



凸集

2020年3月27日 11:15

1. 凸集和凸函数.

我们先给出凸集的概念. 这个概念可以帮助我们解决最值和极值问题. 之前我们取最值时我们需要把我们所有的极值点进行比较. 从图形上来看, 会有两种情况.



第一种情况则有两个极值, 需要比较. 而第二种情况则极值就是最值. 我们如何描述这种区域呢? 可以从直观上看到, 同一 x 值, 若曲线上的点都小于直线上的点, 用 P 点连接一个严格下凸函数. 极值点不是最值点. 我们用数学语言加以描述.

首先我们需要注意, 直线上的点也要在定义域内. 对于横坐标不是实数点, 例如信息论中, 自变量是根号分布. 这也是需要考虑的. 用 P 和 Q 凸集的概念:

若对区域 D 内任意两点 α 和 β , $\alpha \in D$, $\beta \in D$, 均有 $\lambda\alpha + (1-\lambda)\beta \in D$, $0 \leq \lambda \leq 1$. 则称区域 D 为凸域.

通俗一点讲, 若两点 α 和 β 在凸域内, 则 α 和 β 之间的线段也在整个凸域 D 内. 例如实数域是凸域, 但整数域和有理数域不是凸域. 在信息论中, 我们还需要考虑根号分布组成的矢量集合. 例如

$$S_p = \{ \vec{p} \mid p_n \geq 0, n=1, 2, \dots, N, \sum_{n=1}^N p_n = 1 \}$$

这是一个 $N-1$ 维的凸域. 简单证明一下, 设 $\alpha = (p_{\alpha 1}, p_{\alpha 2}, \dots, p_{\alpha N})$, $\beta = (p_{\beta 1}, \dots, p_{\beta N})$, 则有

$$\lambda\alpha + (1-\lambda)\beta = (\lambda p_{\alpha 1} + (1-\lambda)p_{\beta 1}, \dots, \lambda p_{\alpha N} + (1-\lambda)p_{\beta N})$$

$$\sum_{i=1}^N \lambda p_{\alpha i} + (1-\lambda)p_{\beta i} = \lambda + (1-\lambda) = 1$$

所以根号分布的集合也是凸集.

接下来我们可以在定义凸函数和凹函数以解决凸优化的问题.

若在凸域 D 上的 $f(x)$ 满足关系式:

$$f(\lambda\alpha + (1-\lambda)\beta) \leq \lambda f(\alpha) + (1-\lambda)f(\beta) \quad \alpha, \beta \in D \quad 0 \leq \lambda < 1$$

则称函数为下凸函数. 若上式中的不等式是严格不等式, 则称 $f(x)$ 是定义在凸域上的严格下凸函数.

若在凸域 D 上的 $f(x)$ 满足关系式

$$f(\lambda\alpha + (1-\lambda)\beta) \geq \lambda f(\alpha) + (1-\lambda)f(\beta) \quad \alpha, \beta \in D \quad 0 \leq \lambda < 1$$

则称函数为上凸函数. 若上式中的不等式是严格不等式, 则称 $f(x)$ 是定义在凸域上的严格上凸函数.

2. Jensen 不等式

Jensen 不等式是以丹麦数学家 Johan Jensen 命名的. 内容如下:

设 $f(x)$ 是凸域上的凸函数 (下凸函数), 且 $a_m \in D$, $m=1, 2, \dots, M$. 则对 $0 \leq \lambda_m \leq 1$, $\sum_{m=1}^M \lambda_m = 1$ 有:

$$f\left(\sum_{m=1}^M \lambda_m a_m\right) \leq \sum_{m=1}^M \lambda_m f(a_m)$$

这个凸函数和凸函数的定义是紧密相关的. 可以用数学归纳法证明.

当 $M=1$, $M=2$ 时, 依照定义成立.

当 $M=k$ 时, 若有:

$$f\left(\sum_{m=1}^k \lambda_m a_m\right) \leq \sum_{m=1}^k \lambda_m f(a_m)$$

当 $M=k+1$ 时, 则:

$$f\left(\sum_{m=1}^k \lambda_m a_m + \lambda_{k+1} a_{k+1}\right) = f\left[\lambda_{k+1} a_{k+1} + (1-\lambda_{k+1}) \sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} a_m\right]$$

由于 $\sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} = 1$. 符合定义域. 因为假设了在 $M=k$ 时成立.

$$f\left(\sum_{m=1}^k \lambda_m a_m + \lambda_{k+1} a_{k+1}\right) = f\left[\lambda_{k+1} a_{k+1} + (1-\lambda_{k+1}) \sum_{m=1}^k \frac{1-\lambda_{k+1}}{1-\lambda_{k+1}} a_m\right]$$

由于 $\sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} = 1$, 所以 $\sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} a_m$ 符合定义域. 因为假设了在 $m=k$ 时成立.

由上式可得

$$f\left(\sum_{m=1}^k \lambda_m a_m + \lambda_{k+1} a_{k+1}\right) \leq \lambda_{k+1} f(a_{k+1}) + (1-\lambda_{k+1}) f\left(\sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} a_m\right)$$

且由假设.

$$f\left(\sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} a_m\right) \leq \sum_{m=1}^k \frac{\lambda_m}{1-\lambda_{k+1}} f(a_m)$$

代入得.

$$f\left(\sum_{m=1}^{k+1} \lambda_m a_m\right) \leq \sum_{m=1}^{k+1} \lambda_m f(a_m)$$

由此得证. 由于 $\sum_{m=1}^k \lambda_m = 1$, 我们也可认为整个过程是求取期望的过程. 则有

$$f[E(x)] \leq E[f(x)].$$

对于连续变量.

$$f\left[\int p(x) \cdot x \, dx\right] \leq \int p(x) \cdot f(x) \, dx$$

最后我们来探究一下等号成立的条件. 从几何考虑. 取等号会在极值点取得. 而这时两点 α, β 均缩成一个点, 在根号中也即是等根分布时取到等号.

3. 凸优化浅谈.

凸优化不仅在信号处理中应用于泛. 在机器学习中的应用也很广. 幸运的是所有优化目标都是凸函数.

但是利用凸优化近似求解仍然是一个很大的思路前提. 例如梯度下降法. 在信息论中, 信道编码, 互信息以及鉴别信息的优化问题都与凸优化有关.