

数理统计  
第二章  
抽样分布及若干预备知识

2026 年 3 月 31 日

## 1 2.6 充分统计量

- 2.6.1 引言与定义
- 2.6.2 充分性的判别准则——因子分解定理

## 2.6.1 引言与定义

统计量的充分性是数理统计的一个基本概念，它是由R. A. Fisher 在其1922年的奠基性工作中提出来的。

## 2.6.1 引言与定义

统计量的充分性是数理统计的一个基本概念，它是由R. A. Fisher 在其1922年的奠基性工作中提出来的。

统计量是对样本的简化，希望达到：（1）简化的程度高；（2）信息的损失少。

## 2.6.1 引言与定义

统计量的充分性是数理统计的一个基本概念，它是由R. A. Fisher 在其1922年的奠基性工作中提出来的。

统计量是对样本的简化，希望达到：（1）简化的程度高；（2）信息的损失少。

一个统计量能集中样本中信息的多少，与统计量的具体形式有关，也依赖于问题的统计模型。

## 2.6.1 引言与定义

统计量的充分性是数理统计的一个基本概念，它是由R. A. Fisher 在其1922年的奠基性工作中提出来的。

统计量是对样本的简化，希望达到：（1）简化的程度高；（2）信息的损失少。

一个统计量能集中样本中信息的多少，与统计量的具体形式有关，也依赖于问题的统计模型。

最好的情况是统计量把样本中的全部信息都集中起来，也就是说信息无损失，称这样的统计量为**充分统计量**。

## 2.6.1 引言与定义

例如，设  $\mathbf{X} = (X_1, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
即  $P(X_i = 1) = \theta$ ,  $P(X_i = 0) = 1 - \theta$ ,  $0 < \theta < 1$ 。

## 2.6.1 引言与定义

例如，设  $\mathbf{X} = (X_1, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
即  $P(X_i = 1) = \theta$ ,  $P(X_i = 0) = 1 - \theta$ ,  $0 < \theta < 1$ 。

记  $T(\mathbf{X}) = \sum_{i=1}^n X_i$ ，如果目的仅仅为了推断  $\theta$ ，则  $T(\mathbf{X})$  是充分统计量。

## 2.6.1 引言与定义

从直观上看，知道了 $T(\mathbf{X})$ 推断 $\theta$ 的效果，与知道样本 $(X_1, X_2, \dots, X_n)$ 一样，因为 $T(\mathbf{X})$ 表示事件 $A$ 在 $n$ 次独立的Bernoulli试验中成功的次数。

## 2.6.1 引言与定义

从直观上看，知道了 $T(\mathbf{X})$ 推断 $\theta$ 的效果，与知道样本 $(X_1, X_2, \dots, X_n)$ 一样，因为 $T(\mathbf{X})$ 表示事件 $A$ 在 $n$ 次独立的Bernoulli试验中成功的次数。

而 $(X_1, X_2, \dots, X_n)$ 比 $T(\mathbf{X})$ 更详细的地方在于指出了事件 $A$ 是在哪几次试验中发生是随机的。因此，知道了 $A$ 出现的总次数后，再知道上述细节对推断 $\theta$ 不会有更多的用处。

## 2.6.1 引言与定义

一大堆原始资料，加工成统计量 $T(\mathbf{X})$ 后，一般来说在信息上会有**损失**。

## 2.6.1 引言与定义

一大堆原始资料，加工成统计量 $T(\mathbf{X})$ 后，一般来说在信息上会有**损失**。

但也有可能，将样本 $\mathbf{X}$ 加工成 $T(\mathbf{X})$ 时抓住了问题的实质，即 $T(\mathbf{X})$ 中保留了样本 $\mathbf{X}$ 中所含参数 $\theta$ 的全部信息，所丢掉的只是无关紧要的东西。

## 2.6.1 引言与定义

一大堆原始资料，加工成统计量 $T(\mathbf{X})$ 后，一般来说在信息上会有**损失**。

但也有可能，将样本 $\mathbf{X}$ 加工成 $T(\mathbf{X})$ 时抓住了问题的实质，即 $T(\mathbf{X})$ 中保留了样本 $\mathbf{X}$ 中所含参数 $\theta$ 的全部信息，所丢掉的只是无关紧要的东西。

如果一个统计量满足这个要求，即使没有样本 $\mathbf{X}$ 也能**恢复**参数 $\theta$ 的信息，则称此统计量为充分的。

## 2.6.1 引言与定义

仍看上例，样本  $X$  的分布为

## 2.6.1 引言与定义

仍看上例，样本  $\mathbf{X}$  的分布为

$$\begin{aligned} P_{\theta}(\mathbf{X} = \mathbf{x}) &= P_{\theta}(X_1 = x_1, \dots, X_n = x_n) \\ &= \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} \\ &= \theta^t (1 - \theta)^{n-t}, \end{aligned} \tag{1}$$

## 2.6.1 引言与定义

仍看上例，样本  $\mathbf{X}$  的分布为

$$\begin{aligned} P_{\theta}(\mathbf{X} = \mathbf{x}) &= P_{\theta}(X_1 = x_1, \dots, X_n = x_n) \\ &= \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} \\ &= \theta^t (1 - \theta)^{n-t}, \end{aligned} \tag{1}$$

其中  $t = \sum_{i=1}^n x_i$ 。

## 2.6.1 引言与定义

仍看上例，样本  $\mathbf{X}$  的分布为

$$\begin{aligned}P_{\theta}(\mathbf{X} = \mathbf{x}) &= P_{\theta}(X_1 = x_1, \dots, X_n = x_n) \\&= \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} \\&= \theta^t (1 - \theta)^{n-t},\end{aligned}\tag{1}$$

其中  $t = \sum_{i=1}^n x_i$ 。

而  $T(\mathbf{X}) = \sum_{i=1}^n X_i \sim B(n, \theta)$ ，故有

## 2.6.1 引言与定义

仍看上例，样本  $\mathbf{X}$  的分布为

$$\begin{aligned} P_{\theta}(\mathbf{X} = \mathbf{x}) &= P_{\theta}(X_1 = x_1, \dots, X_n = x_n) \\ &= \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} \\ &= \theta^t (1 - \theta)^{n-t}, \end{aligned} \quad (1)$$

其中  $t = \sum_{i=1}^n x_i$ 。

而  $T(\mathbf{X}) = \sum_{i=1}^n X_i \sim B(n, \theta)$ ，故有

$$P_{\theta}(T(\mathbf{X}) = t) = \binom{n}{t} \theta^t (1 - \theta)^{n-t}, \quad t = 0, 1, 2, \dots, n, \quad 0 < \theta < 1. \quad (2)$$

## 2.6.1 引言与定义

可见，基于式（1）和式（2）推断参数 $\theta$ 的效果是相同的。因此 $T(\mathbf{X})$ 为充分统计量。

## 2.6.1 引言与定义

可见，基于式 (1) 和式 (2) 推断参数 $\theta$ 的效果是相同的。因此 $T(\mathbf{X})$ 为充分统计量。

### 充分性原则

如果 $T(\mathbf{X})$ 为 $\theta$ 的充分统计量，则依赖样本 $\mathbf{X}$ 对 $\theta$ 所作出的任何统计推断都可以仅通过统计量 $T(\mathbf{X})$ 进行，不会有关于 $\theta$ 信息的损失。也就是说，如果 $x$ 和 $y$ 为满足 $T(x) = T(y)$ 的两个样本点，则无论是观测到 $\mathbf{X} = x$ 还是 $\mathbf{X} = y$ ，关于 $\theta$ 的推断都是相同的。

## 2.6.1 引言与定义

关于样本  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  的信息可以设想成如下的公式：

## 2.6.1 引言与定义

关于样本  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  的信息可以设想成如下的公式:

$$\begin{aligned} \{\text{样本 } \mathbf{X} \text{ 中的信息}\} &= \{T(\mathbf{X}) \text{ 中所含样本的信息}\} \\ &+ \{\text{在知道 } T(\mathbf{X}) \text{ 后样本 } \mathbf{X} \text{ 尚含有的剩余信息}\}. \end{aligned}$$

## 2.6.1 引言与定义

关于样本  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  的信息可以设想成如下的公式：

$$\begin{aligned} \{\text{样本 } \mathbf{X} \text{ 中的信息}\} &= \{T(\mathbf{X}) \text{ 中所含样本的信息}\} \\ &+ \{\text{在知道 } T(\mathbf{X}) \text{ 后样本 } \mathbf{X} \text{ 尚含有的剩余信息}\}. \end{aligned}$$

故  $T(\mathbf{X})$  为充分统计量的要求归结为：要求后一项信息为0。

## 2.6.1 引言与定义

关于样本  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  的信息可以设想成如下的公式：

$$\begin{aligned} \{\text{样本 } \mathbf{X} \text{ 中的信息}\} &= \{T(\mathbf{X}) \text{ 中所含样本的信息}\} \\ &+ \{\text{在知道 } T(\mathbf{X}) \text{ 后样本 } \mathbf{X} \text{ 尚含有的剩余信息}\}. \end{aligned}$$

故  $T(\mathbf{X})$  为充分统计量的要求归结为：要求后一项信息为0。

用统计的语言来描述，即要求  $P_\theta(\mathbf{X} \in A | T = t)$  与  $\theta$  无关，其中  $A$  为任一事件。

## 2.6.1 引言与定义

### 定义 (2.6.1)

设样本  $\mathbf{X}$  的分布族为  $\{f(x, \theta), \theta \in \Theta\}$ ,  $\Theta$  是参数空间。令  $T = T(\mathbf{X})$  为一统计量, 若在已知  $T$  的条件下, 样本  $\mathbf{X}$  的条件分布与参数  $\theta$  无关, 则称  $T(\mathbf{X})$  为  $\theta$  的 **充分统计量** (sufficient statistics)。

## 2.6.1 引言与定义

### 例 (2.6.1)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  为充分统计量。

证：

## 2.6.1 引言与定义

### 例 (2.6.1)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  为充分统计量。

证：

记  $T = T(\mathbf{X})$ ，当  $\sum_{i=1}^n x_i = t_0$  时，按定义只要证明下列条件概率与  $\theta$  无关。

## 2.6.1 引言与定义

### 例 (2.6.1)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  为充分统计量。

证：

记  $T = T(\mathbf{X})$ ，当  $\sum_{i=1}^n x_i = t_0$  时，按定义只要证明下列条件概率与  $\theta$  无关。

$$P(X_1 = x_1, \dots, X_n = x_n | T = t_0)$$

## 2.6.1 引言与定义

### 例 (2.6.1)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从0-1分布中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  为充分统计量。

证：

记  $T = T(\mathbf{X})$ ，当  $\sum_{i=1}^n x_i = t_0$  时，按定义只要证明下列条件概率与  $\theta$  无关。

$$\begin{aligned} & P(X_1 = x_1, \dots, X_n = x_n | T = t_0) \\ &= \frac{P_\theta(X_1 = x_1, \dots, X_n = x_n, T = t_0)}{P_\theta(T = t_0)} \end{aligned}$$

## 2.6.1 引言与定义

$$= \frac{P_{\theta}(X_1 = x_1, \dots, X_n = t_0 - \sum_{i=1}^{n-1} x_i)}{P_{\theta}(T = t_0)},$$

=

## 2.6.1 引言与定义

$$= \frac{P_{\theta}(X_1 = x_1, \dots, X_n = t_0 - \sum_{i=1}^{n-1} x_i)}{P_{\theta}(T = t_0)},$$

$$= \frac{P_{\theta}(X_1 = x_1)P_{\theta}(X_2 = x_2) \cdots P_{\theta}(X_{n-1} = x_{n-1})P_{\theta}(X_n = t_0 - \sum_{i=1}^{n-1} x_i)}{P_{\theta}(T = t_0)}$$

=

## 2.6.1 引言与定义

$$\begin{aligned} & P_\theta(X_1 = x_1, \dots, X_n = t_0 - \sum_{i=1}^{n-1} x_i) \\ = & \frac{P_\theta(X_1 = x_1)P_\theta(X_2 = x_2) \cdots P_\theta(X_{n-1} = x_{n-1})P_\theta(X_n = t_0 - \sum_{i=1}^{n-1} x_i)}{P_\theta(T = t_0)}, \\ = & \frac{\theta^{x_1}(1-\theta)^{1-x_1} \cdots \theta^{x_{n-1}}(1-\theta)^{1-x_{n-1}} \theta^{t_0 - \sum_{i=1}^{n-1} x_i} (1-\theta)^{1-t_0 + \sum_{i=1}^{n-1} x_i}}{\binom{n}{t_0} \theta^{t_0} (1-\theta)^{n-t_0}} \end{aligned}$$

## 2.6.1 引言与定义

$$= \frac{\theta^{\sum_{i=1}^{n-1} x_i + t_0} (1 - \theta)^{n - \sum_{i=1}^{n-1} x_i - t_0}}{\binom{n}{t_0} \theta^{t_0} (1 - \theta)^{n - t_0}}$$
$$=$$

## 2.6.1 引言与定义

$$\begin{aligned} & \theta^{\sum_{i=1}^{n-1} x_i + t_0} (1 - \theta)^{n - \sum_{i=1}^{n-1} x_i - t_0} \\ = & \frac{\theta^{\sum_{i=1}^{n-1} x_i + t_0} (1 - \theta)^{n - \sum_{i=1}^{n-1} x_i - t_0}}{\binom{n}{t_0} \theta^{t_0} (1 - \theta)^{n - t_0}} \\ = & \frac{\theta^{t_0} (1 - \theta)^{n - t_0}}{\binom{n}{t_0} \theta^{t_0} (1 - \theta)^{n - t_0}} \\ = & \end{aligned}$$

## 2.6.1 引言与定义

$$\begin{aligned} & \theta^{\sum_{i=1}^{n-1} x_i + t_0} (1 - \theta)^{n - \sum_{i=1}^{n-1} x_i - t_0} \\ = & \frac{\theta^{\sum_{i=1}^{n-1} x_i + t_0} (1 - \theta)^{n - \sum_{i=1}^{n-1} x_i - t_0}}{\binom{n}{t_0} \theta^{t_0} (1 - \theta)^{n - t_0}} \\ = & \frac{\theta^{t_0} (1 - \theta)^{n - t_0}}{\binom{n}{t_0} \theta^{t_0} (1 - \theta)^{n - t_0}} \\ = & \frac{1}{\binom{n}{t_0}}, \end{aligned}$$

## 2.6.1 引言与定义

因此有

## 2.6.1 引言与定义

因此有

$$P(X_1 = x_1, \dots, X_n = x_n | T = t_0)$$

=

## 2.6.1 引言与定义

因此有

$$P(X_1 = x_1, \dots, X_n = x_n | T = t_0) = \begin{cases} \frac{1}{\binom{n}{t_0}}, & \sum_{i=1}^n x_i = t_0, \\ 0, & \sum_{i=1}^n x_i \neq t_0. \end{cases}$$

## 2.6.1 引言与定义

因此有

$$P(X_1 = x_1, \dots, X_n = x_n | T = t_0) = \begin{cases} \frac{1}{\binom{n}{t_0}}, & \sum_{i=1}^n x_i = t_0, \\ 0, & \sum_{i=1}^n x_i \neq t_0. \end{cases}$$

上述条件概率与 $\theta$ 无关, 因此 $T(\mathbf{X}) = \sum_{i=1}^n X_i$ 为 $\theta$ 的充分统计量。  $\square$

## 2.6.1 引言与定义

### 例 (2.6.2)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从正态总体  $N(\theta, 1)$  中抽取的简单样本,

则  $T(\mathbf{X}) = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$  为  $\theta$  的充分统计量。

证:

## 2.6.1 引言与定义

### 例 (2.6.2)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从正态总体  $N(\theta, 1)$  中抽取的简单样本,

则  $T(\mathbf{X}) = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$  为  $\theta$  的充分统计量。

证:

如果直接证明在给定  $T$  时  $\mathbf{X}$  的条件概率密度与  $\theta$  无关, 则推导过程比较复杂。

## 2.6.1 引言与定义

### 例 (2.6.2)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从正态总体  $N(\theta, 1)$  中抽取的简单样本,

则  $T(\mathbf{X}) = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$  为  $\theta$  的充分统计量。

证:

如果直接证明在给定  $T$  时  $\mathbf{X}$  的条件概率密度与  $\theta$  无关, 则推导过程比较复杂。

采用如下办法: 作正交变换

## 2.6.1 引言与定义

### 例 (2.6.2)

设  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  为从正态总体  $N(\theta, 1)$  中抽取的简单样本，则  $T(\mathbf{X}) = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}$  为  $\theta$  的充分统计量。

证：

如果直接证明在给定  $T$  时  $\mathbf{X}$  的条件概率密度与  $\theta$  无关，则推导过程比较复杂。

采用如下办法：作正交变换

$$(Y_1, \dots, Y_n)^T = \mathbf{A}(X_1, \dots, X_n)^T,$$

## 2.6.1 引言与定义

其中正交阵

## 2.6.1 引言与定义

其中正交阵

$$\mathbf{A} = \begin{pmatrix} \frac{1}{\sqrt{n}} & \frac{1}{\sqrt{n}} & \cdots & \frac{1}{\sqrt{n}} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix}.$$

## 2.6.1 引言与定义

其中正交阵

$$\mathbf{A} = \begin{pmatrix} \frac{1}{\sqrt{n}} & \frac{1}{\sqrt{n}} & \cdots & \frac{1}{\sqrt{n}} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix}.$$

由代数学中的*Schmidt*正交化方法可知上述正交阵 $\mathbf{A}$ 是存在的。变换的Jacobi行列式的绝对值为 $|J| = 1$ 。

## 2.6.1 引言与定义

由正交变换 $Y = AX$ 可知

## 2.6.1 引言与定义

由正交变换  $Y = AX$  可知

$$Y_1 = \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i = \sqrt{n}\bar{X},$$

$$Y_j = \sum_{k=1}^n a_{jk} X_k, \quad j = 2, \dots, n.$$

## 2.6.1 引言与定义

由正交变换  $Y = AX$  可知

$$Y_1 = \frac{1}{\sqrt{n}} \sum_{i=1}^n X_i = \sqrt{n}\bar{X},$$
$$Y_j = \sum_{k=1}^n a_{jk} X_k, \quad j = 2, \dots, n.$$

由定理2.2.3的证明过程可知  $\sum_{i=1}^n Y_i^2 = \sum_{i=1}^n X_i^2$ ,  $Y_1, \dots, Y_n$  是相互独立的,

## 2.6.1 引言与定义

并且

## 2.6.1 引言与定义

并且

$$Y_1 \sim N(\sqrt{n}\theta, 1),$$

$$Y_i \sim N(0, 1), \quad i = 2, \dots, n.$$

## 2.6.1 引言与定义

并且

$$Y_1 \sim N(\sqrt{n}\theta, 1),$$

$$Y_i \sim N(0, 1), \quad i = 2, \dots, n.$$

显然,  $\bar{X}$  对原样本  $X$  的充分性等价于  $Y_1$  对  $(Y_1, \dots, Y_n)$  的充分性。

## 2.6.1 引言与定义

并且

$$Y_1 \sim N(\sqrt{n}\theta, 1),$$

$$Y_i \sim N(0, 1), \quad i = 2, \dots, n.$$

显然,  $\bar{X}$  对原样本  $X$  的充分性等价于  $Y_1$  对  $(Y_1, \dots, Y_n)$  的充分性。

因此, 只要证明给定  $Y_1 = y_1$  时,  $(Y_1, \dots, Y_n)$  的条件密度与  $\theta$  无关即可。

## 2.6.1 引言与定义

易见 $Y_1, \dots, Y_n$ 的联合密度为

## 2.6.1 引言与定义

易见 $Y_1, \dots, Y_n$ 的联合密度为

$$f(y_1, \dots, y_n) = (2\pi)^{-\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2 - \frac{1}{2}(y_1 - \sqrt{n}\theta)^2\right\}.$$

## 2.6.1 引言与定义

易见 $Y_1, \dots, Y_n$ 的联合密度为

$$f(y_1, \dots, y_n) = (2\pi)^{-\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2 - \frac{1}{2}(y_1 - \sqrt{n}\theta)^2\right\}.$$

$Y_1$ 的边缘密度函数为

## 2.6.1 引言与定义

易见 $Y_1, \dots, Y_n$ 的联合密度为

$$f(y_1, \dots, y_n) = (2\pi)^{-\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2 - \frac{1}{2}(y_1 - \sqrt{n}\theta)^2\right\}.$$

$Y_1$ 的边缘密度函数为

$$f(y_1, \dots, y_n) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2}(y_1 - \sqrt{n}\theta)^2\right\},$$

## 2.6.1 引言与定义

给定 $Y_1 = y_1$ 时,  $(Y_1, \dots, Y_n)$ 的条件密度是

## 2.6.1 引言与定义

给定 $Y_1 = y_1$ 时,  $(Y_1, \dots, Y_n)$ 的条件密度是

$$f(y_1, \dots, y_n | y_1) = \frac{f(y_1, \dots, y_n)}{f_{Y_1}(y_1)}$$

=

## 2.6.1 引言与定义

给定 $Y_1 = y_1$ 时,  $(Y_1, \dots, Y_n)$ 的条件密度是

$$\begin{aligned} f(y_1, \dots, y_n | y_1) &= \frac{f(y_1, \dots, y_n)}{f_{Y_1}(y_1)} \\ &= (2\pi)^{-\frac{n-1}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2\right\}, \end{aligned}$$

它与 $\theta$ 无关。

## 2.6.1 引言与定义

给定 $Y_1 = y_1$ 时,  $(Y_1, \dots, Y_n)$ 的条件密度是

$$\begin{aligned} f(y_1, \dots, y_n | y_1) &= \frac{f(y_1, \dots, y_n)}{f_{Y_1}(y_1)} \\ &= (2\pi)^{-\frac{n-1}{2}} \exp\left\{-\frac{1}{2} \sum_{i=2}^n y_i^2\right\}, \end{aligned}$$

它与 $\theta$ 无关。所以 $T(\mathbf{X}) = \bar{X}$ 是 $\theta$ 的充分统计量。 □

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

证:

在 $T = T(\mathbf{X}) = X_1$ 的条件下,  $(X_1, \dots, X_n)$ 的条件密度为

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

证:

在 $T = T(\mathbf{X}) = X_1$ 的条件下,  $(X_1, \dots, X_n)$ 的条件密度为

$$f(x_1, \dots, x_n | x_1) = \frac{f(x_1, \dots, x_n)}{f_T(x_1)} = \frac{\prod_{i=1}^n f(x_i)}{f_T(x_1)}$$

=

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

证:

在 $T = T(\mathbf{X}) = X_1$ 的条件下,  $(X_1, \dots, X_n)$ 的条件密度为

$$\begin{aligned} f(x_1, \dots, x_n | x_1) &= \frac{f(x_1, \dots, x_n)}{f_T(x_1)} = \frac{\prod_{i=1}^n f(x_i)}{f_T(x_1)} \\ &= \prod_{i=2}^n f(x_i) = \left(\frac{1}{\sqrt{2\pi}}\right)^{n-1} \exp\left\{-\frac{1}{2} \sum_{i=2}^n (x_i - \theta)^2\right\}, \end{aligned}$$

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

证:

在 $T = T(\mathbf{X}) = X_1$ 的条件下,  $(X_1, \dots, X_n)$ 的条件密度为

$$\begin{aligned} f(x_1, \dots, x_n | x_1) &= \frac{f(x_1, \dots, x_n)}{f_T(x_1)} = \frac{\prod_{i=1}^n f(x_i)}{f_T(x_1)} \\ &= \prod_{i=2}^n f(x_i) = \left(\frac{1}{\sqrt{2\pi}}\right)^{n-1} \exp\left\{-\frac{1}{2} \sum_{i=2}^n (x_i - \theta)^2\right\}, \end{aligned}$$

与 $\theta$ 有关,

## 2.6.1 引言与定义

### 例 (2.6.3)

在例2.6.2中, 令 $T(\mathbf{X}) = X_1$ , 则 $T(\mathbf{X})$ 不是充分统计量。

证:

在 $T = T(\mathbf{X}) = X_1$ 的条件下,  $(X_1, \dots, X_n)$ 的条件密度为

$$\begin{aligned} f(x_1, \dots, x_n | x_1) &= \frac{f(x_1, \dots, x_n)}{f_T(x_1)} = \frac{\prod_{i=1}^n f(x_i)}{f_T(x_1)} \\ &= \prod_{i=2}^n f(x_i) = \left(\frac{1}{\sqrt{2\pi}}\right)^{n-1} \exp\left\{-\frac{1}{2} \sum_{i=2}^n (x_i - \theta)^2\right\}, \end{aligned}$$

与 $\theta$ 有关, 因此 $T(\mathbf{X}) = X_1$ 不是充分统计量。 □

## 2.6.1 引言与定义

注：上例中 $T(\mathbf{X}) = X_1$ 不是充分统计量，这个道理是显然的。

## 2.6.1 引言与定义

注：上例中 $T(\mathbf{X}) = X_1$ 不是充分统计量，这个道理是显然的。

因为  $T(\mathbf{X})$ 只使用了一个观察值 $X_1$ ，把其余观察值 $X_2, \dots, X_n$ 全丢掉了，它当然不能把 $X_1, X_2, \dots, X_n$ 的全部信息集中起来。

## 2.6.2 充分性的判别准则——因子分解定理

2.6.1小节的例子表明，从定义出发验证一个统计量是充分的，计算太复杂。幸好有[因子分解定理](#)这一判别方法，在应用上很方便。

## 2.6.2 充分性的判别准则——因子分解定理

2.6.1小节的例子表明，从定义出发验证一个统计量是充分的，计算太复杂。幸好有因子分解定理这一判别方法，在应用上很方便。

因子分解定理是由R. A. Fisher 在20世纪20年代提出来的，它的最一般形式和严格数学证明是 Halmos 和 Savage 在1949年作出来的。

## 2.6.2 充分性的判别准则——因子分解定理

### 定理 (2.6.1 (因子分解定理))

设样本  $\mathbf{X} = (X_1, \dots, X_n)$  的概率函数  $f(\mathbf{x}, \theta)$  依赖于参数  $\theta$ ,  $T = T(\mathbf{X})$  是一个统计量, 则  $T$  为充分统计量的充要条件是  $f(\mathbf{x}, \theta)$  可以分解为

## 2.6.2 充分性的判别准则——因子分解定理

### 定理 (2.6.1 (因子分解定理))

设样本  $\mathbf{X} = (X_1, \dots, X_n)$  的概率函数  $f(\mathbf{x}, \theta)$  依赖于参数  $\theta$ ,  $T = T(\mathbf{X})$  是一个统计量, 则  $T$  为充分统计量的充要条件是  $f(\mathbf{x}, \theta)$  可以分解为

$$f(\mathbf{x}, \theta) = g(t(\mathbf{x}), \theta)h(\mathbf{x})$$

的形状。

## 2.6.2 充分性的判别准则——因子分解定理

### 定理 (2.6.1 (因子分解定理))

设样本  $\mathbf{X} = (X_1, \dots, X_n)$  的概率函数  $f(\mathbf{x}, \theta)$  依赖于参数  $\theta$ ,  $T = T(\mathbf{X})$  是一个统计量, 则  $T$  为充分统计量的充要条件是  $f(\mathbf{x}, \theta)$  可以分解为

$$f(\mathbf{x}, \theta) = g(t(\mathbf{x}), \theta)h(\mathbf{x})$$

的形状。

注意此处函数  $h(\mathbf{x}) = h(x_1, x_2, \dots, x_n)$  不依赖于  $\theta$ ,  $t(\mathbf{x})$  为  $T(\mathbf{X})$  的观察值。

## 2.6.2 充分性的判别准则——因子分解定理

这里的概率函数是指若  $X$  为连续型，则  $f(x, \theta)$  是其密度函数；

## 2.6.2 充分性的判别准则——因子分解定理

这里的概率函数是指若  $X$  为连续型，则  $f(\mathbf{x}, \theta)$  是其密度函数；

若  $X$  是离散型，则  $f(\mathbf{x}, \theta) = P_{\theta}(X_1 = x_1, \dots, X_n = x_n)$ ，即样本  $X$  的概率分布。

## 2.6.2 充分性的判别准则——因子分解定理

证:

考虑 $X$ 有密度的情形。设统计量 $T = (T_1, \dots, T_k)$ ,  $T_1, \dots, T_k$ 都是一维随机变量,  $k$ 一般是较小的自然数, 并可以找到 $n - k$ 维统计量 $Y = (Y_1, \dots, Y_{n-k})$ 使得变换

## 2.6.2 充分性的判别准则——因子分解定理

证:

考虑 $X$ 有密度的情形。设统计量 $T = (T_1, \dots, T_k)$ ,  $T_1, \dots, T_k$ 都是一维随机变量,  $k$ 一般是较小的自然数, 并可以找到 $n - k$ 维统计量 $Y = (Y_1, \dots, Y_{n-k})$ 使得变换

$$X = (X_1, \dots, X_n) \rightarrow (T, Y) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$$

是一个一一对应的变换, 且有一阶连续偏导数。

## 2.6.2 充分性的判别准则——因子分解定理

假定  $X$  的样本空间  $\mathcal{X}$  和  $T$  的样本空间  $\mathcal{J}$  皆为欧式的，即  $\mathcal{X} = \mathcal{R}^n$ ，  
 $\mathcal{J} = \mathcal{R}^k$ 。

## 2.6.2 充分性的判别准则——因子分解定理

假定  $X$  的样本空间  $\mathcal{X}$  和  $T$  的样本空间  $\mathcal{J}$  皆为欧式的, 即  $\mathcal{X} = \mathcal{R}^n$ ,  
 $\mathcal{J} = \mathcal{R}^k$ 。

由变换是一一对应可知

## 2.6.2 充分性的判别准则——因子分解定理

假定  $X$  的样本空间  $\mathcal{X}$  和  $T$  的样本空间  $\mathcal{J}$  皆为欧式的, 即  $\mathcal{X} = \mathcal{R}^n$ ,  
 $\mathcal{J} = \mathcal{R}^k$ 。

由变换是一一对应可知

$$X_i = X_i(\mathbf{T}, \mathbf{Y}) = X_i(T_1, \dots, T_k, Y_1, \dots, Y_{n-k}), \quad i = 1, 2, \dots, n;$$

$$T_j = T_j(X_1, \dots, X_n), \quad j = 1, 2, \dots, k;$$

$$Y_\ell = Y_\ell(X_1, \dots, X_n), \quad \ell = 1, 2, \dots, n - k.$$

## 2.6.2 充分性的判别准则——因子分解定理

假定 $X$ 的样本空间 $\mathcal{X}$ 和 $T$ 的样本空间 $\mathcal{J}$ 皆为欧式的, 即 $\mathcal{X} = \mathcal{R}^n$ ,  
 $\mathcal{J} = \mathcal{R}^k$ 。

由变换是一一对应可知

$$X_i = X_i(\mathbf{T}, \mathbf{Y}) = X_i(T_1, \dots, T_k, Y_1, \dots, Y_{n-k}), \quad i = 1, 2, \dots, n;$$

$$T_j = T_j(X_1, \dots, X_n), \quad j = 1, 2, \dots, k;$$

$$Y_\ell = Y_\ell(X_1, \dots, X_n), \quad \ell = 1, 2, \dots, n - k.$$

变换的Jacobi行列式的绝对值为 $|J| = \left| \frac{\partial(x_1, \dots, x_n)}{\partial(\mathbf{t}, \mathbf{y})} \right| \triangleq w(\mathbf{t}, \mathbf{y})$ , 此处 $\mathbf{t} = \mathbf{t}(x)$ 为 $T$ 的观察值,  $\mathbf{y}$ 为 $Y$ 的观察值,  $w$ 是 $(\mathbf{t}, \mathbf{y})$ 的函数。

## 2.6.2 充分性的判别准则——因子分解定理

充分性的证明：

## 2.6.2 充分性的判别准则——因子分解定理

充分性的证明：

已知因子分解定理成立，即

$$f(\mathbf{x}, \theta) = g(\mathbf{t}(\mathbf{x}), \theta)h(\mathbf{x}).$$

## 2.6.2 充分性的判别准则——因子分解定理

故 $(\mathbf{T}, \mathbf{Y}) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$ 的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

故  $(\mathbf{T}, \mathbf{Y}) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$  的联合密度为

$$\begin{aligned} k(\mathbf{t}, \mathbf{y}; \theta) &= f(\mathbf{x}(\mathbf{t}, \mathbf{y}), \theta) |J| = g(\mathbf{t}(\mathbf{x}), \theta) h(\mathbf{x}) w(\mathbf{t}, \mathbf{y}) \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

故  $(\mathbf{T}, \mathbf{Y}) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$  的联合密度为

$$\begin{aligned}k(\mathbf{t}, \mathbf{y}; \theta) &= f(\mathbf{x}(\mathbf{t}, \mathbf{y}), \theta) |J| = g(\mathbf{t}(\mathbf{x}), \theta) h(\mathbf{x}) w(\mathbf{t}, \mathbf{y}) \\ &= g(\mathbf{t}, \theta) \underbrace{h(x_1(\mathbf{t}, \mathbf{y}), \dots, x_n(\mathbf{t}, \mathbf{y}))}_{\text{wavy line}} w(\mathbf{t}, \mathbf{y}) \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

故  $(\mathbf{T}, \mathbf{Y}) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$  的联合密度为

$$\begin{aligned}k(\mathbf{t}, \mathbf{y}; \theta) &= f(\mathbf{x}(\mathbf{t}, \mathbf{y}), \theta) |J| = g(\mathbf{t}(\mathbf{x}), \theta) h(\mathbf{x}) w(\mathbf{t}, \mathbf{y}) \\&= g(\mathbf{t}, \theta) \underbrace{h(x_1(\mathbf{t}, \mathbf{y}), \dots, x_n(\mathbf{t}, \mathbf{y}))}_{w(\mathbf{t}, \mathbf{y})} \\&= g(\mathbf{t}, \theta) \underbrace{\mu(\mathbf{t}, \mathbf{y})}_{w(\mathbf{t}, \mathbf{y})},\end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

故 $(\mathbf{T}, \mathbf{Y}) = (T_1, \dots, T_k, Y_1, \dots, Y_{n-k})$ 的联合密度为

$$\begin{aligned}k(\mathbf{t}, \mathbf{y}; \theta) &= f(\mathbf{x}(\mathbf{t}, \mathbf{y}), \theta) |J| = g(\mathbf{t}(\mathbf{x}), \theta) h(\mathbf{x}) w(\mathbf{t}, \mathbf{y}) \\ &= g(\mathbf{t}, \theta) \underbrace{h(x_1(\mathbf{t}, \mathbf{y}), \dots, x_n(\mathbf{t}, \mathbf{y}))}_{\mu(\mathbf{t}, \mathbf{y})} w(\mathbf{t}, \mathbf{y}) \\ &= g(\mathbf{t}, \theta) \underbrace{\mu(\mathbf{t}, \mathbf{y})}_{\mu(\mathbf{t}, \mathbf{y})},\end{aligned}$$

此处 $\mu(\mathbf{t}, \mathbf{y}) = h(x_1(\mathbf{t}, \mathbf{y}), \dots, x_n(\mathbf{t}, \mathbf{y})) w(\mathbf{t}, \mathbf{y})$ 与 $\theta$ 无关。

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

$$V(\mathbf{t}; \theta) = \int_{\mathcal{R}^{n-k}} k(\mathbf{t}, \mathbf{y}; \theta) d\mathbf{y} = g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}.$$

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

$$V(\mathbf{t}; \theta) = \int_{\mathcal{R}^{n-k}} k(\mathbf{t}, \mathbf{y}; \theta) d\mathbf{y} = g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}.$$

故给定 $T = t$ 时 $Y$ 的条件密度为

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

$$V(\mathbf{t}; \theta) = \int_{\mathcal{R}^{n-k}} k(\mathbf{t}, \mathbf{y}; \theta) d\mathbf{y} = g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}.$$

故给定 $T = \mathbf{t}$ 时 $Y$ 的条件密度为

$$\begin{aligned} q(\mathbf{y}|\mathbf{t}) &= \frac{k(\mathbf{t}, \mathbf{y}; \theta)}{V(\mathbf{t}; \theta)} = \frac{g(\mathbf{t}, \theta)\mu(\mathbf{t}, \mathbf{y})}{g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}} \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

$$V(\mathbf{t}; \theta) = \int_{\mathcal{R}^{n-k}} k(\mathbf{t}, \mathbf{y}; \theta) d\mathbf{y} = g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}.$$

故给定 $T = \mathbf{t}$ 时 $\mathbf{Y}$ 的条件密度为

$$\begin{aligned} q(\mathbf{y}|\mathbf{t}) &= \frac{k(\mathbf{t}, \mathbf{y}; \theta)}{V(\mathbf{t}; \theta)} = \frac{g(\mathbf{t}, \theta) \mu(\mathbf{t}, \mathbf{y})}{g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}} \\ &= \frac{\mu(\mathbf{t}, \mathbf{y})}{\int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}}, \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

$T = T(\mathbf{X})$ 的边缘密度为

$$V(\mathbf{t}; \theta) = \int_{\mathcal{R}^{n-k}} k(\mathbf{t}, \mathbf{y}; \theta) d\mathbf{y} = g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}.$$

故给定 $T = \mathbf{t}$ 时 $Y$ 的条件密度为

$$\begin{aligned} q(\mathbf{y}|\mathbf{t}) &= \frac{k(\mathbf{t}, \mathbf{y}; \theta)}{V(\mathbf{t}; \theta)} = \frac{g(\mathbf{t}, \theta) \mu(\mathbf{t}, \mathbf{y})}{g(\mathbf{t}, \theta) \int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}} \\ &= \frac{\mu(\mathbf{t}, \mathbf{y})}{\int_{\mathcal{R}^{n-k}} \mu(\mathbf{t}, \mathbf{y}) d\mathbf{y}}, \end{aligned}$$

与 $\theta$ 无关, 故 $T = T(\mathbf{X})$ 为充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

必要性的证明：

## 2.6.2 充分性的判别准则——因子分解定理

必要性的证明：

此时已知 $T = T(\mathbf{X})$ 为充分统计量，因此给定 $T = t$ 时 $Y$ 的条件密度 $q(\mathbf{y}|t)$ 与 $\theta$ 无关。

## 2.6.2 充分性的判别准则——因子分解定理

必要性的证明：

此时已知 $T = T(\mathbf{X})$ 为充分统计量，因此给定 $T = t$ 时 $Y$ 的条件密度 $q(\mathbf{y}|t)$ 与 $\theta$ 无关。 $(T, Y)$ 的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

必要性的证明：

此时已知 $T = T(\mathbf{X})$ 为充分统计量，因此给定 $T = t$ 时 $Y$ 的条件密度 $q(\mathbf{y}|t)$ 与 $\theta$ 无关。 $(T, Y)$ 的联合密度为

$$k(\mathbf{t}, \mathbf{y}; \theta) = q(\mathbf{y}|t)g(\mathbf{t}, \theta).$$

## 2.6.2 充分性的判别准则——因子分解定理

故通过前面的一一对应变换可知 $(X_1, X_2, \dots, X_n)$ 的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

故通过前面的一一对应变换可知 $(X_1, X_2, \dots, X_n)$ 的联合密度为

$$f(\mathbf{x}, \theta) = k(\mathbf{t}, \mathbf{y}; \theta) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right|$$
$$=$$

## 2.6.2 充分性的判别准则——因子分解定理

故通过前面的一一对应变换可知 $(X_1, X_2, \dots, X_n)$ 的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= k(\mathbf{t}, \mathbf{y}; \theta) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right| \\ &= \underbrace{g(\mathbf{t}, \theta)q(\mathbf{y}|\mathbf{t})}_{\text{wavy line}} \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right| \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

故通过前面的一一对应变换可知 $(X_1, X_2, \dots, X_n)$ 的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= k(\mathbf{t}, \mathbf{y}; \theta) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right| \\ &= \underbrace{g(\mathbf{t}, \theta) q(\mathbf{y}|\mathbf{t})}_{\text{wavy line}} \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right| \\ &= g(\mathbf{t}, \theta) \cdot \underbrace{h(\mathbf{x})}_{\text{wavy line}}. \end{aligned} \quad (3)$$

## 2.6.2 充分性的判别准则——因子分解定理

将

$$\mathbf{t} = (t_1(x_1, \dots, x_n), \dots, t_k(x_1, \dots, x_n))$$

$$\mathbf{y} = (y_1(x_1, \dots, x_n), \dots, y_{n-k}(x_1, \dots, x_n))$$

代入式 (3) 中  $q(\mathbf{y}|\mathbf{t}) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right|$  的表达式中, 可见它是  $x_1, \dots, x_n$  的函数。

## 2.6.2 充分性的判别准则——因子分解定理

用 $h(\mathbf{x})$ 表示, 即

$$h(\mathbf{x}) = q(\mathbf{x}|\mathbf{t}) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right|.$$

## 2.6.2 充分性的判别准则——因子分解定理

用 $h(\mathbf{x})$ 表示, 即

$$h(\mathbf{x}) = q(\mathbf{x}|\mathbf{t}) \left| \frac{\partial(\mathbf{t}, \mathbf{y})}{\partial(x_1, \dots, x_n)} \right|.$$

显而易见,  $h(\mathbf{x})$ 与 $\theta$ 无关。因此由式(3)可知因子分解定理成立。  $\square$

## 2.6.2 充分性的判别准则——因子分解定理

### 推论 (2.6.1)

设  $T = T(\mathbf{X})$  为  $\theta$  的充分统计量,  $S = \varphi(\mathbf{T})$  是单值可逆函数, 则  $S = \varphi(\mathbf{T})$  也是  $\theta$  的充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

### 推论 (2.6.1)

设  $T = T(\mathbf{X})$  为  $\theta$  的充分统计量,  $S = \varphi(T)$  是单值可逆函数, 则  $S = \varphi(T)$  也是  $\theta$  的充分统计量。

**证** 由于  $S = \varphi(T)$  为单值可逆函数, 故

$$\{\mathbf{X} : T(\mathbf{X}) = t_0\} = \{\mathbf{X} : S = \varphi(T) = s_0\}$$

表示相同的事件。

## 2.6.2 充分性的判别准则——因子分解定理

故对任一事件 $A$ ,

## 2.6.2 充分性的判别准则——因子分解定理

故对任一事件 $A$ ,

$$P(A|\mathbf{T} = \mathbf{t}_0) = P(A|S = s_0)$$

与 $\theta$ 无关, 按充分统计量的定义2.6.1可知 $S = \varphi(\mathbf{T})$ 也是充分统计量。 □

## 2.6.2 充分性的判别准则——因子分解定理

利用因子分解定理也不难证明推论2.6.1。

## 2.6.2 充分性的判别准则——因子分解定理

利用因子分解定理也不难证明推论2.6.1。

证明如下：

## 2.6.2 充分性的判别准则——因子分解定理

利用因子分解定理也不难证明推论2.6.1。

证明如下：

已知 $T = T(\mathbf{X})$ 是 $\theta$ 的充分统计量，由因子分解定理有

## 2.6.2 充分性的判别准则——因子分解定理

利用因子分解定理也不难证明推论2.6.1。

证明如下：

已知 $T = T(\mathbf{X})$ 是 $\theta$ 的充分统计量，由因子分解定理有

$$f(\mathbf{x}; \theta) = g(\mathbf{t}(\mathbf{x}); \theta)h(\mathbf{x}),$$

这里 $h(\mathbf{x})$ 与 $\theta$ 无关。

## 2.6.2 充分性的判别准则——因子分解定理

又因为 $S = \varphi(\mathbf{T})$ 是单值可逆函数，则 $S(\mathbf{X}) = \varphi(\mathbf{T}(\mathbf{X}))$ 是样本 $\mathbf{X}$ 统计量； $\mathbf{T}(\mathbf{X}) = \varphi^{-1}(S)$ ， $|\frac{\partial t}{\partial s}|$ 是统计量 $s$ 的函数。经计算

## 2.6.2 充分性的判别准则——因子分解定理

又因为 $S = \varphi(\mathbf{T})$ 是单值可逆函数，则 $S(\mathbf{X}) = \varphi(\mathbf{T}(\mathbf{X}))$ 是样本 $\mathbf{X}$ 统计量； $\mathbf{T}(\mathbf{X}) = \varphi^{-1}(S)$ ， $\left| \frac{\partial \mathbf{t}}{\partial s} \right|$ 是统计量 $s$ 的函数。经计算

$$\begin{aligned} f(\mathbf{x}; \theta) &= g(\mathbf{t}(\mathbf{x}); \theta) h(\mathbf{x}) \\ &= \underbrace{g(\varphi^{-1}(s); \theta)}_{\left| \frac{\partial \mathbf{t}}{\partial s} \right|} h(\mathbf{x}) \\ &= \underbrace{q(s(\mathbf{x}); \theta)}_{\left| \frac{\partial \mathbf{t}}{\partial s} \right|} h(\mathbf{x}) \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

又因为 $S = \varphi(\mathbf{T})$ 是单值可逆函数，则 $S(\mathbf{X}) = \varphi(\mathbf{T}(\mathbf{X}))$ 是样本 $\mathbf{X}$ 统计量； $\mathbf{T}(\mathbf{X}) = \varphi^{-1}(S)$ ， $\left| \frac{\partial \mathbf{t}}{\partial s} \right|$ 是统计量 $s$ 的函数。经计算

$$\begin{aligned} f(\mathbf{x}; \theta) &= g(\mathbf{t}(\mathbf{x}); \theta) h(\mathbf{x}) \\ &= \underbrace{g(\varphi^{-1}(s); \theta) \left| \frac{\partial \mathbf{t}}{\partial s} \right|}_{q(s(\mathbf{x}); \theta)} h(\mathbf{x}) \\ &= \underbrace{q(s(\mathbf{x}); \theta)} h(\mathbf{x}) \end{aligned}$$

这里 $q(s(\mathbf{x}); \theta) = g(\varphi^{-1}(s(\mathbf{x})); \theta) \left| \frac{\partial \mathbf{t}}{\partial s} \right|$ 是统计量 $s(\mathbf{x})$ 和参数 $\theta$ 的函数， $h(\mathbf{x})$ 是 $\mathbf{x}$ 的函数与 $\theta$ 无关，故由因子分解定理， $S = \varphi(\mathbf{T})$ 也是 $\theta$ 的充分统计量。



## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.4)

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，令  $\theta = (a, \sigma^2)$ ，则  $(\bar{X}, S^2)$  为  $\theta$  的充分统计量，此处  $\bar{X}$ ,  $S^2$  分别为样本均值和样本方差。

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.4)

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，令  $\theta = (a, \sigma^2)$ ，则  $(\bar{X}, S^2)$  为  $\theta$  的充分统计量，此处  $\bar{X}, S^2$  分别为样本均值和样本方差。

证：

样本  $\mathbf{X}$  的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.4)

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，令  $\boldsymbol{\theta} = (a, \sigma^2)$ ，则  $(\bar{X}, S^2)$  为  $\boldsymbol{\theta}$  的充分统计量，此处  $\bar{X}$ ,  $S^2$  分别为样本均值和样本方差。

证：

样本  $\mathbf{X}$  的联合密度为

$$f(\mathbf{x}; \boldsymbol{\theta}) = \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a)^2 \right\}$$

=

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.4)

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，令  $\boldsymbol{\theta} = (a, \sigma^2)$ ，则  $(\bar{X}, S^2)$  为  $\boldsymbol{\theta}$  的充分统计量，此处  $\bar{X}, S^2$  分别为样本均值和样本方差。

证：

样本  $\mathbf{X}$  的联合密度为

$$\begin{aligned} f(\mathbf{x}; \boldsymbol{\theta}) &= \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a)^2 \right\} \\ &= \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp \left\{ -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n x_i^2 - 2a \sum_{i=1}^n x_i + na^2 \right) \right\} \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

$$= g(t(\mathbf{x}); \boldsymbol{\theta})h(\mathbf{x}).$$

## 2.6.2 充分性的判别准则——因子分解定理

$$= g(t(\mathbf{x}); \boldsymbol{\theta})h(\mathbf{x}).$$

此处  $g(t(\mathbf{x}); \boldsymbol{\theta}) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left\{-\frac{1}{2\sigma^2}\left(\sum_{i=1}^n x_i^2 - 2a\sum_{i=1}^n x_i + na^2\right)\right\}$ ,

$h(\mathbf{x}) = 1$ , 由因子分解定理可知  $T(\mathbf{X}) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2\right)$  为  $\boldsymbol{\theta}$  的充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

$$= g(t(\mathbf{x}); \boldsymbol{\theta})h(\mathbf{x}).$$

此处  $g(t(\mathbf{x}); \boldsymbol{\theta}) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left\{-\frac{1}{2\sigma^2}\left(\sum_{i=1}^n x_i^2 - 2a\sum_{i=1}^n x_i + na^2\right)\right\}$ ,

$h(\mathbf{x}) = 1$ , 由因子分解定理可知  $T(\mathbf{X}) = \left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2\right)$  为  $\boldsymbol{\theta}$  的充分统计量。

由于  $\left(\sum_{i=1}^n X_i, \sum_{i=1}^n X_i^2\right)$  与  $(\bar{X}, S^2)$  为一一对应的变换, 由推论2.6.1可知  $(\bar{X}, S^2)$  也是  $\boldsymbol{\theta}$  的充分统计量。 □

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.5)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从总体  $B(1, \theta)$  中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  是  $\theta$  的充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.5)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从总体  $B(1, \theta)$  中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  是  $\theta$  的充分统计量。

证：

样本  $\mathbf{X}$  的联合分布是

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.5)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从总体  $B(1, \theta)$  中抽取的简单样本，  
则  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  是  $\theta$  的充分统计量。

证：

样本  $\mathbf{X}$  的联合分布是

$$\begin{aligned} f(\mathbf{x}, \theta) &= P_{\theta}(X_1 = x_1, \dots, X_n = x_n) \\ &= \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i} = g(t(\mathbf{x}), \theta)h(\mathbf{x}). \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

其中  $g(t(\mathbf{x}), \theta) = \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}$ ,  $h(\mathbf{x}) = 1$ , 由因子分解定理可知  $T(\mathbf{X}) = \sum_{i=1}^n X_i$  为  $\theta$  的充分统计量。 □

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.6)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从均匀分布  $U(0, \theta)$  中抽取的简单样本，  
则  $T(\mathbf{X}) = X_{(n)} = \max\{X_1, \dots, X_n\}$  为  $\theta$  的充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

证

样本  $X$  的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

证

样本  $X$  的联合密度为

$$f(\mathbf{x}, \theta) = \frac{1}{\theta^n} I_{\{0 < x_{(1)} \leq \dots \leq x_{(n)} < \theta\}}$$

=

## 2.6.2 充分性的判别准则——因子分解定理

证

样本  $X$  的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= \frac{1}{\theta^n} I_{\{0 < x_{(1)} \leq \dots \leq x_{(n)} < \theta\}} \\ &= \frac{1}{\theta^n} I_{\{x_{(n-1)} \leq x_{(n)} < \theta\}} I_{\{0 < x_{(1)} \leq \dots \leq x_{(n-1)}\}} = g(t(\mathbf{x}), \theta) h(\mathbf{x}), \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

证

样本  $X$  的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= \frac{1}{\theta^n} I_{\{0 < x_{(1)} \leq \dots \leq x_{(n)} < \theta\}} \\ &= \frac{1}{\theta^n} I_{\{x_{(n-1)} \leq x_{(n)} < \theta\}} I_{\{0 < x_{(1)} \leq \dots \leq x_{(n-1)}\}} = g(t(\mathbf{x}), \theta) h(\mathbf{x}), \end{aligned}$$

其中  $g(t(\mathbf{x}), \theta) = \frac{1}{\theta^n} I_{\{x_{(n-1)} \leq x_{(n)} < \theta\}}$ ,  $h(\mathbf{x}) = I_{\{0 < x_{(1)} \leq \dots \leq x_{(n-1)}\}}$  与  $\theta$  无关。

由因子分解定理可知  $T(\mathbf{X}) = X_{(n)}$  为  $\theta$  的充分统计量。 □

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.7)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从均匀分布  $U(\theta - \frac{1}{2}, \theta + \frac{1}{2})$  中抽取的简单样本，其中  $-\infty < \theta < \infty$ ， $\theta$  是区间  $[\theta - \frac{1}{2}, \theta + \frac{1}{2}]$  的中点，也是总体分布的均值。利用因子分解定理，验证样本均值  $\bar{X}$  不是充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.7)

设  $\mathbf{X} = (X_1, \dots, X_n)$  为从均匀分布  $U(\theta - \frac{1}{2}, \theta + \frac{1}{2})$  中抽取的简单样本，其中  $-\infty < \theta < \infty$ ， $\theta$  是区间  $[\theta - \frac{1}{2}, \theta + \frac{1}{2}]$  的中点，也是总体分布的均值。利用因子分解定理，验证样本均值  $\bar{X}$  不是充分统计量。

证

记  $X_{(1)} = \min\{X_1, \dots, X_n\}$ ， $X_{(n)} = \max\{X_1, \dots, X_n\}$ ，

$T(\mathbf{X}) = (X_{(1)}, X_{(n)})$ 。

## 2.6.2 充分性的判别准则——因子分解定理

样本  $\mathbf{X}$  的联合密度为

$$f(\mathbf{x}, \theta) = \begin{cases} 1, & \theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}, \\ 0, & \text{其他} \end{cases}$$

=

## 2.6.2 充分性的判别准则——因子分解定理

样本  $\mathbf{X}$  的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= \begin{cases} 1, & \theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}, \\ 0, & \text{其他} \end{cases} \\ &= I_{\{\theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}\}} \\ &= g(t(\mathbf{x}), \theta)h(\mathbf{x}). \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

样本  $\mathbf{X}$  的联合密度为

$$\begin{aligned} f(\mathbf{x}, \theta) &= \begin{cases} 1, & \theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}, \\ 0, & \text{其他} \end{cases} \\ &= I_{\{\theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}\}} \\ &= g(t(\mathbf{x}), \theta) h(\mathbf{x}). \end{aligned}$$

其中  $g(t(\mathbf{x}), \theta) = I_{\{\theta - \frac{1}{2} < x_{(1)} \leq x_{(n)} < \theta + \frac{1}{2}\}}$ ,  $h(\mathbf{x}) = 1$ , 因此由因子分解定理可知  $T(\mathbf{X})$  是充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

又因为该样本的概率密度函数 $f(x; \theta)$ 不能表示成 $g(\bar{x}; \theta)h(\mathbf{x})$ 的形式，因此 $\bar{X}$ 不是充分统计量。 □

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.8)

若  $\mathbf{X} = (X_1, \dots, X_n)$  为从指数族 (1.5.1)

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

中抽取的简单样本，其中  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)$ ，求  $\boldsymbol{\theta}$  的充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

**解:**

## 2.6.2 充分性的判别准则——因子分解定理

**解：**

样本  $X$  的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

解:

样本  $X$  的联合密度为

$$f(\mathbf{x}; \boldsymbol{\theta}) = \prod_{j=1}^n f(x_j; \boldsymbol{\theta}) = \prod_{j=1}^n [C(\boldsymbol{\theta}) \exp \{Q_i(\boldsymbol{\theta})T_i(x_j)\} h(x_j)]$$

=

## 2.6.2 充分性的判别准则——因子分解定理

解:

样本  $X$  的联合密度为

$$\begin{aligned} f(\mathbf{x}; \boldsymbol{\theta}) &= \prod_{j=1}^n f(x_j; \boldsymbol{\theta}) = \prod_{j=1}^n [C(\boldsymbol{\theta}) \exp \{Q_i(\boldsymbol{\theta}) T_i(x_j)\} h(x_j)] \\ &= [C(\boldsymbol{\theta})]^n \exp \left\{ \sum_{i=1}^k Q_i(\boldsymbol{\theta}) \sum_{j=1}^n T_i(x_j) \right\} \prod_{j=1}^n h(x_j) \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

解:

样本  $X$  的联合密度为

$$\begin{aligned} f(\mathbf{x}; \boldsymbol{\theta}) &= \prod_{j=1}^n f(x_j; \boldsymbol{\theta}) = \prod_{j=1}^n [C(\boldsymbol{\theta}) \exp \{Q_i(\boldsymbol{\theta}) T_i(x_j)\} h(x_j)] \\ &= [C(\boldsymbol{\theta})]^n \exp \left\{ \sum_{i=1}^k Q_i(\boldsymbol{\theta}) \sum_{j=1}^n T_i(x_j) \right\} \prod_{j=1}^n h(x_j) \\ &= \tilde{C}(\boldsymbol{\theta}) \exp \left\{ \sum_{i=1}^k Q_i(\boldsymbol{\theta}) \tilde{T}_i(\mathbf{x}) \right\} \tilde{h}(\mathbf{x}) = g(\tilde{\mathbf{T}}(\mathbf{x}), \boldsymbol{\theta}) \tilde{h}(\mathbf{x}), \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

其中

$$\tilde{T}_i(\mathbf{x}) = \sum_{j=1}^n T_i(x_j), \quad i = 1, \dots, k,$$

## 2.6.2 充分性的判别准则——因子分解定理

其中

$$\tilde{T}_i(\mathbf{x}) = \sum_{j=1}^n T_i(x_j), \quad i = 1, \dots, k,$$

$$\tilde{C}(\boldsymbol{\theta}) = [C(\boldsymbol{\theta})]^n, \quad \tilde{h}(\mathbf{x}) = \prod_{j=1}^n h(x_j),$$

## 2.6.2 充分性的判别准则——因子分解定理

其中

$$\tilde{T}_i(\mathbf{x}) = \sum_{j=1}^n T_i(x_j), \quad i = 1, \dots, k,$$

$$\tilde{C}(\boldsymbol{\theta}) = [C(\boldsymbol{\theta})]^n, \quad \tilde{h}(\mathbf{x}) = \prod_{j=1}^n h(x_j),$$

$$g(\tilde{\mathbf{T}}(\mathbf{x}), \boldsymbol{\theta}) = \tilde{C}(\boldsymbol{\theta}) \exp \left\{ \sum_{i=1}^k Q_i(\boldsymbol{\theta}) \tilde{T}_i(\mathbf{x}) \right\}.$$

## 2.6.2 充分性的判别准则——因子分解定理

其中

$$\tilde{T}_i(\mathbf{x}) = \sum_{j=1}^n T_i(x_j), \quad i = 1, \dots, k,$$

$$\tilde{C}(\boldsymbol{\theta}) = [C(\boldsymbol{\theta})]^n, \quad \tilde{h}(\mathbf{x}) = \prod_{j=1}^n h(x_j),$$

$$g(\tilde{\mathbf{T}}(\mathbf{x}), \boldsymbol{\theta}) = \tilde{C}(\boldsymbol{\theta}) \exp \left\{ \sum_{i=1}^k Q_i(\boldsymbol{\theta}) \tilde{T}_i(\mathbf{x}) \right\}.$$

由因子分解定理立得 $\tilde{\mathbf{T}}(\mathbf{x}) = (\tilde{T}_1(\mathbf{x}), \dots, \tilde{T}_k(\mathbf{x}))$ 为 $\boldsymbol{\theta}$ 的充分统计量。  $\square$

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.9)

次序统计量的充分性。

## 2.6.2 充分性的判别准则——因子分解定理

### 例 (2.6.9)

次序统计量的充分性。

设  $\mathcal{F} = \{f(x, \theta) : \theta \in \Theta\}$ ,  $\mathbf{X} = (X_1, \dots, X_n)$  是从分布族  $\mathcal{F}$  中抽取的简单样本, 则次序统计量

$$T(\mathbf{X}) = (X_{(1)}, \dots, X_{(n)})$$

是充分统计量。

## 2.6.2 充分性的判别准则——因子分解定理

**证：**

特别地，若总体  $X$  是连续型的，由定理2.4.1可知  $X = (X_1, \dots, X_n)$  的联合密度为

## 2.6.2 充分性的判别准则——因子分解定理

证:

特别地, 若总体  $X$  是连续型的, 由定理2.4.1可知  $X = (X_1, \dots, X_n)$  的联合密度为

$$f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

=

## 2.6.2 充分性的判别准则——因子分解定理

证:

特别地, 若总体  $X$  是连续型的, 由定理2.4.1可知  $X = (X_1, \dots, X_n)$  的联合密度为

$$\begin{aligned} f(x_1, \dots, x_n; \theta) &= \prod_{i=1}^n f(x_i; \theta) \\ &= \frac{1}{n!} f(x_{(1)}, \dots, x_{(n)}; \theta) \\ &= \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

证:

特别地, 若总体  $X$  是连续型的, 由定理2.4.1可知  $\mathbf{X} = (X_1, \dots, X_n)$  的联合密度为

$$\begin{aligned} f(x_1, \dots, x_n; \theta) &= \prod_{i=1}^n f(x_i; \theta) \\ &= \frac{1}{n!} f(x_{(1)}, \dots, x_{(n)}; \theta) \\ &= g(T(\mathbf{x}); \theta) h(\mathbf{x}), \end{aligned}$$

## 2.6.2 充分性的判别准则——因子分解定理

证:

特别地, 若总体  $X$  是连续型的, 由定理2.4.1可知  $\mathbf{X} = (X_1, \dots, X_n)$  的联合密度为

$$\begin{aligned} f(x_1, \dots, x_n; \theta) &= \prod_{i=1}^n f(x_i; \theta) \\ &= \frac{1}{n!} f(x_{(1)}, \dots, x_{(n)}; \theta) \\ &= g(T(\mathbf{x}); \theta) h(\mathbf{x}), \end{aligned}$$

其中  $h(\mathbf{x}) = 1$ ,  $g(T(\mathbf{x}); \theta) = \frac{1}{n!} f(x_{(1)}, \dots, x_{(n)}; \theta)$ 。由因子分解定理可知  $T(\mathbf{X}) = (X_{(1)}, \dots, X_{(n)})$  为充分统计量。 □