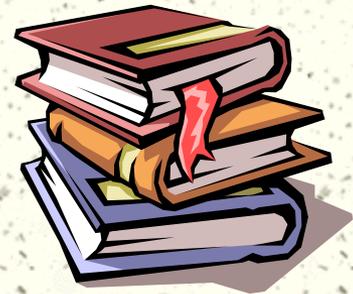


第五章 贝叶斯决策



第五章 贝叶斯决策

第一节 贝叶斯决策问题

第二节 后验风险决策

第三节 常用损失函数下的贝叶斯估计

第四节 抽样信息期望值

第五节 最佳样本量的确定

第六节 二行动线性决策问题的EVPI

第一节 贝叶斯决策问题

一、决策问题分类

(1)仅使用先验信息的决策问题称为无数据(或无样本信息)的决策问题;

(2)仅使用抽样信息的决策问题称为统计决策问题;

(3)先验信息和抽样信息都使用的决策问题称为贝叶斯决策问题.

二、贝叶斯决策问题

先验信息和抽样信息都用的决策问题称为贝叶斯决策问题。若以下条件已知，则我们认为一个贝叶斯决策问题给定了。

$$(1) \quad X \sim p(x|\theta), \theta \in \Theta$$

$$(2) \quad \theta \sim \pi(\theta)$$

$$(3) \quad A = \{a\}$$

(4) 定义在 $\Theta \times A$ 上的二元函数 $L(\theta, a)$ 称为损失函数

三、贝叶斯决策的优缺点

1. 优点主要表现在：

- (1) 贝叶斯决策充分利用各种信息,使决策结果更加科学化;
- (2) 能对调查结果的可能性加以数量化的评价;
- (3) 贝叶斯决策巧妙地将调查结果和先验知识有机地结合起来;
- (4) 贝叶斯决策过程可以不断地使用,使决策结果逐步完善.

2. 缺点：

- (1) 贝叶斯决策所需要的数据多,分析计算也比较复杂,如果解决的问题比较复杂时,这个矛盾就更加突出;
- (2) 在决策的过程中,有些数据必须要使用主观概率,有些人不是很相信,这也妨碍了贝叶斯决策方法的推广和使用. [Q](#)

第二节 后验风险决策

1. 后验风险函数

我们把损失函数 $L(\theta, a)$ 对后验分布 $\pi(\theta|x)$ 的期望称为后验风险,记 $R(a|x)$,即

$$R(a|x) = E^{\theta|x} [L(\theta, a)] = \begin{cases} \sum_i L(\theta_i, a) \pi(\theta_i|x) \\ \int_{\Theta} L(\theta, a) \pi(\theta|x) d\theta \end{cases}$$

后验风险就是用后验分布计算的平均损失.

11

2. 决策函数

定义5.1 在给定的贝叶斯决策问题中,从样本空间 $\mathcal{X} = \{x = (x_1, x_2, \dots, x_n)\}$ 到行动集A上的一个映照 $\delta(x)$ 称为该决策问题的一个决策函数, $D = \{\delta(x)\}$ 表示所有从样本空间 \mathcal{X} 到A上的决策函数组成的类,称为决策函数类.

在贝叶斯决策中我们面临的是决策函数类D,要在D中选择决策函数 $\delta(x)$,使其风险最小.

例题分析

3. 后验风险准则

定义 在给定的贝叶斯决策问题中 $D = \{\delta(x)\}$ 是其决策函数类, 则称

$$R(\delta|x) = E^{\theta|x}[L(\theta, \delta(x))], x \in \mathcal{X}, \theta \in \Theta$$

为决策函数 $\delta = \delta(x)$ 的后验风险. 假如在决策函数类中存在这样的决策函数 $\delta' = \delta'(x)$, 它在 D 中有最小的风险, 即

$$R(\delta'|x) = \min_{\delta \in D} R(\delta|x)$$

则称 $\delta' = \delta'(x)$ 为后验风险准则下的最优决策函数, 或称贝叶斯决策, 或贝叶斯解, 或**贝叶斯估计**。

注: (1) 定义中的条件: 给定的贝叶斯决策问题

(2) 定义中的先验分布允许是广义的.

例1 设 $x = (x_1, \dots, x_n)$ 是来自正态分布 $N(\theta, 1)$ 的一个样本。又设参数 θ 的先验分布为共轭先验分布 $N(0, \tau^2)$, 其中 τ^2 已知. 而损失函数为0-1损失函数

$$L(\theta, \delta) = \begin{cases} 0, & |\delta - \theta| \leq \varepsilon \\ 1, & |\delta - \theta| > \varepsilon \end{cases}$$

试求参数 θ 的贝叶斯估计。

解: 分三步求解:

(1) 求参数 θ 的后验分布 $\pi(\theta | x) = N\left(\frac{\sum x_i}{n + \tau^{-2}}, (n + \tau^{-2})^{-1}\right)$

(2) 对于任意一个决策函数 $\delta = \delta(x)$ 计算后验风险函数:

$$\begin{aligned} R(\delta | x) &= \int_{-\infty}^{+\infty} L(\theta, \delta) \pi(\theta | x) d\theta = \int_{|\delta - \theta| > \varepsilon} \pi(\theta | x) d\theta \\ &= P^{\theta|x}(|\delta - \theta| > \varepsilon) = 1 - P^{\theta|x}(|\delta - \theta| \leq \varepsilon) \end{aligned}$$

(3) 求出使得上述风险函数达到最小时的决策函数:

$$\delta_{\tau}(x) = \frac{\sum x_i}{(n + \tau^{-2})}$$

例2 在市场占有率 θ 的估计问题中, 已知损失函数为:

$$L(\theta, \delta) = \begin{cases} 2(\delta - \theta), & 0 < \theta < \delta \\ \theta - \delta, & \delta \leq \theta \leq 1 \end{cases}$$

药厂厂长对市场占有率 θ 无任何先验信息, 另外在市场调查中, 在 n 个购买止痛剂的顾客中有 x 人买了新药, 试在后验风险准则下对 θ 作出贝叶斯估计。

解:(1)求参数 θ 的后验分布: 结果为 $\text{Be}(x+1, n-x+1)$

(2) $\forall \delta = \delta(x)$ 计算风险函数

$$R(\delta | x) = \int_0^1 L(\theta, \delta) \pi(\theta | x) d\theta = 2 \int_0^\delta (\delta - \theta) \pi(\theta | x) d\theta +$$

$$\int_\delta^1 (\theta - \delta) \pi(\theta | x) d\theta = 3 \int_0^\delta (\delta - \theta) \pi(\theta | x) d\theta + E(\theta | x) - \delta$$

(3)求最优行动使上述风险函数达到最小. 令:

$$\frac{dR(\delta | x)}{d\delta} = 3 \int_0^\delta \pi(\theta | x) d\theta - 1 = 0 \quad \text{则得: } \int_0^\delta \pi(\theta | x) d\theta = \frac{1}{3}$$

(4)数值计算:

例3 如何判断一个样本是来自密度函数为 $p_0(x)$ 的总体还是来自密度函数为 $p_1(x)$ 的总体。

解:两个假设:

$H_0: x$ 来自 $p_0(x)$, $H_1: x$ 来自 $p_1(x)$

问题:接受 H_0 还是 H_1 ?

(1)把假设检验问题转化为贝叶斯决策问题:

①参数空间 $\Theta = \{0, 1\}$

②行动空间 $A = \{0, 1\}$

③先验分布: $P(\theta = 0) = \pi_0$,

$P(\theta = 1) = \pi_1$

④损失函数:决策正确无损失,决策错误的损失为1. 则

$$L = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

(2)求后验分布:

$$P(\theta = i | x) = \begin{cases} \frac{p_0(x)\pi_0}{p_0(x)\pi_0 + p_1(x)\pi_1}, & i = 0 \\ \frac{p_1(x)\pi_1}{p_0(x)\pi_0 + p_1(x)\pi_1}, & i = 1 \end{cases}$$

(3)计算每个行动下的后验风险: $R(a=0 | x) = P(\theta = 1 | x)$

$R(a=1 | x) = P(\theta = 0 | x)$

(4)找出最佳行动,即确定拒绝域.

$$\delta^*(x) = \begin{cases} 0, & \frac{p_1(x)}{p_0(x)} < \frac{\pi_0}{\pi_1} \\ 1, & \frac{p_1(x)}{p_0(x)} \geq \frac{\pi_0}{\pi_1} \end{cases}$$

第三节 常用损失函数下的贝叶斯估计

1. 平方损失函数下的贝叶斯估计

定理5.1 在平方损失函数 $L(\theta, \delta) = (\delta - \theta)^2$ 下, θ 的贝叶斯估计为后验均值, 即

$$\delta_B(x) = E(\theta|x)$$

[Pr] 在平方损失函数下, 任何一个决策函数 $\delta = \delta(x)$ 的后验风险为 $E[(\delta - \theta)^2|x] = \delta^2 - 2\delta E(\theta|x) + E(\theta^2|x)$

$$\text{令 } \frac{dE[(\delta - \theta)^2|x]}{d\delta} = 2\delta - 2E(\theta|x) = 0$$

$$\text{得: } \delta = E(\theta|x)$$

定理5.2 在加权平方损失函数 $L(\theta, \delta) = \lambda(\theta)(\delta - \theta)^2$ 下, θ 的贝叶斯估计为:

$$\delta_B(x) = \frac{E[\lambda(\theta)\theta | x]}{E[\lambda(\theta) | x]}$$

其中 $\lambda(\theta)$ 为参数空间 Θ 上的正值函数.

定理5.3 在参数向量 $\theta' = (\theta_1, \dots, \theta_k)$ 的情况下, 对多元二次损失函数 $L(\theta, \delta) = (\delta - \theta)'Q(\delta - \theta)$, Q 为正定阵, θ 的贝叶斯估计为后验均值向量:

$$\delta_B(x) = E(\theta | x) = \begin{pmatrix} E(\theta_1 | x) \\ \vdots \\ E(\theta_k | x) \end{pmatrix}$$

例4 设 $x = (x_1, \dots, x_n)$ 是来自泊松分布 $P(X = x) = \frac{\theta^x}{x!} e^{-\theta}$ 的一个样本. 若 θ 的先验分布用其共轭先验分布 $G(\alpha, \lambda)$, 即 $\pi(\theta) = \frac{\lambda^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} e^{-\lambda\theta}, \theta > 0$

其中参数 α 与 λ 已知. 求平方损失函数下 θ 的贝叶斯估计.

解: 解题过程分为以下三步:

(1) 根据题意求出 θ 的后验分布 $Ga(n\bar{x} + \alpha, n + \lambda)$

(2) 写出后验均值 $E(\theta | \mathbf{x}) = \frac{n\bar{x} + \alpha}{n + \lambda}$

(3) 结论: 由定理5.1知 θ 的贝叶斯估计为:

$$\delta_B(\mathbf{x}) = \frac{n\bar{x} + \alpha}{n + \lambda} = \frac{n}{n + \lambda} \bar{x} + \frac{\lambda}{n + \lambda} \cdot \frac{\alpha}{\lambda}$$

例5 设 $x = (x_1, \dots, x_n)$ 是来自均匀分布 $U(0, \theta)$ 的一个样本. 又设 θ 的先验分布为Pareto分布. 在损失函数分别为绝对值损失函数和平方损失函数下求 θ 的贝叶斯估计.

解题步骤:

第一步: 求 θ 的后验分布:

$$\pi(\theta | x) = \frac{(\alpha + n)\theta_1^{\alpha+n}}{\theta^{\alpha+n+1}}, \theta > \theta_1$$

第二步: 在绝对值损失函数下 θ 的贝叶斯估计: 恰为后验分布的中位数.

第三步: 平方损失函数下 θ 的贝叶斯估计:

$$\hat{\theta}_{B1} = \frac{(\alpha + n)\theta_1}{\alpha + n - 1}$$

Pareto分布的分布函数:

$$F(\theta) = 1 - \left(\frac{\mu}{\theta}\right)^\alpha, \theta > \mu$$

密度函数为:

$$p(\theta) = \frac{\alpha}{\mu} \left(\frac{\mu}{\theta}\right)^{\alpha+1}, \theta > \mu$$

期望: $E(\theta) = \alpha\mu/(\alpha - 1), \alpha > 1$

方差:

$$Var(\theta) = \frac{\alpha\mu^2}{(\alpha - 1)^2(\alpha - 2)}, \alpha > 2$$

中位数: μ

例6 贝叶斯决策在可靠性统计中的应用

问题的描述:假设某产品的寿命 T 服从指数分布,其分布函数为:

$$F(t) = 1 - e^{-\lambda t}, t > 0$$

把指定时间 t_0 后该产品才失效的概率

$$R(t_0) = P(T > t_0) = e^{-\lambda t_0}$$

称为产品在 t_0 时刻的可靠度。在平方损失函数下怎样估计可靠度 $R(t_0)$?

2. 线性损失函数下的贝叶斯估计

定理5.4 在绝对值损失函数 $L(\theta, \delta) = |\theta - \delta|$ 下, θ 的贝叶斯估计 $\delta_B(x)$ 为后验分布 $\pi(\theta | x)$ 的中位数.

证明:(1)证明的思路:

设 m 为 $\pi(\theta | x)$ 的中位数,要证明定理成立,即要证: $\forall \delta \in D$, 都有 $R(m | x) \leq R(\delta | x)$

即 $E^{\theta|x}[L(\theta, m) - L(\theta, \delta)] \leq 0$

(2)证明的过程:先证 $\delta > m$ 的情形,此时:

$$L(\theta, m) - L(\theta, \delta) = \begin{cases} m - \delta, & \theta \leq m < \delta \\ 2\theta - (m + \delta), & m < \theta < \delta \\ \delta - m, & m < \delta \leq \theta \end{cases}$$

当 $m < \theta < \delta$ 时, $2\theta - (m + \delta)$

$< 2\delta - (m + \delta) = \delta - m$, 故

$$L(\theta, m) - L(\theta, \delta)$$

$$= \begin{cases} m - \delta, & \theta \leq m \\ \delta - m, & m < \delta \leq \theta \end{cases}$$

因此 $E^{\theta|x}[L(\theta, m) - L(\theta, \delta)]$

$$\leq (m - \delta)P(\theta \leq m | x)$$

$$+ (\delta - m)P(\theta > m | x)$$

$$= (m - \delta)/2 + (\delta - m)/2 = 0$$

(3)同理可证 $\delta < m$ 的情形。

定理5.5 在线性损失函数: $L(\theta, \delta) = \begin{cases} k_0(\theta - \delta), & \delta \leq \theta \\ k_1(\delta - \theta), & \delta > \theta \end{cases}$

下, θ 的贝叶斯估计 $\delta_n(x)$ 为后验分布 $\pi(\theta | x)$ 的 $k_0/(k_0 + k_1)$ 分位数.

证明:(1) 计算任一决策函数 $\delta = \delta(x)$ 的后验风险:

$$\begin{aligned} R(\delta | x) &= \int_{-\infty}^{+\infty} L(\theta, \delta) \pi(\theta | x) d\theta \\ &= k_1 \int_{-\infty}^{\delta} (\delta - \theta) \pi(\theta | x) d\theta + k_0 \int_{\delta}^{+\infty} (\theta - \delta) \pi(\theta | x) d\theta \\ &= (k_1 + k_0) \int_{-\infty}^{\delta} (\delta - \theta) \pi(\theta | x) d\theta + k_0 (E(\theta | x) - \delta) \end{aligned}$$

(2) 求 $R(\delta|x)$ 的驻点: 令

$$\frac{dR(\delta | x)}{d\delta} = (k_0 + k_1) \int_{-\infty}^{\delta} \pi(\theta | x) d\theta - k_0 = 0 \Rightarrow \int_{-\infty}^{\delta} \pi(\theta | x) d\theta = \frac{k_0}{k_0 + k_1}$$

(3) 结论: θ 的贝叶斯估计是后验分布的 $k_0/(k_0 + k_1)$ 分位数.

例9(p191例题5.13)自学

3. 有限个行动问题的假设检验

- (1) 一般问题: 设 $A = \{a_1, a_2, \dots, a_r\}$, 在 a_i 下的损失为 $L(\theta, a_i)$, 如何从这些行动当中选择一个最优行动? (使后验期望损失 $E^{\theta|x} L(\theta, a_i)$ 达到最小的行动)
- (2) 特例: $r=2$ 的情形, 即 二个行动的假设检验 问题
- (3) 特例: $r=3$ 的情形 (三个行动的假设检验问题)
(儿童智商检验的实例P193)

二个行动的假设检验问题

1. 问题的描述:

有两个假设: $H_0: \theta \in \Theta_0$, $H_1: \theta \in \Theta_1$

两个行动: a_0 : 表示接受 H_0 的行动,

a_1 : 表示接受 H_1 的行动.

决策方法: 如果 $\theta \in \Theta_0$, 则认为 a_0 为最优行动;

如果 $\theta \in \Theta_1$, 则认为 a_1 为最优行动.

2. 损失函数的确定: 确定原则: 决策正确无损失, 决策错误损失 k_i 个单位. 则得到损失矩阵:

$$L = \begin{matrix} & \begin{matrix} a_0 & a_1 \end{matrix} \\ \begin{pmatrix} 0 & k_1 \\ k_0 & 0 \end{pmatrix} & \begin{matrix} \theta_0 \\ \theta_1 \end{matrix} \end{matrix}$$

3. 计算每个行动的后验期望损失：假设后验分布已经求出, 则

$$R(a_0 | x) = E^{\theta|x} L(a_0, \theta) = \int k_0 \pi(\theta | x) d\theta = k_0 P(\Theta_1 | x)$$

$$R(a_1 | x) = E^{\theta|x} L(a_1, \theta) = \int_{\Theta_0} k_1 \pi(\theta | x) d\theta = k_1 P(\Theta_0 | x)$$

4. 按照后验风险准则, 确定最优行动:

如果 $R(a_0 | x) > R(a_1 | x)$, 即: $k_0 P(\Theta_1 | x) > k_1 P(\Theta_0 | x)$ 则
应选择 a_1 , 拒绝 a_0 .

如果 $R(a_0 | x) < R(a_1 | x)$, 即: $k_0 P(\Theta_1 | x) < k_1 P(\Theta_0 | x)$ 则
应选择 a_0 , 拒绝 a_1 .

5. 确定拒绝域:

若 $\Theta_0 \cup \Theta_1 = \Theta$, 则 $P(\Theta_0 | x) = 1 - P(\Theta_1 | x)$
则由上一步可算得: $P(\Theta_1 | x) > \frac{k_1}{k_0 + k_1}$

即拒绝域 $W = \{x : P(\Theta_1 | x) > \frac{k_1}{k_0 + k_1}\}$

第四节 抽样信息期望值

一、基本概念

1. 完全信息：对需要作决策的问题，假如决策者所获得的信息足以肯定那一个状态即将发生，则该信息就称为(该状态的)完全信息。

2. 完全信息期望值 (EVPI)：设某决策问题有 n 种状态 $\theta_1, \theta_2, \dots, \theta_n$ ，且各种状态的先验概率 $\pi(\theta_i)$ 已知，又有 m 种行动 a_1, a_2, \dots, a_m 。设 Q_{ij} 为出现 θ_i 采取行动 a_j 的收益， a' 为使 $E^\theta[Q(\theta_i, a_j)]$ 取得最大时的行动，则称

$$E^\theta[\max_{a_j}\{Q(\theta_i, a_j)\}] - \max_{a_j}\{E^\theta[Q(\theta_i, a_j)]\}$$
为完全信息期望值，记为 EVPI。

3. 先验EVPI: 在一个决策问题中 $\pi(\theta)$ 是状态集 $\Theta = \{\theta\}$ 上的先验分布。 a' 是先验期望准则下的最优行动,则在 a' 下的损失函数 $L(\theta, a')$ 的先验期望 $E^\theta L(\theta, a')$ 称为完全信息先验期望值,记为先验EVPI。

4. 两者的关系:

$$\begin{aligned} EVPI &= \sum_{i=1}^n (\max_{a_j} Q_{ij}) \pi(\theta_i) - \sum_{i=1}^n Q_{ik} \pi(\theta_i) \\ &= \sum_{i=1}^n (\max_{a_j} Q_{ij} - Q_{ik}) \pi(\theta_i) = \sum_{i=1}^n L_{ik} \pi(\theta_i) \\ &= E^\theta [L(\theta_i, a_k)] \end{aligned}$$

5. 例题:对给定的Q或L怎样计算EVPI和先验EVPI? 如:

$$Q = \begin{matrix} & a_1 & a_2 & a_3 \\ \begin{pmatrix} 10 & 50 & 100 \\ 9 & 40 & 30 \\ 6 & -20 & -60 \end{pmatrix} & \theta_1 \\ & \theta_2 \\ & \theta_3 \end{matrix} \leftrightarrow L = \begin{matrix} & a_1 & a_2 & a_3 \\ \begin{pmatrix} 90 & 50 & 0 \\ 31 & 0 & 10 \\ 0 & 26 & 66 \end{pmatrix} & \theta_1 & 0.6 \\ & \theta_2 & 0.3 \\ & \theta_3 & 0.1 \end{matrix}$$

二、抽样信息期望值

1. 定义：在一个贝叶斯决策问题中， a' 是先验期望准则下的最优行动， $\delta'(x)$ 是后验风险准则下的最优决策函数。则先验EVPI与后验EVPI期望值的差称为抽样信息期望值，记为：

$$EVSI = E^\theta L(\theta, a') - E^x E^{\theta|x} L(\theta, \delta'(x))$$

2. 计算一个EVSI的基本步骤：

第一步：计算先验EVPI；

第二步：计算 θ 的后验分布；

第三步：计算每个行动的后验期望损失 $E^{\theta|x} L(\theta, a)$ ；

第四步：确定最优决策函数；

第五步：计算后验EVPI；

第六步：计算后验EVPI的期望值；

第七步：计算抽样信息期望值。

案例分析

甲厂的某一零件由乙厂生产，每批1000只，其次品率 θ 的概率分布如下表所示：

θ	0.02	0.05	0.10
$\pi(\theta)$	0.45	0.39	0.16

甲厂在整机装配时，如发现零件是次品，必须更换，每换一只，乙厂赔偿2.20元的损失费，但也可以在送装前采取全部检查的办法，使每批零件的次品率降为1%，但乙厂必须支付每只0.10元的检查费。乙厂面临如下两种选择：

a_1 ：一批中一件都不检查

a_2 ：一批中每件都检查

若乙厂厂长想从每批中任取三只零件进行抽查，根据不合格品个数来决定是采取行动 a_1 还是行动 a_2 ，并想知道这样能否带来更大的收益？

分析过程

一、计算先验EVPI:

$$\text{支付函数: } W(\theta, a_1) = 1000\theta \times 2.20 = 2200\theta$$

$$W(\theta, a_2) = 1000 \times 0.10 + 1000 \times 1\% \times 2.20 = 122$$

由此的支付矩阵和损失矩阵:

$$W = \begin{matrix} & \begin{matrix} a_1 & a_2 \end{matrix} \\ \begin{pmatrix} 44 & 122 \\ 110 & 122 \\ 220 & 122 \end{pmatrix} \end{matrix} \quad L = \begin{matrix} & \begin{matrix} a_1 & a_2 \end{matrix} \\ \begin{pmatrix} 0 & 78 \\ 0 & 12 \\ 98 & 0 \end{pmatrix} \quad \begin{matrix} \theta_1 \\ \theta_2 \\ \theta_3 \end{matrix} \end{matrix}$$

计算每个行动下的先验期望损失: $E^\theta L(\theta, a_1) = 15.68$

$E^\theta L(\theta, a_2) = 39.78$ 由此得在先验期望准则下, **a1**是最优行动, 则: 先验**EVPI**=**15.68**

2. 计算的后验分布

x	0	1	2	3
m(x)	0.8745	0.1176	0.0076	0.0002

x	0	1	2	3
$\theta_1=0.02$	0.4843	0.2202	0.0658	0.0028
$\theta_2=0.05$	0.3824	0.4490	0.3684	0.0190
$\theta_3=0.10$	0.1333	0.3308	0.5658	0.9782

3. 计算各行动的后验期望损失

x	0	1	2	3
$E^{\theta x} L(\theta, a_1)$	13.0634	32.4148	55.4484	95.8636
$E^{\theta x} L(\theta, a_2)$	42.3642	22.5636	9.5532	0.4464

4. 确定最优决策函数:

$$\delta'(x) = \begin{cases} a_1, & x = 0 \\ a_2, & x = 1, 2, 3 \end{cases}$$

5. 计算后验EVPI: $x=0$ 时, 后验EVPI=13.0634

$x=1$ 时, 后验EVPI=22.5636

$x=2$ 时, 后验EVPI=9.5532

$x=3$ 时, 后验EVPI=0.4494

6. 计算后验EVPI的期望值:

$$\begin{aligned} E^x E^{\theta|x} L(\theta, \delta'(x)) &= 13.0634 \times 0.8745 + 22.5636 \times 0.1176 \\ &\quad + 9.5532 \times 0.0076 + 0.4494 \times 0.0002 \\ &= 14.1501 \end{aligned}$$

7. 计算抽样信息期望值:

$$EVSI = 15.68 - 14.15$$

思考: 该厂长所确定的抽取三件产品检查, 是否是最好?

第五节 最佳样本量的确定

一、抽样净益

1. 抽样成本: 抽样费用称为抽样成本, 记为 $C(n) = C_f + C_v \cdot n$ ($n \geq 1$)

其中 C_f 是固定成本, C_v 是可变成本.

2. 抽样净益: 从抽样信息期望值中扣除抽样成本所剩下的净收益. 记为 **ENGs**, 即 $ENGs(n) = EVSI(n) - C(n)$

二、最佳样本量及其上界

1. 最佳样本量: 使得抽样净益达到最大的样本量 n^* 称为最佳样本量. 即 $ENGs(n^*) = \max_{n>0} ENGs(n)$

2. 上界的确定: $n^* \leq \frac{\text{先验}EVPI - C_f}{C_v}$

三、最佳样本量的求法

第六节 二行动线性决策问题的EVPI

- 一、正态分布下二行动线性决策问题的先验EVPI
- 二、贝塔分布下二行动线性决策问题的先验EVPI
- 三、伽玛分布下二行动线性决策问题的先验EVPI

案例分析

某厂的产品每100件装成一箱运交顾客.在向顾客交货前面临如下二中选择: a_1 :一箱中逐一检查; a_2 一箱中一件也不检查.若工厂选择 a_1 ,则可保证交货时每件产品都是合格品,但因每件产品的检查费为0.8元,为此工厂要支付检查费80元/箱.若工厂选择 a_2 ,虽可免去每箱80元的检查费,但一旦顾客发现不合格品时,不仅要免费更换,而且每件还要支付12.5元的赔偿费.假设该厂产品的不合格率 θ 没有超过0.12的记录.根据下列不同的情形,作出相应的最优决策.

- (1)不作任何抽样,怎样做决策? ([解答](#))
- (2)每箱中抽取两件进行检查,结果如何? ([解答](#))
- (3)每箱中抽取三件进行检查,结果又如何?

[B](#)

决策函数

x	0	1	2
$\delta_1(x)$	a_1	a_1	a_1
$\delta_2(x)$	a_1	a_1	a_2
$\delta_3(x)$	a_1	a_2	a_1
$\delta_4(x)$	a_1	a_2	a_2
$\delta_5(x)$	a_2	a_1	a_1
$\delta_6(x)$	a_2	a_1	a_2
$\delta_7(x)$	a_2	a_2	a_1
$\delta_8(x)$	a_2	a_2	a_2

各决策函数的后验风险

x	0	1	2
$R(\delta_1 x)$	22.2030	15.0483	2.7986
$R(\delta_2 x)$	22.2030	15.0483	36.8924
$R(\delta_3 x)$	22.2030	55.9783	2.7986
$R(\delta_4 x)$	22.2030	55.9783	36.8924
$R(\delta_5 x)$	15.6159	15.0483	2.7986
$R(\delta_6 x)$	15.6159	15.0483	36.8924
$R(\delta_7 x)$	15.6159	55.9783	2.7986
$R(\delta_8 x)$	15.6159	55.9783	36.8924

(1) 第一步：由支付函数确定损失函数：

支付函数

$$W(\theta, a) = \begin{cases} 80 & , a = a_1 \\ 12.5 \times 100\theta & , a = a_2 \end{cases}$$

其中 $\theta \in (0, 1)$ 。这是一个典型的决策问题。这时相应的损失函数可由支付函数换算得

$$L(\theta, a_1) = \begin{cases} 80 - 1250\theta, & \theta \leq \theta_0 \\ 0, & \theta > \theta_0 \end{cases}$$

$$L(\theta, a_2) = \begin{cases} 0, & \theta \leq \theta_0 \\ -80 + 1250\theta, & \theta > \theta_0 \end{cases}$$

其中 $\theta_0 = 0.064$ 。

第二步：计算每一个行动的先验期望损失

B

假如工厂从产品检查部门发现,该厂产品的不合格品率 θ 没有超过0.12的纪录。若取区间 $(0, 0.12)$ 上的均匀分布作为 θ 的先验分布,又在决策中使用这个先验分布。则就构成一个无数据的决策问题。在这个决策问题中可以分别算得行动 a_1 和行动 a_2 的先验期望损失

$$\begin{aligned} \bar{L}(a_1) &= \frac{1}{0.12} \int_0^{\theta_0} (80 - 1250\theta) d\theta \\ &= 8.33(80\theta_0 - 1250\theta_0^2/2) \\ &= 21.32(\text{元} / \text{箱}) \end{aligned}$$

$$\begin{aligned} \bar{L}(a_2) &= 8.33 \int_{\theta_0}^{0.12} (-80 + 1250\theta) d\theta \\ &= 8.33[-80(0.12 - \theta_0) + 1250(0.12^2 - \theta_0^2)/2] \\ &= 16.33(\text{元} / \text{箱}) \end{aligned}$$

按先验期望损失愈小愈好原则,应取行动 a_2 ,即每箱中一件都不检查可使工厂损失小。

(2) 第一步：由支付函数确定损失函数：

假如工厂决定先在每箱中抽取两件进行检查, 设 X 为其不合格品数, 则 $X \sim b(2, \theta)$ 。然后工厂根据 X 的取值(可能取 0, 1, 2 三种)再选择行动 a_1 或行动 a_2 。这时工厂的支付函数为

$$W(\theta, a) = \begin{cases} 80 & , a = a_1 \\ 1.6 + 1250\theta & , a = a_2 \end{cases}$$

相应的损失函数为

$$L(\theta, a_1) = \begin{cases} 78.4 - 1250\theta & , \theta \leq \theta_0 \\ 0 & , \theta > \theta_0 \end{cases}$$

$$L(\theta, a_2) = \begin{cases} 0 & , \theta \leq \theta_0 \\ -78.4 + 1250\theta & , \theta > \theta_0 \end{cases}$$

其中 $\theta_0 = 0.06272$ 。此种利用抽样信息的决策问题就是统计决策问

第二步：计算后验分布：

产品的不合格品率 θ 不超过 0.12。且取均匀分布 $U(0, 0.12)$ 作为 θ 的先验分布，由此例即可得 x 与 θ 的联合分布

$$h(x, \theta) = c^{-1} \binom{2}{x} \theta^x (1-\theta)^{2-x}, x=0, 1, 2, \quad 0 < \theta < 0.12$$

其中 $c=0.12$ 。 x 的边缘分布为

$$m(x) = c^{-1} \binom{2}{x} \int_0^c \theta^x (1-\theta)^{2-x} d\theta$$

这个积分并不复杂，但要在 x 给定下才能算出，为此在 $x=0, 1, 2$ ，情况下分别计算

$$\begin{aligned} m(0) &= c^{-1} \int_0^c (1-\theta)^2 d\theta = c^{-1} [c - c^2 + c^3/3] \\ &= 1 - c + c^2/3 = 0.8848 \end{aligned}$$

$$m(1) = 2c^{-1} \int_0^c \theta(1-\theta) d\theta = 2c^{-1} [c^2/2 - c^3/3]$$

$$= c - 2c^2/3 = 0.1104$$

$$m(3) = c^{-1} \int_0^c \theta^2 d\theta = c^2/3 = 0.0048$$

这样就得到 x 的边缘分布

θ	0	1	2
$m(x)$	0.8848	0.1104	0.0048

接着在 $x=0,1,2$ 给定下,容易写出 θ 的后验分布

$$\pi(\theta|x=0) = c^{-1}(1-\theta)^2/0.8848 = 9.4183(1-\theta)^2, 0 < \theta < 0.12$$

$$\pi(\theta|x=1) = 2c^{-1}\theta(1-\theta)/0.1104$$

$$= 150.9662\theta(1-\theta), 0 < \theta < 0.12$$

$$\pi(\theta|x=2) = c^{-1}\theta^2/0.0048 = 1736.1111\theta^2, 0 < \theta < 0.12$$

第三步：利用后验风险准则做决策

计算每一个决策行动的后验风险

$$\begin{aligned}R(a_1 | x = 0) &= \int_0^{\theta_0} (78.4 - 1250\theta) \times 9.4183(1 - \theta)^2 d\theta \\ &= 9.4183 \int_0^{\theta_0} (78.4 - 1406.8\theta + 2578.4\theta^2 \\ &\quad - 1250\theta^3) d\theta \\ &= 22.2030\end{aligned}$$

$$\begin{aligned}R(a_2 | x = 2) &= 1736.1111 \times \int_{\theta_1}^{0.12} (-78.4 + 1250\theta)\theta^2 d\theta \\ &= 1736.1111 \times \left[-78.4\theta^3/3 + 1250\theta^4/4 \right]_{\theta_1}^{0.12} \\ &= 36.8924\end{aligned}$$

其余的后验风险可类似算得。现在 6 个后验风险列表如下

表 5.1 例 5.3 的后验风险

$R(a x)$	x		
	0	1	2
a_1	22.2030	15.0483	2.7986
a_2	15.6159	55.9783	36.8924

如何从表 5.1 上按后验风险最小的准则挑选最优行动呢？假如选 a_1 ，那么在 $x=0$ 时 a_1 的后验风险下是最小的。假如选 a_2 ，那么 $x=1, 2$ 时 a_2 的后验风险不是最小的。这时最优行动应随着样本观察值 x 的变化而变化。即

$$a = \begin{cases} a_2, & x=0 \\ a_1, & x=1, 2 \end{cases}$$

这表明最优行动应是样本 x 的函数。为了准确表达这一点，需要决策函数的概念。