

凸优化初步

3月机器学习在线班 邹博

2015年3月14日

历史遗留问题

- 估计量的优良性准则
 - 无偏性
 - 均方误差准则



无偏性 $E(\hat{\theta}) = \theta$

- 利用已知样本 X_1, X_2, \dots, X_n 能够得到参数的一个估计 $\hat{\theta}$ ，因此， $\hat{\theta}$ 可以写成 $\hat{\theta}(X_1, X_2, \dots, X_n)$ ，对于不同的样本， $\hat{\theta}$ 的值一般不同。因此，可以看成是关于样本的随机变量。它是可以求均值的： $E(\hat{\theta})$
- 如果 $E(\hat{\theta})$ 等于总体的实际分布 θ ，就说这个估计是无偏估计。 $E(\hat{\theta}) = \theta$
 - 用 $\hat{\theta}$ 去估计 θ ，有时偏高，有时偏低，但平均来说，它等于位置参数 θ



举例

□ 无偏估计

$$\hat{\mu} = X_1$$

$$\hat{\mu} = \frac{X_1 + X_2}{2}$$

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$$

□ 不是无偏估计

$$\hat{\mu} = 2X_1$$

$$\hat{\mu} = \frac{X_1 + X_2}{3}$$

$$\hat{\mu} = \frac{1}{n-3} \sum_{i=1}^n X_i$$



样本均值和方差是总体的无偏估计

- 设总体均值为 μ ，方差为 σ^2 ， X_1, X_2, \dots, X_n 为来自该总体的样本，即：

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$S = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- 则：
 $E(\bar{X}) = \mu$
 $E(S^2) = \sigma^2$



均值的无偏性

□ 因为 X_1, X_2, \dots, X_n 为同分布的，于是 $E(X_i) = \mu$ ，所以：

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \cdot n\mu = \mu$$



方差的无偏性

□ 首先
$$\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{\sigma^2}{n}$$

□ 因此
$$E(\bar{X}^2) = \text{Var}(\bar{X}) + [E(\bar{X})]^2 = \frac{\sigma^2}{n} + \mu^2$$

□ 而
$$E(X_i^2) = \text{Var}(X_i) + [E(X_i)]^2 = \sigma^2 + \mu^2$$

$$\sum_{i=1}^n (X_i - \bar{X})^2 = \sum_{i=1}^n X_i^2 - 2\left(\sum_{i=1}^n X_i\right)\bar{X} + n\bar{X}^2 = \sum_{i=1}^n X_i^2 - 2(n\bar{X}) \cdot \bar{X} + n\bar{X}^2 = \sum_{i=1}^n X_i^2 - n\bar{X}^2$$

□ 所以

$$E(S^2) = \frac{1}{n-1} \left[E\left(\sum_{i=1}^n X_i^2\right) - nE(\bar{X}^2) \right] = \frac{1}{n-1} \left[(n\sigma^2 + n\mu^2) - n\left(\frac{\sigma^2}{n} + \mu^2\right) \right] = \sigma^2$$



均方误差准则 $MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$

- 用估计量 $\hat{\theta}$ 去估计 θ ，其误差是 $\hat{\theta} - \theta$ ，该误差显然随样本 X_1, X_2, \dots, X_n 而定，因此， $\hat{\theta} - \theta$ 是随机变量，它的平方的均值，称作均方误差。这个量越小，平均误差越小，估计结果越优。

$$MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$$

- 显然，若 $\hat{\theta}$ 是无偏估计，则MSE即方差。

$$MSE(\hat{\theta}) = E[(\hat{\theta} - \theta)^2] = E[(\hat{\theta} - E(\hat{\theta}))^2] = Var(\hat{\theta})$$



凸优化

- 凸集
- 凸函数
- 共轭函数
- 凸优化
- 对偶函数
- KKT条件



思考两个不等式

- 两个正数的算术平均数大于等于几何平均数

$$\frac{a+b}{2} \geq \sqrt{ab}, \quad a > 0, b > 0$$

- 给定可逆对称阵 Q , 对于任意的向量 x, y , 有:

$$x^T Q x + y^T Q^{-1} y \geq 2x^T y$$

- 都可以在凸函数的框架下得到解决。



思考凸集和凸函数

- $y=x^2$ 是凸函数，函数图像上位于 $y=x^2$ 上方的区域构成凸集。
 - 凸函数图像的上方区域，一定是凸集；
 - 一个函数图像的上方区域为凸集，则该函数是凸函数。
 - 稍后给出上述表述的形式化定义。
- 因此，学习凸优化，考察凸函数，先从凸集及其性质开始。



(超)几何体的向量表达

- 给定二维平面上两个定点: $\mathbf{a}(x_1, y_1)$, $\mathbf{b}(x_2, y_2)$, 则:
 - 直线
 - $\mathbf{x} = \theta \mathbf{a} + (1 - \theta) \mathbf{b}$, $\theta \in \mathbb{R}$
 - 线段
 - $\mathbf{x} = \theta \mathbf{a} + (1 - \theta) \mathbf{b}$, $\theta \in [0, 1]$
- 一般的, $f(x, y) = 0$ 表示定义域在 \mathbb{R}^2 的曲线
 - 特殊的, $y = g(x)$ 表示定义域在 \mathbb{R} 的曲线, $f(x, y) = y - g(x)$
- 一般的, $f(x, y, z) = 0$ 表示定义域在 \mathbb{R}^3 的曲面
 - 特殊的, $z = h(x, y)$ 表示定义域在 \mathbb{R}^2 的曲面, $f(x, y, z) = z - h(x, y)$
- 上述表达方式可以方便的推广到高维
 - 记 $\mathbf{x} = (u_1, u_2, \dots, u_n)$, 则 $f(\mathbf{x}) = 0$ 表示定义域在 \mathbb{R}^n 的超曲面。
 - 不特殊说明, 后面将使用 \mathbf{x}_1 表示向量, 如: 定义两个点 $\mathbf{x}_1, \mathbf{x}_2$, 则 $\mathbf{x} = \theta \mathbf{x}_1 + (1 - \theta) \mathbf{x}_2$, $\theta \in \mathbb{R}$ 表示经过这两点的直线



仿射集(Affine set)

- 定义：通过集合C中任意两个不同点的直线仍然在集合C内，则称集合C为仿射集。

$$\forall \theta \in R, \forall x_1, x_2 \in C, \text{则 } x = \theta x_1 + (1 - \theta)x_2 \in C$$

- 仿射集的例子：直线、平面、超平面
 - 超平面： $Ax=b$
 - $f(x)=0$ 表示定义域在 R^n 的超曲面：令 $f(x)=Ax-b$ ，则 $f(x)=0$ 表示“截距”为 b 的超平面。
 - 三维空间的平面是二维的；四维空间的平面是几维的？
 - n 维空间的 $n-1$ 维仿射集为 $n-1$ 维超平面。
 - 后面将继续考察超平面的定义。



仿射包

□ 仿射包：包含集合C的最小仿射集。

$$\text{aff } C = \left\{ \sum \theta_i x_i \mid x_i \in C, \sum \theta_i = 1 \right\}$$

□ 仿射维数：仿射包的维数。

■ 三角形的仿射维数为2

■ 线段的仿射维数为1

■ 球的仿射维数为3



内点和相对内点

□ 给定一个集合C，如何定义哪些点在“边界”上，哪些点在内部？

■ 直观的想法：对于集合C中的某个点x，以x为中心做半径为r的球($r > 0$ ，且非常小)，若球和C的交集完全落在C的内部(即：是C的子集)，则x为C的内点。

■ 将该概念用在C的仿射集 $\text{aff } C$ 上，则为相对内点。一般用 $\text{rel int } C$ 表示C的相对内点。

$$\text{rel int } C = \{x \in C \mid \exists r > 0, (B(x, r) \cap \text{aff } C) \subseteq C\}$$



举例

Consider a square in the (x_1, x_2) -plane in \mathbf{R}^3 , defined as

$$C = \{x \in \mathbf{R}^3 \mid -1 \leq x_1 \leq 1, -1 \leq x_2 \leq 1, x_3 = 0\}.$$

Its affine hull is the (x_1, x_2) -plane, *i.e.*, $\mathbf{aff} C = \{x \in \mathbf{R}^3 \mid x_3 = 0\}$.

The interior of C is empty, but the relative interior is

$$\mathbf{relint} C = \{x \in \mathbf{R}^3 \mid -1 < x_1 < 1, -1 < x_2 < 1, x_3 = 0\}.$$

Its boundary (in \mathbf{R}^3) is itself C .

Its relative boundary is the wire-frame outline,

$$\{x \in \mathbf{R}^3 \mid \max\{|x_1|, |x_2|\} = 1, x_3 = 0\}.$$



凸集

□ 集合C内任意两点间的线段均在集合C内，
则称集合C为凸集。

$\forall x_1, x_2 \in C, \theta \in [0, 1],$ 则 $\theta x_1 + (1 - \theta)x_2 \in C$

$\forall x_1, \dots, x_k \in C, \theta_i \in [0, 1]$ 且 $\sum_{i=1}^k \theta_i = 1,$

则 $\sum_{i=1}^k \theta_i x_i \in C$



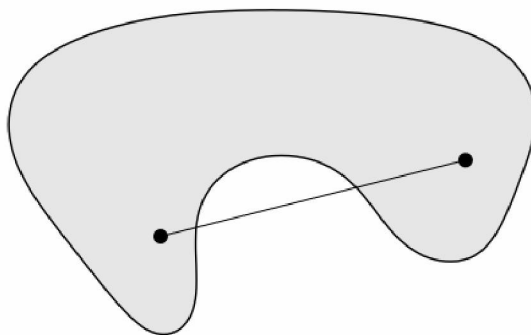



仿射集和凸集的关系


- 因为仿射集的条件比凸集的条件强，所以，仿射集必然是凸集。




凸集



(a) 有界凸集



(b) 无界凸集



(c) 非凸集



凸包



- 集合C的所有点的凸组合形成的集合，叫做集合C的凸包。

$$\text{conv } C = \left\{ \sum_{i=1}^k \theta_i x_i \mid x_i \in C, \theta_i \geq 0, \sum_{i=1}^k \theta_i = 1 \right\}$$

- 集合C的凸包是能够包含C的最小的凸集。



凸包的例子



锥(Cones)

锥的定义 (**nonnegative homogeneous**)

$$\forall x \in C, \theta \geq 0, \text{ 则有 } \theta x \in C.$$

凸锥的定义：集合**C**既是凸集又是锥。




$$\forall x_1, x_2 \in C, \theta_1, \theta_2 \geq 0, \text{ 则有 } \theta_1 x_1 + \theta_2 x_2 \in C.$$

锥包的定义：集合**C**内点的所有锥组合。

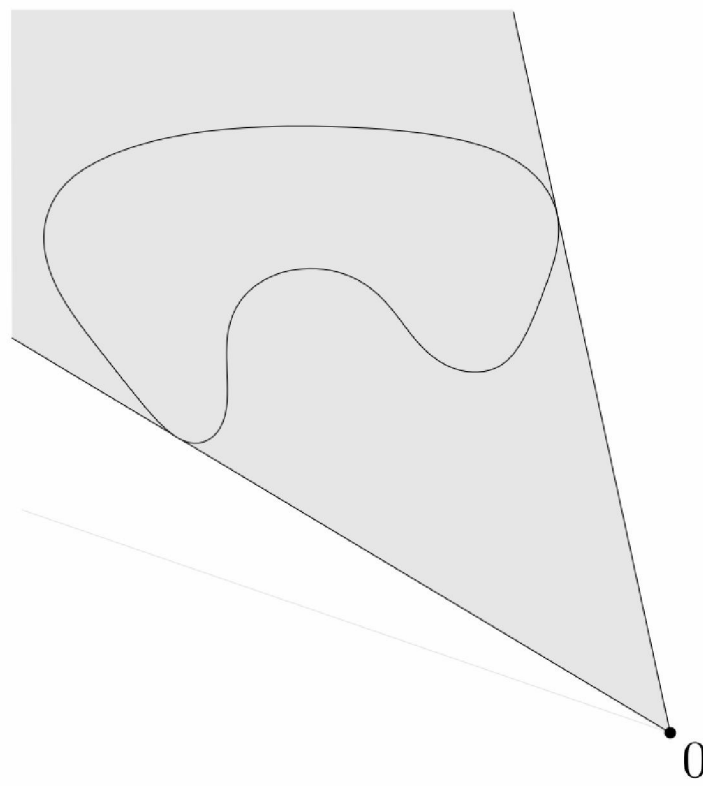

$$\left\{ \sum_{i=1}^k \theta_i x_i \mid x_i \in C, \theta_i \geq 0 \right\}$$



锥的举例：过原点的射线、射线族、角



锥包



思考

- 试证明： n 阶半正定方阵的集合为凸锥。
 - 考察半正定阵的定义



超平面和半空间

□ 超平面hyperplane


$$\{x \mid a^T x = b\}$$

□ 半空间halfspace

$$\{x \mid a^T x \leq b\} \quad \{x \mid a^T x \geq b\}$$



超平面和半空间



欧式球和椭球

□ 欧式球

$$\begin{aligned} B(x_c, r) &= \{x \mid \|x - x_c\|_2 \leq r\} \\ &= \{x \mid (x - x_c)^T (x - x_c) \leq r^2\} \end{aligned}$$

□ 椭球

$$E = \{x \mid (x - x_c)^T P (x - x_c) \leq r^2\},$$

P 为对称正定矩阵



范数球和范数锥(欧式空间的推广)

□ 范数 $\|x\| \geq 0, \|x\| = 0$ 当且仅当 $x = 0$;

$$\|tx\| = |t| \|x\|, t \in R;$$

$$\|x + y\| \leq \|x\| + \|y\|$$

□ 范数球


$$B(x_c, r) = \{x \mid \|x - x_c\| \leq r\}$$

□ 范数锥

$$\{(x, t) \mid \|x\| \leq t\}$$



\mathbb{R}^3 空间中的二阶锥



多面体


- 多面体有限个半空间和超平面的交集。

$$P = \{x \mid a_j^T x \leq b_j, c_i^T x = d_i\}$$

- 仿射集(如超平面、直线)、射线、线段、半空间都是多面体。
- 多面体是凸集。
- 此外：有界的多面体有时称作多胞形(polytope)。
 - 注：该定义略混乱，不同文献的含义不同。



多面体



保持凸性的运算

□ 集合交运算

■ 思考：如何证明？（提示：根据定义）

□ 仿射变换


■ 函数 $f=Ax+b$ 的形式，称函数是仿射的：即线性函数加常数的形式

□ 透视变换

□ 投射变换(线性分式变换)



集合交运算：半空间的交



仿射变换

- 仿射变换 $f(x) = Ax + b$, $A \in \mathbf{R}^{m \times n}$, $b \in \mathbf{R}^m$
 - 伸缩、平移、投影
- 若 f 是仿射变换, $f: \mathbf{R}^n \rightarrow \mathbf{R}^m$ $f(S) = \{f(x) \mid x \in S\}$
 - 若 S 为凸集, 则 $f(S)$ 为凸集;
 - 若 $f(S)$ 为凸集, 则 S 为凸集。



进一步分析仿射变换

□ 两个凸集的和为凸集

$$S_1 + S_2 = \{x + y \mid x \in S_1, y \in S_2\}$$

□ 两个凸集的笛卡尔积(直积)为凸集

$$S_1 \times S_2 = \{(x_1, x_2) \mid x_1 \in S_1, x_2 \in S_2\}$$

□ 两个集合的部分和为凸集(分配率)

$$S = \{(x, y_1 + y_2) \mid (x, y_1) \in S_1, (x, y_2) \in S_2\}$$




透视变换

- 透视函数对向量进行伸缩(规范化), 使得最后一维的分量为1并舍弃之。

$$P : \mathbf{R}^{n+1} \rightarrow \mathbf{R}^n, P(z, t) = z/t$$

- 透视的直观意义

- 小孔成像



透视变换的保凸性

- 凸集的透视变换仍然是凸集。
- 思考：反过来，若某集合的透视变换是凸集，这个集合一定是凸集吗？



投射函数(线性分式函数)

□ 投射函数是透视函数和仿射函数的复合。

□ g 为仿射函数: $g: \mathbf{R}^n \rightarrow \mathbf{R}^{m+1}$

$$g(x) = \begin{bmatrix} A \\ c^T \end{bmatrix} x + \begin{bmatrix} b \\ d \end{bmatrix}$$

$$A \in \mathbf{R}^{m \times n}, b \in \mathbf{R}^m, c \in \mathbf{R}^n, d \in \mathbf{R}$$

□ 定义 f 为线性分式函数



$$f(x) = (Ax + b)/(c^T x + d), \text{ dom } f = \{x \mid c^T x + d > 0\}$$

□ 若 $c=0, d>0$, 则 f 即为普通的仿射函数。



投射的作用

$$f(x_1, x_2) = \begin{cases} f_1(x_1) = \frac{x_1}{x_1 + x_2 + 1}, \\ f_2(x_2) = \frac{x_2}{x_1 + x_2 + 1} \end{cases}, \quad \text{dom } f = \{(x_1, x_2) \mid x_1 + x_2 + 1 > 0\}$$



分割超平面


- 设C和D为两不相交的凸集，则存在超平面P，P可以将C和D分离。

$$\forall x \in C, a^T x \leq b \text{ 且 } \forall x \in D, a^T x \geq b$$

- 注意上式中可以取等号。
 - “若两个凸集C和D的分割超平面存在，C和D不相交”为假命题。
 - 加强条件：若两个凸集至少有一个是开集，那么当且仅当存在分割超平面，它们不相交。




分割超平面



分割超平面的构造

- 两个集合的距离，定义为两个集合间元素的最短距离。
- 做集合C和集合D最短线段的垂直平分线。



思考

- 如何定义两个集合的“最优”分割超平面？
- 若两个集合有部分相交，如何定义超平面，使得两个集合“尽量”分开？
 - 上述“集合”的元素，可能是若干离散点。若一组集合为 $(x,1)$ ，另一组集合为 $(x,2)$ ，则为机器学习中的分类问题。



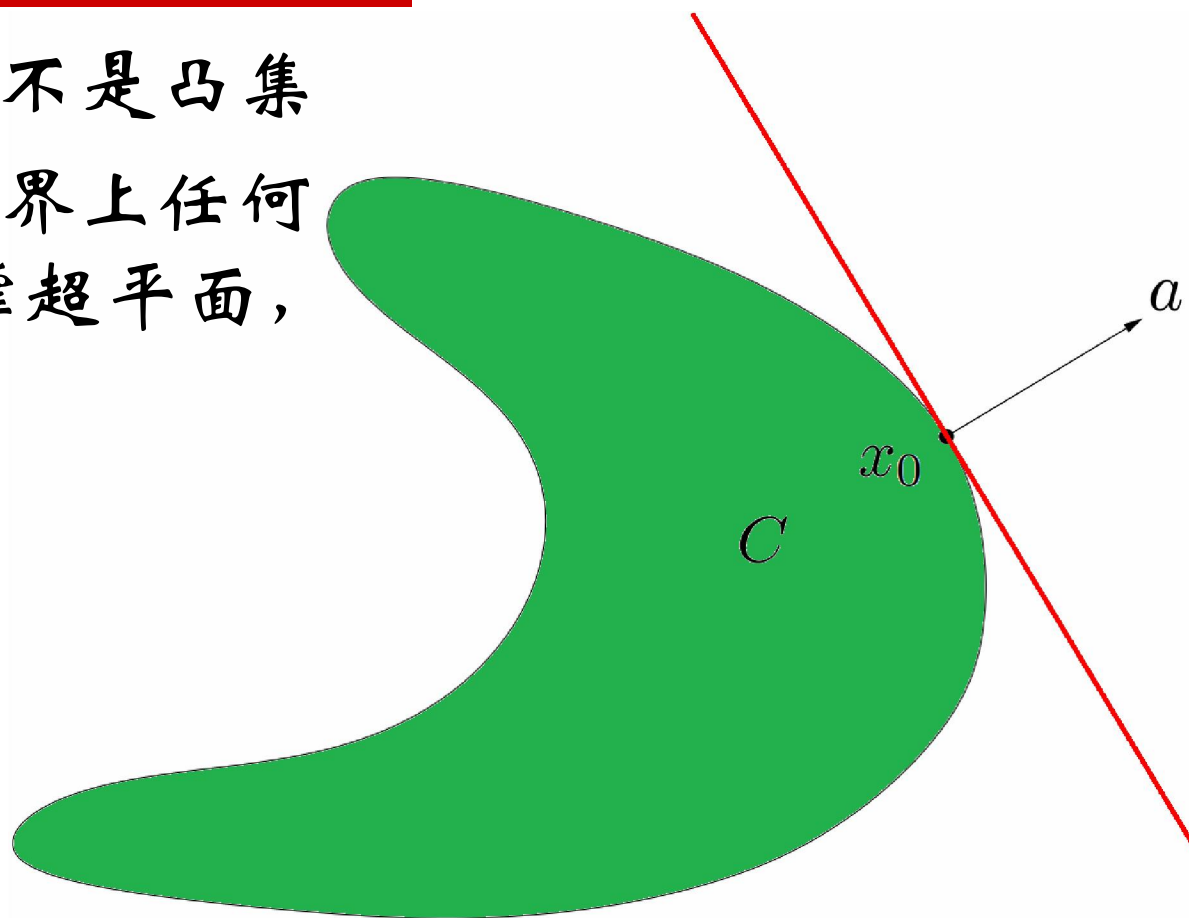
支撑超平面

- 设集合 C ， x_0 为 C 边界上的点。若存在 $a \neq 0$ ，满足对任意 $x \in C$ ，都有 $a^T x \leq a^T x_0$ 成立，则称超平面 $\{x \mid a^T x = a^T x_0\}$ 为集合 C 在点 x_0 处的支撑超平面。
- 凸集边界上任意一点，均存在支撑超平面。
- 若一个闭的非中空集合，在边界上的任意一点存在支撑超平面，则该集合为凸集。



支撑超平面

- 注意：图中 C 不是凸集
- 但如果 C 的边界上任何点都存在支撑超平面，则 C 是凸集。




凸函数

□ 若函数 f 的定义域 $\text{dom}f$ 为凸集，且满足

$\forall x, y \in \text{dom} f, 0 \leq \theta \leq 1$ ，有


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



一阶可微

□ 若 f 一阶可微，则函数 f 为凸函数当前仅当 f 的定义域 $\text{dom}f$ 为凸集，且

$$\forall x, y \in \text{dom}f, f(y) \geq f(x) + \nabla f(x)^T (y - x)$$



进一步的思考 $f(y) \geq f(x) + \nabla f(x)^T (y - x)$

- 结合凸函数图像和支撑超平面理解该问题
- 对于凸函数，其一阶Taylor近似本质上是该函数的全局下估计。
- 反之，如果一个函数的一阶Taylor近似总是起全局下估计，则该函数是凸函数。
- 该不等式说明从一个函数的局部信息，可以得到一定程度的全局信息。



二阶可微

- 若函数 f 二阶可微，则函数 f 为凸函数当前仅当 dom 为凸集，且

$$\nabla^2 f(x) \succeq 0$$

- 若 f 是一元函数，上式表示二阶导大于等于0
- 若 f 是多元函数，上式表示二阶导Hessian矩阵半正定。



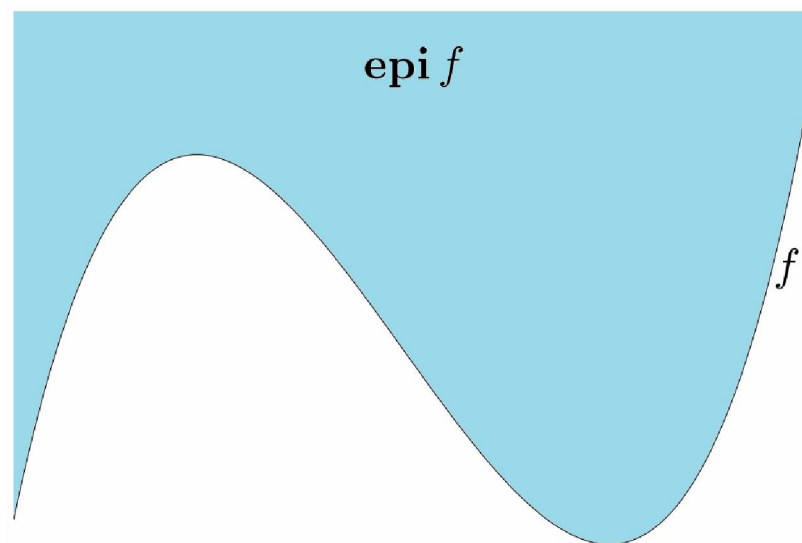
凸函数举例

- 指数函数 e^{ax}
- 幂函数 $x^a, x \in R_+, a \geq 1$ or $a \leq 0$
- 负对数函数 $-\log x$
- 负熵函数 $x \log x$
- 范数函数 $\|x\|_p$
 $f(x) = \max(x_1, \dots, x_n)$
 $f(x) = x^2 / y, y > 0$
 $f(x) = \log(e^{x_1} + \dots + e^{x_n})$



上境图

- 函数 f 的图像定义为: $\{(x, f(x)) \mid x \in \text{dom } f\}$
- 函数 f 的上境图(epigraph)定义为:
$$\text{epi } f = \{(x, t) \mid x \in \text{dom } f, f(x) \leq t\}$$



凸函数与凸集

□ 一个函数是凸函数，当且仅当其上境图是凸集。

■ 思考：如何证明？（提示：定义）

□ 进一步，一个函数是凹函数，当且仅当其亚图(hypograph)是凸集。

$$\text{hypo } f = \{(x, t) \mid t \leq f(x)\}$$



Jensen不等式：若f是凸函数

□ 基本Jensen不等式

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

□ 若 $\theta_1, \dots, \theta_k \geq 0, \theta_1 + \dots + \theta_k = 1$

□ 则 $f(\theta_1 x_1 + \dots + \theta_k x_k) \leq \theta_1 f(x_1) + \dots + \theta_k f(x_k)$

□ 若 $p(x) \geq 0$ on $S \subseteq \mathbf{dom} f, \int_S p(x) dx = 1$

□ 则 $f\left(\int_S p(x)x dx\right) \leq \int_S f(x)p(x) dx$

$$f(\mathbf{E} x) \leq \mathbf{E} f(x)$$



思考

- 利用 $f(E(x)) \leq E(f(x))$, (f 是凸函数), 证明下式 $D \geq 0$

$$D(p \parallel q) = \sum_x p(x) \log \frac{p(x)}{q(x)} = E_{p(x)} \log \frac{p(x)}{q(x)}$$

- 利用 $y = -\log x$ 是凸函数, 证明:

$$\frac{a+b}{2} \geq \sqrt{ab}, \quad a > 0, b > 0$$

- 提示: 任取 $a, b > 0$, $\theta = 0.5$ 带入基本 Jensen 不等式



保持函数凸性的算子

- 凸函数的非负加权和

$$f(x) = \omega_1 f_1(x) + \dots + \omega_n f_n(x)$$

- 凸函数与仿射函数的复合

$$g(x) = f(Ax + b)$$

- 凸函数的逐点最大值、逐点上确界

$$f(x) = \max(f_1(x), \dots, f_n(x))$$

$$f(x) = \sup_{y \in A} g(x, y)$$



凸函数的逐点最大值

□ f_1, f_2 均为凸函数，定义函数 f :

$$f(x) = \max\{f_1(x), f_2(x)\}$$

□ 则函数 f 为凸函数。

$$\begin{aligned} & f(\theta x + (1 - \theta)y) \\ &= \max\{f_1(\theta x + (1 - \theta)y), f_2(\theta x + (1 - \theta)y)\} \\ &\leq \max\{\theta f_1(x) + (1 - \theta)f_1(y), \theta f_2(x) + (1 - \theta)f_2(y)\} \\ &\leq \theta \max\{f_1(x), f_2(x)\} + (1 - \theta) \max\{f_1(y), f_2(y)\} \\ &= \theta f(x) + (1 - \theta)f(y) \end{aligned}$$



思考

□ 逐点上确界和上境图的关系

- 一系列函数逐点上确界函数对应着这些函数上境图的交集。
- Oxy平面上随意画N条直线，在每个x处取这些直线的最大的点，则构成的新函数是凸函数。
- 点x到任意集合C的最远距离 $f(x) = \sup_{y \in C} \|x - y\|$
 - f是凸函数
 - 证明：范数是凸的(思考：为什么?)，逐点求上界，仍然是凸的。



共轭函数

□ 原函数 $f : \mathbf{R}^n \rightarrow \mathbf{R}$ 共轭函数定义：

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

□ 显然，定义式的右端是关于 y 的仿射函数，它们逐点求上确界，得到的函数 $f^*(y)$ 一定是凸函数。


□ 该名称的原因：

■ 凸函数的共轭函数的共轭函数是其本身。



对共轭函数的理解 $f^*(y) = \sup_{x \in \text{dom } f} (y^T x - f(x))$

□ 如果函数 f 可微，在满足 $f'(x)=y$ 的点 x 处差值最大。



例：求共轭函数

- 可逆对称阵 Q ，对于任意的向量 x ，定义函数
 $f: f(x) = \frac{1}{2}x^T Qx$
- 关于 (x,y) 的函数 $y^T x - \frac{1}{2}x^T Qx$
- 在 $x = Q^{-1}y$ 时取上确界，带入，得到：

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

- f^* 即是 f 的共轭函数



Fenchel不等式

□ 根据定义

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

□ 立刻可以得到：

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



Fenchel不等式的应用

□ 根据 $f(x)$ 及其共轭函数 $f^*(x)$

$$f(x) = \frac{1}{2} x^T Q x \quad f^*(y) = \frac{1}{2} y^T Q^{-1} y$$

□ 带入Fenchel不等式，得到：

$$x^T Q x + y^T Q^{-1} y \geq 2x^T y$$



凸优化

□ 优化问题的基本形式

$$\text{minimize } f_0(x), \quad x \in \mathbf{R}^n$$

$$\text{subject to } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$h_j(x) = 0, \quad j = 1, \dots, p$$

$$\text{优化变量 } \quad x \in \mathbf{R}^n$$

$$\text{不等式约束 } \quad f_i(x) \leq 0$$

$$\text{等式约束 } \quad h_j(x) = 0.$$

$$\text{无约束优化 } \quad m = p = 0$$



优化问题的基本形式

□ 优化问题的域

$$D = \bigcap_{i=0}^m \text{dom}f_i \cap \bigcap_{j=1}^p \text{dom}h_j$$

□ 可行点(解)(feasible)

■ $x \in D$, 且满足约束条件

□ 可行域(可解集)

■ 所有可行点的集合

□ 最优化值

$$p^* = \inf\{f_0(x) \mid f_i(x) \leq 0, i = 1, \dots, m, h_j(x) = 0, j = 1, \dots, p\}$$

□ 最优化解

$$p^* = f_0(x^*)$$



局部最优问题

minimize $f_0(x)$, $x \in \mathbf{R}^n$

subject to $f_i(x) \leq 0$, $i = 1, \dots, m$

$h_j(x) = 0$, $j = 1, \dots, p$

$\|x - z\|_2 \leq R$, $R > 0$



凸优化问题的基本形式

$$\text{minimize } f_0(x), \quad x \in \mathbf{R}^n$$

$$\text{subject to } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$h_j(x) = 0, \quad j = 1, \dots, p$$

- 其中， $f_i(x)$ 为凸函数， $h_j(x)$ 为仿射函数
- 凸优化问题的重要性质
 - 凸优化问题的可行域为凸集
 - 凸优化问题的局部最优解即为全局最优解



非凸优化问题的变形

$$\begin{aligned} &\text{minimize} && f_0(x) = x_1^2 + x_2^2 \\ &\text{subject to} && f_1(x) = x_1 / (1 + x_2^2) \leq 0 \\ &&& h_1(x) = (x_1 + x_2)^2 = 0 \end{aligned}$$

等价于凸优化问题

$$\begin{aligned} &\text{minimize} && f_0(x) = x_1^2 + x_2^2 \\ &\text{subject to} && \tilde{f}_1(x) = x_1 \leq 0 \\ &&& \tilde{h}_1(x) = x_1 + x_2 = 0 \end{aligned}$$



对偶问题

□ 一般优化问题的Lagrange乘子法

$$\text{minimize } f_0(x), \quad x \in \mathbf{R}^n$$

$$\text{subject to } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$h_j(x) = 0, \quad j = 1, \dots, p$$

□ Lagrange函数

$$L(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{j=1}^p \nu_j h_j(x)$$

- 对固定的 x , Lagrange函数 $L(x, \lambda, \nu)$ 为关于 λ 和 ν 的仿射函数



Lagrange对偶函数(dual function)

□ Lagrange对偶函数

$$g(\lambda, \nu) = \inf_{x \in D} L(x, \lambda, \nu) = \inf_{x \in D} (f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x))$$

□ 若没有下确界，定义：

$$g(\lambda, \nu) = -\infty$$



□ 根据定义，显然有：对 $\forall \lambda > 0$, $\forall \nu$, 若原优化问题有最优值 p^* , 则

$$g(\lambda, \nu) \leq p^*$$

□ 进一步：Lagrange对偶函数为凹函数。



左侧为原函数，右侧为对偶函数



线性方程的最小二乘问题

□ 原问题 minimize $x^T x, x \in \mathbf{R}^n$

subject to $Ax = b$

□ Lagrange函数

$$L(x, v) = x^T x + v^T (Ax - b)$$

□ Lagrange对偶函数

$$g(v) = -\frac{1}{4} v^T A A^T v - b^T v$$

■ 对L求x的偏导, 带入L

■ 对g求v的偏导



强对偶条件

□ 若要对偶函数的最大值即为原问题的最小值，考察需要满足的条件：

$$\begin{aligned} f_0(x^*) &= g(\lambda^*, \nu^*) \\ &= \inf_x \left(f_0(x) + \sum_{i=1}^m \lambda_i^* f_i(x) + \sum_{i=1}^p \nu_i^* h_i(x) \right) \\ &\leq f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*) \\ &\leq f_0(x^*). \end{aligned}$$



Karush-Kuhn-Tucker (KKT)条件

$$\begin{aligned}f_i(x^*) &\leq 0, \quad i = 1, \dots, m \\h_i(x^*) &= 0, \quad i = 1, \dots, p \\ \lambda_i^* &\geq 0, \quad i = 1, \dots, m \\ \lambda_i^* f_i(x^*) &= 0, \quad i = 1, \dots, m\end{aligned}$$

$$\nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) = 0$$



参考文献

- Convex Optimization, Stephen Boyd, Lieven Vandenberghe, Cambridge University Press, 2004
 - 中译本: 王书宁, 许鋆, 黄晓霖译, 凸优化, 清华大学出版社, 2013
- 同济大学数学教研室主编, 高等数学, 高等教育出版社, 1996
- 同济大学数学系编, 工程数学线性代数(第五版), 高等教育出版社, 2007



感谢大家!

恳请大家批评指正!

