

数理统计

第三章

点估计

2026 年 4 月 19 日

- 1 3.4* 一致最小方差无偏估计
 - 3.4.1 引言及定义
- 2 3.5 Carmer-Rao 不等式

3.4.1 引言及定义

设有一参数分布族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$, 其中 Θ 为参数空间。

3.4.1 引言及定义

设有一参数分布族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$, 其中 Θ 为参数空间。

设 $g(\theta)$ 是定义在 Θ 上的实函数, $\mathbf{X} = (X_1, \dots, X_n)$ 为自 \mathcal{F} 中抽取的简单样本, $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个估计量。

3.4.1 引言及定义

设有一参数分布族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$, 其中 Θ 为参数空间。

设 $g(\theta)$ 是定义在 Θ 上的实函数, $\mathbf{X} = (X_1, \dots, X_n)$ 为自 \mathcal{F} 中抽取的简单样本, $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个估计量。

如何评价 $\hat{g}(\mathbf{X})$ 的优劣?

3.4.1 引言及定义

一般用 $\hat{g}(\mathbf{X}) - g(\theta)$ 作为其偏差，为消除 $\hat{g}(\mathbf{X}) - g(\theta)$ 取值出现“正负”可能抵消的影响，一般用 $[\hat{g}(\mathbf{X}) - g(\theta)]^2$ 来代替。

3.4.1 引言及定义

一般用 $\hat{g}(\mathbf{X}) - g(\theta)$ 作为其偏差，为消除 $\hat{g}(\mathbf{X}) - g(\theta)$ 取值出现“正负”可能抵消的影响，一般用 $[\hat{g}(\mathbf{X}) - g(\theta)]^2$ 来代替。

由于这个量是随机的，将其求平均，即计算其均值，以得到一个整体性的指标

$$E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2,$$

这就是估计量 $\hat{g}(\mathbf{X})$ 的均方误差。

3.4.1 引言及定义

定义 (3.4.1)

设 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的估计量, 则称

$$E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2$$

为 $\hat{g}(\mathbf{X})$ 的**均方误差 (mean squared error, MSE)**。

3.4.1 引言及定义

定义 (3.4.1)

设 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的估计量, 则称

$$E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2$$

为 $\hat{g}(\mathbf{X})$ 的**均方误差 (mean squared error, MSE)**。

设 $\hat{g}_1(\mathbf{X})$ 和 $\hat{g}_2(\mathbf{X})$ 为 $g(\theta)$ 的两个不同的估计量, 若

$$E_{\theta}[\hat{g}_1(\mathbf{X}) - g(\theta)]^2 \geq E[\hat{g}_2(\mathbf{X}) - g(\theta)]^2, \text{ 一切 } \theta \in \Theta,$$

且不等号至少对某个 $\theta \in \Theta$ 成立, 则称在MSE准则下 $\hat{g}_2(\mathbf{X})$ 优于 $\hat{g}_1(\mathbf{X})$ 。

3.4.1 引言及定义

定义 (3.4.1 (续))

若存在 $\hat{g}^*(\mathbf{X})$, 使得对 $g(\theta)$ 的任一估计量 $\hat{g}(\mathbf{X})$, 都有

$$E_{\theta}[\hat{g}^*(\mathbf{X}) - g(\theta)]^2 \leq E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2, \quad \text{一切 } \theta \in \Theta,$$

则称 $\hat{g}^*(\mathbf{X})$ 为 $g(\theta)$ 的**一致最小均方误差估计**。

3.4.1 引言及定义

可惜的是，一致最小均方误差估计常不存在。

3.4.1 引言及定义

可惜的是，一致最小均方误差估计常不存在。

解决这个问题的办法之一是把最优性准则放宽一些，使适合这种最优性准则的估计一般能存在。

3.4.1 引言及定义

可惜的是，一致最小均方误差估计**常不存在**。

解决这个问题的办法之一是把最优性准则放宽一些，使适合这种最优性准则的估计一般能存在。

从直观上想，在一个大的估计类中，一致最优估计量不存在，把估计类缩小，就有可能存在一致最优的估计量。因此把估计类缩小为**无偏估计类**来考虑。

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

即当 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计时， $E(\hat{g}(\mathbf{X})) = g(\theta)$ ，其均方误差为

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

即当 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计时， $E(\hat{g}(\mathbf{X})) = g(\theta)$ ，其均方误差为

$$\begin{aligned}MSE[\hat{g}(\mathbf{X})] &= E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2 \\ &= \end{aligned}$$

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

即当 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计时， $E(\hat{g}(\mathbf{X})) = g(\theta)$ ，其均方误差为

$$\begin{aligned}MSE[\hat{g}(\mathbf{X})] &= E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2 \\ &= E_{\theta}[\hat{g}(\mathbf{X}) - E(\hat{g}(\mathbf{X}))]^2 \\ &= \end{aligned}$$

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

即当 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计时， $E(\hat{g}(\mathbf{X})) = g(\theta)$ ，其均方误差为

$$\begin{aligned}MSE[\hat{g}(\mathbf{X})] &= E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2 \\&= E_{\theta}[\hat{g}(\mathbf{X}) - E(\hat{g}(\mathbf{X}))]^2 \\&= Var_{\theta}[\hat{g}(\mathbf{X})],\end{aligned}$$

3.4.1 引言及定义

在无偏估计类中，估计量的均方误差就变为其方差。

即当 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计时， $E(\hat{g}(\mathbf{X})) = g(\theta)$ ，其均方误差为

$$\begin{aligned}MSE[\hat{g}(\mathbf{X})] &= E_{\theta}[\hat{g}(\mathbf{X}) - g(\theta)]^2 \\ &= E_{\theta}[\hat{g}(\mathbf{X}) - E(\hat{g}(\mathbf{X}))]^2 \\ &= Var_{\theta}[\hat{g}(\mathbf{X})],\end{aligned}$$

此处 $Var_{\theta}[\hat{g}(\mathbf{X})]$ 表示 $\hat{g}(\mathbf{X})$ 的方差。

3.4.1 引言及定义

存在这样的情形，参数 $g(\theta)$ 的无偏估计不存在。请看下例。

3.4.1 引言及定义

存在这样的情形，参数 $g(\theta)$ 的无偏估计不存在。请看下例。

例 (3.4.1)

设样本 $X \sim$ 二项分布 $B(n, p)$ ， n 已知而 p 未知。令 $g(p) = 1/p$ ，则参数 $g(p)$ 的无偏估计不存在。

3.4.1 引言及定义

存在这样的情形，参数 $g(\theta)$ 的无偏估计不存在。请看下例。

例 (3.4.1)

设样本 $X \sim$ 二项分布 $B(n, p)$ ， n 已知而 p 未知。令 $g(p) = 1/p$ ，则参数 $g(p)$ 的无偏估计不存在。

证： 采用反证法。

3.4.1 引言及定义

存在这样的情形，参数 $g(\theta)$ 的无偏估计不存在。请看下例。

例 (3.4.1)

设样本 $X \sim$ 二项分布 $B(n, p)$ ， n 已知而 p 未知。令 $g(p) = 1/p$ ，则参数 $g(p)$ 的无偏估计不存在。

证： 采用反证法。

若不然，存在 $g(p)$ 有无偏估计 $\hat{g}(X)$ 。由于 X 只取 $0, 1, \dots, n$ 这些值，令 $\hat{g}(X)$ 的取值用 $\hat{g}(i) = a_i$ 表示， $i = 0, 1, \dots, n$ 。

3.4.1 引言及定义

由 $\hat{g}(X)$ 的无偏性，应有

3.4.1 引言及定义

由 $\hat{g}(X)$ 的无偏性, 应有

$$\begin{aligned} E_p(\hat{g}(X)) &= \sum_{i=0}^n a_i P(\hat{g}(X) = a_i) = \sum_{i=0}^n a_i P(X = i) \\ &= \sum_{i=0}^n a_i \binom{n}{i} p^i (1-p)^{n-i} = \frac{1}{p}, \quad 0 < p < 1. \end{aligned}$$

3.4.1 引言及定义

由 $\hat{g}(X)$ 的无偏性, 应有

$$\begin{aligned} E_p(\hat{g}(X)) &= \sum_{i=0}^n a_i P(\hat{g}(X) = a_i) = \sum_{i=0}^n a_i P(X = i) \\ &= \sum_{i=0}^n a_i \binom{n}{i} p^i (1-p)^{n-i} = \frac{1}{p}, \quad 0 < p < 1. \end{aligned}$$

于是有

3.4.1 引言及定义

由 $\hat{g}(X)$ 的无偏性, 应有

$$\begin{aligned} E_p(\hat{g}(X)) &= \sum_{i=0}^n a_i P(\hat{g}(X) = a_i) = \sum_{i=0}^n a_i P(X = i) \\ &= \sum_{i=0}^n a_i \binom{n}{i} p^i (1-p)^{n-i} = \frac{1}{p}, \quad 0 < p < 1. \end{aligned}$$

于是有

$$\sum_{i=0}^n a_i \binom{n}{i} p^{i+1} (1-p)^{n-i} - 1 = 0, \quad 0 < p < 1.$$

3.4.1 引言及定义

但上式左端是 p 的 $n + 1$ 次多项式，即

3.4.1 引言及定义

但上式左端是 p 的 $n + 1$ 次多项式，即

$$\sum_{i=0}^n a_i \binom{n}{i} p^{i+1} (1-p)^{n-i} - 1$$

=

3.4.1 引言及定义

但上式左端是 p 的 $n + 1$ 次多项式，即

$$\begin{aligned} & \sum_{i=0}^n a_i \binom{n}{i} p^{i+1} (1-p)^{n-i} - 1 \\ &= a_0 \binom{n}{0} p (1-p)^n + a_1 \binom{n}{1} p^2 (1-p)^{n-1} \\ & \quad + \cdots + a_n \binom{n}{n} p^{n+1} (1-p)^0 - 1, \end{aligned}$$

3.4.1 引言及定义

但上式左端是 p 的 $n + 1$ 次多项式，即

$$\begin{aligned} & \sum_{i=0}^n a_i \binom{n}{i} p^{i+1} (1-p)^{n-i} - 1 \\ &= a_0 \binom{n}{0} p (1-p)^n + a_1 \binom{n}{1} p^2 (1-p)^{n-1} \\ & \quad + \cdots + a_n \binom{n}{n} p^{n+1} (1-p)^0 - 1, \end{aligned}$$

它最多在 $(0, 1)$ 区间有 $n + 1$ 个实根。

3.4.1 引言及定义

但上式左端是 p 的 $n + 1$ 次多项式，即

$$\begin{aligned} & \sum_{i=0}^n a_i \binom{n}{i} p^{i+1} (1-p)^{n-i} - 1 \\ &= a_0 \binom{n}{0} p (1-p)^n + a_1 \binom{n}{1} p^2 (1-p)^{n-1} \\ & \quad + \cdots + a_n \binom{n}{n} p^{n+1} (1-p)^0 - 1, \end{aligned}$$

它最多在 $(0, 1)$ 区间有 $n + 1$ 个实根。可无偏性要求对 $(0, 1)$ 中的任一实数 p 上式都成立，这个矛盾说明 $g(p) = 1/p$ 的无偏估计不存在。 \square

3.4.1 引言及定义

今后把不存在无偏估计的参数除外。

3.4.1 引言及定义

今后把不存在无偏估计的参数除外。

参数的无偏估计若存在，则称此参数为**可估参数**；

3.4.1 引言及定义

今后把不存在无偏估计的参数除外。

参数的无偏估计若存在，则称此参数为**可估参数**；

若参数函数的无偏估计存在，则称此函数为**可估函数** (estimable function)。因此可估函数的无偏估计类是非空的。

3.4.1 引言及定义

今后把不存在无偏估计的参数除外。

参数的无偏估计若存在，则称此参数为**可估参数**；

若参数函数的无偏估计存在，则称此函数为**可估函数** (estimable function)。因此可估函数的无偏估计类是非空的。

假如可估函数的无偏估计类中的无偏估计不止一个，怎样比较它们的优劣？

3.4.1 引言及定义

定义 (3.4.2 (一致最小方差无偏估计))

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是一个参数分布族, 其中 Θ 为参数空间, $g(\theta)$ 为定义在 Θ 上的可估函数。

3.4.1 引言及定义

定义 (3.4.2 (一致最小方差无偏估计))

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是一个参数分布族, 其中 Θ 为参数空间, $g(\theta)$ 为定义在 Θ 上的可估函数。

设 $\hat{g}^*(\mathbf{X}) = \hat{g}^*(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个无偏估计, 若对 $g(\theta)$ 的任一无偏估计 $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$, 都有

3.4.1 引言及定义

定义 (3.4.2 (一致最小方差无偏估计))

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是一个参数分布族, 其中 Θ 为参数空间, $g(\theta)$ 为定义在 Θ 上的可估函数。

设 $\hat{g}^*(\mathbf{X}) = \hat{g}^*(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个无偏估计, 若对 $g(\theta)$ 的任一无偏估计 $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$, 都有

$$\text{Var}_\theta[\hat{g}^*(\mathbf{X})] \leq \text{Var}_\theta[\hat{g}(\mathbf{X})], \text{ 一切 } \theta \in \Theta,$$

3.4.1 引言及定义

定义 (3.4.2 (一致最小方差无偏估计))

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是一个参数分布族, 其中 Θ 为参数空间, $g(\theta)$ 为定义在 Θ 上的可估函数。

设 $\hat{g}^*(\mathbf{X}) = \hat{g}^*(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个无偏估计, 若对 $g(\theta)$ 的任一无偏估计 $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$, 都有

$$\text{Var}_\theta[\hat{g}^*(\mathbf{X})] \leq \text{Var}_\theta[\hat{g}(\mathbf{X})], \text{ 一切 } \theta \in \Theta,$$

则称 $\hat{g}^*(\mathbf{X})$ 是 $g(\theta)$ 的一致最小方差无偏估计 (uniformly minimum variance unbiased estimation, **UMVUE**)。

3.4.1 引言及定义

对给定参数分布族，如何寻找可估函数的UMVUE呢？

3.4.1 引言及定义

对给定参数分布族，如何寻找可估函数的UMVUE呢？

有三种方法：

3.4.1 引言及定义

对给定参数分布族，如何寻找可估函数的UMVUE呢？

有三种方法：

1. 零无偏估计法（不做要求）；

3.4.1 引言及定义

对给定参数分布族，如何寻找可估函数的UMVUE呢？

有三种方法：

1. 零无偏估计法（不做要求）；
2. 充分完全统计量法（不做要求）；

3.4.1 引言及定义

对给定参数分布族，如何寻找可估函数的UMVUE呢？

有三种方法：

1. 零无偏估计法（不做要求）；
2. 充分完全统计量法（不做要求）；
3. Cramer-Rao不等式法（3.5节）。

- 1 3.4* 一致最小方差无偏估计
- 2 3.5 Carmer-Rao 不等式
 - 3.5.1 引言
 - 3.5.2 单参数 C-R 不等式
 - 3.5.3 多参数 C-R 不等式简介
 - 3.5.4 有效估计和估计的效率

3.5.1 引言

Cramer-Rao 不等式（简称 C-R 不等式）是判别一个无偏估计量是否为 UMVUE 的主要方法之一。

这一方法的思想如下：

3.5.1 引言

Cramer-Rao 不等式（简称 C-R 不等式）是判别一个无偏估计量是否为 UMVUE 的主要方法之一。

这一方法的思想如下：

设 \mathcal{U}_g 是 $g(\theta)$ 的一切无偏估计构成的类。 \mathcal{U}_g 中估计量的方差有一个下界，如果 $g(\theta)$ 的一个无偏估计量 \hat{g} 的方差达到这个下界，则 \hat{g} 就是 $g(\theta)$ 的一个 UMVUE，当然样本分布族和 \hat{g} 要满足一定的正则条件。

3.5.1 引言

这个不等式是由C. R. Rao 和 H. Cramer 在 1945 年和 1946 年分别证明的，故称此不等式为 Cramer-Rao 不等式（简称 C-R 不等式）。

3.5.1 引言

这个不等式是由C. R. Rao 和 H. Cramer 在 1945 年和 1946 年分别证明的，故称此不等式为 Cramer-Rao 不等式（简称 C-R 不等式）。

以后一些统计学者将此不等式的条件作了一些改进和精确化，但结果的基本形式并无重大变化。

3.5.1 引言

这一方法的缺陷是：

3.5.1 引言

这一方法的缺陷是：

由于 C-R 不等式确定的下界（称为 C-R 下界）常比真下界小。在一些场合，虽然 $g(\theta)$ 的 UMVUE \hat{g} 存在，但其方差大于 C-R 下界。

3.5.1 引言

这一方法的缺陷是：

由于 C-R 不等式确定的下界（称为 C-R 下界）常比真下界小。在一些场合，虽然 $g(\theta)$ 的 UMVUE \hat{g} 存在，但其方差大于 C-R 下界。

在这一情况下，用 C-R 不等式就无法判定 $g(\theta)$ 的 UMVUE 存在。因此这一方法的适用范围不广。

3.5.1 引言

C-R 不等式除用于判别 $g(\theta)$ 的UMVUE之外，它在数理统计理论上还要其他的用处，如估计的效率和有效估计的概念以及 Fisher 信息量都与之有关。

3.5.1 引言

C-R 不等式除用于判别 $g(\theta)$ 的UMVUE之外，它在数理统计理论上还要其他的用处，如估计的效率和有效估计的概念以及 Fisher 信息量都与之有关。

C-R 不等式成立需要样本分布族满足一些正则条件，适合这些条件的分布族称为 C-R 正则分布族，下面给出其定义。

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件))

若单参数概率函数族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 满足下列条件:

- (1) 参数空间 Θ 是直线上的某个开区间;

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件))

若单参数概率函数族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 满足下列条件:

- (1) 参数空间 Θ 是直线上的某个开区间;
- (2) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $f(x, \theta) > 0$, 即分布族具有共同支撑;

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件))

若单参数概率函数族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 满足下列条件:

- (1) 参数空间 Θ 是直线上的某个开区间;
- (2) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $f(x, \theta) > 0$, 即分布族具有共同支撑;
- (3) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $\partial f(x, \theta) / \partial \theta$ 存在;

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件))

若单参数概率函数族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 满足下列条件:

- (1) 参数空间 Θ 是直线上的某个开区间;
- (2) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $f(x, \theta) > 0$, 即分布族具有共同支撑;
- (3) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $\partial f(x, \theta) / \partial \theta$ 存在;
- (4) 概率函数 $f(x, \theta)$ 的积分与微分运算可交换, 即

$$\frac{\partial}{\partial \theta} \int f(x, \theta) dx = \int \frac{\partial}{\partial \theta} f(x, \theta) dx,$$

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件))

若单参数概率函数族 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 满足下列条件:

- (1) 参数空间 Θ 是直线上的某个开区间;
- (2) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $f(x, \theta) > 0$, 即分布族具有共同支撑;
- (3) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $\partial f(x, \theta) / \partial \theta$ 存在;
- (4) 概率函数 $f(x, \theta)$ 的积分与微分运算可交换, 即

$$\frac{\partial}{\partial \theta} \int f(x, \theta) dx = \int \frac{\partial}{\partial \theta} f(x, \theta) dx,$$

若 $f(x, \theta)$ 为离散随机变量的概率分布, 上述条件改为无穷级数和微分运算可交换;

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件) 续)

(5) 下列数学期望存在, 且

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件) 续)

(5) 下列数学期望存在, 且

$$0 < I(\theta) = E_{\theta} \left[\frac{\partial \ln f(X, \theta)}{\partial \theta} \right]^2 < \infty, \quad (1)$$

3.5.1 引言

定义 (3.5.1 (C-R 正则分布族, C-R 正则条件) 续)

(5) 下列数学期望存在, 且

$$0 < I(\theta) = E_{\theta} \left[\frac{\partial \ln f(X, \theta)}{\partial \theta} \right]^2 < \infty, \quad (1)$$

则称该分布族为**C-R 正则分布族**, 其中 (1) - (5) 称为**C-R 正则条件**。

$I(\theta)$ 称为该分布的**Fisher 信息量** (或称为**Fisher 信息函数**)。

3.5.2 单参数 C-R 不等式

1. C-R 不等式及例

3.5.2 单参数 C-R 不等式

1. C-R 不等式及例

定理 (3.5.1)

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是 C-R 正则分布族, $g(\theta)$ 是定义于参数空间 Θ 上的可微函数。设 $\mathbf{X} = (X_1, \dots, X_n)$ 是由总体 $f(x, \theta) \in \mathcal{F}$ 中抽取的简单样本, $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的任一无偏估计, 且满足下列条件:

3.5.2 单参数 C-R 不等式

1. C-R 不等式及例

定理 (3.5.1)

设 $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ 是 C-R 正则分布族, $g(\theta)$ 是定义于参数空间 Θ 上的可微函数。设 $\mathbf{X} = (X_1, \dots, X_n)$ 是由总体 $f(x, \theta) \in \mathcal{F}$ 中抽取的简单样本, $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的任一无偏估计, 且满足下列条件:

(6) 积分

$$\int \cdots \int \hat{g}(\mathbf{x}) f(\mathbf{x}, \theta) d\mathbf{x}$$

可在积分号下对 θ 求导数 (此处 $d\mathbf{x} = dx_1 \cdots dx_n$),

3.5.2 单参数 C-R 不等式

定理 (3.5.1 (续))

则有

$$\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)}, \forall \theta \in \Theta. \quad (2)$$

此不等式称为 **Cramer-Rao 不等式**，简称 **C-R 不等式**。

3.5.2 单参数 C-R 不等式

注 3.5.1 在 C-R 不等式中出现的 $I(\theta)$ 是由式 (1)

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

定义的 Fisher 信息量。

3.5.2 单参数 C-R 不等式

注 3.5.1 在 C-R 不等式中出现的 $I(\theta)$ 是由式 (1)

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

定义的 Fisher 信息量。

- $I(\theta)$ 可以解释成单个样品（即样本容量为1的样本）提供的信息量，它反映了总体分布的性质。

3.5.2 单参数 C-R 不等式

注 3.5.1 在 C-R 不等式中出现的 $I(\theta)$ 是由式 (1)

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

定义的 Fisher 信息量。

- $I(\theta)$ 可以解释成单个样品（即样本容量为1的样本）提供的信息量，它反映了总体分布的性质。
- 由于 X_1, \dots, X_n 是 *i.i.d.* 的，它们的地位是平等的，故每个样品 X_i 提供同样多的信息 $I(\theta)$ ，故整个样本 (X_1, \dots, X_n) 所含的信息量为 $nI(\theta)$ ，它与样本容量 n 和总体分布的信息量 $I(\theta)$ 成正比。

3.5.2 单参数 C-R 不等式

- 因此，式 (2)

$$\text{Var}_\theta[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)}$$

右端的 C-R 下界表明，当样本的容量 n 越大或总体分布的信息量 $I(\theta)$ 越大，C-R 下界就越小，UMVUE 的精度就越高。这与人们的直观认知相符。

3.5.2 单参数 C-R 不等式

证 由于 X_1, \dots, X_n 为*i.i.d.*样本, 故有 $f(\mathbf{x}, \theta) = \prod_{i=1}^n f(x_i, \theta)$ 。记

3.5.2 单参数 C-R 不等式

证 由于 X_1, \dots, X_n 为 *i.i.d.* 样本, 故有 $f(\mathbf{x}, \theta) = \prod_{i=1}^n f(x_i, \theta)$ 。记

$$S(\mathbf{x}, \theta) = \frac{\partial \ln f(\mathbf{x}, \theta)}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(x_i, \theta)}{\partial \theta},$$

因此由正则条件 (3) 和 (4) 可知

3.5.2 单参数 C-R 不等式

证 由于 X_1, \dots, X_n 为 *i.i.d.* 样本, 故有 $f(\mathbf{x}, \theta) = \prod_{i=1}^n f(x_i, \theta)$ 。记

$$S(\mathbf{x}, \theta) = \frac{\partial \ln f(\mathbf{x}, \theta)}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(x_i, \theta)}{\partial \theta},$$

因此由正则条件 (3) 和 (4) 可知

$$\begin{aligned} E_{\theta}\{S(\mathbf{X}, \theta)\} &= \sum_{i=1}^n E_{\theta} \left\{ \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right\} \\ &= \sum_{i=1}^n \int \frac{1}{f(x_i, \theta)} \frac{\partial f(x_i, \theta)}{\partial \theta} \cdot f(x_i, \theta) dx_i \\ &= \sum_{i=1}^n \int \frac{\partial f(x_i, \theta)}{\partial \theta} dx_i = \sum_{i=1}^n \frac{\partial}{\partial \theta} \int f(x_i, \theta) dx = 0. \end{aligned}$$

3.5.2 单参数 C-R 不等式

由 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计和正则条件 (5) 和 (6) 可知

3.5.2 单参数 C-R 不等式

由 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计和正则条件 (5) 和 (6) 可知

$$\begin{aligned} \text{Cov}_\theta[\hat{g}(\mathbf{X}), S(\mathbf{X}, \theta)] &= E_\theta\{\hat{g}(\mathbf{X}) \cdot S(\mathbf{X}, \theta)\} \\ &= \int \cdots \int \hat{g}(\mathbf{x}) \left[\frac{1}{f(\mathbf{x}, \theta)} \frac{\partial f(\mathbf{x}, \theta)}{\partial \theta} \right] f(\mathbf{x}, \theta) d\mathbf{x} \\ &= \int \cdots \int \hat{g}(\mathbf{x}) \frac{\partial f(\mathbf{x}, \theta)}{\partial \theta} d\mathbf{x} \\ &= \frac{\partial}{\partial \theta} \int \cdots \int \hat{g}(\mathbf{x}) f(\mathbf{x}, \theta) d\mathbf{x} = \frac{\partial g(\theta)}{\partial \theta} \triangleq g'(\theta), \end{aligned}$$

3.5.2 单参数 C-R 不等式

$$\begin{aligned} \text{Var}_\theta(S(\mathbf{X}, \theta)) &= \sum_{i=1}^n \text{Var}_\theta \left\{ \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right\} \\ &= \sum_{i=1}^n E_\theta \left\{ \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right\}^2 = nI(\theta). \end{aligned} \quad (3)$$

由 Cauchy-Schwarz 不等式，得

3.5.2 单参数 C-R 不等式

$$\begin{aligned} \text{Var}_\theta(S(\mathbf{X}, \theta)) &= \sum_{i=1}^n \text{Var}_\theta \left\{ \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right\} \\ &= \sum_{i=1}^n E_\theta \left\{ \frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right\}^2 = nI(\theta). \end{aligned} \quad (3)$$

由 Cauchy-Schwarz 不等式，得

$$\text{Var}_\theta\{\hat{g}(\mathbf{X})\} \cdot \text{Var}_\theta\{S(\mathbf{X}, \theta)\} \geq [\text{Cov}_\theta(\hat{g}(\mathbf{X}), S(\mathbf{X}, \theta))]^2 = [g'(\theta)]^2,$$

3.5.2 单参数 C-R 不等式

将式 (3) 代入上式可得

3.5.2 单参数 C-R 不等式

将式 (3) 代入上式可得

$$\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)}, \forall \theta \in \Theta.$$



3.5.2 单参数 C-R 不等式

由式

$$\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)}, \forall \theta \in \Theta$$

给出的 C-R 不等式可视为验证某一无偏估计是否为 UMVUE 的方法。

3.5.2 单参数 C-R 不等式

由式

$$\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)}, \forall \theta \in \Theta$$

给出的 C-R 不等式可视为验证某一无偏估计是否为 UMVUE 的方法。

用 C-R 不等式寻找 $g(\theta)$ 的 UMVUE 时，首先要验证样本分布族是否满足 C-R 正则条件 (1) - (5) 和 (6)，然后再计算 Fisher 信息量 $I(\theta)$ 和无偏估计 $\hat{g}(\mathbf{X})$ 的方差 $\text{Var}_{\theta}[\hat{g}(\mathbf{X})]$ ，看其是否达到 C-R 下界。

3.5.2 单参数 C-R 不等式

验证正则条件 (1) - (5) 和条件 (6) 十分麻烦。

3.5.2 单参数 C-R 不等式

验证正则条件 (1) - (5) 和条件 (6) 十分麻烦。

但幸运的是对**指数族**，上述正则条件 (1) - (5) 皆成立，而条件 (6) 正好是由定理1.5.2给出的指数族的一条重要性质。因此对于指数族，定理3.5.1的条件皆成立。

3.5.2 单参数 C-R 不等式

但要注意一点的是：

3.5.2 单参数 C-R 不等式

但要注意一点的是：

若 $Var_{\theta}[\hat{g}(\mathbf{X})]$ 达不到 C-R 下界，并不能得出结论说 $g(\theta)$ 的 UMVUE 不存在，而只能说此法判别失效。

3.5.2 单参数 C-R 不等式

但要注意一点的是：

若 $Var_{\theta}[\hat{g}(\mathbf{X})]$ 达不到 C-R 下界，并不能得出结论说 $g(\theta)$ 的 UMVUE 不存在，而只能说此法判别失效。

存在这样的例子， $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的 UMVUE，但其方差大于 C-R 下界。

3.5.2 单参数 C-R 不等式

例 (3.5.1)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从两点分布 $B(1, p)$ 中抽取的简单样本，利用 $C - R$ 不等式证明样本均值 $\bar{X} = \sum_{i=1}^n X_i/n$ 为 p 的 UMVUE。

3.5.2 单参数 C-R 不等式

证:

设随机变量 $X \sim B(1, p)$, 则其概率分布为

$$f(x, p) = p^x(1 - p)^{1-x}, \quad x = 0, 1, \quad 0 < p < 1.$$

3.5.2 单参数 C-R 不等式

证:

设随机变量 $X \sim B(1, p)$, 则其概率分布为

$$f(x, p) = p^x(1 - p)^{1-x}, \quad x = 0, 1, \quad 0 < p < 1.$$

由于两点分布族是指数族, C-R正则条件成立。

3.5.2 单参数 C-R 不等式

Fisher信息函数为

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(p) &= E_p \left[\frac{\partial \ln f(X, p)}{\partial p} \right]^2 = E_p \left[\frac{X - p}{p(1 - p)} \right]^2 \\ &= \frac{\text{Var}_p(X)}{p^2(1 - p)^2} = \frac{1}{p(1 - p)}, \end{aligned}$$

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(p) &= E_p \left[\frac{\partial \ln f(X, p)}{\partial p} \right]^2 = E_p \left[\frac{X - p}{p(1 - p)} \right]^2 \\ &= \frac{\text{Var}_p(X)}{p^2(1 - p)^2} = \frac{1}{p(1 - p)}, \end{aligned}$$

因此C-R下界为 $1/[nI(p)] = p(1 - p)/n$ 。

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(p) &= E_p \left[\frac{\partial \ln f(X, p)}{\partial p} \right]^2 = E_p \left[\frac{X - p}{p(1 - p)} \right]^2 \\ &= \frac{\text{Var}_p(X)}{p^2(1 - p)^2} = \frac{1}{p(1 - p)}, \end{aligned}$$

因此C-R下界为 $1/[nI(p)] = p(1 - p)/n$ 。

而 \bar{X} 为 p 的无偏估计，其方差 $\text{Var}_p(\bar{X}) = p(1 - p)/n$ 达到C-R下界。

故 \bar{X} 为 p 的UMVUE。 □

3.5.2 单参数 C-R 不等式

例 (3.5.2)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从 Poisson 分布 $P(\lambda)$ 中抽取的简单样本，用 C-R 不等式验证样本均值 $\bar{X} = \sum_{i=1}^n X_i/n$ 为 λ 的 UMVUE。

3.5.2 单参数 C-R 不等式

证:

设随机变量 $X \sim P(\lambda)$, 其概率分布为

3.5.2 单参数 C-R 不等式

证:

设随机变量 $X \sim P(\lambda)$, 其概率分布为

$$f(x, \lambda) = e^{-\lambda} \lambda^x / x!, \quad x = 0, 1, \dots; \lambda > 0.$$

3.5.2 单参数 C-R 不等式

证:

设随机变量 $X \sim P(\lambda)$, 其概率分布为

$$f(x, \lambda) = e^{-\lambda} \lambda^x / x!, \quad x = 0, 1, \dots; \lambda > 0.$$

由于Poisson分布族为指数族, 故C-R正则条件成立。

3.5.2 单参数 C-R 不等式

Fisher信息函数为

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{X - \lambda}{\lambda} \right)^2 \\ &= \frac{1}{\lambda^2} \text{Var}_{\lambda}(X) = \frac{1}{\lambda}, \end{aligned}$$

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{X - \lambda}{\lambda} \right)^2 \\ &= \frac{1}{\lambda^2} \text{Var}_{\lambda}(X) = \frac{1}{\lambda}, \end{aligned}$$

C-R下界为 $1/[nI(\lambda)] = \lambda/n$ 。

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{X - \lambda}{\lambda} \right)^2 \\ &= \frac{1}{\lambda^2} \text{Var}_{\lambda}(X) = \frac{1}{\lambda}, \end{aligned}$$

C-R下界为 $1/[nI(\lambda)] = \lambda/n$ 。

$\hat{g}(\mathbf{X}) = \bar{X}$ 为 $g(\lambda) = \lambda$ 的无偏估计，且方差 $\text{Var}_{\lambda}(\bar{X}) = \lambda/n$ 达到C-R下界。故 \bar{X} 为 λ 的UMVUE。 □

3.5.2 单参数 C-R 不等式

例 (3.5.3)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从指数分布 $Exp(\lambda)$ 中抽取的简单样本，用 C-R 不等式验证 $\hat{g}(\mathbf{X}) = \bar{X}$ 为 $g(\lambda) = 1/\lambda$ 的 UMVUE。

3.5.2 单参数 C-R 不等式

证:

指数分布 $Exp(\lambda)$ 的密度函数为

3.5.2 单参数 C-R 不等式

证:

指数分布 $Exp(\lambda)$ 的密度函数为

$$f(x, \lambda) = \lambda e^{-\lambda x} I_{(0, \infty)}(x), \lambda > 0.$$

3.5.2 单参数 C-R 不等式

证:

指数分布 $Exp(\lambda)$ 的密度函数为

$$f(x, \lambda) = \lambda e^{-\lambda x} I_{(0, \infty)}(x), \lambda > 0.$$

指数分布族是指数族，故C-R正则条件成立。

3.5.2 单参数 C-R 不等式

Fisher信息函数为

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{1}{\lambda} - X \right)^2 \\ &= \text{Var}_{\lambda}(X) = \frac{1}{\lambda^2}, \end{aligned}$$

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{1}{\lambda} - X \right)^2 \\ &= \text{Var}_{\lambda}(X) = \frac{1}{\lambda^2}, \end{aligned}$$

故C-R下界为

3.5.2 单参数 C-R 不等式

Fisher信息函数为

$$\begin{aligned} I(\lambda) &= E_{\lambda} \left[\frac{\partial \ln f(X, \lambda)}{\partial \lambda} \right]^2 = E_{\lambda} \left(\frac{1}{\lambda} - X \right)^2 \\ &= \text{Var}_{\lambda}(X) = \frac{1}{\lambda^2}, \end{aligned}$$

故C-R下界为

$$\frac{g'(\lambda)^2}{nI(\lambda)} = \frac{\left(\frac{\partial \frac{1}{\lambda}}{\partial \lambda} \right)^2}{nI(\lambda)} = \frac{\frac{1}{\lambda^4}}{\frac{n}{\lambda^2}} = \frac{1}{n\lambda^2}.$$

3.5.2 单参数 C-R 不等式

而 $\hat{g}(\bar{X}) = \bar{X}$ 为 $g(\lambda) = 1/\lambda$ 的无偏估计, 其方差 $Var_{\lambda}(\bar{X}) = \frac{1}{n\lambda^2}$ 达到 C-R 下界, 故 \bar{X} 为 $g(\lambda) = 1/\lambda$ 的 UMVUE。 □

3.5.2 单参数 C-R 不等式

例 (3.5.4)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从 $N(a, \sigma^2)$ 中抽取的简单样本，其中 σ^2 已知，用 C-R 不等式验证 \bar{X} 为 a 的 UMVUE。

3.5.2 单参数 C-R 不等式

证:

由于正态分布族是指数族，C-R正则条件皆成立。正态分布 $N(a, \sigma^2)$ 的密度函数为

3.5.2 单参数 C-R 不等式

证:

由于正态分布族是指数族, C-R正则条件皆成立。正态分布 $N(a, \sigma^2)$ 的密度函数为

$$f(x, a) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{1}{2\sigma^2} (x - a)^2 \right\}.$$

3.5.2 单参数 C-R 不等式

证:

由于正态分布族是指数族, C-R正则条件皆成立。正态分布 $N(a, \sigma^2)$ 的密度函数为

$$f(x, a) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{1}{2\sigma^2} (x - a)^2 \right\}.$$

Fisher信息函数为

3.5.2 单参数 C-R 不等式

证:

由于正态分布族是指数族, C-R正则条件皆成立。正态分布 $N(a, \sigma^2)$ 的密度函数为

$$f(x, a) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{1}{2\sigma^2}(x - a)^2 \right\}.$$

Fisher信息函数为

$$\begin{aligned} I(a) &= E_a \left[\frac{\partial \ln f(X, a)}{\partial a} \right]^2 = E_a \left[\frac{(X - a)^2}{\sigma^4} \right] \\ &= \frac{1}{\sigma^4} \text{Var}_\alpha(X) = \frac{1}{\sigma^2}. \end{aligned}$$

3.5.2 单参数 C-R 不等式

故C-R下界为 $1/[nI(a)] = \sigma^2/n$ 。而 $Var_a(\bar{X}) = \sigma^2/n$ 达到C-R下界，故 \bar{X} 为 a 的UMVUE。 □

3.5.2 单参数 C-R 不等式

故C-R下界为 $1/[nI(a)] = \sigma^2/n$ 。而 $Var_a(\bar{X}) = \sigma^2/n$ 达到C-R下界，故 \bar{X} 为 a 的UMVUE。 □

同样，若本题中改 a 为已知，但 σ^2 未知，容易验证

$$S_a^2 = \frac{1}{n} \sum_{i=1}^n (X_i - a)^2$$

为 σ^2 的UMVUE（习题）。

3.5.3 多参数 C-R 不等式简介

以上讨论的都是参数 θ 为一维的情形，对 θ 为高维的情形也可以建立类似的结果。为此先引进一些记号。

3.5.3 多参数 C-R 不等式简介

以上讨论的都是参数 θ 为一维的情形，对 θ 为高维的情形也可以建立类似的结果。为此先引进一些记号。

设 $A = (a_{ij})$ 和 $B = (b_{ij})$ 是同阶的非负定方阵，若 $A - B$ 是非负定的，则记为 $A \geq B$ 。这时必有 $a_{ii} \geq b_{ii}$ ，对一切 i 。

3.5.3 多参数 C-R 不等式简介

以上讨论的都是参数 θ 为一维的情形，对 θ 为高维的情形也可以建立类似的结果。为此先引进一些记号。

设 $A = (a_{ij})$ 和 $B = (b_{ij})$ 是同阶的非负定方阵，若 $A - B$ 是非负定的，则记为 $A \geq B$ 。这时必有 $a_{ii} \geq b_{ii}$ ，对一切 i 。

现设 $\theta = (\theta_1, \dots, \theta_k)$ ，总体概率函数记为 $f(x, \theta)$ ， $\mathbf{X} = (X_1, \dots, X_n)$ 为从总体中抽取的简单样本。

3.5.3 多参数 C-R 不等式简介

设 $\hat{\theta} = \hat{\theta}(\mathbf{X}) = (\hat{\theta}_1, \dots, \hat{\theta}_k)$ 是 θ 的一个无偏估计。以 $Cov_{\theta}(\hat{\theta})$ 记 $\hat{\theta}$ 的协方差阵，它是一个 k 阶非负定方阵，其 (i, j) 元为 $E_{\theta}[(\hat{\theta}_i - \theta_i)(\hat{\theta}_j - \theta_j)]$ ，则在类似于 θ 为一维的正则条件下，可以证明

3.5.3 多参数 C-R 不等式简介

设 $\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}(\mathbf{X}) = (\hat{\theta}_1, \dots, \hat{\theta}_k)$ 是 $\boldsymbol{\theta}$ 的一个无偏估计。以 $Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}})$ 记 $\hat{\boldsymbol{\theta}}$ 的协方差阵，它是一个 k 阶非负定方阵，其 (i, j) 元为 $E_{\boldsymbol{\theta}}[(\hat{\theta}_i - \theta_i)(\hat{\theta}_j - \theta_j)]$ ，则在类似于 $\boldsymbol{\theta}$ 为一维的正则条件下，可以证明

$$Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) \geq (n\mathbf{I}(\boldsymbol{\theta}))^{-1}, \quad (4)$$

3.5.3 多参数 C-R 不等式简介

设 $\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}(\mathbf{X}) = (\hat{\theta}_1, \dots, \hat{\theta}_k)$ 是 $\boldsymbol{\theta}$ 的一个无偏估计。以 $Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}})$ 记 $\hat{\boldsymbol{\theta}}$ 的协方差阵，它是一个 k 阶非负定方阵，其 (i, j) 元为 $E_{\boldsymbol{\theta}}[(\hat{\theta}_i - \theta_i)(\hat{\theta}_j - \theta_j)]$ ，则在类似于 $\boldsymbol{\theta}$ 为一维的正则条件下，可以证明

$$Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) \geq (n\mathbf{I}(\boldsymbol{\theta}))^{-1}, \quad (4)$$

其中 $\mathbf{I}(\boldsymbol{\theta}) = (I_{ij}(\boldsymbol{\theta}))$ 是总体的 Fisher 信息矩阵（样本量是 1 时的信息阵），其中

3.5.3 多参数 C-R 不等式简介

设 $\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}(\mathbf{X}) = (\hat{\theta}_1, \dots, \hat{\theta}_k)$ 是 $\boldsymbol{\theta}$ 的一个无偏估计。以 $Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}})$ 记 $\hat{\boldsymbol{\theta}}$ 的协方差阵，它是一个 k 阶非负定方阵，其 (i, j) 元为 $E_{\boldsymbol{\theta}}[(\hat{\theta}_i - \theta_i)(\hat{\theta}_j - \theta_j)]$ ，则在类似于 $\boldsymbol{\theta}$ 为一维的正则条件下，可以证明

$$Cov_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) \geq (n\mathbf{I}(\boldsymbol{\theta}))^{-1}, \quad (4)$$

其中 $\mathbf{I}(\boldsymbol{\theta}) = (I_{ij}(\boldsymbol{\theta}))$ 是总体的 Fisher 信息矩阵（样本量是 1 时的信息阵），其中

$$I_{ij}(\boldsymbol{\theta}) = E_{\boldsymbol{\theta}} \left[\left(\frac{\partial \ln f(X, \boldsymbol{\theta})}{\partial \theta_i} \right) \left(\frac{\partial \ln f(X, \boldsymbol{\theta})}{\partial \theta_j} \right) \right], \quad i, j = 1, 2, \dots, k, \quad (5)$$

3.5.3 多参数 C-R 不等式简介

则式 (4) 就是**多维的C-R不等式**。

3.5.3 多参数 C-R 不等式简介

则式 (4) 就是多参数的 C-R 不等式。

若记 $[I(\boldsymbol{\theta})]^{-1} = \mathbf{I}^*(\boldsymbol{\theta}) = (I_{ij}^*(\boldsymbol{\theta}))$, 故由式 (4) 得

3.5.3 多参数 C-R 不等式简介

则式 (4) 就是多维的 C-R 不等式。

若记 $[I(\boldsymbol{\theta})]^{-1} = \mathbf{I}^*(\boldsymbol{\theta}) = (I_{ij}^*(\boldsymbol{\theta}))$, 故由式 (4) 得

$$\text{Var}_{\boldsymbol{\theta}}(\hat{\theta}_i) \geq \frac{I_{ii}^*(\boldsymbol{\theta})}{n}, \quad i = 1, 2, \dots, k.$$

3.5.3 多参数 C-R 不等式简介

则式 (4) 就是多维的C-R不等式。

若记 $[I(\theta)]^{-1} = I^*(\theta) = (I_{ij}^*(\theta))$, 故由式 (4) 得

$$\text{Var}_{\theta}(\hat{\theta}_i) \geq \frac{I_{ii}^*(\theta)}{n}, \quad i = 1, 2, \dots, k.$$

这给出了 θ 的每个分量 θ_i 的无偏估计 $\hat{\theta}_i$ 的方差的下限。

3.5.3 多参数 C-R 不等式简介

注 3.5.2

3.5.3 多参数 C-R 不等式简介

注 3.5.2

在上述多参数 C-R 不等式中, Fisher 信息阵 $I(\boldsymbol{\theta}) = (I_{ij}(\boldsymbol{\theta}))$, 其元素 $I_{ij}(\boldsymbol{\theta})$ 由式 (5) 给出, 以后我们会看到 $I_{ij}(\boldsymbol{\theta})$ 还有另一种表示方式, 即

3.5.3 多参数 C-R 不等式简介

注 3.5.2

在上述多参数 C-R 不等式中, Fisher 信息阵 $I(\boldsymbol{\theta}) = (I_{ij}(\boldsymbol{\theta}))$, 其元素 $I_{ij}(\boldsymbol{\theta})$ 由式 (5) 给出, 以后我们会看到 $I_{ij}(\boldsymbol{\theta})$ 还有另一种表示方式, 即

$$I_{ij}(\boldsymbol{\theta}) = E_{\boldsymbol{\theta}} \left[- \left(\frac{\partial^2 \ln f(X, \boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right) \right], \quad i, j = 1, 2, \dots, k. \quad (6)$$

3.5.3 多参数 C-R 不等式简介

注 3.5.2

在上述多参数 C-R 不等式中, Fisher 信息阵 $I(\boldsymbol{\theta}) = (I_{ij}(\boldsymbol{\theta}))$, 其元素 $I_{ij}(\boldsymbol{\theta})$ 由式 (5) 给出, 以后我们会看到 $I_{ij}(\boldsymbol{\theta})$ 还有另一种表示方式, 即

$$I_{ij}(\boldsymbol{\theta}) = E_{\boldsymbol{\theta}} \left[- \left(\frac{\partial^2 \ln f(X, \boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right) \right], \quad i, j = 1, 2, \dots, k. \quad (6)$$

可以证明: 在 C-R 正则条件下, 由式 (5) 和式 (6) 给出的 Fisher 信息阵是相等的。

3.5.3 多参数 C-R 不等式简介

例 (3.5.6)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从正态总体 $N(a, \sigma^2)$ 中抽取的简单样本，记 $\theta = (a, \sigma^2)$ ，其中 $\theta_1 = a$ ， $\theta_2 = \sigma^2$ 。求 θ 的两个分量无偏估计方差的 C-R 下界，并将其与 θ_1 和 θ_2 的无偏估计 \bar{X} 和 S^2 的方差进行比较。

3.5.3 多参数 C-R 不等式简介

解

3.5.3 多参数 C-R 不等式简介

解

正态随机变量的密度函数为

3.5.3 多参数 C-R 不等式简介

解

正态随机变量的密度函数为

$$f(x, \boldsymbol{\theta}) = (2\pi\theta_2)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2\theta_2}(x - \theta_1)^2\right\},$$

可知

3.5.3 多参数 C-R 不等式简介

解

正态随机变量的密度函数为

$$f(x, \boldsymbol{\theta}) = (2\pi\theta_2)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2\theta_2}(x - \theta_1)^2\right\},$$

可知

$$\frac{\partial \ln f(x, \boldsymbol{\theta})}{\partial \theta_1} = \frac{x - \theta_1}{\theta_2},$$

3.5.3 多参数 C-R 不等式简介

解

正态随机变量的密度函数为

$$f(x, \boldsymbol{\theta}) = (2\pi\theta_2)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2\theta_2}(x - \theta_1)^2\right\},$$

可知

$$\begin{aligned}\frac{\partial \ln f(x, \boldsymbol{\theta})}{\partial \theta_1} &= \frac{x - \theta_1}{\theta_2}, \\ \frac{\partial \ln f(x, \boldsymbol{\theta})}{\partial \theta_2} &= \frac{-\theta_2 + (x - \theta_1)^2}{2\theta_2^2}.\end{aligned}$$

3.5.3 多参数 C-R 不等式简介

由此算出

3.5.3 多参数 C-R 不等式简介

由此算出

$$I_{11}(\boldsymbol{\theta}) = \frac{1}{\sigma^2}, \quad I_{22}(\boldsymbol{\theta}) = \frac{1}{2\sigma^4}, \quad I_{12}(\boldsymbol{\theta}) = I_{21}(\boldsymbol{\theta}) = 0,$$

故有

3.5.3 多参数 C-R 不等式简介

由此算出

$$I_{11}(\boldsymbol{\theta}) = \frac{1}{\sigma^2}, \quad I_{22}(\boldsymbol{\theta}) = \frac{1}{2\sigma^4}, \quad I_{12}(\boldsymbol{\theta}) = I_{21}(\boldsymbol{\theta}) = 0,$$

故有

$$n\mathbf{I}(\boldsymbol{\theta}) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix}, \quad (n\mathbf{I}(\boldsymbol{\theta}))^{-1} = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix},$$

3.5.3 多参数 C-R 不等式简介

若记

3.5.3 多参数 C-R 不等式简介

若记

$$\hat{\theta}_1 = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\theta}_2 = S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

3.5.3 多参数 C-R 不等式简介

若记

$$\hat{\theta}_1 = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\theta}_2 = S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

则由多维C-R不等式可知

3.5.3 多参数 C-R 不等式简介

若记

$$\hat{\theta}_1 = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\theta}_2 = S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

则由多维C-R不等式可知

$$\text{Cov}_{\theta}(\hat{\theta}) = \text{Cov}_{\theta} \begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} \geq \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^2}{n} \end{pmatrix}.$$

3.5.3 多参数 C-R 不等式简介

而 $Var_{\theta}(\hat{\theta}_1) = \sigma^2/n$ 达到C-R下界，故它是 $\theta_1 = a$ 的UMVUE。

3.5.3 多参数 C-R 不等式简介

而 $Var_{\theta}(\hat{\theta}_1) = \sigma^2/n$ 达到C-R下界, 故它是 $\theta_1 = a$ 的UMVUE。

利用 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$ 及 $Var_{\theta}[(n-1)S^2/\sigma^2] = 2(n-1)$ 可得

3.5.3 多参数 C-R 不等式简介

而 $\text{Var}_\theta(\hat{\theta}_1) = \sigma^2/n$ 达到 C-R 下界, 故它是 $\theta_1 = a$ 的 UMVUE。

利用 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$ 及 $\text{Var}_\theta[(n-1)S^2/\sigma^2] = 2(n-1)$ 可得

$$\text{Var}_\theta(\hat{\theta}_2) = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n}.$$

3.5.3 多参数 C-R 不等式简介

而 $Var_{\theta}(\hat{\theta}_1) = \sigma^2/n$ 达到C-R下界，故它是 $\theta_1 = a$ 的UMVUE。

利用 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$ 及 $Var_{\theta}[(n-1)S^2/\sigma^2] = 2(n-1)$ 可得

$$Var_{\theta}(\hat{\theta}_2) = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n}.$$

因此， $S^2 = \hat{\theta}_2$ 的方差大于C-R下界。

3.5.3 多参数 C-R 不等式简介

而 $\text{Var}_\theta(\hat{\theta}_1) = \sigma^2/n$ 达到 C-R 下界, 故它是 $\theta_1 = a$ 的 UMVUE。

利用 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$ 及 $\text{Var}_\theta[(n-1)S^2/\sigma^2] = 2(n-1)$ 可得

$$\text{Var}_\theta(\hat{\theta}_2) = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n}.$$

因此, $S^2 = \hat{\theta}_2$ 的方差大于 C-R 下界。

在例 3.4.10 中已证明了 \bar{X} 和 S^2 分别是 a 和 σ^2 的 UMVUE。 □

3.5.3 多参数 C-R 不等式简介

由本例看出，即使在正态总体方差这样简单的场合，方差 σ^2 的UMVUE S^2 也达不到C-R下界。

3.5.3 多参数 C-R 不等式简介

由本例看出，即使在正态总体方差这样简单的场合，方差 σ^2 的UMVUE S^2 也达不到C-R下界。

因此在一些问题中C-R下界常比真下界小。这表明以C-R不等式作为寻找UMVUE的方法是不够理想的。

3.5.4 有效估计和估计的效率

定义 ((有效估计))

设 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计, 比值

$$e_{\hat{g}_n}(\theta) = \frac{[g'(\theta)]^2 / (nI(\theta))}{\text{Var}_{\theta}[\hat{g}_n(\mathbf{X})]}$$

称为无偏估计 $\hat{g}_n(\mathbf{X})$ 的**效率**。

3.5.4 有效估计和估计的效率

定义 ((有效估计))

设 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计, 比值

$$e_{\hat{g}_n}(\theta) = \frac{[g'(\theta)]^2 / (nI(\theta))}{\text{Var}_{\theta}[\hat{g}_n(\mathbf{X})]}$$

称为无偏估计 $\hat{g}_n(\mathbf{X})$ 的**效率**。

显然 $0 < e_{\hat{g}_n}(\theta) \leq 1$, 当 $e_{\hat{g}_n}(\theta) = 1$ 时, 称 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的**有效估计**。

3.5.4 有效估计和估计的效率

定义 ((有效估计))

设 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的无偏估计, 比值

$$e_{\hat{g}_n}(\theta) = \frac{[g'(\theta)]^2 / (nI(\theta))}{\text{Var}_{\theta}[\hat{g}_n(\mathbf{X})]}$$

称为无偏估计 $\hat{g}_n(\mathbf{X})$ 的**效率**。

显然 $0 < e_{\hat{g}_n}(\theta) \leq 1$, 当 $e_{\hat{g}_n}(\theta) = 1$ 时, 称 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的**有效估计**。

若 $\hat{g}_n(\mathbf{X})$ 不是 $g(\theta)$ 的有效估计, 但 $\lim_{n \rightarrow \infty} e_{\hat{g}_n}(\theta) = 1$, 则

称 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的**渐近有效估计**。

3.5.4 有效估计和估计的效率

- 这一概念有其不足之处：有效估计是无偏估计类中最好的估计，当然希望使用它。可惜，有效估计是不多的，但渐近有效估计却不少。

3.5.4 有效估计和估计的效率

- 这一概念有其不足之处：有效估计是无偏估计类中最好的估计，当然希望使用它。可惜，有效估计是不多的，但渐近有效估计却不少。
- 从有效估计的定义看，有效估计一定是UMVUE，但很多UMVUE不是有效估计。这是因为C-R下界偏小，在很多场合UMVUE的方差达不到C-R下界。

3.5.4 有效估计和估计的效率

- 这一概念有其不足之处：有效估计是无偏估计类中最好的估计，当然希望使用它。可惜，有效估计是不多的，但渐近有效估计却不少。
- 从有效估计的定义看，有效估计一定是UMVUE，但很多UMVUE不是有效估计。这是因为C-R下界偏小，在很多场合UMVUE的方差达不到C-R下界。
- 另外C-R不等式成立的前提是要求样本分布族满足C-R正则条件。当这些条件不成立时，C-R不等式的结果可以不对，这时依据它所提供的C-R下界去定义估计的效率或求有效估计就不合理了。

3.5.4 有效估计和估计的效率

例 (3.5.8)

由例3.5.1-例3.5.4给出的有关参数的无偏估计，其方差都能达到C-R下界，因此它们都是相应参数的有效估计。

3.5.4 有效估计和估计的效率

例 (3.5.9)

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从 $N(a, \sigma^2)$ 中抽取的简单样本。

- (1) 当 a 未知时，证明样本方差 S^2 不是 σ^2 的有效估计，但是渐近有效估计。
- (2) 当 a 已知时，求 σ^2 的有效估计。

3.5.4 有效估计和估计的效率

解:

3.5.4 有效估计和估计的效率

解:

(1) 设 $g(\sigma^2) = \sigma^2$, 由例3.5.6知, 当 a 未知时,

$S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)$ 的方差为

3.5.4 有效估计和估计的效率

解:

(1) 设 $g(\sigma^2) = \sigma^2$, 由例3.5.6知, 当 a 未知时,

$S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)$ 的方差为

$$\text{Var}_\sigma^2(S^2) = 2\sigma^4 / (n - 1),$$

3.5.4 有效估计和估计的效率

解:

(1) 设 $g(\sigma^2) = \sigma^2$, 由例3.5.6知, 当 a 未知时,

$S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)$ 的方差为

$$\text{Var}_\sigma^2(S^2) = 2\sigma^4 / (n - 1),$$

达不到C-R下界 $2\sigma^4/n$, 故它不是 σ^2 的有效估计。

3.5.4 有效估计和估计的效率

估计的效率为

3.5.4 有效估计和估计的效率

估计的效率为

$$e_{S^2}(\sigma^2) = \frac{\left[\frac{\partial g(\sigma^2)}{\partial \sigma^2} \right] / (nI(\sigma^2))}{\text{Var}_{\sigma}^2(S^2)} = \frac{\frac{2\sigma^4}{n}}{\frac{2\sigma^4}{n-1}} = \frac{n-1}{n} < 1,$$

3.5.4 有效估计和估计的效率

估计的效率为

$$e_{S^2}(\sigma^2) = \frac{\left[\frac{\partial g(\sigma^2)}{\partial \sigma^2} \right] / (nI(\sigma^2))}{\text{Var}_\sigma^2(S^2)} = \frac{\frac{2\sigma^4}{n}}{\frac{2\sigma^4}{n-1}} = \frac{n-1}{n} < 1,$$

但是

$$\lim_{n \rightarrow \infty} e_{S^2}(\sigma^2) = \lim_{n \rightarrow \infty} \frac{n-1}{n} = 1,$$

3.5.4 有效估计和估计的效率

估计的效率为

$$e_{S^2}(\sigma^2) = \frac{\left[\frac{\partial g(\sigma^2)}{\partial \sigma^2} \right] / (nI(\sigma^2))}{\text{Var}_{\sigma^2}(S^2)} = \frac{\frac{2\sigma^4}{n}}{\frac{2\sigma^4}{n-1}} = \frac{n-1}{n} < 1,$$

但是

$$\lim_{n \rightarrow \infty} e_{S^2}(\sigma^2) = \lim_{n \rightarrow \infty} \frac{n-1}{n} = 1,$$

因此 S^2 是 σ^2 的渐近有效估计。

3.5.4 有效估计和估计的效率

(2) 由于 a 已知, 令 $S_a^2 = \sum_{i=1}^n (X_i - a)^2/n$, 由于 $nS_a^2/\sigma^2 \sim \chi_n^2$,
故 $Var(nS_a^2/\sigma^2) = 2n$, 因此有 $Var(S_a^2) = 2\sigma^4/n$, 它达到C-R下界,
故 S_a^2 为 σ^2 的有效估计。 □