

4.4 区间估计

4.4.1 基本概念

如前所述,点估计是用一个点(即一个数)去估计未知参数.顾名思义,区间估计就是用一个区间去估计未知参数,即把未知参数值估计在某两界限之间.例如,估计一个人的年龄在 30 到 35 岁之间;估计所需费用在 1000—1200 元之间等等.区间估计是一种很常用的估计形式,其好处是把可能的误差用醒目的形式标出来了.你估计费用需 1000 元,我相信多少会有误差.误差多少?单从你提出的 1000 这个数字还给不出什么信息,你若估计费用在 800~1200 元之间,则人们会相信你在作出这估计时,已把可能出现的误差考虑到了,多少给人们以更大的信任感.

现今最流行的一种区间估计理论是原籍波兰的美国统计学家 J. 奈曼在本世纪 30 年代建立起来的. 他的理论的基本概念很简单. 为书写简单计, 我们暂设总体分布只包含一个未知参数 θ , 且要估计的就是 θ 本身. 如果总体分布包含若干个未知参数 $\theta_1, \dots, \theta_k$, 而要估计的是 $g(\theta_1, \dots, \theta_k)$, 基本概念并无不同. 这将在后面的例子中看到.

设 X_1, \dots, X_n 是从该总体中抽出的样本. 所谓 θ 的区间估计, 就是满足条件 $\hat{\theta}_1(X_1, \dots, X_n) \leq \hat{\theta}_2(X_1, \dots, X_n)$ 的两个统计量 $\hat{\theta}_1, \hat{\theta}_2$ 为端点的区间 $[\hat{\theta}_1, \hat{\theta}_2]$. 一旦有了样本 X_1, \dots, X_n , 就把 θ 估计在区间 $[\hat{\theta}_1(X_1, \dots, X_n), \hat{\theta}_2(X_1, \dots, X_n)]$ 之内, 不难理解, 这里有两个要求:

1. θ 要以很大的可能性落在区间 $[\hat{\theta}_1, \hat{\theta}_2]$ 内, 也就是说, 概率

$$P_{\theta}(\hat{\theta}_1(X_1, \dots, X_n) \leq \theta \leq \hat{\theta}_2(X_1, \dots, X_n)) \quad (4.1)$$

要尽可能大.

2. 估计的精密度要尽可能高. 比方说, 要求区间的长度 $\hat{\theta}_2 - \hat{\theta}_1$ 尽可能小, 或某种能体现这个要求的其他准则.

例如, 估一个人的年龄在某一区间内, 例如 $[30, 35]$ 内. 我们要求这估计尽量可靠, 即该人的年龄有很大把握确在这区间内, 同时, 也要求区间不能太长: 比如, 估计一人的年龄在 10—90 岁之间, 当然可靠了, 但精度太差, 用处不大.

但这两个要求是相互矛盾的. 区间估计理论和方法的基本问题, 莫不在于在已有的样本资源的限制下, 怎样找出更好的估计方法, 以尽量提高此二者——可靠性和精度, 但终归有一定的限度. 奈曼所提出并为现今所广泛接受的原则是: 先保证可靠度, 在这个前提下尽量使精度提高. 为此他引进了如下的定义.

定义 4.1 给定一个很小的数 $\alpha > 0$. 如果对参数 θ 的任何值, 概率(4.1)都等于 $1 - \alpha$, 则称区间估计 $[\hat{\theta}_1, \hat{\theta}_2]$ 的置信系数为

$1 - \alpha$.

区间估计也常称为“置信区间”. 字面上的意思是:对该区间能包含未知参数 θ 可置信到何种程度.

有时,我们无法证明概率(4.1)对一切 θ 都恰好等于 $1 - \alpha$,但知道它不会小于 $1 - \alpha$,则我们称 $1 - \alpha$ 是 $[\hat{\theta}_1, \hat{\theta}_2]$ 的“置信水平”. 按此,置信水平不是一个唯一的数. 因为,若概率(4.1)总不小于 0.8,那它也总不小于 0.7, 0.6, \dots 等. 就是说,若 β 为置信水平,则小于 β 的数也是置信水平,置信系数是置信水平中的最大者. 在实用上,人们并不总是把这两个术语严加区别,这要看各人的习惯.

定义 4.1 中的 α ,一般以取为 0.05 的最多,还有 0.01, 0.10, 以至 0.001 等,也视情况需要而使用. 这几个数字本身并无特殊意义,主要是这样标准化了以后对造表方便.

区间估计理论的主要问题,按奈曼的上述原则,就是在保证给定的置信系数之下,去寻找有优良精度的区间估计. 而这个“优良”,也可以有种种准则. 这方面现已有了一些结果,但在本课程范围之内,我们无法去涉及这些较深的理论问题,我们所能做的,就是从直观出发如何去构造看来是合理的区间估计. 这就是下面两段要讨论的问题.

4.4.2 枢轴变量法

从一个简单例子入手. 设 X_1, \dots, X_n 为抽自正态总体 $N(\mu, \sigma^2)$ 的样本, σ^2 已知,要求 μ 的区间估计.

先找一个 μ 的良好点估计. 在此可选择样本均值 \bar{X} . 由总体为正态易知

$$\sqrt{n}(\bar{X} - \mu)/\sigma \sim N(0, 1) \quad (4.2)$$

以 Φ 记 $N(0, 1)$ 的分布函数. 对 $0 < \beta < 1$ (一般是 β 很小), 用方程

$$\Phi(u_\beta) = 1 - \beta \quad (4.3)$$

定义记号 u_β . u_β 称为分布 $N(0, 1)$ 的“上 β 分位点”. 其意义是:

$N(0,1)$ 分布中大于 u_β 的那部分的概率,就是 β . 图 4.2 中画出的是 $N(0,1)$ 的密度函数 $\varphi(x) = (\sqrt{2\pi})^{-1}e^{-x^2/2}$ 的图形,涂黑部分标出的面积为 β .




图 4.2

上 β 分位点的概念可推广到任何分布 F : 满足条件 $F(v_\beta) = 1 - \beta$ 的点 v_β , 就是分布函数 F 的上 β 分位点. 在数理统计学的应用中, 除正态分布外, “统计三大分布”的上分位点很常用. 以后, 我们分别用 $x_n^2(\beta)$, $t_n(\beta)$ 和 $F_{n,m}(\beta)$ 记自由度 n 的卡方分布, 自由度 n 的 t 分布, 以及自由

度为 (n, m) 的 F 分布的上 β 分位点, 这些都有表可查.

另外, 读者还须注意: 在有的著作中使用“下分位点”, 分布函数 F 的下 β 分位点是指满足条件 $F(w_\beta) = \beta$ 的点 w_β . 上、下分位点之间的换算不难: 分布 F 的 β 下分位点, 就是其 $1 - \beta$ 上分位点. 当分布 F 的密度函数 f 关于原点对称(即 $f(-x) = f(x)$)时, F 的上、下 β 分位点只相差一个符号, 本书以后只使用上分位点.

现在回到 μ 的区间估计问题. 由 (4.2) 及 μ_β 的定义, 并注意到 $\Phi(-t) = 1 - \Phi(t)$, 有

$$\begin{aligned} P(-u_{\alpha/2} \leq \sqrt{n}(\bar{X} - \mu)/\sigma \leq u_{\alpha/2}) &= \Phi(u_{\alpha/2}) - \Phi(-u_{\alpha/2}) \\ &= (1 - \alpha/2) - \alpha/2 = 1 - \alpha \end{aligned}$$

此式可改写为

$$P(\bar{X} - \sigma u_{\alpha/2}/\sqrt{n} \leq \mu \leq \bar{X} + \sigma u_{\alpha/2}/\sqrt{n}) = 1 - \alpha$$

此式指出

$$[\hat{\theta}_1, \hat{\theta}_2] = [\bar{X} - \sigma u_{\alpha/2}/\sqrt{n}, \bar{X} + \sigma u_{\alpha/2}/\sqrt{n}] \quad (4.4)$$

可作为 μ 的区间估计, 置信系数为 $1 - \alpha$.

由这个例子悟出一种找区间估计的一般方法, 可总结为以下几条:

1° 找一个与要估计的参数 $g(\theta)$ 有关的统计量 T , 一般是其

一良好的点估计(此例 T 为 \bar{X});

2° 设法找出 T 和 $g(\theta)$ 的某一函数 $S(T, g(\theta))$, 其分布 F 要与 θ 无关(在此例中, $S(T, g(\theta))$ 为 $\sqrt{n}(\bar{X} - \mu)/\sigma$, 分布 F 就是 Φ). S 称为“枢轴变量”;

3° 对任何常数 $a < b$, 不等式 $a \leq S(T, g(\theta)) \leq b$ 要能改写为等价的形式 $A \leq g(\theta) \leq B$, A, B 只与 T, a, b 有关而与 θ 无关;

4° 取分布 F 的上 $\alpha/2$ 分位点 $w_{\alpha/2}$ 和上 $(1 - \alpha/2)$ 分位点 $w_{1-\alpha/2}$. 有 $F(w_{\alpha/2}) - F(w_{1-\alpha/2}) = 1 - \alpha$. 因此

$$P(w_{1-\alpha/2} \leq S(T, g(\theta)) \leq w_{\alpha/2}) = 1 - \alpha$$

根据第 3 条, 不等式 $w_{1-\alpha/2} \leq S(T, g(\theta)) \leq w_{\alpha/2}$ 可改写为 $A \leq g(\theta) \leq B$ 的形式, A, B 与 T 有关因而与样本有关. $[A, B]$ 就是 $g(\theta)$ 的一个置信系数 $1 - \alpha$ 的区间估计.

现在举一些例子来说明这个方法, 这些例子包含了许多常用的重要区间估计.

例 4.1 从正态总体 $N(\mu, \sigma^2)$ 中抽样本 X_1, \dots, X_n , μ 和 σ^2 都未知, 求 μ 的区间估计.

μ 的点估计仍取为样本均值 \bar{X} . 作为枢轴变量, 再取 $\sqrt{n}(\bar{X} - \mu)/\sigma$ 已不行. 因为虽然这变量的分布 $N(0, 1)$ 与参数无关, 但因 σ 未知, 条件 3° 已不满足. 现把 σ 改为样本标准差 S , 则枢轴变量一切条件都满足了, 因为(见第二章(4.34))变量 $\sqrt{n}(\bar{X} - \mu)/S$ 服从自由度为 $n - 1$ 的 t 分布, 与参数无关. 由此出发用 4°, 并注意 t 分布密度关于 0 对称因而 $t_{n-1}(1 - \alpha/2) = -t_{n-1}(\alpha/2)$, 得 μ 的区间估计

$$\left[\bar{X} - St_{n-1}(\alpha/2)/\sqrt{n}, \bar{X} + St_{n-1}(\alpha/2)/\sqrt{n} \right] \quad (4.5)$$

置信系数为 $1 - \alpha$. 它称为“一样本 t 区间估计”.

例如, 为估计一物件的重量 μ , 把它在天平上重复秤了 5 次, 得结果为(单位为克)

5.52, 5.48, 5.64, 5.51, 5.43

假定此天平无系统误差且随机误差服从正态分布. 则总体分布为

$N(\mu, \sigma^2)$, μ 即未知的重量, 方差 σ^2 也未知. 算出

$$\bar{X} = (5.52 + \cdots + 5.43)/5 = 5.516$$

$$S = \sqrt{\frac{1}{5-1} [(5.52 - 5.516)^2 + \cdots + (5.43 - 5.516)^2]} \\ = \frac{1}{2} \sqrt{0.02412} = 0.078$$

查表, 知 $t_4(0.025) = 2.776$. 以这些数值代入(4.5), 得 μ 的置信系数 0.95 的区间估计为 $[5.419, 5.613]$.

$[5.419, 5.613]$ 是一个具体的区间, μ 是一个虽然未知, 但其值确定的数. $[5.419, 5.613]$ 这区间或者包含 μ , 或者不包含, 二者只居其一. 说这区间的置信系数为 0.95, 其确切意义应当是: 它是根据所有的数据, 用一个其置信系数为 0.95 的方法作出的. 可见置信系数一词是针对方法: 用这方法作出的区间估计, 平均 100 次中 95 次确包含所要估计的值. 一旦算出具体区间, 就不能再说它有 95% 的机会包含要估计的值了. 这一点意义上的理解必须分清, 正如说一个人长于挑西瓜: 他挑的瓜, 平均 100 个中有 95 个好的. 某天他给你挑一个, 结果或好或坏, 必居其一, 不是 95% 的好. 但是, 考虑到他挑瓜的技术, 我对他挑的比较放心, 这就是置信系数.

区间估计(4.5)叫做一样本 t 区间估计. “一样本”是指这里只有一个总体, 因而只有一组样本, 以别于下例.

例 4.2 设有两个正态总体, 其分布分别为 $N(\mu_1, \sigma^2)$ 和 $N(\mu_2, \sigma^2)$. 注意方差相同. 设 μ_1, μ_2, σ^2 都未知. 现从这两个总体分别抽出样本 X_1, \cdots, X_n 和 Y_1, \cdots, Y_m . 要求 $\mu_1 - \mu_2$ 的区间估计.

记 \bar{X} 和 \bar{Y} 分别为 X_i 和 Y_j 的样本均值, 而

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

据第二章(4.36)式, 知

$$T = \sqrt{\frac{mn}{m+n}} \cdot ((\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)) / S \sim t_{n+m-2}$$

的分布不依赖于参数 μ_1, μ_2, σ^2 . 它适合于作为枢轴变量的条件, 按 4° , 定出 $\mu_1 - \mu_2$ 的区间估计为

$$\left[(\bar{X} - \bar{Y}) - St_{n+m-2}(\alpha/2) \sqrt{\frac{n+m}{nm}}, \right. \\ \left. (\bar{X} - \bar{Y}) + St_{n+m-2}(\alpha/2) \sqrt{\frac{n+m}{nm}} \right] \quad (4.6)$$

置信系数为 $1 - \alpha$. 这个区间称为“两样本 t 区间估计”, 是应用上常用的区间估计之一.

如考虑上例, 设有另一物件, 其重量 μ_2 也未知. 在这同一架天平上秤 4 次, 得结果为

$$5.45, 5.40, 5.34, 5.51$$

把上例中的 μ 记为 μ_1 . 因是同一架天平, 方差不变. 要对两物件重量之差 $\mu_1 - \mu_2$ 作区间估计. 可用(4.6). 算出

$$\bar{Y} = (5.45 + \cdots + 5.51)/4 = 5.425$$

$$\sum_{j=1}^n (Y_j - \bar{Y})^2 = (5.45 - 5.425)^2 + \cdots + (5.51 - 5.425)^2 \\ = 0.01570$$

结合前例数据, 算出

$$\bar{X} - \bar{Y} = -0.091, S = \sqrt{0.02412 + 0.01570} / \sqrt{5 + 4 - 2} \\ = 0.075$$

又 $\sqrt{(n+m)/nm} = \sqrt{9/20} = 0.671$. 取 $\alpha = 0.05$, 查 t 分布表得 $t_7(0.025) = 2.365$. 把这些都代入(4.6), 算出 $\mu_1 - \mu_2$ 的区间估计为 $[-0.210, 0.028]$, 置信系数 0.95.

在实际问题中, 两总体方差相等的假定往往只是近似成立. 当方差之比接近 1 时, 用(4.6)产生的误差不大(这里的“误差”一词是指实际的置信系数与名义的置信系数 $1 - \alpha$ 有出入). 如果差别较大, 则必须假定两正态总体分别有方差 σ_1^2 和 σ_2^2 , σ_1^2 和 σ_2^2 都未知. 在这样的假定下求 $\mu_1 - \mu_2$ 的区间估计问题, 是数理统计学上一个著名的问题, 叫贝伦斯-费歇尔问题. 因为这两位学者分别在 1929 和 1930 年研究过这个问题, 他们以及后来的研究者提出过

一些解法,但还没有一个被公认为是满意的.

例 4.3 再考虑例 4.1,但现在要求作 σ^2 的区间估计.

据第二章(4.33),有 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$. 于是 $(n-1)S^2/\sigma^2$ 适合枢轴变量的条件. 按 4° , 得 σ^2 的区间估计为

$$[(n-1)S^2/\chi_{n-1}^2(\alpha/2), (n-1)S^2/\chi_{n-1}^2(1-\alpha/2)] \quad (4.7)$$

置信系数为 $1-\alpha$. 类似地, 若另有一正态总体 $N(\mu, \sigma_2^2)$ 及从中抽出的样本 Y_1, \dots, Y_m , 要作方差比 σ_1^2/σ_2^2 的区间估计. 记 S_1^2 和 S_2^2 分别为 X_1, \dots, X_n 和 Y_1, \dots, Y_m 的样本方差, 按第二章(4.35), 有

$$(S_2^2/\sigma_2^2)/(S_1^2/\sigma_1^2) \sim F_{m-1, n-1}$$

即 $\lambda \cdot S_2^2/S_1^2 \sim F_{m-1, n-1}$, 其中 $\lambda = \sigma_1^2/\sigma_2^2$. 于是得到枢轴变量. 按 4° , 得出比值 λ 的置信系数 $1-\alpha$ 的区间估计为

$$[(S_1^2/S_2^2)F_{m-1, n-1}(1-\alpha/2), (S_1^2/S_2^2)F_{m-1, n-1}(\alpha/2)] \quad (4.8)$$

例 4.4 设 X_1, \dots, X_n 为抽自指数分布总体的样本, 要求其参数 λ 的区间估计.

在第二章 2.4.3 小节中曾证明 $2n\lambda \bar{X} \sim \chi_{2n}^2$. 故 $2n\lambda \bar{X}$ 可作为枢轴变量. 由 4° , 得 λ 的区间估计为

$$[\chi_{2n}^2(1-\alpha/2)/(2n\bar{X}), \chi_{2n}^2(\alpha/2)/(2n\bar{X})] \quad (4.9)$$

置信系数为 $1-\alpha$. 若要求总体均值 $1/\lambda$ 的区间估计, 则为

$$[2n\bar{X}/\chi_{2n}^2(\alpha/2), 2n\bar{X}/\chi_{2n}^2(1-\alpha/2)] \quad (4.10)$$

从这些例子可以看出“枢轴变量法”这名称的由来. 拿本例来说, 变量 $2n\lambda \bar{X}$ 起了一个“轴心”的作用, 把一个变量(即 $2n\lambda \bar{X}$)介于某两个界限之间的不等式轻轻一转, 就成为未知参数 λ 介于某两个界限之间的不等式.

对离散型变量来说, 枢轴变量法不易使用. 不仅由于满足条件 $1^\circ-4^\circ$ 的枢轴变量 $S(T, g(\theta))$ 大多不存在, 即使存在了, 由于其分布 F 为离散, 对指定的 β , 一般也不一定存在确切的上 β 分位点. 对离散型总体的参数去找具有所指定的置信系数的区间估计方法, 超出本书范围之外. 在下一段中, 对二项和波哇松分布参数

这两个重要情况,将给出一种基于极限分布的方法.

在实用中,除了指定的置信系数外,往往还对于区间估计的长度,或其他某种反映其精度的量,有一定的要求.在有些情况下这个问题比较好处理.例如, $N(\mu, \sigma^2)$ 当 σ^2 已知时, μ 的区间估计(4.4)的长为 $2\sigma u_{\alpha/2}/\sqrt{n}$.为要使这个长度不超过指定的 $L > 0$,只须取 n 为不小于 $(2\sigma u_{\alpha/2}/L)^2$ 的最小整数即可.

对例4.3正态分布方差或方差比的估计,由于方差本身的意义,在实际问题中,考虑估计值与它相差多少倍,往往比考虑估计值与其差的绝对值更好.这就要求,例如,区间(4.7)的右端不超过左端的 L 倍($L > 1$),即

$$\chi_{n-1}^2(\alpha/2)/\chi_{n-1}^2(1-\alpha/2) \leq L$$

在给定了 L 之后,可以查 χ^2 分布表,找一个最小的 n 使上式成立即可.对方差比的情况,以及指数分布参数 λ (或 $1/\lambda$)的情况,也完全类似地处理.

对 t 区间估计,则情况不同.拿一样本 t 区间估计(4.5)来说,其长 $2St_{n-1}(\alpha/2)/\sqrt{n}$ 与 S 有关,而 S 与样本有关,故无法决定这样一个 n ,它能保证在任何情况下都有 $2St_{n-1}(\alpha/2)/\sqrt{n} \leq L$.1945年,美国统计学家斯泰因提出了一个“两阶段抽样”的方法来解决这个问题:先抽出样本 X_1, \dots, X_n ,算出样本标准差 S 如前.根据 S 的大小决定追加抽样的数目: S 愈大,追加抽样次数愈多.具体公式如下:先引进记号 $[\alpha] =$ 不超过 α 的最大整数,例如 $[3.12] = 3, [2] = 2$ 等,追加抽样次数 m 的公式为

$$m = \begin{cases} 0, & \text{若 } n \geq [4t_{n-1}^2(\alpha/2)S^2/L^2] + 1 \\ n - 1 - [4t_{n-1}^2(\alpha/2)S^2/L^2], & \text{其他情况} \end{cases}$$

记原有样本和追加样本全体的样本均值为 \tilde{X} ,则可以证明,长为 L 的区间估计 $[\tilde{X} - L/2, \tilde{X} + L/2]$ 有置信系数 $1 - \alpha$.

4.4.3 大样本法

大样本法就是利用极限分布,主要是中心极限定理,以建立枢

轴变量,它近似满足枢轴变量的条件 2°. 最好通过例子来说明.

例 4.5 某事件 A 在每次试验中发生的概率为 p . 作 n 次独立试验,以 Y_n 记 A 发生的次数,要求 p 的区间估计.

设 n 相当大,则按定理 4.3,近似地有 $(Y_n - np)/\sqrt{np(1-p)} \sim N(0,1)$. 于是 $(Y_n - np)/\sqrt{np(1-p)} \sim N(0,1)$ 可取为枢轴变量. 由

$$P(-u_{\alpha/2} \leq (Y_n - np)/\sqrt{np(1-p)} \leq u_{\alpha/2}) \approx 1 - \alpha \quad (4.11)$$

可改写为

$$P(A \leq p \leq B) \approx 1 - \alpha \quad (4.12)$$

其中 A, B 是二次方程

$$(Y_n - np)^2 / (np(1-p)) = u_{\alpha/2}^2$$

的两个根,即

$$A, B = \frac{n}{n + u_{\alpha/2}^2} \left(\hat{p} + \frac{u_{\alpha/2}^2}{2n} \pm u_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{u_{\alpha/2}^2}{4n^2}} \right) \quad (4.13)$$

A 取负号, B 取正号, $\hat{p} = Y_n/n$.

因为(4.11)和(4.12)只是近似的,故区间估计 $[A, B]$ 的置信系数,也只是近似地等于 $1 - \alpha$. 当 n 较大,例如 $n \geq 30$ 时,相去不远,实际上, n 太小时,找 p 的区间估计意义不大. 因为这种区间都失之过长,实际意义不大. 这可由下面的分析看出: 由于 $0 \leq \hat{p} \leq 1$, $\hat{p}(1-\hat{p})$ 的最大值可为 $1/4$. 这时,区间 $[A, B]$ 之长,在把 $\hat{p}(1-\hat{p})$ 改为 $1/4$ 后,为 $u_{\alpha/2}/\sqrt{n + u_{\alpha/2}^2}$. 取 $\alpha = 0.05$, 有 $u_{\alpha/2} = 1.96$. 若要求这区间之长不超过 0.3 (这是一个很低的要求), 必须 $1.96/\sqrt{n + (1.96)^2} \leq 0.3$. 算出 n 至少应为 39 . 可以看出: 在试验次数 n 低于 40 时,求 p 的区间估计没有多大实用意义.

例 4.6 设 X_1, \dots, X_n 为抽自有波哇松分布 $P(\lambda)$ 的总体的样本,求 λ 的区间估计.

记 $Y_n = X_1 + \cdots + X_n$. 设 n 相当大, 注意到波哇松分布的均值方差都是 λ , 由第三章定理 4.2, 知 $(Y_n - n\lambda)/\sqrt{n\lambda}$ 近似地有分布 $N(0, 1)$. 仿前例的做法, 即得到 λ 的区间估计 $[A, B]$, A, B 为二次方程

$$(Y_n - n\lambda)^2 = n\lambda u_{\alpha/2}^2$$

的两根, 即

$$A, B = \bar{X} + u_{\alpha/2}^2/(2n) \pm u_{\alpha/2} \sqrt{u_{\alpha/2}^2/(4n^2) + \bar{X}/n} \quad (4.14)$$

A 取负号, B 取正号, $\bar{X} = Y_n/n$.

例 4.7 设某总体有均值 θ , 方差 σ^2 . θ 和 σ^2 都未知, 从这总体中抽出样本 X_1, \cdots, X_n , 要作 θ 的区间估计.

因为对总体分布没有作任何假定, 要作出满足条件 1°—4°的枢轴变量是不可能的. 但是, 若 n 相当大, 则据中心极限定理(第三章定理 4.2), 有 $\sqrt{n}(\bar{X} - \theta)/\sigma \sim N(0, 1)$. 但此处 σ 未知, 仍不能以 $\sqrt{n}(\bar{X} - \theta)/\sigma$ 作为枢轴变量. 因为 n 相当大, 样本均方差 S 是 σ 的一个相合估计, 故可近似地用 S 代 σ , 得

$$\sqrt{n}(\bar{X} - \theta)/S \sim N(0, 1)$$

由此就不难得出 θ 的区间估计

$$[\bar{X} - S\mu_{\alpha/2}/\sqrt{n}, \bar{X} + S\mu_{\alpha/2}/\sqrt{n}]$$

它的置信系数, 当 n 相当大时, 近似地为 $1 - \alpha$. 近似的程度如何不仅取决于 n 的大小, 还要看总体的分布如何.

例 4.8 考虑在例 4.2 中提出的贝伦斯-费歇尔问题: X_1, \cdots, X_n 是从正态总体 $N(\mu, \sigma_1^2)$ 中抽出的样本, Y_1, \cdots, Y_m 是从正态总体 $N(\mu_2, \sigma_2^2)$ 中抽出的样本, 要求 $\mu_1 - \mu_2$ 的区间估计.

在本例中有

$$[(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)]/\sqrt{\sigma_1^2/n + \sigma_2^2/m} \sim N(0, 1) \quad (4.15)$$

这里没有近似: 分布是严格成立的. 但是, 由于 σ_1, σ_2 未知, (4.15)

并不构成枢轴变量. 如果 n, m 都相当大, 则 σ_1^2 和 σ_2^2 分别可用 X 样本的样本方差 S_1^2 和 Y 样本的样本方差 S_2^2 近似地代替之, 得

$$\frac{[(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)]}{\sqrt{S_1^2/n + S_2^2/m}} \sim N(0, 1) \quad (4.16)$$

与(4.15)不同, (4.16)只是近似而非严格. (4.16)可作为枢轴变量, 而得出 $\mu_1 - \mu_2$ 的区间估计. 当然, 其置信系数只是近似的.

例 4.5—4.8 所导出的区间估计, 叫“大样本区间估计”. 一般如果一个统计方法是基于有关变量的当样本大小 n 很大时的极限分布, 则称这一统计方法为“大样本方法”. 反之, 若依据的是有关变量的确切分布, 则称为“小样本方法”. 如例 4.1—4.4 导出的区间估计就是小样本区间估计. 这不在于 n 多大多小: 在例 4.1—4.4 中, 即使样本大小 $n = 10^{10}$, 仍是小样本方法. 对例 4.5 而言, 因使用的是极限分布, 即使 $n = 40$, 仍算是大样本方法, 不言而喻, 大样本方法只有在样本大小较大时才宜于使用.

4.4.4 置信界

在实际问题中, 有时我们只对参数 θ 的一端的界限感兴趣. 例如, θ 是在一种物质中某种杂质的百分率, 则我们可能只关心其上界, 即要求找到这样一个统计量 $\bar{\theta}$, 使 $\{\theta \leq \bar{\theta}\}$ 的概率很大. $\bar{\theta}$ 就称为 θ 的置信上界(或上限). 又如, θ 是某种材料的强度, 则我们可能只关心其下界, 即要求找到这样一个统计量 $\underline{\theta}$, 使 $\{\theta \geq \underline{\theta}\}$ 的概率很大. $\underline{\theta}$ 就称为 θ 的置信下界(或下限). 下面给出正式的定义, 为行文简单, 就以一个参数 θ 的情况为例.

定义 4.2 设 X_1, \dots, X_n 是从某一总体中抽出的样本, 总体分布包含未知参数 θ , $\bar{\theta} = \bar{\theta}(X_1, \dots, X_n)$ 和 $\underline{\theta} = \underline{\theta}(X_1, \dots, X_n)$ 都是统计量(它们与 θ 无关), 则

1. 若对 θ 的一切可取的值有

$$P_{\theta}(\bar{\theta}(X_1, \dots, X_n) \geq \theta) = 1 - \alpha \quad (4.17)$$

则称 $\bar{\theta}$ 为 θ 的一个置信系数为 $1 - \alpha$ 的置信上界;

2. 若对 θ 的一切可取的值有

$$P_{\theta}(\underline{\theta}(X_1, \dots, X_n) \leq \theta) = 1 - \alpha \quad (4.18)$$

则称 $\underline{\theta}$ 为 θ 的一个置信系数为 $1 - \alpha$ 的置信下界.

把(4.17)与(4.18)与区间估计的置信系数定义去比较, 看出: 置信上、下界无非是一种特殊的置信区间, 其一端为 ∞ 或 $-\infty$. 因此, 前面用于求区间估计的方法, 都很容易平行地移至此处. 例如, 找 $N(\mu, \sigma^2)$ 的均值 μ 的置信下界, 假定 σ^2 已知, 以 $\sqrt{n}(\bar{X} - \mu)/\sigma$ 为枢轴变量, 其分布为 $N(0, 1)$. 有

$$P(\sqrt{n}(\bar{X} - \mu)/\sigma \leq u_{\alpha}) = 1 - \alpha$$

此式可改写为

$$P(\mu \geq \bar{X} - u_{\alpha}\sigma/\sqrt{n}) = 1 - \alpha \quad (4.19)$$

把(4.19)与(4.18)比较, 即知 $\bar{X} - u_{\alpha}\sigma/\sqrt{n}$ 为 μ 的一个置信下界, 置信系数为 $1 - \alpha$. 将这个办法用于以前讨论过的诸例, 得出一些置信上、下界的结果, 例如(记号均见有关各例):

1. 例 4.1 μ 的置信上、下界分别为(正号为上界)

$$\bar{X} \pm St_{n-1}(\alpha)/\sqrt{n}$$

2. 例 4.2 $\mu_1 - \mu_2$ 的置信上、下界分别为(正号为上界)

$$(\bar{X} - \bar{Y}) \pm St_{n+m-2}(\alpha) \sqrt{\frac{m+n}{mn}}$$

3. 例 4.3 σ^2 的置信上界为 $(n-1)S^2/\chi_{n-1}^2(1-\alpha)$, 下界为 $(n-1)S^2/\chi_{n-1}^2(\alpha)$.

以上置信系数都是 $1 - \alpha$, 其余各例都与此类似, 我们注意到一点: 在置信区间中的 $\alpha/2$ 在这里都被 α 取代. 这是由于区间估计是双侧的. 共为 α 的概率由两边均分, 各占 $\alpha/2$. 而置信界则是单侧的.

4.4.5 贝叶斯法

用贝叶斯法处理统计问题的基本思想, 已在 4.2 节 4.2.4 中阐述过了. 用它来处理区间估计问题, 概念上和做法上都很简单:

沿用 4.2 节 4.2.4 中的记号. 在有了先验分布密度 $h(\theta)$ 和样本 X_1, \dots, X_n 后, 算出后验密度 $h(\theta | X_1, \dots, X_n)$. 再找两个数 $\hat{\theta}_1, \hat{\theta}_2$ 都与 X_1, \dots, X_n 有关, 使

$$\int_{\hat{\theta}_1}^{\hat{\theta}_2} h(\theta | X_1, \dots, X_n) d\theta = 1 - \alpha \quad (4.20)$$

区间 $[\hat{\theta}_1, \hat{\theta}_2]$ 的意思是: 在所得后验分布之下, θ 落在这区间内的概率为 $1 - \alpha$. 因此, $[\hat{\theta}_1, \hat{\theta}_2]$ 可作为 θ 的一区间估计, 其后验信度为 $1 - \alpha$. “后验”是指“有了样本以后”的意思. 因此, 所谓“后验信度为 $1 - \alpha$ ”, 可以解释为: 在已有了样本以后, 我对区间 $[\hat{\theta}_1, \hat{\theta}_2]$ 能包含未知参数 θ 的相信程度为 $1 - \alpha$. 这与奈曼理论中的置信系数的含义相似, 但理论观念上有别. 因为这里整个架构根本不同.

如果要找贝叶斯上下界, 则只须把(4.20)分别改为

$$\int_{-\infty}^{\hat{\theta}} h(\theta | X_1, \dots, X_n) d\theta = 1 - \alpha (\text{上界}) \quad (4.21)$$

和

$$\int_{\hat{\theta}}^{\infty} h(\theta | X_1, \dots, X_n) d\theta = 1 - \alpha (\text{下界}) \quad (4.22)$$

对(4.20)而言还有一个问题: 满足条件(4.20)的 $\hat{\theta}_1, \hat{\theta}_2$ 很多, 如何决定一对? 一般是以使 $\hat{\theta}_1 - \hat{\theta}_2$ 最小为原则* (也可以是使 $\hat{\theta}_2 / \hat{\theta}_1$ 最小, 这要看参数的性质与实际问题中的要求如何而定). 下面将通过例子解释这一点.

例 4.9 考虑例 2.14. 在该例中所规定的先验分布之下, 找 θ

* 另一种可取的方法是找 $\hat{\theta}_1, \hat{\theta}_2$, 使

$$\int_{-\infty}^{\hat{\theta}_1} h(\theta | X_1, \dots, X_n) d\theta = \alpha/2, \quad \int_{\hat{\theta}_2}^{\infty} h(\theta | X_1, \dots, X_n) d\theta = \alpha/2$$

的区间估计.

在该例中已找出 θ 的后验分布为 $N(t, \eta^2)$, t, η^2 分别由 (2.17), (2.18) 决定, 这个密度函数在 t 点处达到最大值, 然后在两边对称地下降. 由此易见, 如要找 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 满足 (4.20) 式, 它只有在 $\hat{\theta}_1, \hat{\theta}_2 = t \pm c$ 时才能使 $\hat{\theta}_2 - \hat{\theta}_1$ 最小. 由正态分布即知, c 必须取为 $\eta\mu_{\alpha/2}$. 于是得出贝叶斯区间估计

$$[t - \eta\mu_{\alpha/2}, t + \eta\mu_{\alpha/2}]$$

其后验信度为 $1 - \alpha$.

例 4.10 考虑例 2.13. 在此已求出当取 $R(0, 1)$ 为先验分布时, p 的后验密度为

$$\begin{aligned} h(p | X_1, \dots, X_n) \\ = p^X(1-p)^{n-X} / \beta(X+1, n-X+1), 0 \leq p \leq 1 \end{aligned} \quad (4.23)$$

要找 \hat{p}_1, \hat{p}_2 , 使

$$\int_{\hat{p}_1}^{\hat{p}_2} p^X(1-p)^{n-X} dp / \beta(X+1, n-X+1) = 1 - \alpha$$

并使 $\hat{p}_2 - \hat{p}_1$ 最小, 问题就麻烦些. (4.23)

的图形大致如图 4.3. 它在点 $p = X/n$ 处达到最大, 然后往两边下降. 故只有图中 c, d 那种对子, 才能使 $d - c$ 最小. 方法是: 先在 X/n 左边取定一个值 c . 由方程

$$c^X(1-c)^{n-X} = p^X(1-p)^{n-X}$$

以 p 为未知量, 解出 $p = d$. 从图 4.3 看出, d 必大于 X/n . 计算积分

$$\int_c^d p^X(1-p)^{n-X} dp / \beta(X+1, n-X+1) = A$$

若 $A > 1 - \alpha$, 表示 c 取得太小. 若 $A < 1 - \alpha$, 则表示 c 取得太大. 经过几次调整后即可找到足够接近的近似值.

与奈曼的理论相比, 我们看出, 这里求区间估计的过程容易多




图 4.3

了.固然,在寻找适合(4.20)的 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 时,往往计算很繁,但并无原则困难,用计算机也很容易实现.但用奈曼的方法,则涉及到麻烦的分布问题.如例4.1—4.4这几个例,就基于有关的统计量服从 t 分布,卡方和 F 分布等.这不是常有的情况,而只是少见的几个特例(幸好这几个特例在实用中用得很多).往往由于分布问题无法解决,而只好求助于大样本理论.实用上往往样本不很大,使我们对由此而产生的误差(即实际的置信系数与名义的置信系数的距离)不甚了然.贝叶斯方法不存在这些问题.当然,贝叶斯方法有其自身的问题,即先验分布如何定,这一点我们在前面已提过了.