

复习.

- 总体  $X \sim F_\theta$ ,  $\theta \in \Theta$ .
- 样本  $\vec{X} = (X_1, \dots, X_n)$ ,
- 样本(值)  $\vec{x} = (x_1, \dots, x_n)$ .
- 目标: 用统计量  $T(X_1, \dots, X_n)$  作为  $\theta$  (或  $g(\theta)$ ) 的估计.
- 最大似然估计:

$L(\theta) = \prod_{i=1}^n p_\theta(x_i)$  在  $\Theta$  中的最大值点  $\hat{\theta}$ .

## §7.2 矩估计

总体  $X \sim F_\theta$ . 目标: 给出  $\theta$  的估计值  $\hat{\theta}$ .

思想: 样本矩 = 真实矩. 支撑: LLN.

## §7.2 矩估计

总体  $X \sim F_\theta$ . 目标: 给出  $\theta$  的估计值  $\hat{\theta}$ .

思想: 样本矩 = 真实矩. 支撑: LLN.

- 总体矩:  $m_k(\theta) = EX^k$ , 参数的函数.

样本矩:  $a_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  或  $\frac{1}{n} \sum_{i=1}^n x_i^k$ , 数据的函数(统计量).

令:

$$m_k(\hat{\theta}) = a_k, \quad k = 1, \dots, r.$$

(其中  $r$  是使得方程组有唯一解的最小整数), 唯一解  $\hat{\theta}$  称为  $\theta$  的矩估计.

## §7.2 矩估计

总体  $X \sim F_\theta$ . 目标: 给出  $\theta$  的估计值  $\hat{\theta}$ .

思想: 样本矩 = 真实矩. 支撑: LLN.

- 总体矩:  $m_k(\theta) = EX^k$ , 参数的函数.

样本矩:  $a_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  或  $\frac{1}{n} \sum_{i=1}^n x_i^k$ , 数据的函数(统计量).  
令:

$$m_k(\hat{\theta}) = a_k, \quad k = 1, \dots, r.$$

(其中  $r$  是使得方程组有唯一解的最小整数), 唯一解  $\hat{\theta}$  称为  $\theta$  的矩估计.

- 习题一、11(续).  $N$  条鱼中有 80 条有标记, 100 条中 4 条有标记. 估计  $N$ .

$n = 1$ , 总体矩  $m_1 = m_1(N) = 100 * \frac{80}{N}$ , 样本矩  $a_1 = 4$ .

求解  $m_1(\hat{N}) = a_1$ , 得  $\hat{N} = 2000$ .

例1.1(续) 飞机最大飞行速度  $X \sim N(\mu, \sigma^2)$ , 数据  $x_1, \dots, x_{15}$ . 估计  $\mu, \sigma^2$ .

例1.1(续) 飞机最大飞行速度  $X \sim N(\mu, \sigma^2)$ , 数据  $x_1, \dots, x_{15}$ . 估计  $\mu, \sigma^2$ .

- 两个参数, 则用前两阶矩:

例1.1(续) 飞机最大飞行速度  $X \sim N(\mu, \sigma^2)$ , 数据  $x_1, \dots, x_{15}$ . 估计  $\mu, \sigma^2$ .

- 两个参数, 则用前两阶矩:
- 总体矩:  $m_1 = \mu, m_2 = \sigma^2 + \mu^2$ .

样本矩:  $a_1 = \bar{x}, a_2 = \frac{1}{n} \sum_{i=1}^n x_i^2$ .

例1.1(续) 飞机最大飞行速度  $X \sim N(\mu, \sigma^2)$ , 数据  $x_1, \dots, x_{15}$ . 估计  $\mu, \sigma^2$ .

- 两个参数, 则用前两阶矩:
- 总体矩:  $m_1 = \mu, m_2 = \sigma^2 + \mu^2$ .

样本矩:  $a_1 = \bar{x}, a_2 = \frac{1}{n} \sum_{i=1}^n x_i^2$ .

- 求解

$$\begin{cases} m_1 = \bar{x}, \\ m_2 = \frac{1}{n} \sum_{i=1}^n x_i^2, \end{cases} \text{即} \begin{cases} \hat{\mu} = \bar{x}, \\ \widehat{\sigma^2} + \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2. \end{cases}$$

解得  $\hat{\mu} = \bar{x}, \widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ .

例1.1(续) 飞机最大飞行速度  $X \sim N(\mu, \sigma^2)$ , 数据  $x_1, \dots, x_{15}$ . 估计  $\mu, \sigma^2$ .

- 两个参数, 则用前两阶矩:
- 总体矩:  $m_1 = \mu, m_2 = \sigma^2 + \mu^2$ .

$$\text{样本矩: } a_1 = \bar{x}, a_2 = \frac{1}{n} \sum_{i=1}^n x_i^2.$$

- 求解

$$\begin{cases} m_1 = \bar{x}, \\ m_2 = \frac{1}{n} \sum_{i=1}^n x_i^2, \end{cases} \quad \text{即} \quad \begin{cases} \hat{\mu} = \bar{x}, \\ \widehat{\sigma^2} + \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2. \end{cases}$$

$$\text{解得 } \hat{\mu} = \bar{x}, \widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

- 定义2.1. 若待估量  $g(\theta) = \phi(m_1, \dots, m_k)$  (不一定是参数本身). 定义  $g(\theta)$  的矩估计为  $\widehat{g(\theta)} := \phi(a_1, \dots, a_k)$ .

### §7.3 估计的无偏性

称  $T(X_1, \dots, X_n)$  是  $g(\theta)$  的 无偏估计, 如果

$$E_\theta T(X_1, \dots, X_n) = g(\theta), \forall \theta \in \Theta.$$

### §7.3 估计的无偏性

称  $T(X_1, \dots, X_n)$  是  $g(\theta)$  的 无偏估计, 如果

$$E_\theta T(X_1, \dots, X_n) = g(\theta), \forall \theta \in \Theta.$$

- 样本均值  $\hat{\mu} = \bar{X} = \frac{1}{n}(X_1 + \dots + X_n)$ .

$$E_\theta \hat{\mu} = \frac{1}{n}(E_\theta X_1 + \dots + E_\theta X_n) = \mu, \text{ 无偏.}$$

### §7.3 估计的无偏性

称  $T(X_1, \dots, X_n)$  是  $g(\theta)$  的 无偏估计, 如果

$$E_\theta T(X_1, \dots, X_n) = g(\theta), \forall \theta \in \Theta.$$

- 样本均值  $\hat{\mu} = \bar{X} = \frac{1}{n}(X_1 + \dots + X_n).$

$$E_\theta \hat{\mu} = \frac{1}{n}(E_\theta X_1 + \dots + E_\theta X_n) = \mu, \text{ 无偏.}$$

- 样本方差  $\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2.$

- $\bullet \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 + (\mu - \bar{x})^2.$

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

- $\bullet E_\theta \widehat{\sigma^2} = \text{var}(X_1) - \text{var}(\bar{X}) = \sigma^2 - \frac{1}{n}\sigma^2 = \frac{n-1}{n}\sigma^2.$

### §7.3 估计的无偏性

称  $T(X_1, \dots, X_n)$  是  $g(\theta)$  的 无偏估计, 如果

$$E_\theta T(X_1, \dots, X_n) = g(\theta), \forall \theta \in \Theta.$$

- 样本均值  $\hat{\mu} = \bar{X} = \frac{1}{n}(X_1 + \dots + X_n).$

$$E_\theta \hat{\mu} = \frac{1}{n}(E_\theta X_1 + \dots + E_\theta X_n) = \mu, \text{ 无偏.}$$

- 样本方差  $\widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2.$

- $\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 + (\mu - \bar{x})^2.$

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

- $E_\theta \widehat{\sigma^2} = \text{var}(X_1) - \text{var}(\bar{X}) = \sigma^2 - \frac{1}{n}\sigma^2 = \frac{n-1}{n}\sigma^2.$

- 估小了:  $Y_i = X_i - \bar{X}, \forall i$  不独立, 一个约束条件  $\sum_i Y_i = 0.$

- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  是  $\sigma^2$  的无偏估计. (定理3.1)

有些书称  $S^2$  为样本方差.

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .
- 其最大值点  $\hat{\theta}_1$  需使得  $0 \leq x_i \leq \theta, \forall i$  都成立, 即  $\hat{\theta}_1 \geq \max_i x_i$ .

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .
- 其最大值点  $\hat{\theta}_1$  需使得  $0 \leq x_i \leq \theta, \forall i$  都成立, 即  $\hat{\theta}_1 \geq \max_i x_i$ .
- 进一步,  $\hat{\theta}_1$  使得  $\frac{1}{\theta^n}$  达到最大, 即  $\hat{\theta}_1$  尽量小, 故  $\hat{\theta}_1 = \max_i x_i$ .

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .
- 其最大值点  $\hat{\theta}_1$  需使得  $0 \leq x_i \leq \theta, \forall i$  都成立, 即  $\hat{\theta}_1 \geq \max_i x_i$ .
- 进一步,  $\hat{\theta}_1$  使得  $\frac{1}{\theta^n}$  达到最大, 即  $\hat{\theta}_1$  尽量小, 故  $\hat{\theta}_1 = \max_i x_i$ .
- 分析  $\hat{\theta}_1 = \max_i X_i$ :

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .
- 其最大值点  $\hat{\theta}_1$  需使得  $0 \leq x_i \leq \theta, \forall i$  都成立, 即  $\hat{\theta}_1 \geq \max_i x_i$ .
- 进一步,  $\hat{\theta}_1$  使得  $\frac{1}{\theta^n}$  达到最大, 即  $\hat{\theta}_1$  尽量小, 故  $\hat{\theta}_1 = \max_i x_i$ .
- 分析  $\hat{\theta}_1 = \max_i X_i$ :
  - 缺点:  $\hat{\theta}_1 = \max_i X_i < \theta$ , 故  $E_\theta \hat{\theta}_1 < \theta$ , 估小了!

例1.4+2.4.  $X \sim U[0, \theta]$ , 数据  $x_1, \dots, x_n$ . 求  $\theta$  的最大似然估计  $\hat{\theta}_1$  与矩估计  $\hat{\theta}_2$ .

最大似然估计:

- 似然函数  $L(\theta) = \prod_{i=1}^n \frac{1}{\theta} 1_{0 \leq x_i \leq \theta}$ .
- 其最大值点  $\hat{\theta}_1$  需使得  $0 \leq x_i \leq \theta, \forall i$  都成立, 即  $\hat{\theta}_1 \geq \max_i x_i$ .
- 进一步,  $\hat{\theta}_1$  使得  $\frac{1}{\theta^n}$  达到最大, 即  $\hat{\theta}_1$  尽量小, 故  $\hat{\theta}_1 = \max_i x_i$ .
- 分析  $\hat{\theta}_1 = \max_i X_i$ :
  - 缺点:  $\hat{\theta}_1 = \max_i X_i < \theta$ , 故  $E_\theta \hat{\theta}_1 < \theta$ , 估小了!
  - 进一步计算:

$$\begin{aligned} E_\theta \hat{\theta}_1 &= E_\theta \max_i X_i = \int_0^\theta P(\max_{1 \leq i \leq n} X_i > x) dx \\ &= \int_0^\theta (1 - P(\max_{1 \leq i \leq n} X_i \leq x)) dx \\ &= \theta - \int_0^\theta (\frac{1}{\theta} x)^n dx = (1 - \frac{1}{n+1})\theta. \end{aligned}$$

矩估计：

矩估计：

- 总体矩  $m_1(\theta) = \frac{1}{2}\theta$ , 样本矩  $\bar{x}$ .

矩估计：

- 总体矩  $m_1(\theta) = \frac{1}{2}\theta$ , 样本矩  $\bar{x}$ .
- 求解  $m_1(\hat{\theta}_2) = \bar{x}$ , 得  $\hat{\theta}_2 = 2\bar{x}$ .

矩估计：

- 总体矩  $m_1(\theta) = \frac{1}{2}\theta$ , 样本矩  $\bar{x}$ .
- 求解  $m_1(\hat{\theta}_2) = \bar{x}$ , 得  $\hat{\theta}_2 = 2\bar{x}$ .
- 分析  $\hat{\theta}_2 = 2\bar{X}$ :

矩估计：

- 总体矩  $m_1(\theta) = \frac{1}{2}\theta$ , 样本矩  $\bar{x}$ .
- 求解  $m_1(\hat{\theta}_2) = \bar{x}$ , 得  $\hat{\theta}_2 = 2\bar{x}$ .
- 分析  $\hat{\theta}_2 = 2\bar{X}$ :
  - $E_{\theta}\hat{\theta}_2 = 2E_{\theta}\bar{X} = 2E_{\theta}X_1 = 2 \times \frac{1}{2}\theta = \theta$ , 无偏.

矩估计：

- 总体矩  $m_1(\theta) = \frac{1}{2}\theta$ , 样本矩  $\bar{x}$ .
- 求解  $m_1(\hat{\theta}_2) = \bar{x}$ , 得  $\hat{\theta}_2 = 2\bar{x}$ .
- 分析  $\hat{\theta}_2 = 2\bar{X}$ :
  - $E_{\theta}\hat{\theta}_2 = 2E_{\theta}\bar{X} = 2E_{\theta}X_1 = 2 \times \frac{1}{2}\theta = \theta$ , 无偏.
  - 缺点: 有可能  $2\bar{x} < \max_i x_i$ , 明显不合理.
- 不能单纯追求无偏性.

## §7.4 无偏估计的优良性

假设  $\hat{\theta}_1, \hat{\theta}_2$  都是  $\theta$  的无偏估计, 即  $E_{\theta}\hat{\theta}_1 = E_{\theta}\hat{\theta}_2 = \theta$ .

若  $\text{var}_{\theta}(\hat{\theta}_1) \leq \text{var}_{\theta}(\hat{\theta}_2)$ , 则认为  $\hat{\theta}_1$  更好.

例.  $X \sim \text{Exp}(\lambda)$ . 样本  $X_1, \dots, X_n$ . 估计  $\theta = \frac{1}{\lambda} = EX$ .

## §7.4 无偏估计的优良性

假设  $\hat{\theta}_1, \hat{\theta}_2$  都是  $\theta$  的无偏估计, 即  $E_{\theta}\hat{\theta}_1 = E_{\theta}\hat{\theta}_2 = \theta$ .

若  $\text{var}_{\theta}(\hat{\theta}_1) \leq \text{var}_{\theta}(\hat{\theta}_2)$ , 则认为  $\hat{\theta}_1$  更好.

例.  $X \sim \text{Exp}(\lambda)$ . 样本  $X_1, \dots, X_n$ . 估计  $\theta = \frac{1}{\bar{X}} = EX$ .

- 最大似然估计与矩估计:  $\hat{\theta}_1 = \bar{X}$ .

## §7.4 无偏估计的优良性

假设  $\hat{\theta}_1, \hat{\theta}_2$  都是  $\theta$  的无偏估计, 即  $E_{\theta}\hat{\theta}_1 = E_{\theta}\hat{\theta}_2 = \theta$ .

若  $\text{var}_{\theta}(\hat{\theta}_1) \leq \text{var}_{\theta}(\hat{\theta}_2)$ , 则认为  $\hat{\theta}_1$  更好.

例.  $X \sim \text{Exp}(\lambda)$ . 样本  $X_1, \dots, X_n$ . 估计  $\theta = \frac{1}{\bar{X}} = EX$ .

- 最大似然估计与矩估计:  $\hat{\theta}_1 = \bar{X}$ .
- 令  $\hat{\theta}_2 = n \min_{1 \leq i \leq n} X_i$ .

## §7.4 无偏估计的优良性

假设  $\hat{\theta}_1, \hat{\theta}_2$  都是  $\theta$  的无偏估计, 即  $E_{\theta}\hat{\theta}_1 = E_{\theta}\hat{\theta}_2 = \theta$ .  
若  $\text{var}_{\theta}(\hat{\theta}_1) \leq \text{var}_{\theta}(\hat{\theta}_2)$ , 则认为  $\hat{\theta}_1$  更好.

例.  $X \sim \text{Exp}(\lambda)$ . 样本  $X_1, \dots, X_n$ . 估计  $\theta = \frac{1}{\bar{X}} = EX$ .

- 最大似然估计与矩估计:  $\hat{\theta}_1 = \bar{X}$ .
- 令  $\hat{\theta}_2 = n \min_{1 \leq i \leq n} X_i$ .
  - 理由:  $\min_{1 \leq i \leq n} X_i \sim \text{Exp}(n\lambda)$ , (第七章, 例4.8)  
 $\hat{\theta}_2 \sim \text{Exp}(\lambda)$ ,  $P(\hat{\theta}_2 > x) = P(X > \frac{1}{n}x)^n = e^{n \times (-\lambda \frac{1}{n}x)}$ .  
 $E_{\theta}\hat{\theta}_2 = \frac{1}{\lambda} = \theta$ . 无偏!

## §7.4 无偏估计的优良性

假设  $\hat{\theta}_1, \hat{\theta}_2$  都是  $\theta$  的无偏估计, 即  $E_{\theta}\hat{\theta}_1 = E_{\theta}\hat{\theta}_2 = \theta$ .  
若  $\text{var}_{\theta}(\hat{\theta}_1) \leq \text{var}_{\theta}(\hat{\theta}_2)$ , 则认为  $\hat{\theta}_1$  更好.

例.  $X \sim \text{Exp}(\lambda)$ . 样本  $X_1, \dots, X_n$ . 估计  $\theta = \frac{1}{\bar{X}} = EX$ .

- 最大似然估计与矩估计:  $\hat{\theta}_1 = \bar{X}$ .
- 令  $\hat{\theta}_2 = n \min_{1 \leq i \leq n} X_i$ .
  - 理由:  $\min_{1 \leq i \leq n} X_i \sim \text{Exp}(n\lambda)$ , (第七章, 例4.8)  
 $\hat{\theta}_2 \sim \text{Exp}(\lambda)$ ,  $P(\hat{\theta}_2 > x) = P(X > \frac{1}{n}x)^n = e^{n \times (-\lambda \frac{1}{n}x)}$ .  
 $E_{\theta}\hat{\theta}_2 = \frac{1}{\lambda} = \theta$ . 无偏!
- $\text{var}_{\theta}(\hat{\theta}_1) = \frac{1}{n}\text{var}(X) = \frac{1}{n}\frac{1}{\lambda^2} = \frac{1}{n}\theta^2$ .  
 $\text{var}_{\theta}(\hat{\theta}_2) = \frac{1}{\lambda^2} = \theta^2$ .  
故,  $\hat{\theta}_1$  比  $\hat{\theta}_2$  好.

## (一致)最小方差无偏估计

(Uniformly Minimum Variance Unbiased Estimator, UMVUE):

假设  $T = T(X_1, \dots, X_n)$  是  $\theta$  的无偏估计, 且对于  $\theta$  的任意无偏估计  $\tilde{T} = \tilde{T}(X_1, \dots, X_n)$  都有

$$\text{var}_\theta(T) \leq \text{var}_\theta(\tilde{T}), \quad \forall \theta \in \Theta.$$

则称  $T = T(X_1, \dots, X_n)$  是  $\theta$  的(一致)最小方差无偏估计.

指数族分布: 指密度(或分布列)为

$$p_{\theta}(x) = S(\theta) \color{red}{h(x)} \exp\{\sum_{k=1}^m C_k(\theta) \color{red}{T_k(x)}\}.$$

指数族分布特性: 假设总体  $X \sim p_{\theta}(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_{\theta}(x_i) = S^n(\theta) \prod_{i=1}^n \color{red}{h(x_i)} \exp\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\}$$

指数族分布: 指密度(或分布列)为

$$p_{\theta}(x) = S(\theta) \color{red}{h(x)} \exp\{\sum_{k=1}^m C_k(\theta) \color{red}{T_k(x)}\}.$$

- $\theta$  与  $x$  分离. 例4.8, 4.9, 4.10.

指数族分布特性: 假设总体  $X \sim p_{\theta}(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_{\theta}(x_i) = S^n(\theta) \prod_{i=1}^n \color{red}{h(x_i)} \exp\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\}$$

指数族分布: 指密度(或分布列)为

$$p_{\theta}(x) = S(\theta) \color{red}{h(x)} \exp\{\sum_{k=1}^m C_k(\theta) \color{red}{T_k(x)}\}.$$

- $\theta$  与  $x$  分离. 例4.8, 4.9, 4.10.
- 指数:  $p_{\lambda}(x) = \lambda e^{-\lambda x} \mathbf{1}_{\{x>0\}} = \lambda \mathbf{1}_{\{x>0\}} e^{-\lambda x}.$

指数族分布特性: 假设总体  $X \sim p_{\theta}(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_{\theta}(x_i) = S^n(\theta) \prod_{i=1}^n \color{red}{h(x_i)} \exp\left\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\right\}$$

指数族分布: 指密度(或分布列)为

$$p_{\theta}(x) = S(\theta)h(x) \exp\{\sum_{k=1}^m C_k(\theta)T_k(x)\}.$$

- $\theta$  与  $x$  分离. 例4.8, 4.9, 4.10.
- 指数:  $p_{\lambda}(x) = \lambda e^{-\lambda x} 1_{\{x>0\}} = \lambda 1_{\{x>0\}} e^{-\lambda x}.$
- 正态:  $p_{\theta}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2-2\mu x+\mu^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$

指数族分布特性: 假设总体  $X \sim p_{\theta}(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_{\theta}(x_i) = S^n(\theta) \prod_{i=1}^n h(x_i) \exp\left\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\right\}$$

指数族分布: 指密度(或分布列)为

$$p_\theta(x) = S(\theta) \color{red}{h(x)} \exp\{\sum_{k=1}^m C_k(\theta) T_k(x)\}.$$

- $\theta$  与  $x$  分离. 例4.8, 4.9, 4.10.
- 指数:  $p_\lambda(x) = \lambda e^{-\lambda x} \mathbf{1}_{\{x>0\}} = \lambda \mathbf{1}_{\{x>0\}} e^{-\lambda x}.$
- 正态:  $p_\theta(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2 - 2\mu x + \mu^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$
- 二项:  $P_{n,\color{blue}{p}}(X = \color{red}{k}) = C_n^k p^k (1-p)^{n-k} = C_n^k e^{k \log p + (n-k) \log(1-p)} = \color{red}{C_n^k} e^{(\log p - \log(1-p))\color{red}{k} + n \log(1-p)}$

指数族分布特性: 假设总体  $X \sim p_\theta(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_\theta(x_i) = S^n(\theta) \prod_{i=1}^n \color{red}{h(x_i)} \exp\left\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\right\}$$

指数族分布: 指密度(或分布列)为

$$p_\theta(x) = S(\theta)h(x) \exp\{\sum_{k=1}^m C_k(\theta)T_k(x)\}.$$

- $\theta$  与  $x$  分离. 例4.8, 4.9, 4.10.
- 指数:  $p_\lambda(x) = \lambda e^{-\lambda x} 1_{\{x>0\}} = \lambda 1_{\{x>0\}} e^{-\lambda x}.$
- 正态:  $p_\theta(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2-2\mu x+\mu^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$
- 二项:  $P_{n,p}(X = k) = C_n^k p^k (1-p)^{n-k} = C_n^k e^{k \log p + (n-k) \log(1-p)} = C_n^k e^{(\log p - \log(1-p))k + n \log(1-p)}$
- 泊松:  $P_\lambda(X = k) = \frac{\lambda^k}{k!} e^{-\lambda} 1_{\{k \geq 0\}} = \frac{1}{k!} 1_{\{k \geq 0\}} e^{(\log \lambda)k - \lambda}.$

指数族分布特性: 假设总体  $X \sim p_\theta(x)$ ,  $X_1, \dots, X_n$  为  $X$  的样本, 则  $(X_1, \dots, X_n)$  的密度(或分布列)为

$$\prod_{i=1}^n p_\theta(x_i) = S^n(\theta) \prod_{i=1}^n h(x_i) \exp\left\{\sum_{k=1}^m C_k(\theta) \sum_{i=1}^n T_k(x_i)\right\}$$

假设总体  $X$  密度为  $p_\theta(x) = S(\theta)h(x)\exp\{\sum_{k=1}^m C_k(\theta)T_k(x)\}$ .

**定理(4.2+4.3).** 若

- $\Theta$  是  $\mathbb{R}^m$  中有内点的集合.
- $(C_1, \dots, C_m) : \Theta \rightarrow \mathbb{R}^m$  一一对应, 连续.
- $C_k(\theta), 1 \leq k \leq m$  线性无关;  $T_k(x), 1 \leq k \leq m$  线性无关.  
(例如, 当  $T_1(x) = x, T_2(x) = x^2, T_3(x) = x + x^2$  时, 应化简为  $(C_1(\theta) + C_3(\theta))x + (C_2(\theta) + C_3(\theta))x^2$ .)
- $\hat{\theta} = \phi(T_1(\vec{X}), \dots, T_m(\vec{X}))$  是  $\theta$  (或  $g(\theta)$ ) 的无偏估计.

则  $\hat{\theta}$  是 UMVUE.

注:  $T_k(\vec{X}) = \sum_{i=1}^n T_k(X_i), \quad k = 1, \dots, m.$

例4.14.  $X \sim N(\mu, \sigma^2)$ .

例4.14.  $X \sim N(\mu, \sigma^2)$ .

- $\theta = (\mu, \sigma^2)$  二维,  $m = 2$ .

例4.14.  $X \sim N(\mu, \sigma^2)$ .

- $\theta = (\mu, \sigma^2)$  二维,  $m = 2$ .

- $p_\theta(x) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$ .

$$C_1(\theta) = \frac{\mu}{\sigma^2}, C_2(\theta) = -\frac{1}{2\sigma^2} \text{ 线性无关.}$$

$$T_1(x) = x, T_2(x) = x^2 \text{ 线性无关.}$$

例4.14.  $X \sim N(\mu, \sigma^2)$ .

- $\theta = (\mu, \sigma^2)$  二维,  $m = 2$ .

- $p_\theta(x) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$ .

$$C_1(\theta) = \frac{\mu}{\sigma^2}, C_2(\theta) = -\frac{1}{2\sigma^2} \text{ 线性无关.}$$

$$T_1(x) = x, T_2(x) = x^2 \text{ 线性无关.}$$

- $T_1(\vec{X}) = \sum_{i=1}^n X_i = n\bar{X}$ ,

$$T_2(\vec{X}) = \sum_{i=1}^n X_i^2 = \sum_{i=1}^n (X_i - \bar{X})^2 + n\bar{X}^2 = (n-1)S^2 + n\bar{X}^2.$$

$$\phi(T_1(\vec{X}), T_2(\vec{X})) = \varphi(\bar{X}, S^2),$$

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

例4.14.  $X \sim N(\mu, \sigma^2)$ .

- $\theta = (\mu, \sigma^2)$  二维,  $m = 2$ .

- $p_\theta(x) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{\mu^2}{2\sigma^2}} e^{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x}$ .

$$C_1(\theta) = \frac{\mu}{\sigma^2}, C_2(\theta) = -\frac{1}{2\sigma^2} \text{ 线性无关.}$$

$$T_1(x) = x, T_2(x) = x^2 \text{ 线性无关.}$$

- $T_1(\vec{X}) = \sum_{i=1}^n X_i = n\bar{X}$ ,

$$T_2(\vec{X}) = \sum_{i=1}^n X_i^2 = \sum_{i=1}^n (X_i - \bar{X})^2 + n\bar{X}^2 = (n-1)S^2 + n\bar{X}^2.$$

$$\phi(T_1(\vec{X}), T_2(\vec{X})) = \varphi(\bar{X}, S^2),$$

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

- 若  $\varphi(\bar{X}, S^2)$  是无偏估计, 则是UMVUE.

特别地,  $\bar{X}, S^2$  分别是  $\mu, \sigma^2$  的UMVUE.