lo siguiente:




# Aceleración

Probemos mejor lo siguiente:



# Aceleración

Probemos mejor lo siguiente:



# Aceleración

Algoritmo gradiente-proximal acelerado:

$$\begin{cases} y_k &= x_k + \frac{k-2}{k+1}(x_k - x_{k-1}) \\ x_{k+1} &= \text{Prox}_{\lambda h}(\text{Grad}_{\lambda g}(y_k)) \end{cases}$$

donde  $\nabla g$  es Lipschitz-continuo con constante  $L$ , y  $\lambda L \leq 1$ .

Teorema

$$(g + h)(x_k) - \min(g + h) \leq \frac{\text{dist}(x_0, S)^2}{\lambda k^2}, \quad k \geq 1$$

# Aceleración

Algoritmo gradiente-proximal acelerado:

$$\begin{cases} y_k &= x_k + \frac{k-2}{k+1}(x_k - x_{k-1}) \\ x_{k+1} &= \text{Prox}_{\lambda h}(\text{Grad}_{\lambda g}(y_k)) \end{cases}$$

donde  $\nabla g$  es Lipschitz-continuo con constante  $L$ , y  $\lambda L \leq 1$ .

## Teorema

$$(g + h)(x_k) - \min(g + h) \leq \frac{\text{dist}(x_0, S)^2}{\lambda k^2}, \quad k \geq 1$$

# Aceleración

Usaremos la propiedad fundamental:

## Proposición

Si  $\nabla g$  es Lipschitz-continuo con constante  $L$  y  $\lambda L \leq 1$ , entonces

$$f(T_\lambda(x)) + \frac{\|y - T_\lambda(x)\|^2}{2\lambda} \leq f(y) + \frac{\|y - x\|^2}{2\lambda}.$$

Con:

$$\begin{aligned} x &= y_k &= x_k + \frac{k-2}{k+1}(x_k - x_{k-1}) \\ T_\lambda(x) &= T_\lambda(y_k) &= x_{k+1} \\ y &= \frac{2}{k+1}x^* + \frac{k-1}{k+1}x_k \end{aligned}$$