

Proximal Methods


Ser $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ convexa y propia ($f \neq +\infty$)

Definimos el operador proximal $\text{prox}_{\lambda f}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ como

$$\text{prox}_{\lambda f}(z) = \arg\min_x (f(x) + \frac{1}{2\lambda} \|x - z\|_2^2)$$

La función $f(x) + \frac{1}{2\lambda} \|x - z\|_2^2$ es estrictamente convexa, por lo que el mínimo es único, y la función $\text{prox}_{\lambda f}(z)$ está bien definida.

Interpretación



El parámetro λ repula qué tanto se mueve hacia el mínimo de f , y cuando se queda cerca de z .

Obs: Si f es la función indicativa de un conjunto C cerrado, convexo :

$$f(x) = \begin{cases} 0 & x \in C \\ +\infty & x \notin C \end{cases}, \text{ entonces el operador proximal coincide con la proyección } z \in C.$$

Propiedad (Separabilidad de la suma)

$$\text{Si } f(x, y) = \ell(x) + \Psi(y) \Rightarrow \text{prox}_f(x, w) = (\text{prox}_{\ell}(x), \text{prox}_{\Psi}(w))$$

$$\text{En particular si } f(x) = \sum_{i=1}^n f_i(x_i) \Rightarrow (\text{prox}_f(x))_i = \text{prox}_{f_i}(x_i)$$

Prop (del punto fijo)

$$x^* \text{ minimiza } f \text{ si } x^* = \text{prox}_f(x^*) \quad (\text{consideremos } \lambda=1 \text{ sin pérdida de generalidad})$$

Dem

$$(\Rightarrow) \quad x^* \text{ minimiza } f \Rightarrow f(x) \geq f(x^*) \quad \forall x \Rightarrow f(x) + \frac{1}{2} \|x - x^*\|_2^2 \geq f(x^*) + \frac{1}{2} \|x^* - x^*\|_2^2$$

$\forall x$

$$\Rightarrow x^* \text{ minimiza } f(x) + \frac{1}{2} \|x - x^*\|_2^2 \Rightarrow x^* = \text{prox}_f(x^*)$$

$$(\Leftarrow) \quad y \text{ minimiza } f(x) + \frac{1}{2} \|x - z\|_2^2 \quad (\text{es decir } y = \text{prox}_f(z)) \quad \text{si} \quad 0 \in \partial f(y) + (y - z)$$

Teniendo $y = z = x^*$ tenemos que $0 \in \partial f(x^*) \Rightarrow x^* \text{ minimiza } f$

Entonces buscar el mínimo de f es equivalente a buscar puntos fijos del operador proximal.

Si prox_f fuera una contracción $\Rightarrow x^{k+1} = \text{prox}_f(x^k)$ converge a un punto fijo.

Sin embargo prox_f no es necesariamente una contracción.

Veremos más adelante que de todos modos tenemos resultados de convergencia.

Ejemplo

Tenemos $f(x) = |x|$ y calculemos $\text{prox}_f(n)$

La condición de optimidad es $0 \in \partial f(x) + x - n \Leftrightarrow n \in x + \partial f(x)$

Dado n , para calcular $x = \text{prox}_f(n)$ tenemos que encontrar el x que verifique la cond. de optimidad $n \in x + \partial f(x)$

Entonces, si $n > 1 \Rightarrow x = n - 1$

si $n < -1 \Rightarrow x = n + 1$


si $|n| < 1 \Rightarrow x = 0$

$$\text{prox}_f(n) = \begin{cases} n-1 & \text{si } n > 1 \\ 0 & \text{si } |n| < 1 \\ n+1 & \text{si } n < -1 \end{cases}$$

Por la prop. de separabilidad, si $f: \mathbb{R}^n \rightarrow \mathbb{R}$

$f(x) = \|x\|_1$, entonces

$$(\text{prox}_f(n))_i = \begin{cases} n_i - 1 & \text{si } n_i > 1 \\ 0 & \text{si } |n_i| < 1 \\ n_i + 1 & \text{si } n_i < -1 \end{cases}$$



Interpretación: Gradient Flow

Consideremos la ecuación diferencial $\dot{x}(t) = -\nabla f(x(t))$ (flujo de predicción)

Los puntos de equilibrio son ceros de ∇f , que es donde se minimiza f .

Discretizando la ec. dif. (método Forward-Euler) :

$$\frac{x^{k+1} - x^k}{h} = -\nabla f(x^k) \Rightarrow x^{k+1} = x^k - h \nabla f(x^k)$$

que es el método de descenso por predicción con paso h .

Ahora, si usamos Backward-Euler :

$$\frac{x^{k+1} - x^k}{h} = -\nabla f(x^{k+1}) \quad \text{que tiene mejores propiedades de convergencia en ec. dif.}$$

resulta $x^{k+1} + h \nabla f(x^{k+1}) = x^k$ que es exactamente la condición de optimidad para $x^{k+1} = \text{prox}_{h\nabla f}(x^k)$

Es decir, si discretizamos la ec. dif con Forward-Euler obtenemos el método de descenso por predicción, y si discretizamos con Backward-Euler obtenemos el método proximal.

Proximal Gradient Method

Consideremos ahora el problema $\min_x f(x) + g(x)$ con $f: \mathbb{R}^n \rightarrow \mathbb{R}$ y $g: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ propias y convexas, y f diferenciable.

Usualmente se usa para partir el problema en una parte diferenciable y otra que no necesariamente lo es.

El Proximal Gradient Method es: $x^{k+1} = \text{prox}_{\lambda g}(x^k - \lambda \nabla f(x^k))$

Es decir, es como hacer un descenso por gradiente de la parte diferenciable, y luego aplicar el operador proximal de g .

Obs:

- Cuando $g=0$, obtenemos el clásico descenso por gradiente.
- Cuando g es la indicatrix de un conjunto convexo, obtenemos el Projected Gradient Descent.

Interpretación

Como antes, estamos buscando puntos fijos. En este caso

$$x^* = \text{prox}_{\lambda g}(x^* - \lambda \nabla f(x^*)).$$

Vemos que este punto fijo es

$$x^* = \text{prox}_{\lambda g}(x^* - \lambda \nabla f(x^*)) \Leftrightarrow x^* \text{ minimiza } g(x) + \frac{1}{2\lambda} \|x - x^* + \lambda \nabla f(x^*)\|_2^2$$

$$\Leftrightarrow 0 \in \partial g(x^*) + \frac{1}{\lambda} (x^* - x^* + \lambda \nabla f(x^*)) \Leftrightarrow 0 \in \partial g(x^*) + \nabla f(x^*)$$

$$\Leftrightarrow x^* \text{ minimiza } f(x) + g(x).$$

Obs En este caso, como hay un peso de gradiente, λ no puede ser arbitrario.

Por ejemplo si ∇f es Lipschitz de constante L , entonces λ tiene que estar en $[0, \frac{2}{L}]$. Se puede hacer line-search también, o Armijo.