

# 邻近算子

文再文

北京大学北京国际数学研究中心

教材《最优化：建模、算法与理论》配套电子教案

<http://bicmr.pku.edu.cn/~wenzw/optbook.html>

致谢：本教案由陈乐恒、朱桢源协助准备

- 1 闭函数
- 2 共轭函数
- 3 邻近算子
- 4 投影算子
- 5 性质和推广

# 闭集

一个包含其边界的集合  $C$  被称为闭集：

$$x^k \in C, \quad x^k \rightarrow \bar{x} \quad \Longrightarrow \quad \bar{x} \in C$$

保持闭性的操作：

- (有限或无限个) 闭集的交集仍是闭集
- 有限个闭集的并集仍是闭集
- 线性映射的原象集: 在  $C$  闭的情形下,  $\{x \mid Ax \in C\}$  是闭集,

# 线性映射的像

一个闭集在线性映射下的像不一定是闭的

例: ( $C$  闭,  $AC = \{Ax \mid x \in C\}$  开)

$$C = \{(x_1, x_2) \in \mathbf{R}_+^2 \mid x_1 x_2 \geq 1\}, \quad A = \begin{bmatrix} 1 & 0 \end{bmatrix}, \quad AC = \mathbf{R}_{++}$$

(充分条件) 以下条件成立时,  $AC$  为闭集:

- $C$  是闭凸集
- $A$  的零空间中不包含  $C$  的衰退方向 (recession direction), 即

$$Ay = 0, \quad \hat{x} \in C, \quad \hat{x} + \alpha y \in C \quad \forall \alpha \geq 0 \quad \implies \quad y = 0$$

特别地, 若  $C$  有界, 则  $AC$  为闭集

# 闭函数

## 定义

一个函数被称为闭函数，如果它的上方图是闭集

闭函数的例子：

- $f(x) = -\log(1 - x^2)$ ,  $\text{dom } f = \{x \mid |x| < 1\}$
- $f(x) = x \log x$ ,  $\text{dom } f = \mathbf{R}_+$  且  $f(0) = 0$
- 闭集  $C$  的示性函数

不是闭函数的例子：

- $f(x) = x \log x$ ,  $\text{dom } f = \mathbf{R}_{++}$  或  $\text{dom } f = \mathbf{R}_+$ ,  $f(0) = 1$
- 不是闭集的集合  $C$  的示性函数

**下水平集:**  $f$  是闭函数当且仅当  $f$  的所有  $\alpha$ -下水平集都是闭集

**最小值:** 如果  $f$  是闭函数且存在有界的下水平集, 则  $f$  有最小值点

常见的保闭性的操作 (凸函数)

- 加法:  $f + g$  是闭函数, 如果  $f$  和  $g$  都是闭的 ( $\text{dom } f \cap \text{dom } g \neq \emptyset$ )
- 复合线性映射:  $f(Ax + b)$  是闭函数, 如果  $f$  是闭的
- 取上确界:  $\sup_{\alpha} f_{\alpha}(x)$  是闭函数, 如果任意函数  $f_{\alpha}$  是闭的

1 闭函数

2 共轭函数

3 邻近算子

4 投影算子

5 性质和推广

# 共轭函数


函数  $f$  的共轭函数定义为：

$$f^*(y) = \sup_{x \in \text{dom } f} (y^T x - f(x))$$

$f^*$  恒为闭凸函数

**Fenchel 不等式：**

$$f(x) + f^*(y) \geq x^T y \quad \forall x, y$$



**Proof.**

$$f^*(y) = \sup_{x \in \text{dom } f} \{y^T x - f(x)\} \geq y^T x - f(x), \quad \forall x \in \text{dom } f$$

□

# 二次函数

考察二次函数  $f$  的共轭函数：

$$f(x) = \frac{1}{2}x^T A x + b^T x + c$$

- 强凸情形 ( $A \succ 0$ )

$$f^*(y) = \frac{1}{2}(y - b)^T A^{-1}(y - b) - c$$

- 一般凸情形 ( $A \succeq 0$ )

$$f^*(y) = \frac{1}{2}(y - b)^T A^\dagger (y - b) - c, \quad \mathbf{dom} f^* = \mathcal{R}(A) + b$$

这里  $\mathcal{R}(A)$  为  $A$  的像空间。

# 负熵与负对数

- 负熵

$$f(x) = \sum_{i=1}^n x_i \log x_i \quad f^*(y) = \sum_{i=1}^n e^{y_i - 1}$$

- 负对数

$$f(x) = - \sum_{i=1}^n \log x_i \quad f^*(y) = - \sum_{i=1}^n \log(-y_i) - n$$

- 矩阵对数

$$f(X) = - \log \det X \quad (\mathbf{dom} f = \mathbf{S}_{++}^n) \quad f^*(Y) = - \log \det(-Y) - n$$

## 示性函数与范数

凸集  $C$  的示性函数：共轭为  $C$  的支撑函数

$$f(x) = \begin{cases} 0, & x \in C \\ +\infty, & x \notin C \end{cases} \quad f^*(y) = \sup_{x \in C} y^T x$$

范数：共轭为单位对偶范数球的示性函数

$$f(x) = \|x\| \quad f^*(y) = \begin{cases} 0, & \|y\|_* \leq 1 \\ +\infty, & \|y\|_* > 1 \end{cases}$$

### Proof.

回忆对偶范数的定义： $\|y\|_* = \sup_{\|x\| \leq 1} x^T y$

分两类讨论计算  $f^*(y) = \sup_x (y^T x - \|x\|)$

- 若  $\|y\|_* \leq 1$ ，则  $y^T x \leq \|x\| \quad \forall x$  (对偶范数的定义)  
 $x = 0$  时等式成立，因此  $\sup_x (y^T x - \|x\|) = 0$
- 若  $\|y\|_* > 1$ ，则存在一个  $x$ ，满足  $\|x\| \leq 1, x^T y > 1$ ，因此有

$$f^*(y) \geq y^T(tx) - \|tx\| = t(y^T x - \|x\|) \rightarrow \infty \quad (t \rightarrow \infty)$$

□

## 二次共轭函数

任一函数 $f$ 的二次共轭函数定义为

$$f^{**}(x) = \sup_{y \in \text{dom } f^*} (x^T y - f^*(y))$$

- $f^{**}(x)$  为闭凸函数
- 由Fenchel不等式,  $x^T y - f^*(y) \leq f(x)$  对所有 $x, y$ 都成立, 推出:

$$f^{**}(x) \leq f(x) \quad \forall x$$

等价地,  $\text{epi } f \subseteq \text{epi } f^{**}$  (对任意函数 $f$ 成立)

- 若 $f$ 是闭凸函数, 则

$$f^{**}(x) = f(x) \quad \forall x$$

等价地,  $\text{epi } f = \text{epi } f^{**}$  (若 $f$ 是闭凸函数); 证明在下一面

## Proof.

假设  $(x, f^{**}(x)) \notin \mathbf{epi} f$ , 则存在严格的分割超平面

$$\begin{bmatrix} a \\ b \end{bmatrix}^T \begin{bmatrix} z - x \\ s - f^{**}(x) \end{bmatrix} \leq c \leq 0 \quad \forall (z, s) \in \mathbf{epi} f$$

其中  $a \in \mathbb{R}^n, b, c \in \mathbb{R}$  且  $b \leq 0$  (若  $b > 0$ , 则取  $s \rightarrow +\infty$  可推出矛盾).

- 若  $b < 0$ , 取  $s = f(z)$ , 有  $a^T z + b f(z) - a^T x - b f^{**}(x) \leq c$

记  $y = a/(-b)$ , 两边除以  $-b$ , 并将上式左边关于  $z$  极大化得到

$$f^*(y) - y^T x + f^{**}(x) \leq -\frac{c}{b} < 0$$

与 Fenchel 不等式矛盾.

- 若  $b = 0$ , 取  $\hat{y} \in \mathbf{dom} f^*$  并给  $\begin{bmatrix} a \\ b \end{bmatrix}$  加上一个  $\begin{bmatrix} \hat{y} \\ -1 \end{bmatrix}$  的  $\varepsilon$  倍, 则

$$\begin{bmatrix} a + \varepsilon \hat{y} \\ -\varepsilon \end{bmatrix}^T \begin{bmatrix} z - x \\ s - f^{**}(x) \end{bmatrix} \leq c + \varepsilon (f^*(\hat{y}) - x^T \hat{y} + f^{**}(x)) < 0$$

即化为  $b < 0$  的情况, 矛盾.



# 共轭函数与次梯度

## 定理

如果  $f$  是闭凸函数, 则

$$y \in \partial f(x) \Leftrightarrow x \in \partial f^*(y) \Leftrightarrow x^T y = f(x) + f^*(y)$$

## Proof.

若  $y \in \partial f(x)$ , 则  $f^*(y) = \sup_u (y^T u - f(u)) = y^T x - f(x)$

$$\begin{aligned} f^*(v) &= \sup_u (v^T u - f(u)) \\ &\geq v^T x - f(x) \\ &= x^T (v - y) - f(x) + y^T x \\ &= f^*(y) + x^T (v - y) \end{aligned}$$

对所有的  $v$  成立; 由此根据次梯度的定义推出  $x \in \partial f^*(y)$   
另一方面,  $x \in \partial f^*(y) \Rightarrow y \in \partial f(x)$  可以由  $f^{**} = f$  得到



# 计算规则

- 可分解的和：

$$f(x_1, x_2) = g(x_1) + h(x_2) \quad f^*(y_1, y_2) = g^*(y_1) + h^*(y_2)$$

- 数乘：( $\alpha > 0$ )

$$f(x) = \alpha g(x) \quad f^*(y) = \alpha g^*(y/\alpha)$$

- 添加线性函数：

$$f(x) = g(x) + a^T x + b \quad f^*(y) = g^*(y - a) - b$$

- 卷积下确界：

$$f(x) = \inf_{u+v=x} (g(u) + h(v)) \quad f^*(y) = g^*(y) + h^*(y)$$

# 提纲

- 1 闭函数
- 2 共轭函数
- 3 邻近算子
- 4 投影算子
- 5 性质和推广

# 邻近算子

定义邻近算子：

$$\text{prox}_h(x) = \underset{u}{\operatorname{argmin}} \left( h(u) + \frac{1}{2} \|u - x\|_2^2 \right)$$

直观理解：求解一个距 $x$ 不算太远的点 $u$ ，并使函数值 $h(u)$ 也相对较小

**定理（邻近算子是良定义的）**

如果 $h$ 为闭凸函数，则对任意 $x$ ， $\text{prox}_h(x)$ 存在且唯一

**Proof.**

首先注意到 $h(u) + \frac{1}{2} \|u - x\|_2^2$ 是强凸函数，则

- 存在性：强凸函数的所有 $\alpha$ -下水平集有界，故由Weierstrass定理知最小值存在
- 唯一性：强凸函数最小值唯一



## 邻近算子与次梯度的关系

### 定理

若 $h$ 是适当的闭凸函数, 则  $u = \text{prox}_h(x) \iff x - u \in \partial h(u)$

### Proof.

若 $u = \text{prox}_h(x)$ , 则由最优性条件得 $0 \in \partial h(u) + (u - x)$ , 因此有 $x - u \in \partial h(u)$ . 反之, 若 $x - u \in \partial h(u)$  则由次梯度的定义可得到

$$h(v) \geq h(u) + (x - u)^T(v - u), \quad \forall v \in \text{dom } h$$

两边同时加 $\frac{1}{2}\|v - x\|^2$ , 即有

$$\begin{aligned} h(v) + \frac{1}{2}\|v - x\|^2 &\geq h(u) + (x - u)^T(v - u) + \frac{1}{2}\|(v - u) - (x - u)\|^2 \\ &\geq h(u) + \frac{1}{2}\|u - x\|^2, \quad \forall v \in \text{dom } h \end{aligned}$$

根据定义可得 $u = \text{prox}_h(x)$ . □

## 邻近算子的例子

在近似点梯度法中，我们关心那些邻近算子 $\text{prox}_{th}$ 容易计算的函数  $h$

例： $l_1$  范数

$$h(x) = \|x\|_1, \quad \text{prox}_{th}(x) = \text{sign}(x) \max\{|x| - t, 0\}$$

Proof.

邻近算子 $u = \text{prox}_{th}(x)$  的最优性条件为

$$x - u \in t\partial\|u\|_1 = \begin{cases} \{t\}, & u > 0 \\ [-t, t], & u = 0 \\ \{-t\}, & u < 0 \end{cases}$$

当 $x > t$ 时， $u = x - t$ ；当 $x < -t$ 时， $u = x + t$ ；当 $x \in [-t, t]$ 时， $u = 0$ ，  
即有 $u = \text{sign}(x) \max\{|x| - t, 0\}$ . □

## 邻近算子的例子

例： $l_2$  范数

$$h(x) = \|x\|_2, \quad \text{prox}_{th}(x) = \begin{cases} \left(1 - \frac{t}{\|x\|_2}\right)x, & \|x\|_2 \geq t, \\ 0, & \text{其他.} \end{cases}$$

Proof.

邻近算子  $u = \text{prox}_{th}(x)$  的最优性条件为

$$x - u \in t\partial\|u\|_2 = \begin{cases} \left\{ \frac{tu}{\|u\|_2} \right\}, & u \neq 0, \\ \{w : \|w\|_2 \leq t\}, & u = 0, \end{cases}$$

因此, 当  $\|x\|_2 > t$  时,  $u = x - \frac{tx}{\|x\|_2^2}$ ; 当  $\|x\|_2 \leq t$  时,  $u = 0$ . □

## 邻近算子的例子

- 二次函数(其中  $A$  对称正定)

$$h(x) = \frac{1}{2}x^T A x + b^T x + c, \quad \text{prox}_{th}(x) = (I + tA)^{-1}(x - tb)$$

- 负自然对数的和

$$h(x) = -\sum_{i=1}^n \ln x_i, \quad \text{prox}_{th}(x)_i = \frac{x_i + \sqrt{x_i^2 + 4t}}{2}, \quad i = 1, 2, \dots, n$$

## 邻近算子的计算规则

- 变量的常数倍放缩以及平移 ( $\lambda \neq 0$ ):

$$h(x) = g(\lambda x + a), \quad \text{prox}_h(x) = \frac{1}{\lambda} (\text{prox}_{\lambda^2 g}(\lambda x + a) - a)$$

- 函数（及变量）的常数倍放缩 ( $\lambda > 0$ ):

$$h(x) = \lambda g\left(\frac{x}{\lambda}\right), \quad \text{prox}_h(x) = \lambda \text{prox}_{\lambda^{-1} g}\left(\frac{x}{\lambda}\right)$$

- 加上线性函数:

$$h(x) = g(x) + a^T x, \quad \text{prox}_h(x) = \text{prox}_g(x - a)$$

## 计算规则 (续)

- 加上二次项 ( $u > 0$ )

$$h(x) = g(x) + \frac{u}{2}\|x - a\|_2^2, \quad \text{prox}_h(x) = \text{prox}_{\theta g}(\theta x + (1 - \theta)a)$$

其中  $\theta = \frac{1}{1+u}$

- 向量函数:

$$h\left(\begin{bmatrix} x \\ y \end{bmatrix}\right) = \varphi_1(x) + \varphi_2(y), \quad \text{prox}_h\left(\begin{bmatrix} x \\ y \end{bmatrix}\right) = \begin{bmatrix} \text{prox}_{\varphi_1}(x) \\ \text{prox}_{\varphi_2}(y) \end{bmatrix}$$

# 复合仿射映射

- 已知函数 $g(x)$ 和矩阵 $A$ ，设 $h(x) = g(Ax + b)$ 。在通常情况下，我们不能使用 $g$ 的邻近算子直接计算关于 $h$ 的邻近算子。
- 然而，如果有 $AA^T = \frac{1}{\alpha}I$ （其中 $\alpha$ 为任意正常数），则

$$\text{prox}_h(x) = (I - \alpha A^T A)x + \alpha A^T (\text{prox}_{\alpha^{-1}g}(Ax + b) - b).$$

- 例如， $h(x_1, x_2, \dots, x_m) = g(x_1 + x_2 + \dots + x_m)$ 的邻近算子为

$$\text{prox}_h(x_1, x_2, \dots, x_m)_i = x_i - \frac{1}{m} \left( \sum_{j=1}^m x_j - \text{prox}_{mg} \left( \sum_{j=1}^m x_j \right) \right).$$

## Proof.

考虑如下优化问题：

$$\begin{aligned} \min_{u,y} \quad & g(y) + \frac{1}{2} \|u - x\|^2, \\ \text{s.t.} \quad & Au + b = y, \end{aligned}$$

则其解中的  $u = \text{prox}_h(x)$ . 固定  $y$  对于  $u$  求极小值，这是一个到仿射集的投影问题，其解为

$$\begin{aligned} u &= x + A^T(AA^T)^{-1}(y - b - Ax) \\ &= (I - \alpha A^T A)x + \alpha A^T(y - b). \end{aligned}$$

将其代入优化问题，将目标函数化为

$$g(y) + \frac{\alpha^2}{2} \|A^T(y - b - Ax)\|^2 = g(y) + \frac{\alpha}{2} \|y - b - Ax\|^2.$$

由此得到  $y = \text{prox}_{\alpha^{-1}g}(Ax + b)$ ，再代入  $u$  的表达式中即可得到结果。  $\square$

- 1 闭函数
- 2 共轭函数
- 3 邻近算子
- 4 投影算子
- 5 性质和推广

## 闭凸集上的投影

设  $C$  为闭凸集，则示性函数  $I_C$  的邻近算子为点  $x$  到  $C$  的投影  $\mathcal{P}_C(x)$ ：

$$\begin{aligned}\text{prox}_{I_C}(x) &= \arg \min_u \left\{ I_C(u) + \frac{1}{2} \|u - x\|^2 \right\} \\ &= \operatorname{argmin}_{u \in C} \|u - x\|^2 = \mathcal{P}_C(x)\end{aligned}$$

这个等式具有几何意义：

$$u = \mathcal{P}_C(x) \Leftrightarrow (x - u)^T (z - u) \leq 0, \quad \forall z \in C$$

# 投影到仿射集

超平面  $C = \{x | a^T x = b\}$  ( $a \neq 0$ )

$$P_C(x) = x + \frac{b - a^T x}{\|a\|_2^2} a$$

仿射集  $C = \{x | Ax = b\}$  ( $A \in \mathbb{R}^{p \times n}$ , 且  $\text{rank}(A) = p$ )

$$P_C(x) = x + A^T (AA^T)^{-1} (b - Ax)$$

当  $p \ll n$ , 或  $AA^T = I, \dots$  时, 计算成本较低

# 投影到多面体集

半平面  $C = \{x | a^T x \leq b\}$  ( $a \neq 0$ )

$$P_C(x) = x + \frac{b - a^T x}{\|a\|_2^2} a \quad \text{if } a^T x > b,$$

$$P_C(x) = x \quad \text{if } a^T x \leq b$$

矩形:  $C = [l, u] = \{x | l \leq x \leq u\}$

$$P_C(x)_i = \begin{cases} l_i & x_i \leq l_i \\ x_i & l_i \leq x_i \leq u_i \\ u_i & x_i \geq u_i \end{cases}$$

非负象限:  $C = \mathbf{R}_+^n$

$$P_C(x) = x_+ \quad (x_+ \text{ 表示各分量取 } \max\{0, x\})$$

概率单纯形： $C = \{x | 1^T x = 1, x \geq 0\}$

$$P_C(x) = (x - \lambda 1)_+$$

其中， $\lambda$ 是下面方程的解：

$$1^T (x - \lambda 1)_+ = \sum_{i=1}^n \max\{0, x_k - \lambda\} = 1$$

(一般的) 概率单纯形： $C = \{x | a^T x = b, l \leq x \leq u\}$

$$P_C(x) = P_{[l,u]}(x - \lambda a)$$

其中， $\lambda$ 是下面方程的解：

$$a^T P_{[l,u]}(x - \lambda a) = b$$

# 投影到范数球

**Euclid 球** :  $C = \{x \mid \|x\|_2 \leq 1\}$

$$P_C(x) = \frac{1}{\|x\|_2} x \quad \text{if } \|x\|_2 > 1,$$

$$P_C(x) = x \quad \text{if } \|x\|_2 \leq 1$$

**$\ell_1$  范数球** :  $C = \{x \mid \|x\|_1 \leq 1\}$

$$P_C(x)_k = \begin{cases} x_k - \lambda & x_k > \lambda \\ 0 & -\lambda \leq x_k \leq \lambda \\ x_k + \lambda & x_k < -\lambda \end{cases}$$

若  $\|x\|_1 \leq 1$ , 则  $\lambda = 0$ ; 其他情形,  $\lambda$  是下面方程的解

$$\sum_{k=1}^n \max\{|x_k| - \lambda, 0\} = 1$$

## 投影到简单锥

二阶锥:  $C = \{(x, t) \in \mathbf{R}^{n \times 1} \mid \|x\|_2 \leq t\}$

$$P_C(x, t) = (x, t) \quad \text{if} \quad \|x\|_2 \leq t,$$

$$P_C(x, t) = (0, 0) \quad \text{if} \quad \|x\|_2 \leq -t$$

且

$$P_C(x, t) = \frac{t + \|x\|_2}{2\|x\|_2} \begin{bmatrix} x \\ \|x\|_2 \end{bmatrix} \quad \text{if} \quad \|x\|_2 \geq |t|, x \neq 0$$

半正定锥:  $C = \mathbf{S}_+^n$

$$P_C(X) = \sum_{i=1}^n \max\{0, \lambda_i\} q_i q_i^T$$

其中,  $X = \sum_{i=1}^n \lambda_i q_i q_i^T$  是  $X$  的特征值分解

- 1 闭函数
- 2 共轭函数
- 3 邻近算子
- 4 投影算子
- 5 性质和推广**

# Moreau分解

Moreau分解描述了邻近算子与共轭函数之间的关系：

$$x = \text{prox}_h(x) + \text{prox}_{h^*}(x)$$

- 这来自于共轭函数和次梯度的性质：

$$\begin{aligned} u = \text{prox}_h(x) &\iff x - u \in \partial h(u) \\ &\iff u \in \partial h^*(x - u) \\ &\iff x - u = \text{prox}_{h^*}(x) \end{aligned}$$

- 可以由此推出，子空间的正交投影的广义分解式：

$$x = P_L(x) + P_{L^\perp}(x)$$

$L$ 为一个子空间， $L^\perp$ 是它的正交补

(在Moreau分解中有 $h = I_L$ ， $h^* = I_{L^\perp}$ ，其中 $I$ 表示示性函数)

# 广义Moreau分解

## 定理

对任意的 $\lambda > 0$ ，我们有广义的Moreau分解式：

$$x = \text{prox}_{\lambda f}(x) + \lambda \text{prox}_{\lambda^{-1}f^*}(x/\lambda)$$

## Proof.

对 $\lambda f$ 应用Moreau分解

$$\begin{aligned}x &= \text{prox}_{\lambda f}(x) + \text{prox}_{(\lambda f)^*}(x) \\ &= \text{prox}_{\lambda f}(x) + \lambda \text{prox}_{\lambda^{-1}f^*}(x/\lambda)\end{aligned}$$

第二行运用了共轭函数的性质： $(\lambda f)^*(y) = \lambda f^*(y/\lambda)$  □

# 支撑函数

支撑函数的共轭（在闭凸集上）是示性函数：

$$f(x) = S_C(x) = \sup_{y \in C} x^T y, \quad f^*(y) = I_C(y)$$

支撑函数的邻近算子：（应用Moreau分解）

$$\begin{aligned} \text{prox}_{tf}(x) &= x - t \text{prox}_{t^{-1}f^*}(x/t) \\ &= x - tP_C(x/t) \end{aligned}$$

可以发现，支撑函数的邻近算子可以通过投影计算得到例子： $f(x)$ 是  $x$  最大的  $r$  个分量的和，则

$$f(x) = x_{[1]} + \cdots + x_{[r]} = S_C(x), \quad C = \{y | 0 \leq y \leq 1, 1^T y = r\}$$

# 范数

范数的共轭是对偶范数球的共轭函数：

$$f(x) = \|c\|, \quad f^*(x) = I_B(y) \quad (B = \{y \mid \|y\|_* \leq 1\})$$

范数的邻近算子：（应用Moreau分解）

$$\begin{aligned} \operatorname{prox}_{tf}(x) &= x - t \operatorname{prox}_{t^{-1}f^*}(x/t) \\ &= x - tP_B(x/t) \\ &= x - P_{tB}(x) \end{aligned}$$

当 $tB = \{x \mid \|x\| \leq t\}$ 容易计算时，可以用这个公式高效地计算 $\operatorname{prox}_{t\|\cdot\|}$

# 单点距离

距离（一般范数意义下）

$$f(x) = \|x - a\|$$

邻近算子：令  $g(x) = \|x\|$

$$\begin{aligned}\text{prox}_{t f}(x) &= a + \text{prox}_{t g}(x - a) \\ &= a + x - a - t P_B\left(\frac{x - a}{t}\right) \\ &= x - P_{tB}(x - a)\end{aligned}$$

$B$  定义同上一页

# 集合的 Euclid 距离

**Euclid 距离** (对于闭凸集  $C$ )

$$d(x) = \inf_{y \in C} \|x - y\|_2$$

距离的邻近算子

$$\text{prox}_{td}(x) = \theta P_C(x) + (1 - \theta)x, \quad \theta = \begin{cases} t/d(x) & d(x) \geq t \\ 1 & \text{otherwise} \end{cases}$$

平方距离的邻近算子:  $f(x) = d(x)^2/2$


$$\text{prox}_{tf}(x) = \frac{1}{1+t}x + \frac{t}{1+t}P_C(x)$$

证明 (关于  $\text{prox}_{td}(x)$  的表达式)

- 若  $u = \text{prox}_{td}(x) \notin C$ , 则有

$$x - u = \frac{t}{d(u)}(u - P_C(u))$$

由此可推出  $P_C(u) = P_C(x)$ ,  $d(x) \geq t$ , 且  $u$  是  $x$  和  $P_C(x)$  的加权平均



- 若  $u \in C$  最小化  $d(u) + \frac{1}{2t}\|u - x\|_2^2$ , 等价于最小化  $\frac{1}{2t}\|u - x\|_2^2$ , 即得  $u = P_C(x)$

证明 (关于  $\text{prox}_{tf}(x)$  的表达式, 当  $f(x) = d(x)^2/2$  时)

$$\begin{aligned}\text{prox}_{tf}(x) &= \arg \min_u \left( \frac{1}{2}d(u)^2 + \frac{1}{2t}\|u - x\|_2^2 \right) \\ &= \arg \min_u \inf_{v \in C} \left( \frac{1}{2}\|u - v\|_2^2 + \frac{1}{2t}\|u - x\|_2^2 \right)\end{aligned}$$

最优的  $u$  可以看成  $v$  的函数:

$$u = \frac{t}{t+1}v + \frac{1}{t+1}x$$

最优的  $v$  在集合  $C$  上极小化

$$\frac{1}{2} \left\| \frac{t}{t+1}v + \frac{1}{t+1}x - v \right\|_2^2 + \frac{1}{2t} \left\| \frac{t}{t+1}v + \frac{1}{t+1}x - x \right\|_2^2 = \frac{1}{2(1+t)} \|v - x\|_2^2$$

由此即得,  $v = P_C(x)$

## 非凸函数的邻近算子

(适当闭函数的邻近算子) 设  $h$  是适当闭函数(可以非凸), 且具有有限的下界, 即满足  $\inf_{x \in \text{dom} h} h(x) > -\infty$ , 定义  $h$  的邻近算子为

$$\text{prox}_h(x) = \arg \min_{u \in \text{dom} h} \left\{ h(u) + \frac{1}{2} \|u - x\|^2 \right\}.$$

### 定理

设  $h$  是适当闭函数且  $\inf_{x \in \text{dom} h} h(x) > -\infty$ , 则  $\forall x \in \text{dom} h$ ,  $\text{prox}_h(x)$  是  $\mathbb{R}^n$  上的非空紧集.

### Proof.

定义  $g(u) = h(u) + \frac{1}{2} \|u - x\|^2$ , 设  $\inf_{x \in \text{dom} h} h(x) = l$ .

取  $u_0 \in \text{dom} h$ , 由于  $\frac{1}{2} \|u - x\|^2$  无上界, 故  $\exists R > 0$ , 对  $\forall$  满足  $\|u - x\| > R$  的  $u$ , 成立  $\frac{1}{2} \|u - x\|^2 > g(u_0) - l$ , 即  $g(u) > g(u_0)$ .

这说明下水平集  $\{u \mid g(u) \leq g(u_0)\}$  含于球  $\|u - x\| \leq R$  内, 即  $g$  有一个非空有界下水平集. 显然  $g(u)$  是闭函数, 由 Weierstrass 定理可知,  $g(u)$  的最小值点集合  $\text{prox}_h(x)$  是非空紧集.  $\square$

# 非光滑非凸问题函数的次微分

前面介绍了闭凸函数的邻近算子与次梯度的关系，而对于非凸函数有类似的结论。首先回顾一下非光滑非凸函数的次微分。

## 次微分

设  $f: \mathbb{R}^n \rightarrow (-\infty, +\infty]$  是适当下半连续函数。

- 对给定的  $x \in \text{dom } f$ ，满足如下条件的所有向量  $u \in \mathbb{R}^n$  的集合定义为  $f$  在点  $x$  处的 *Fréchet* 次微分：

$$\liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle u, y - x \rangle}{\|y - x\|} \geq 0,$$

记为  $\hat{\partial}f(x)$ 。当  $x \notin \text{dom } f$  时，将  $\hat{\partial}f(x)$  定义为空集  $\emptyset$ 。

- $f$  在点  $x \in \mathbb{R}^n$  处的极限次微分(或简称为次微分)定义为

$$\partial f(x) = \{u \in \mathbb{R}^n : \exists x^k \rightarrow x, f(x^k) \rightarrow f(x), u^k \in \hat{\partial}f(x^k) \rightarrow u\}.$$


极限次微分通过对  $x$  附近的点处的 *Fréchet* 次微分取极限得到。

- $\hat{\partial}f(x) \subseteq \partial f(x)$ , 前者是闭凸集, 后者是闭集. 并非在所有的  $x \in \text{dom } f$  处都存在 *Fréchet* 次微分.
- 凸函数的次梯度要求不等式

$$f(y) \geq f(x) + \langle g, y - x \rangle, \quad g \in \partial f(x)$$

在定义域内全局成立, 而非凸函数只要求在极限意义下成立.

- 当  $f$  是可微函数时, *Fréchet* 次微分和次微分都退化成梯度.



如图,  $f(x)$  在  $x_3$  处不存在 *Fréchet* 次微分, 但存在次微分

## 定理

设  $h$  是适当闭函数(可非凸)且有下界,  $u \in \text{prox}_h(x)$ , 则  $x - u \in \partial h(u)$