



# 数理统计 · 第二次习题课

2023 年 4 月 15 日



## 1 数据压缩原则之充分性原则

- 充分统计量
- 辅助统计量
- 完全统计量

## 2 指数型分布族与群族

- 指数型分布族的定义与性质
- 指数型分布族中的充分性与完全性
- 群族

## 3 点估计

- 点估计及其评价
- 矩估计
- 极大似然估计
- 最小差异估计与估计方程

## 充分性原则概览

### 充分性原则

如果  $T(\mathbf{X})$  是参数  $\theta$  的充分统计量, 任何基于样本  $\mathbf{X}$  的对  $\theta$  进行的推断应该从  $T(\mathbf{X})$  出发. 也就是说, 如果  $\mathbf{x}$  和  $\mathbf{y}$  是两个满足  $T(\mathbf{x}) = T(\mathbf{y})$  的样本点, 那么对  $\theta$  的推断无论观测到  $\mathbf{X} = \mathbf{x}$  或  $\mathbf{X} = \mathbf{y}$  都应该是一样的.

- **充分统计量:** 捕获了样本中有关  $\theta$  的所有信息;
- **辅助统计量:** 没有任何有关  $\theta$  的信息;
- **完全统计量:** 没有与  $\theta$  无关的冗余信息;
- **最小充分统计量:** 在保留有关  $\theta$  的所有信息的同时又进行了最大程度的样本数据的缩减.



## 定义 1 (充分统计量, sufficient statistic)

设  $\mathbf{X} = (X_1, \dots, X_n)$  是来自未知总体  $P \in \mathcal{P}$  的一个样本, 其中  $\mathcal{P}$  是一族总体. 统计量  $T(\mathbf{X})$  对于  $P \in \mathcal{P}$  (或者对  $\theta \in \Theta$ , 当  $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$  是参数族时) 称为**充分的**, 当且仅当给定  $T$  时  $\mathbf{X}$  的条件分布已知 (不依赖于  $P$  或  $\theta$ ).

- 充分统计量  $T(\mathbf{X})$  包含了  $\mathbf{X}$  中关于  $P$  的所有信息, 且当  $T$  不是一一对一映射时简化了数据.
- 充分统计量不是唯一的: 设  $T$  为充分统计量, 可测函数  $g$  为一一映射 (不依赖于  $P$ ), 则  $g(T)$  也是一个充分统计量.
- 次序统计量  $T(\mathbf{X}) = (X_{(1)}, \dots, X_{(n)})$  是一个充分统计量.



## 定理 1 (因子分解定理)

假设  $\mathbf{X} = (X_1, \dots, X_n)$  是来自未知总体  $P \in \mathcal{P}$  的一个样本, 其中  $\mathcal{P}$  是一族总体. 那么  $T(\mathbf{X})$  是  $P \in \mathcal{P}$  的充分统计量, 当且仅当存在非负 Borel 函数  $h$  (不依赖于  $P$ ) 和定义在  $T$  的值域上的  $g_P$  (依赖于  $P$ ), 使得

$$f_P(\mathbf{x}) = g_P(T(\mathbf{x})) \cdot h(\mathbf{x}).$$

特别地, 当  $\mathcal{P}$  是  $\theta$  参数族时, 也可以写为

$$f(\mathbf{x}; \theta) = g(T(\mathbf{x}); \theta) \cdot h(\mathbf{x}).$$

证明或证伪充分统计量的两大思路:

- 按定义证明  $f(\mathbf{x} | T(\mathbf{x}) = t; \theta)$  与  $\theta$  无关;
- 按因子分解定理  $f(\mathbf{x}; \theta) = g(T(\mathbf{x}); \theta) \cdot h(\mathbf{x})$  进行拆分.



## 定义 2 (最小充分统计量, minimal sufficient statistic)

令  $T$  是  $P \in \mathcal{P}$  的充分统计量.  $T$  称为**最小充分统计量**, 当且仅当对任意其它的对  $P \in \mathcal{P}$  的充分统计量  $S$ , 存在一个可测函数  $\psi$ , 使得

$$T = \psi(S) \quad \text{a.e. } \mathcal{P}.$$

## 定理 2

假设总体  $P$  有密度函数  $f_P(x)$ , 且存在统计量  $T(\mathbf{X})$  使得对  $\mathbf{X}$  的任意可能值  $\mathbf{x}, \mathbf{y}$ ,

$$f_P(\mathbf{x}) = f_P(\mathbf{y})C(\mathbf{x}, \mathbf{y}), \quad \forall P \in \mathcal{P} \iff T(\mathbf{x}) = T(\mathbf{y}),$$

其中  $C(\mathbf{x}, \mathbf{y}) \in \mathbb{R}$  与  $P$  无关, 那么  $T(\mathbf{X})$  是  $P \in \mathcal{P}$  的最小充分统计量.

## 定义 3 (辅助统计量, ancillary statistic)

一个统计量  $V(\mathbf{X})$  称为**辅助的**, 若它的分布不依赖于总体  $P$ ; 称为**一阶辅助的**, 若  $E[V(\mathbf{X})]$  不依赖于总体  $P$ .

- 一个平凡的辅助统计量是常数统计量  $V(\mathbf{X}) \equiv c \in \mathbb{R}$ .
- 若  $V(\mathbf{X})$  是一个非平凡辅助统计量, 则它不包含任何有关  $P$  的信息.
- 如果  $S(\mathbf{X})$  是一个统计量且  $V(S(\mathbf{X}))$  是一个非平凡的辅助统计量, 这意味着  $S(\mathbf{X})$  中有不包含任何有关  $P$  信息的部分, 这就意味着  $S(\mathbf{X})$  可进一步被简化.
- 对充分统计量  $T(\mathbf{X})$  而言, 如果不存在  $T$  的非常值函数是辅助的或一阶辅助的, 则  $T(\mathbf{X})$  最成功地压缩了数据.

## 定义 4 (完全统计量, complete statistic)

统计量  $T(X)$  称为对  $P \in \mathcal{P}$  是**完全的**, 当且仅当对任一 Borel 函数  $h$ ,

$$E[h(T)] = 0, \forall P \in \mathcal{P} \implies h(T) \equiv 0 \text{ a.e. } \mathcal{P}.$$

若该命题对任一有界 Borel 函数  $h$  成立, 则称  $T$  是**有界完全的**.

- 完全统计量一定是有界完全的.
- 若  $T$  是 (有界) 完全的且对可测函数  $\psi$  有  $S = \psi(T)$ , 则  $S$  是 (有界) 完全的.
- (Lehman and Scheffé) 若最小充分统计量存在, 那么一个充分且完全的统计量一定是最小充分统计量, 反之不然.



## 定理 3 (Basu)

设  $V$  和  $T$  是两个来自总体  $P \in \mathcal{P}$  的  $\mathbf{X}$  的统计量. 如果  $V$  是辅助的,  $T$  关于  $P \in \mathcal{P}$  是有界完全且充分的, 则关于任意  $P \in \mathcal{P}$ ,  $V$  与  $T$  独立.

## Proof.

令  $C$  是  $V$  值域上的一个事件.

- 因为  $V$  是辅助的, 所以  $p_C = P(V \in C)$  是一个常数, 与  $P$  无关.
- 因为  $T$  是充分的, 所以  $q_C(T) = P(V \in C | T)$  是  $T$  的函数 (不依赖于  $P$ ).

注意到  $E[q_C(T)] = p_C$ , 于是由有界完全性

$$q_C(T) = P(V \in C | T) \equiv p_C \quad \text{a.e. } \mathcal{P}.$$

这就证明了  $T$  和  $V$  的独立性. □



## 例 1 (2.48)

设  $X_1, \dots, X_n$  是从下列总体中抽取的样本, 其密度函数为

$$f_{\theta}(x) = \frac{1}{2\theta} \exp\left\{-\frac{|x|}{\theta}\right\}, \quad -\infty < x < +\infty, \theta > 0,$$

证明:  $T = \sum_{i=1}^n |X_i|$  是  $\theta$  的充分完全统计量.

- 充分性:
  
  
  
  
  
  
  
  
  
- 完全性:



## 例 2 (2.49)

设  $X_1, \dots, X_n$  为取自下列指数分布总体的简单样本,

$$f_{\theta}(x) = \exp\{-(x - \theta)\}, \quad x > \theta,$$

其中  $-\infty < \theta < +\infty$  为位置参数. 证明:  $T(\mathbf{X}) = X_{(1)}$  为充分完全统计量.

- 充分性:
  
  
  
  
  
  
  
  
  
  
- 完全性:



## 例 3 (2.46)

设  $X_1, \dots, X_n$  i.i.d.  $\sim N(\theta, \theta^2)$ ,  $\theta > 0$ , 问  $\bar{X}$  是否为充分统计量?

- 充分性:
- 最小充分性:
- 完全性:



## 例 4 (2.50)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从均匀分布  $U(-\theta/2, \theta/2)$ ,  $0 < \theta < \infty$  中抽取的简单样本, 证明:  $(X_{(1)}, X_{(n)})$  为充分统计量, 但不是完全的.

- 充分性:
  
  
  
  
  
  
  
  
  
  
- 完全性:



## 例 5 (补充作业)

在均匀分布  $U(0, \theta)$  (其中  $\theta > 1$ ) 下, 统计量  $T = X_{(n)}$  不是  $\theta$  的完全统计量.

## 例 6 (2.53)

设  $X_1, \dots, X_n$  i.i.d.  $\sim N(a, \sigma^2)$ , 证明:  $\bar{X}$  和  $X_{(n)} - X_{(1)}$  独立.



## 例 7 (补充题)

设  $X_1, \dots, X_n$  是 i.i.d. 随机变量, 当  $\theta = 0$  时服从正态分布  $N(\theta, 2)$ , 当  $\theta \in \mathbb{R}$  且  $\theta \neq 0$  时服从正态分布  $N(\theta, 1)$ . 证明: 样本均值  $\bar{X}$  是  $\theta$  的完全统计量, 但不是  $\theta$  的充分统计量.

- **完全性:** 当  $\theta \neq 0$  时,  $\bar{X} \sim N(\theta, 1/n)$ , 于是对任一 Borel 函数  $h$ , 有

$$E_{\theta}[g(\bar{X})] = \int_{-\infty}^{+\infty} g(t) \sqrt{\frac{n}{2\pi}} \exp\left\{-\frac{n(t-\theta)^2}{2}\right\} dt = 0.$$

从而有

$$\int_{-\infty}^{+\infty} g(t) \exp\left\{-\frac{nt^2}{2}\right\} \cdot \exp\{nt\theta\} dt = 0.$$

由 Fourier 变换的逆变换公式可知

$$g(t) \exp\left\{-\frac{nt^2}{2}\right\} = 0 \text{ a.e. } P_{\theta}.$$



- **完全性:** 所以

$$g(t) = 0 \text{ a.e. } P_\theta, \quad \theta \in \mathbb{R} \text{ 且 } \theta \neq 0.$$

而  $m\{\theta = 0\} = 0$ , 因此  $g(t) = 0$  a.e.  $P_\theta$  对任意  $\theta \in \mathbb{R}$  成立.

- **充分性:** 作正交变换  $(Y_1, \dots, Y_n)^T = \mathbf{A}(X_1, \dots, X_n)^T$ , 其中  $\mathbf{A}$  的第一行元素全为  $1/\sqrt{n}$ , 且其为正交矩阵. 于是

- 当  $\theta = 0$  时,  $Y_1 = \sqrt{n}\bar{X} \sim N(\sqrt{n}\theta, 2)$ ,  $Y_2, \dots, Y_n \sim N(0, 2)$ ,

- 当  $\theta \neq 0$  时,  $Y_1 = \sqrt{n}\bar{X} \sim N(\sqrt{n}\theta, 1)$ ,  $Y_2, \dots, Y_n \sim N(0, 1)$ ,

且  $Y_1, \dots, Y_n$  独立. 给定  $Y_1 = y_1$  时,  $Y_1, \dots, Y_n$  的条件联合 p.d.f. 为

$$f_\theta(\mathbf{y} | y_1) = (4\pi)^{-\frac{n-1}{2}} \exp\left\{-\frac{1}{4} \sum_{i=2}^n y_i^2\right\} I\{\theta = 0\} \\ + (2\pi)^{-\frac{n-1}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2\right\} I\{\theta \neq 0\}.$$

这仍然与  $\theta$  有关, 从而  $\bar{X}$  不是充分统计量.





# 指数型分布族与族群

## 指数型分布族的定义与性质

### 定义 5 (指数型分布族, exponential family of distributions)

设有参数分布族  $\{F_{\theta} : \theta \in \Theta\}$  有密度 (p.d.f. 或 p.m.f.)  $f(x; \theta)$ . 如果  $f(x; \theta)$  可表示成如下形式

$$f(x; \theta) = \exp \left\{ \sum_{i=1}^k Q_i(\theta) T_i(x) - A(\theta) \right\} h(x),$$

则称此分布族为**指数型分布族**. 其中  $A(\theta)$ ,  $Q_i(\theta)$  ( $i = 1, \dots, k$ ) 为定义在参数空间  $\Theta$  上的函数, 与  $x$  无关,  $h(x) > 0$ ,  $T_i(x)$  ( $i = 1, \dots, k$ ) 为与  $\theta$  无关的函数. 特别地, 当  $k = 1$  时, 此分布族称为**单参数指数型分布族**.

- 若总体分布族是指数型分布族, 则样本的分布族也是指数型分布族;
- 指数型分布族分布的支撑集与参数  $\theta$  无关, 即有公共支撑;
- 指数型分布族具有良好的解析性质.



# 指数型分布族与群族

指数型分布族的定义与性质

现在我们重参数化  $\eta_i = Q_i(\boldsymbol{\theta})$ ,  $i = 1, \dots, k$ , 而把  $A(\boldsymbol{\theta})$  表示成  $\boldsymbol{\eta} = (\eta_1, \dots, \eta_k)^\top$  的函数  $A^*(\boldsymbol{\eta})$ , 于是我们得到指数型分布族的自然形式

$$f(\mathbf{x}; \boldsymbol{\eta}) = \exp \left\{ \sum_{i=1}^k \eta_i T_i(\mathbf{x}) - A^*(\boldsymbol{\eta}) \right\} h(\mathbf{x}).$$

自然参数空间为

$$\Theta^* = \left\{ \boldsymbol{\eta} : \int_{\mathcal{X}} h(\mathbf{x}) \exp \left\{ \sum_{i=1}^k \eta_i T_i(\mathbf{x}) \right\} d\mathbf{x} < \infty \right\},$$

它是  $\mathbb{R}^k$  上的凸集. 如果  $\dim(\Theta^*) = k$ , 则称它是满秩的指数型分布族.



## 定理 4

设  $X$  来自指数型分布族, 其自然形式为

$$f(\mathbf{x}; \boldsymbol{\eta}) = \exp \left\{ \sum_{i=1}^k \eta_i T_i(\mathbf{x}) - A^*(\boldsymbol{\eta}) \right\} h(\mathbf{x}).$$

设  $\boldsymbol{\eta}$  为自然参数空间  $\Theta^*$  的一个内点, 则

- 如果  $\mathbf{s}$  满足  $\boldsymbol{\eta} + \mathbf{s}$  为  $\Theta^*$  的一个内点, 则  $(T_1(X), \dots, T_k(X))^T$  的联合矩母函数存在且等于

$$M_{\boldsymbol{\eta}}(\mathbf{s}) = \exp\{A(\boldsymbol{\eta} + \mathbf{s}) - A(\boldsymbol{\eta})\}.$$

- $\exp\{A(\boldsymbol{\eta})\}$  对分量  $\eta_i$  任意阶偏导存在, 且可在积分号下求得.
- $E_{\boldsymbol{\eta}}[T_i(X)] = \frac{\partial}{\partial \eta_i} A(\boldsymbol{\eta}), \text{Cov}_{\boldsymbol{\eta}}(T_i(X), T_j(X)) = \frac{\partial^2}{\partial \eta_i \partial \eta_j} A(\boldsymbol{\eta}), 1 \leq i, j \leq k.$



## 定理 5

设  $X$  来自指数型分布族, 其自然参数空间有内点, 记内点集为  $\Theta_0$ . 设  $g(x)$  是任一实函数, 使得积分

$$G(\boldsymbol{\eta}) = \int_{\mathcal{X}} g(x) \exp \left\{ \sum_{i=1}^k \eta_i T_i(x) \right\} h(x) dx$$

在  $\Theta_0$  内存在且有限, 则  $G(\boldsymbol{\eta})$  的任意阶偏导在  $\Theta_0$  内存在, 且可在积分号下求得, 即

$$\frac{\partial^m G(\boldsymbol{\eta})}{\partial \eta_1^{m_1} \cdots \partial \eta_k^{m_k}} = \int_{\mathcal{X}} \frac{\partial^m}{\partial \eta_1^{m_1} \cdots \partial \eta_k^{m_k}} \left[ g(x) \exp \left\{ \sum_{i=1}^k \eta_i T_i(x) \right\} h(x) \right] dx,$$

其中  $m_1 + \cdots + m_k = m$ .



## 定理 6

设样本  $\mathbf{X}$  来自满秩的指数型分布族, 则  $T(\mathbf{X}) = (T_1(\mathbf{X}), \dots, T_k(\mathbf{X}))$  是参数  $\theta$  的最小充分统计量.

## 定理 7

设样本  $\mathbf{X}$  来自满秩的指数型分布族,  $T(\mathbf{X}) = (T_1(\mathbf{X}), \dots, T_k(\mathbf{X}))$  是参数  $\theta$  的最小充分统计量, 且自然参数空间具有内点 (有  $\mathbb{R}^k$  上的开子集), 则  $T(\mathbf{X})$  是完全统计量.



## 定义 6 (位置-尺度分布族)

设  $f(x)$  为密度函数, 于是对任意  $\mu \in \mathbb{R}, \sigma > 0$ , 分布族

$$\left\{ \frac{1}{\sigma} f\left(\frac{x-\mu}{\sigma}\right), \mu \in \mathbb{R}, \sigma > 0 \right\}$$

称为具有标准密度  $f(x)$  的参数为  $(\mu, \sigma)$  的**位置-尺度分布族**,  $\mu$  称为**位置参数**,  $\sigma$  称为**尺度参数**.

- 设  $Z \sim f(z), X \sim \frac{1}{\sigma} f\left(\frac{x-\mu}{\sigma}\right)$ , 则

$$X \stackrel{d}{=} \sigma Z + \mu.$$

特别地, 有  $E(X) = \sigma E(Z) + \mu, \text{Var}(X) = \sigma^2 \text{Var}(Z)$ .

- 对于确定的  $\sigma = 1$  时为位置分布族,  $\mu = 0$  时为尺度分布族.

## 例 8 (补充作业)

证明: 柯西分布  $C(\mu, \lambda)$  不属于指数型分布族, 其密度函数为

$$f(x | \mu, \lambda) = \frac{1}{\pi} \cdot \frac{\lambda}{\lambda^2 + (x - \mu)^2}, \quad x \in \mathbb{R}.$$

## 例 9 (2.47)

设  $X_1, \dots, X_m$  i.i.d.  $\sim N(a, \sigma^2)$ ,  $Y_1, \dots, Y_n$  i.i.d.  $\sim N(b, \sigma^2)$  且两组样本独立. 记  $\bar{X} = \sum_{i=1}^m X_i/m$ ,  $\bar{Y} = \sum_{j=1}^n Y_j/n$ , 而

$$S^2 = \frac{1}{n+m-2} \left[ \sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2 \right].$$

证明:  $(\bar{X}, \bar{Y}, S^2)$  为充分完全统计量.

- 充分性:
  
  
  
  
  
  
  
  
  
  
- 完全性:



## 定义 7 (点估计, point estimator)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为来自总体  $F_{\theta}$ ,  $\theta \in \Theta \subset \mathbb{R}^d$  的样本, 统计量  $\hat{g}_n(\mathbf{X})$  称为对感兴趣参数  $g(\theta)$  的**点估计**.

- **无偏性:**  $E_{\theta}[\hat{g}_n(\mathbf{X})] = g(\theta), \forall \theta \in \Theta.$
- **渐近无偏性:**  $\lim_{n \rightarrow \infty} E_{\theta}[\hat{g}_n(\mathbf{X})] = g(\theta), \forall \theta \in \Theta.$
- **有效性:**  $\text{Var}_{\theta}(\hat{g}_n(\mathbf{X})) \geq \text{Var}_{\theta}(\tilde{g}_n(\mathbf{X})), \forall \theta \in \Theta$  且严格不等号至少对一个  $\theta$  成立, 这里  $\hat{g}_n(\mathbf{X})$  和  $\tilde{g}_n(\mathbf{X})$  都是  $\theta$  的无偏估计.
- **均方误差准则:**  $\text{Mse}_{\theta}(\hat{g}_n(\mathbf{X})) \geq \text{Mse}_{\theta}(\tilde{g}_n(\mathbf{X})), \forall \theta \in \Theta$  且严格不等号至少对一个  $\theta$  成立.
- **相合性:**  $\hat{g}_n(\mathbf{X}) \xrightarrow{\text{rule}} g(\theta)$  as  $n \rightarrow \infty.$
- **渐近正态性:**  $[B_n(\theta)]^{-1}[\hat{g}_n(\mathbf{X}) - g(\theta)] \xrightarrow{\mathcal{L}} N(\mathbf{0}, \mathbf{I})$  as  $n \rightarrow \infty.$

## 定义 8 (矩估计)

设  $g(\boldsymbol{\theta}) = G(\alpha_1, \dots, \alpha_k; \mu_2, \dots, \mu_s)$  表达了感兴趣参数  $g(\boldsymbol{\theta})$  与总体原点矩和中心矩之间的关系, 那么  $g(\boldsymbol{\theta})$  的矩估计定义为

$$\hat{g}_n(\mathbf{X}) = G(a_{n1}, \dots, a_{nk}; m_{n2}, \dots, m_{ns}),$$

其中  $a_{n1}, \dots, a_{nk}$  是样本原点矩,  $m_{n2}, \dots, m_{ns}$  是样本中心矩.

- 矩估计一般不具有无偏性 (除原点矩的线性组合), 但具有渐近无偏性 ( $G$  满足适当条件).
- 矩估计具有相合性 ( $G$  是连续函数).
- 矩估计具有渐近正态性 ( $G$  是连续可微函数).

## 例 10 (3.5)

设总体  $X$  服从均匀分布  $U(0, 2\theta)$ , 令  $X_1, \dots, X_n$  为从总体  $X$  中抽取的简单样本,

(1) 证明:  $\hat{\theta}_1 = \bar{X}$  和  $\hat{\theta}_2 = (n+1)X_{(n)}/(2n)$  为  $\theta$  的无偏估计.

(2) 证明:  $\hat{\theta}_1$  为  $\theta$  的强相合估计,  $\theta_2^* = X_{(n)}/2$  为  $\theta$  的弱相合估计.

(3) 求  $\hat{\theta}_1$  和  $\hat{\theta}_2$  的方差, 问哪一个更有效?

## 例 11 (3.6)

设总体  $X$  服从二项分布  $B(k, p)$ ,  $k$  是正整数,  $0 < p < 1$ , 两者都是未知参数,  $X_1, \dots, X_n$  为从中抽取的简单样本, 求  $k$  和  $p$  的矩估计.

## 例 12 (3.9)

设  $X_1, \dots, X_n$  是来自正态总体  $N(a, \sigma^2)$  的简单样本, 求  $P(X > 1)$  的矩估计量.

## 例 13 (3.10)

设  $X_1, \dots, X_n$  i.i.d.  $\sim$  伽马分布  $\Gamma(r, \lambda)$ , 其中  $r$  已知, 求  $\lambda$  的矩估计量, 并讨论它的无偏性.



## 例 14 (补充题)

一个盒子里有未知的奇数个球, 依次标为  $1, 2, \dots, (2\theta + 1)$ , 其中  $\theta$  是一个未知的非负整数.  $X_1, \dots, X_n$  为一不放回抽取到的简单随机样本,  $X_i$  是第  $i$  个抽出的球的标号且  $n < 2\theta + 1$ .

(1) 试给出  $\theta$  的一个无偏估计.

(2) 若球标号为  $-\theta, -(\theta - 1), \dots, -2, -1, 0, 1, 2, \dots, (\theta - 1), \theta$ , 试给出  $\theta$  的一个无偏估计.

(1) 注意到  $E(X_1) = \theta + 1$ , 因此  $\theta$  的一个无偏估计是  $\hat{\theta} = X_1 - 1$ .

(2) 此时  $E(X_1) = 0$ , 上述方法失效. **怎么办?** 考虑

$$E|X_1| = \sum_{i=1}^{\theta} \frac{2i}{2\theta + 1} = \frac{1}{2}\theta + \frac{\theta}{2(2\theta + 1)},$$

而且  $P(|X_1| \neq 0) = \frac{2\theta}{2\theta + 1}$ , 因此  $E\left(2|X_1| - \frac{1}{2}I\{X_1 \neq 0\}\right) = \theta$ .

(2) 所以  $\theta$  的一个无偏估计是

$$\hat{\theta} = 2|X_1| - \frac{1}{2}I\{X_1 \neq 0\}.$$

**另一种想法:** 基于次序统计量  $X_{(i)}$ .

(1) 注意到

$$P(X_{(i)} = x) = \frac{\binom{x-1}{i-1} \binom{2\theta+1-x}{n-i}}{\binom{2\theta+1}{n}}, \quad x = i, i+1, \dots, i+2\theta+1-n.$$

所以

$$E(X_{(i)}) = \sum_{x=i}^{i+2\theta+1-n} x \frac{\binom{x-1}{i-1} \binom{2\theta+1-x}{n-i}}{\binom{2\theta+1}{n}} = i \cdot \frac{2\theta+2}{n+1}.$$

从而  $\theta$  的一个无偏估计是  $\frac{n+1}{2i}X_{(i)} - 1$ .

(2) 类似地,

$$P(X_{(i)} = x) = \frac{\binom{x+\theta}{i-1} \binom{\theta-x}{n-i}}{\binom{2\theta+1}{n}}, \quad x = -\theta + i - 1, \dots, \theta - n + i.$$

考虑计算  $X_{(i)} + \theta + 1$  的期望 (为什么?) 为

$$E(X_{(i)} + \theta + 1) = i \cdot \frac{2\theta + 2}{n + 1}.$$

从而  $\theta$  的一个无偏估计是  $\frac{n+1}{2i-n-1} X_{(i)} - 1$ .



## 定义 9 (极大似然估计, MLE)

设  $f(\mathbf{x}; \theta)$  是样本  $\mathbf{X}$  的概率函数. 当观测到  $\mathbf{X} = \mathbf{x}$  时, 记

$$L_n(\theta) = f(\mathbf{x}; \theta), \quad \theta \in \Theta.$$

为  $\theta$  的似然函数. 对每个样本观测值  $\mathbf{x}$ , 令

$$\hat{\theta}(\mathbf{x}) = \arg \max_{\theta \in \Theta} L_n(\theta).$$

称  $\hat{\theta}(\mathbf{X})$  为参数  $\theta$  的极大似然估计.

- 具有显式解: (1) 单调似然函数; (2) 基于对数似然函数求极值.
- 没有显式解: (1) 梯度方法; (2) EM 算法.

## 例 15 (3.12)

设  $X_1, \dots, X_n$  是从总体  $X$  中抽取的简单样本,  $X$  的分布为下列之一, 试分别用矩估计法和极大似然估计法求  $\theta$  的估计量.

$$(1) f_{\theta}(x) = \begin{cases} \theta(\theta + 1)x^{\theta-1}(1 - x), & 0 < x < 1, \\ 0, & \text{其他,} \end{cases} \quad \theta > 0.$$

$$(2) f_{\theta}(x) = (\theta + 1)x^{\theta}, \quad 0 < x < 1, \quad \theta > -1.$$

$$(3) f_{\theta}(x) = \begin{cases} \frac{\theta^{-r}}{\Gamma(r)} x^{r-1} \exp\left\{-\frac{x}{\theta}\right\}, & x > 0, \\ 0, & \text{其他,} \end{cases} \quad r > 0 \text{ 已知, } \theta > 0.$$

## 例 16 (3.13)

设总体  $X$  的密度为

$$f(x; a, \sigma) = \frac{1}{2\sigma} \exp\{-|x - a|/\sigma\},$$

其中  $\sigma > 0$  和  $-\infty < a < \infty$  为未知参数. 设  $X_1, \dots, X_n$  为抽自此总体的简单随机样本, 求  $a$  和  $\sigma$  的矩估计和极大似然估计.

## EM 算法

基于观测数据  $\mathbf{X}$  的对数似然函数  $\ell(\theta) = \log f(\mathbf{x} | \theta)$  在计算上不容易, 但如果问题中存在“隐变量”  $\mathbf{Y}$ , 基于“完全观测数据”下的对数似然函数  $\ell_c(\theta) = \log f(\mathbf{x}, \mathbf{y} | \theta)$  在计算上可行.

- E 步: 计算

$$Q(\theta | \theta^{(t)}) = E_{f(\mathbf{y}|\mathbf{x},\theta^{(t)})}[\log f(\mathbf{x}, \mathbf{y} | \theta)].$$

- M 步: 最大化

$$\theta^{(t+1)} = \arg \max_{\theta \in \Theta} Q(\theta | \theta^{(t)}).$$

EM 算法保证了算法每次迭代后基于观测数据  $\mathbf{X}$  的对数似然函数  $\ell(\theta)$  都是递增的, 因此可以收敛到局部最优值, 算法效率依赖于初值的选取.

## 极大似然估计的性质

## 定理 8 (变换不变性)

如果  $\hat{\theta}$  是  $\theta$  的 MLE, 则对于定义在  $\Theta$  上的函数  $h$ ,  $h(\hat{\theta})$  是  $h(\theta)$  的 MLE.

## 定理 9 (MLE 是充分统计量的函数)

设  $T(\mathbf{X})$  是  $\theta$  的充分统计量. 如果  $\theta$  的 MLE 存在, 则它必为  $T$  的函数.

## 定理 10 (存在性与唯一性)

如果基于样本  $\mathbf{X}$  的对数似然函数

$$\ell_n(\theta) = \log f(\mathbf{x}; \theta) = \sum_{i=1}^n \log f(x_i; \theta)$$

是严格凹的, 并且  $\lim_{\theta \rightarrow \partial\Theta} \ell_n(\theta) = -\infty$ , 则 MLE  $\hat{\theta}(\mathbf{X})$  存在且唯一.

## 定理 11 (指数族下 MLE 的唯一性)

设样本  $\mathbf{X}$  来自满秩的自然参数指数族, 具有密度函数

$$f(\mathbf{x}; \boldsymbol{\theta}) = \exp \left\{ \sum_{i=1}^k \theta_i T_i(\mathbf{x}) - A(\boldsymbol{\theta}) \right\} h(\mathbf{x}), \quad \mathbf{x} \in \mathcal{X}.$$

如果

$$\frac{\partial A(\boldsymbol{\theta})}{\partial \theta_i} = \frac{1}{n} \sum_{j=1}^n T_i(X_j), \quad i = 1, \dots, k$$

在自然参数空间的内点集上有解, 则该解必为  $\boldsymbol{\theta}$  唯一的 MLE.

## 例 17 (3.19)

设  $X_1, \dots, X_m$  和  $Y_1, \dots, Y_n$  分别来自总体  $N(\mu_1, \sigma^2)$  和  $N(\mu_2, \sigma^2)$  的两组独立样本, 求  $\mu_1, \mu_2$  和  $\sigma^2$  的 MLE.

## 定理 12 (相合性)

设样本  $\mathbf{X}$  来自密度函数为  $f(x; \theta)$  的总体, 参数空间  $\Theta$  是  $\mathbb{R}^d$  上的开集.  
假设

- (1) 参数可识别: 对  $\forall \theta' \neq \theta$ , 存在  $x$  使得  $f(x, \theta') \neq f(x, \theta)$ ,
- (2) 公共支撑且可微:  $f(\cdot; \theta)$  的支撑不依赖于  $\theta$ , 且  $f(x; \theta)$  对  $\theta \in \Theta$  可微,
- (3) 真实参数是参数空间的内点:  $\theta_0 \in \Theta^0$ ,

则似然函数存在最大值点  $\hat{\theta}$ , 且  $\hat{\theta} \xrightarrow{P} \theta_0$ .

## 例 18 (3.23)

设  $X_1, \dots, X_n$  i.i.d.  $\sim$  均匀分布  $U(0, \theta)$ , 求  $\theta$  的 MLE  $\hat{\theta}_n$ , 证明:  $\hat{\theta}_n$  是  $\theta$  的强相合估计和  $r$  ( $r > 0$ ) 阶矩相合估计.

## 例 19 (3.24)

设  $X_1, \dots, X_n$  i.i.d.  $\sim N(\sigma, \sigma^2)$ ,  $\sigma > 0$ , 试求  $\sigma^2$  的 MLE  $\hat{\sigma}^2$ , 并证明  $\hat{\sigma}$  为  $\sigma$  的弱相合估计.

## 例 20 (3.25)

设总体  $X$  为下列 0-1 分布族

$$P_{\theta}(X=1) = 1 - P_{\theta}(X=0) = \begin{cases} \theta, & \theta \text{ 为有理数,} \\ 1 - \theta, & \theta \text{ 为无理数.} \end{cases}$$

设  $X_1, \dots, X_n$  是来自总体  $X$  的简单随机样本, 证明:  $\theta$  的 MLE 不是相合估计.



## 定理 13 (渐近正态性)

设  $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$  是一个概率函数族,  $\Theta$  为直线上的开区间,  $X_1, \dots, X_n$  是从  $\mathcal{F}$  中某个总体  $X \sim f(x; \theta_0)$  产生的样本. 当  $f(x; \theta)$  满足适当正则条件时, 在参数  $\theta$  的未知真值  $\theta_0$  为  $\Theta$  的一个内点的情况下, 似然方程有一个解  $\hat{\theta}_n$  满足

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{L}} N\left(0, \frac{1}{I(\theta_0)}\right), \quad \text{as } n \rightarrow \infty,$$

其中

$$I(\theta) = E_{\theta} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right]$$

是 Fisher 信息量.

正则条件:

(1) 对一切  $\theta \in \Theta$ , 偏导数

$$\frac{\partial \log f(x; \theta)}{\partial \theta}, \quad \frac{\partial^2 \log f(x; \theta)}{\partial \theta^2}, \quad \frac{\partial^3 \log f(x; \theta)}{\partial \theta^3}$$

存在.

(2) 对一切  $\theta^* \in \Theta$ , 存在  $\theta^*$  的一个邻域  $U_{\theta^*}$  和可积函数  $F_1(x)$ ,  $F_2(x)$ , 以及函数  $H(x)$ , 使得

$$\left| \frac{\partial f(x; \theta)}{\partial \theta} \right| \leq F_1(x), \quad \left| \frac{\partial^2 f(x; \theta)}{\partial \theta^2} \right| \leq F_2(x), \quad \left| \frac{\partial^3 \log f(x; \theta)}{\partial \theta^3} \right| \leq H(x),$$

对  $\theta \in U_{\theta^*}$  成立, 其中  $H(x)$  满足  $E_{\theta}[H(X)] \leq M, \forall \theta \in U_{\theta^*}$ .

(3) 对一切  $\theta \in \Theta$ , 有

$$0 < I(\theta) = E_{\theta} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] < \infty.$$

## 推论 1

设总体分布族是单参数指数族, 其中密度函数具有形式

$$f(x; \theta) = C(\theta) \exp\{Q(\theta) T(x)\} h(x),$$

其中  $C(\theta)$  和  $Q(\theta)$  有一至三阶连续的导数, 则定理的结论成立.

## 例 21 (3.26)

设  $X_1, \dots, X_n$  是来自伽马分布  $\Gamma(\alpha, \lambda)$  的简单样本, 试证明:

(1) 当  $\lambda = 1$  时, 记  $\alpha$  的 MLE 为  $\hat{\alpha}$ , 则

$$\sqrt{n}(\hat{\alpha} - \alpha) \xrightarrow{\mathcal{L}} N\left(0, \left[E\left(\frac{\partial \log g(x, \alpha)}{\partial \alpha}\right)^2\right]^{-1}\right),$$

此处  $g(x, \alpha)$  是参数分别为  $\alpha, \lambda = 1$  的伽马分布的密度函数;

(2) 当  $\alpha$  已知时,  $\lambda$  的 MLE  $\hat{\lambda}$  近似服从  $N(\lambda, \lambda^2/(n\alpha))$ , 即

$$\sqrt{n}(\hat{\lambda} - \lambda) \xrightarrow{\mathcal{L}} N(0, \lambda^2/\alpha).$$

## 最小差异估计

考虑定义差异函数  $\rho: \mathcal{X} \times \Theta \rightarrow \mathbb{R}$ , 以及  $D(\theta_0, \theta)$  来衡量  $\theta$  和真值  $\theta_0$  之间的差距:

$$D(\theta_0, \theta) = E_{\theta_0}[\rho(X, \theta)].$$

- 要求  $D(\theta_0, \theta)$  在  $\theta = \theta_0$  处具有唯一最小值.
- 通常  $\rho(\mathbf{X}, \theta) = \frac{1}{n} \sum_{i=1}^n \rho(X_i, \theta) \rightarrow D(\theta_0, \theta)$  as  $n \rightarrow \infty$ .
- 假设真值  $\theta_0$  是参数空间的内点, 并且  $D(\theta_0, \theta)$  是光滑的, 那么自然希望

$$\nabla_{\theta} D(\theta_0, \theta) = 0.$$

- 进而我们自然有  $\theta$  的估计  $\hat{\theta}$  满足

$$\nabla_{\theta} \rho(\mathbf{X}, \hat{\theta}) = 0.$$

- 基于熵, MLE 是最小差异估计.

## 估计方程

如果  $g(X, \theta)$  是总体  $X$  和待估参数  $\theta$  的函数, 满足

$$S(\theta_0, \theta) = E_{\theta_0}[g(X, \theta)] = \int_{\mathcal{X}} g(x, \theta) dF_{\theta_0}(x) = 0.$$

那么将  $F_{\theta_0}(x)$  用样本经验分布函数  $F_n(x)$  替代, 就可以得到方程

$$\frac{1}{n} \sum_{i=1}^n g(X_i, \theta) = \int_{\mathcal{X}} g(x, \theta) dF_n(x) = 0.$$

上述方程的解  $\hat{\theta}_n$  也就是  $\theta$  的估计方程的解.

- 最小二乘估计:  $\hat{\theta} = \arg \min_{\theta} \sum_{i=1}^n [y_i - g(\mathbf{X}_i, \beta)]^2.$
- 最小一乘估计:  $\hat{\theta} = \arg \min_{\theta} \sum_{i=1}^n |y_i - g(\mathbf{X}_i, \beta)|.$

## 例 22 (3.20)

为了估计湖中有多少条鱼, 从中捞出 1000 条, 标上记号后放回湖中, 然后再捞出 150 条鱼, 发现其中有 10 条鱼有记号. 问湖中有多少条鱼, 才能使 150 条鱼中出现 10 条带记号的鱼的概率最大?

## 例 23 (3.21)

一个罐子中装有黑白两种球, 今有放回地抽取一个大小为  $n$  的样本, 其中有  $k$  个白球, 求罐中黑白球之比的极大似然估计.



Thanks for your time and attention!