

Análisis convexo, cálculo diferencial y aplicaciones

Juan PEYPOUQUET

Universidad Técnica Federico Santa María

V-Escuela 2016

Valparaíso, 11 al 21 de octubre

BÚSQUEDA DE MINIMIZADORES

Sucesiones minimizantes convergentes

Sea $f : X \rightarrow \mathbb{R} \cup \{+\infty\}$ una función propia e inferiormente semicontinua, y sea (x_n) una sucesión minimizante para f . Es decir, tal que

$$\lim_{n \rightarrow \infty} f(x_n) = \inf(f).$$

Tenemos lo siguiente:

- Si x_n converge a \bar{x} , entonces $\bar{x} \in S$.
- Si f es convexa y x_n converge débilmente a \bar{x} , entonces $\bar{x} \in S$.

Sucesiones minimizantes convergentes

Sea $f : X \rightarrow \mathbb{R} \cup \{+\infty\}$ una función propia e inferiormente semicontinua, y sea (x_n) una sucesión minimizante para f . Es decir, tal que

$$\lim_{n \rightarrow \infty} f(x_n) = \inf(f).$$

Tenemos lo siguiente:

- Si x_n converge a \bar{x} , entonces $\bar{x} \in S$.
- Si f es convexa y x_n converge débilmente a \bar{x} , entonces $\bar{x} \in S$.

Sucesiones minimizantes convergentes

Sea $f : X \rightarrow \mathbb{R} \cup \{+\infty\}$ una función propia e inferiormente semicontinua, y sea (x_n) una sucesión minimizante para f . Es decir, tal que

$$\lim_{n \rightarrow \infty} f(x_n) = \inf(f).$$

Tenemos lo siguiente:

- Si x_n converge a \bar{x} , entonces $\bar{x} \in S$.
- Si f es convexa y x_n converge débilmente a \bar{x} , entonces $\bar{x} \in S$.

Sucesiones minimizantes convergentes

Sea $f : X \rightarrow \mathbb{R} \cup \{+\infty\}$ una función propia e inferiormente semicontinua, y sea (x_n) una sucesión minimizante para f . Es decir, tal que

$$\lim_{n \rightarrow \infty} f(x_n) = \inf(f).$$

Tenemos lo siguiente:

- Si x_n converge a \bar{x} , entonces $\bar{x} \in S$.
- Si f es convexa y x_n converge débilmente a \bar{x} , entonces $\bar{x} \in S$.

Una condición suficiente para la convergencia

Teorema

Sea X un espacio de Hilbert y sea $f : X \rightarrow \mathbb{R} \cup \{+\infty\}$ una función propia, convexa e inferiormente semicontinua con $S \neq \emptyset$. Supongamos que (x_n) es una sucesión minimizante para f tal que para cada $s \in S$ existe

$$\lim_{n \rightarrow \infty} \|x_n - s\|.$$

Entonces, x_n converge débilmente a algún $\bar{x} \in S$.

Estrategia para buscar minimizadores

Para aproximar un minimizador de f basta encontrar una sucesión (x_n) tal que

1 $\lim_{n \rightarrow \infty} f(x_n) = \inf(f)$; y

2 $\lim_{n \rightarrow \infty} \|x_n - s\|$ existe para cada $s \in S$.

Bajo estas condiciones, x_n converge débilmente a algún $\bar{x} \in S$.

Estrategia para buscar minimizadores

Para aproximar un minimizador de f basta encontrar una sucesión (x_n) tal que

1 $\lim_{n \rightarrow \infty} f(x_n) = \inf(f)$; y


2 $\lim_{n \rightarrow \infty} \|x_n - s\|$ existe para cada $s \in S$.

Bajo estas condiciones, x_n converge débilmente a algún $\bar{x} \in S$.

ALGORITMO GRADIENTE-PROXIMAL

Inspiración: Dinámica del máximo descenso

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



Principales propiedades

Proposición

- 1 $t \mapsto f(x(t))$ es decreciente;
- 2 $t \mapsto \|x(t) - s\|$ es decreciente para cada $s \in S$;
- 3 $f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}$; y
- 4 Cuando $t \rightarrow +\infty$, $x(t)$ converge débilmente a algún $\bar{x} \in S$.

Principales propiedades

Proposición

- 1 $t \mapsto f(x(t))$ es decreciente;
- 2 $t \mapsto \|x(t) - s\|$ es decreciente para cada $s \in S$;
- 3 $f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}$; y
- 4 Cuando $t \rightarrow +\infty$, $x(t)$ converge débilmente a algún $\bar{x} \in S$.

Principales propiedades

Proposición

- 1 $t \mapsto f(x(t))$ es decreciente;
- 2 $t \mapsto \|x(t) - s\|$ es decreciente para cada $s \in S$;
- 3 $f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}$; y
- 4 Cuando $t \rightarrow +\infty$, $x(t)$ converge débilmente a algún $\bar{x} \in S$.

Principales propiedades

Proposición

- 1 $t \mapsto f(x(t))$ es decreciente;
- 2 $t \mapsto \|x(t) - s\|$ es decreciente para cada $s \in S$;
- 3 $f(x(t)) - \min(f) \leq \frac{\text{dist}(x_0, S)^2}{2t}$; y
- 4 Cuando $t \rightarrow +\infty$, $x(t)$ converge débilmente a algún $\bar{x} \in S$.

Método del gradiente (Cauchy, 1847)

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 $\lambda < 1$, $\lim_{k \rightarrow +\infty} x_k = 0$.

Iteraciones proximales (Martinet, 1970)

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.*

Ejemplos

Ejemplo

Si $f(x) = \delta_C(x)$:

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

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

Si $f(x) = \delta_C(x)$:

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

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

Si $f(x) = \delta_C(x)$:

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

para todo $k \geq 1$.

Ejemplo

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

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

Relación entre los 3

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:

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

Relación entre los 3

Dinámica del máximo descenso:

$$\dot{x}(t) \in -\partial f(x(t))$$

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:

$$\frac{z_{k+1} - z_k}{\lambda} \in -\partial f(z_{k+1}) \quad \Leftrightarrow \quad z_{k+1} + \lambda \partial f(z_{k+1}) \ni z_k.$$


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 ∇f Lipschitz-continuo para tener convergencia. Hay que escoger bien el paso λ .

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 ∇f Lipschitz-continuo para tener convergencia. Hay que escoger bien el paso λ .

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).

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 de datos, entre otros.

Estrategia

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

Método gradiente-proximal:

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

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

Comportamiento del método

Teorema

- *Decrecimiento:* $f(x_{k+1}) + \frac{1}{2\lambda} \|x_{k+1} - x_k\|^2 \leq f(x_k)$
- *Anclaje:* Si $s \in S$, $\|x_{k+1} - s\| \leq \|x_k - s\|$
- *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 .