

一. 随机事件和概率

1、 概率的定义和性质

(1) 概率的公理化定义

设 Ω 为样本空间, A 为事件, 对每一个事件 A 都有一个实数 $P(A)$, 若满足下列三个条件:

1° $0 \leq P(A) \leq 1$,

2° $P(\Omega) = 1$

3° 对于两两互不相容的事件 A_1, A_2, \dots 有

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$$

常称为可列 (完全) 可加性。

则称 $P(A)$ 为事件 A 的概率。

(2) 古典概型 (等可能概型)

1° $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$,

2° $P(\omega_1) = P(\omega_2) = \dots = P(\omega_n) = \frac{1}{n}$ 。

设任一事件 A , 它是由 $\omega_1, \omega_2, \dots, \omega_m$ 组成的, 则有

$$P(A) = \{P(\omega_1) + P(\omega_2) + \dots + P(\omega_m)\}$$

$$= P(\omega_1) + P(\omega_2) + \dots + P(\omega_m)$$

$$= \frac{m}{n} = \frac{A \text{ 所包含的基本事件数}}{\text{基本事件总数}}$$

2、 五大公式 (加法、减法、乘法、全概、

贝叶斯)

(1) 加法公式

$$P(A+B) = P(A) + P(B) - P(AB)$$

当 $P(AB) = 0$ 时, $P(A+B) = P(A) + P(B)$

(2) 减法公式

$$P(A-B) = P(A) - P(AB)$$

当 $B \subset A$ 时, $P(A-B) = P(A) - P(B)$

当 $A = \Omega$ 时, $P(\bar{B}) = 1 - P(B)$

(3) 条件概率和乘法公式

定义 设 A, B 是两个事件, 且 $P(A) > 0$, 则称 $\frac{P(AB)}{P(A)}$ 为事件

A 发生条件下, 事件 B 发生的条件概率, 记为

$$P(B|A) = \frac{P(AB)}{P(A)}$$

条件概率是概率的一种, 所有概率的性质都适合于条件概率。

(4) 全概公式

设事件 B_1, B_2, \dots, B_n 满足

1° B_1, B_2, \dots, B_n 两两互不相容, $P(B_i) > 0 (i = 1, 2, \dots, n)$,

$$A \subset \bigcup_{i=1}^n B_i$$

2°

则有

$$P(A) = P(B_1)P(A|B_1) + P(B_2)P(A|B_2) + \dots + P(B_n)P(A|B_n)$$

此公式即为全概率公式。

(5) 贝叶斯公式

设事件 B_1, B_2, \dots, B_n 及 A 满足

1° B_1, B_2, \dots, B_n 两两互不相容, $P(B_i) > 0, i = 1, 2, \dots, n$,

$$A \subset \bigcup_{i=1}^n B_i, P(A) > 0,$$

则

$$P(B_i|A) = \frac{P(B_i)P(A|B_i)}{\sum_{j=1}^n P(B_j)P(A|B_j)}, i = 1, 2, \dots, n.$$

此公式即为贝叶斯公式。

$P(B_i)$, ($i = 1, 2, \dots, n$), 通常叫先验概率。 $P(B_i|A)$, ($i = 1, 2, \dots, n$), 通常称为后验概率。如果我们把 A 当作观察的“结果”, 而 B_1, B_2, \dots, B_n 理解为“原因”, 则贝叶斯公式反映了“因果”的概率规律, 并作出了“由果溯因”的推断。

3、 事件的独立性和伯努利试验

(1) 两个事件的独立性

设事件 A, B 满足 $P(AB) = P(A)P(B)$, 则称事件 A, B 是相互独立的 (这个性质不是想当然成立的)。

若事件 A, B 相互独立, 且 $P(A) > 0$, 则有

$$P(B|A) = \frac{P(AB)}{P(A)} = \frac{P(A)P(B)}{P(A)} = P(B)$$

所以这与我们所理解的独立性是一致的。

若事件 A, B 相互独立, 则可得到 \bar{A} 与 B, A 与 \bar{B}, \bar{A} 与 \bar{B} 也都相互独立。(证明)

由定义, 我们可知必然事件 Ω 和不可能事件 \emptyset 与任何事件都相互独立。(证明)

同时, \emptyset 与任何事件都互斥。

(2) 多个事件的独立性

设 ABC 是三个事件, 如果满足两两独立的条件,

$$P(AB)=P(A)P(B); P(BC)=P(B)P(C); P(CA)=P(C)P(A)$$

并且同时满足 $P(ABC)=P(A)P(B)P(C)$

那么 A、B、C 相互独立。

对于 n 个事件类似。

两两互斥 \rightarrow 相互互斥。

两两独立 \rightarrow 互相独立?

(3) 伯努利试验

定义 我们作了 n 次试验, 且满足

- ◆ 每次试验只有两种可能结果, A 发生或 A 不发生;
- ◆ n 次试验是重复进行的, 即 A 发生的概率每次均一样;
- ◆ 每次试验是独立的, 即每次试验 A 发生与否与其他次试验 A 发生与否是互不影响的。

这种试验称为伯努利概型, 或称为 n 重伯努利试验。

用 P 表示每次试验 A 发生的概率, 则 \bar{A} 发生的概率为 $1-p=q$, 用 $P_n(k)$ 表示 n 重伯努利试验中 A 出现 $k(0 \leq k \leq n)$ 次的概率,

二. 随机变量及其分布

1、随机变量的分布函数

(1) 离散型随机变量的分布率

设离散型随机变量 X 的可能取值为 $X_k(k=1, 2, \dots)$ 且取各个值的概率, 即事件 $(X=X_k)$ 的概率为

$$P(X=X_k)=p_k, k=1, 2, \dots,$$

则称上式为离散型随机变量 X 的概率分布或分布律。有时也用分布列的形式给出:

$$\begin{array}{c|c} X & x_1, x_2, \Lambda, \dots, x_k, \Lambda \\ \hline P(X = x_k) & p_1, p_2, \Lambda, \dots, p_k, \Lambda \end{array}$$

显然分布律应满足下列条件:

$$(1) p_k \geq 0, k=1, 2, \Lambda,$$

$$(2) \sum_{k=1}^{\infty} p_k = 1$$

(2) 分布函数

对于非离散型随机变量, 通常有 $P(X = x) = 0$, 不可能用分布率表达。例如日光灯管的寿命 X, $P(X = x_0) = 0$ 。

所以我们考虑用 X 落在某个区间 $(a, b]$ 内的概率表示。

定义 设 X 为随机变量, x 是任意实数, 则函数

$$F(x) = P(X \leq x)$$

称为随机变量 X 的分布函数。

$$P(a < X \leq b) = F(b) - F(a) \quad \text{可以得到 } X \text{ 落入区}$$

间 $(a, b]$ 的概率。也就是说, 分布函数完整地描述了随机变量 X 随机取值的统计规律性。

分布函数 $F(x)$ 是一个普通的函数, 它表示随机变量落入区间 $(-\infty, x]$ 内的概率。

$F(x)$ 的图形是阶梯图形, x_1, x_2, Λ 是第一类间断点, 随机变量 X 在 x_k 处的概率就是 $F(x)$ 在 x_k 处的跃度。

分布函数具有如下性质:

$$1^\circ \quad 0 \leq F(x) \leq 1, \quad -\infty < x < +\infty;$$

$$2^\circ \quad F(x) \text{ 是单调不减的函数, 即 } x_1 < x_2 \text{ 时, 有 } F(x_1) \leq F(x_2);$$

$$3^\circ \quad F(-\infty) = \lim_{x \rightarrow -\infty} F(x) = 0,$$

$$F(+\infty) = \lim_{x \rightarrow +\infty} F(x) = 1;$$

$$4^\circ \quad F(x+0) = F(x), \text{ 即 } F(x) \text{ 是右连续的;}$$

$$5^\circ \quad P(X = x) = F(x) - F(x-0).$$

(3) 连续型随机变量的密度函数

定义 设 $F(x)$ 是随机变量 X 的分布函数, 若存在非负函数 $f(x)$, 对任意实数 x, 有

$$F(x) = \int_{-\infty}^x f(x)dx,$$

则称 X 为连续型随机变量。 $f(x)$ 称为 X 的概率密度函数或密度函数, 简称概率密度。 $f(x)$ 的图形是一条曲线, 称为密度 (分布) 曲线。

由上式可知, 连续型随机变量的分布函数 $F(x)$ 是连续函数。

所以,

$$P(x_1 \leq X \leq x_2) = P(x_1 < X < x_2) = P(x_1 \leq X < x_2) = P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

密度函数具有下面 4 个性质:

$$1^\circ \quad f(x) \geq 0.$$

$$2^\circ \quad \int_{-\infty}^{+\infty} f(x)dx = 1.$$

$F(+\infty) = \int_{-\infty}^{+\infty} f(x)dx = 1$ 的几何意义：在横轴上面、密度曲线下方的全部面积等于 1。

如果一个函数 $f(x)$ 满足 1°、2°，则它一定是某个随机变量的密度函数。

$$3^\circ \quad P(x_1 < X \leq x_2) = F(x_2) - F(x_1) = \int_{x_1}^{x_2} f(x)dx.$$

4° 若 $f(x)$ 在 x 处连续，则有 $F'(x) = f(x)$ 。

$$P(x < X \leq x + dx) \approx f(x)dx$$

它在连续型随机变量理论中所起的作用与 $P(X = x_k) = p_k$

在离散型随机变量理论中所起的作用相类似。

$E \rightarrow \omega, \Omega \rightarrow A \rightarrow P(A)$, (古典概型, 五大公式,

$$X(\omega) \rightarrow X(\omega) \leq x \rightarrow F(x) = P(X \leq x)$$

对于连续型随机变量 X ，虽然有 $P(X = x) = 0$ ，但事件

$(X = x)$ 并非是不可能事件 \emptyset 。

$$P(X = x) \leq P(x < X \leq x + h) = \int_x^{x+h} f(x)dx$$

令 $h \rightarrow 0$ ，则右端为零，而概率 $P(X = x) \geq 0$ ，故得 $P(X = x) = 0$ 。

不可能事件 (\emptyset) 的概率为零，而概率为零的事件不一定是不可事件；同理，必然事件 (Ω) 的概率为 1，而概率为 1 的事件也不一定是必然事件。

2、常见分布

①0-1 分布

$$P(X=1)=p, P(X=0)=q$$

②二项分布

在 n 重贝努里试验中，设事件 A 发生的概率为 p 。事件 A 发生的次数是随机变量，设为 X ，则 X 可能取值为 $0, 1, 2, \dots, n$ 。

$$P(X = k) = P_n(k) = C_n^k p^k q^{n-k}, \quad \text{其中}$$

$$q = 1 - p, 0 < p < 1, k = 0, 1, 2, \dots, n,$$

则称随机变量 X 服从参数为 n, p 的二项分布。记为

$$X \sim B(n, p).$$

$$P(X = k) = \frac{C_n^k p^k q^{n-k}}{q^n, npq^{n-1}, C_n^2 p^2 q^{n-2}, \dots, C_n^k p^k q^{n-k}, \dots, p^n}$$

容易验证，满足离散型分布率的条件。

当 $n = 1$ 时， $P(X = k) = p^k q^{1-k}$ ， $k = 0, 1$ ，这就是 (0-1)

分布，所以 (0-1) 分布是二项分布的特例。

③泊松分布

设随机变量 X 的分布律为

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad \lambda > 0, k = 0, 1, 2, \dots, \lambda,$$

独立性)

则称随机变量 X 服从参数为 λ 的泊松分布，记为

$$X \sim \pi(\lambda) \text{ 或者 } P(\lambda).$$

泊松分布为二项分布的极限分布 ($np = \lambda, n \rightarrow \infty$)。

④超几何分布

$$P(X = k) = \frac{C_M^k \cdot C_{N-M}^{n-k}}{C_N^n}, \quad k = 0, 1, 2, \dots, l, \quad l = \min(M, n)$$

随机变量 X 服从参数为 n, N, M 的超几何分布。

⑤几何分布

$$P(X = k) = q^{k-1} p, k = 1, 2, 3, \dots, \lambda, \quad \text{其中 } p \geq 0, q = 1 - p.$$

随机变量 X 服从参数为 p 的几何分布。

⑥均匀分布

设随机变量 X 的值只落在 $[a, b]$ 内，其密度函数 $f(x)$ 在 $[a, b]$ 上为常数 k ，即

$$f(x) = \begin{cases} k, & a \leq x \leq b \\ 0, & \text{其他,} \end{cases}$$

$$\text{其中 } k = \frac{1}{b-a},$$

则称随机变量 X 在 $[a, b]$ 上服从均匀分布，记为 $X \sim U(a, b)$ 。

分布函数为

$$\begin{cases} 0, & x < a, \\ \frac{x-a}{b-a}, & a \leq x \leq b \end{cases}$$

$$F(x) = \int_{-\infty}^x f(x)dx = 1, \quad x > b.$$

当 $a \leq x_1 < x_2 \leq b$ 时, X 落在区间 (x_1, x_2) 内的概率为

$$P(x_1 < X < x_2) = \int_{x_1}^{x_2} f(x)dx = \int_{x_1}^{x_2} \frac{1}{b-a} dx = \frac{x_2 - x_1}{b-a}.$$

⑦指数分布

设随机变量 X 的密度函数为

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0, \\ 0, & x < 0, \end{cases}$$

其中 $\lambda > 0$, 则称随机变量 X 服从参数为 λ 的指数分布。
 X 的分布函数为

$$F(x) = \begin{cases} 1 - e^{-\lambda x}, & x \geq 0, \\ 0, & x < 0. \end{cases}$$

记住几个积分:

$$\int_0^{+\infty} x e^{-x} dx = 1, \quad \int_0^{+\infty} x^2 e^{-x} dx = 2,$$

$$\int_0^{+\infty} x^{n-1} e^{-x} dx = (n-1)!$$

$$\Gamma(\alpha) = \int_0^{+\infty} x^{\alpha-1} e^{-x} dx, \quad \Gamma(\alpha+1) = \alpha \Gamma(\alpha)$$

⑧正态分布

设随机变量 X 的密度函数为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < +\infty,$$

其中 $\mu, \sigma > 0$ 为常数, 则称随机变量 X 服从参数为 μ, σ 的正态分布或高斯 (Gauss) 分布, 记为 $X \sim N(\mu, \sigma^2)$ 。

$f(x)$ 具有如下性质:

- 1° $f(x)$ 的图形是关于 $x = \mu$ 对称的;
- 2° 当 $x = \mu$ 时, $f(\mu) = \frac{1}{\sqrt{2\pi}\sigma}$ 为最大值;
- 3° $f(x)$ 以 ox 轴为渐近线。

特别当 σ 固定、改变 μ 时, $f(x)$ 的图形形状不变, 只是集体沿 ox 轴平行移动, 所以 μ 又称为位置参数。当 μ 固定、改变 σ 时, $f(x)$ 的图形形状要发生变化, 随 σ 变大, $f(x)$ 图形的形状变得平坦, 所以又称 σ 为形状参数。

若 $X \sim N(\mu, \sigma^2)$, 则 X 的分布函数为

$$F(x) = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt$$

参数 $\mu = 0, \sigma = 1$ 时的正态分布称为标准正态分布, 记为 $X \sim N(0,1)$, 其密度函数记为

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}, \quad -\infty < x < +\infty,$$

分布函数为

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt. \quad \Phi(x) \text{ 是不可求积函数, 其函数值, 已编制成表可供查用。}$$

$\phi(x)$ 和 $\Phi(x)$ 的性质如下:

- 1° $\phi(x)$ 是偶函数, $\phi(x) = \phi(-x)$;
- 2° 当 $x=0$ 时, $\phi(x) = \frac{1}{\sqrt{2\pi}}$ 为最大值;
- 3° $\Phi(-x) = 1 - \Phi(x)$ 且 $\Phi(0) = \frac{1}{2}$ 。

如果 $X \sim N(\mu, \sigma^2)$, 则 $\frac{X-\mu}{\sigma} \sim N(0,1)$ 。

所以我们可以通过变换将 $F(x)$ 的计算转化为 $\Phi(x)$ 的计算, 而 $\Phi(x)$ 的值是可以查表得到的。

$$P(x_1 < X \leq x_2) = \Phi\left(\frac{x_2 - \mu}{\sigma}\right) - \Phi\left(\frac{x_1 - \mu}{\sigma}\right).$$

分位数的定义

3、随机变量函数的分布

随机变量 Y 是随机变量 X 的函数 $Y = g(X)$, 若 X 的分布函数 $F_X(x)$ 或密度函数 $f_X(x)$ 知道, 则如何求出

$Y = g(X)$ 的分布函数 $F_Y(y)$ 或密度函数 $f_Y(y)$ 。

(1) X 是离散型随机变量

已知 X 的分布列为

$$\frac{X}{P(X = x_i)} \left| \begin{array}{c} x_1, x_2, \Lambda, x_n, \Lambda \\ p_1, p_2, \Lambda, p_n, \Lambda \end{array} \right.,$$

显然, $Y = g(X)$ 的取值只可能是 $g(x_1), g(x_2), \Lambda, g(x_n), \Lambda$, 若 $g(x_i)$ 互不相等, 则 Y 的分布列如下:

$$\frac{Y}{P(Y = y_i)} \left| \begin{array}{c} g(x_1), g(x_2), \Lambda, g(x_n), \Lambda \\ p_1, p_2, \Lambda, p_n, \Lambda \end{array} \right.,$$

若有某些 $g(x_i)$ 相等, 则应将对应的 P_i 相加作为 $g(x_i)$ 的概率。

(2) **X 是连续型随机变量**

先利用 X 的概率密度 $f_X(x)$ 写出 Y 的分布函数 $F_Y(y)$, 再利用变上下限积分的求导公式求出 $f_Y(y)$ 。

三. 二维随机变量及其分布

1、二维随机变量的基本概念

(1) **二维连续型随机向量联合分布密度及边缘分布**

对于二维随机向量 $\xi = (X, Y)$, 如果存在非负函数

$f(x, y)(-\infty < x < +\infty, -\infty < y < +\infty)$, 使对任意一个其邻边分别平行于坐标轴的矩形区域 D, 即 $D = \{(X, Y) | a < x < b, c < y < d\}$ 有

$$P\{(X, Y) \in D\} = \iint_D f(x, y) dx dy,$$

则称 ξ 为连续型随机向量; 并称 $f(x, y)$ 为 $\xi = (X, Y)$ 的分布密度或称为 X 和 Y 的联合分布密度。

分布密度 $f(x, y)$ 具有下面两个性质:

(1) $f(x, y) \geq 0$;

(2) $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = 1.$

一般来说, 当 (X, Y) 为连续型随机向量, 并且其联合分布密度为 $f(x, y)$, 则 X 和 Y 的边缘分布密度为

$$f_X(x) = \int_{-\infty}^{+\infty} f(x, y) dy, f_Y(y) = \int_{-\infty}^{+\infty} f(x, y) dx.$$

注意: 联合概率分布 \rightarrow 边缘分布

(2) **条件分布**

当 (X, Y) 为离散型, 并且其联合分布律为

$$P\{(X, Y) = (x_i, y_j)\} = p_{ij} (i, j = 1, 2, \dots, \Lambda),$$

在已知 $X=x_i$ 的条件下, Y 取值的条件分布为

$$P(Y = y_j | X = x_i) = \frac{p_{ij}}{p_{i\cdot}}$$

其中 $p_{i\cdot}, p_{\cdot j}$ 分别为 X, Y 的边缘分布。

当 (X, Y) 为连续型随机向量, 并且其联合分布密度为 $f(x, y)$, 则在已知 $Y=y$ 的条件下, X 的条件分布密度为

$$f(x | y) = \frac{f(x, y)}{f_Y(y)}$$

在已知 $X=x$ 的条件下, Y 的条件分布密度为

$$f(y | x) = \frac{f(x, y)}{f_X(x)}$$

其中 $f_X(x) > 0, f_Y(y) > 0$ 分别为 X, Y 的边缘分布密度。

(3) **常见的二维分布**

① **均匀分布**

设随机向量 (X, Y) 的分布密度函数为

$$f(x, y) = \begin{cases} \frac{1}{S_D} & (x, y) \in D \\ 0, & \text{其他} \end{cases}$$

其中 S_D 为区域 D 的面积, 则称 (X, Y) 服从 D 上的均匀分布, 记为 $(X, Y) \sim U(D)$ 。

② **正态分布**

设随机向量 (X, Y) 的分布密度函数为

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - \frac{2\rho(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \left(\frac{y-\mu_2}{\sigma_2}\right)^2\right]}$$

其中 $\mu_1, \mu_2, \sigma_1 > 0, \sigma_2 > 0, |\rho| < 1$, 共 5 个参数, 则称 (X, Y) 服从二维正态分布,

记为 $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$ 。

由边缘密度的计算公式, 可以推出二维正态分布的两个边缘分布仍为正态分布, 反推则错。

即 $X \sim N(\mu_1, \sigma_1^2), Y \sim N(\mu_2, \sigma_2^2)$ 。

(5) **二维随机向量联合分布函数及其性质**

设 (X, Y) 为二维随机变量, 对于任意实数 x, y , 二元函数

$$F(x, y) = P\{X \leq x, Y \leq y\}$$

称为二维随机向量 (X, Y) 的分布函数, 或称为随机变量 X 和 Y 的联合分布函数。

分布函数是一个以全平面为其定义域, 以事件 $\{(\omega_1, \omega_2) | -\infty < X(\omega_1) \leq x, -\infty < Y(\omega_2) \leq y\}$ 的概率为函数值的一个实值函数。分布函数 $F(x, y)$ 具有以下的基本性质:

(1) $0 \leq F(x, y) \leq 1$;

(2) $F(x, y)$ 分别对 x 和 y 是非减的, 即
 当 $x_2 > x_1$ 时, 有 $F(x_2, y) \geq F(x_1, y)$; 当 $y_2 > y_1$ 时, 有 $F(x, y_2) \geq F(x, y_1)$;

(3) $F(x, y)$ 分别对 x 和 y 是右连续的, 即

$$F(x, y) = F(x + 0, y), F(x, y) = F(x, y + 0);$$

() 4 ()

$$F(-\infty, -\infty) = F(-\infty, y) = F(x, -\infty) = 0, F(+\infty, +\infty) = 1.$$

2、随机变量的独立性

(1) 连续型随机变量

$$f(x, y) = f_x(x) f_y(y)$$

联合分布 \rightarrow 边缘分布 $\rightarrow f(x, y) = f_x(x) f_y(y)$

直接判断, 充要条件:

- ① 可分离变量
- ② 正概率密度区间为矩形

(2) 二维正态分布

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - \frac{2\rho(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \left(\frac{y-\mu_2}{\sigma_2}\right)^2\right]}$$

$$\rho = 0$$

(3) 随机变量函数的独立性

若 X 与 Y 独立, h, g 为连续函数, 则: $h(X)$ 和 $g(Y)$ 独立。

四. 随机变量的数字特征

(1) 一维随机变量及其函数的期望

① 设 X 是离散型随机变量, 其分布律为 $P(X = x_k) = p_k$,

$k=1, 2, \dots, n$,

$$E(X) = \sum_{k=1}^n x_k p_k$$

期望就是平均值。

② 设 X 是连续型随机变量, 其概率密度为 $f(x)$,

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx$$

③ 数学期望的性质

- (1) $E(C) = C$
- (2) $E(CX) = CE(X)$

$$(3) E(X+Y) = E(X) + E(Y), E\left(\sum_{i=1}^n C_i X_i\right) = \sum_{i=1}^n C_i E(X_i)$$

(4) $E(XY) = E(X)E(Y)$, 充分条件: X 和 Y 独立;
 充要条件: X 和 Y 不相关。

(5) $Y = g(X)$

$$\text{离散: } E(Y) = \sum_{i=1}^n g(x_k) p_k$$

$$\text{连续: } E(X) = \int_{-\infty}^{+\infty} x f(x) dx$$

$$E(Y) = \int_{-\infty}^{+\infty} g(x) f(x) dx$$

(2) 方差

$$D(X) = E[X - E(X)]^2, \text{ 方差}$$

$$\sigma(X) = \sqrt{D(X)}, \text{ 标准差}$$

① 离散型随机变量

$$D(X) = \sum_k [x_k - E(X)]^2 p_k$$

② 连续型随机变量

$$D(X) = \int_{-\infty}^{+\infty} [x - E(X)]^2 f(x) dx$$

③ 方差的性质

- (1) $D(C) = 0; E(C) = C$
- (2) $D(aX) = a^2 D(X); E(aX) = aE(X)$
- (3) $D(aX+b) = a^2 D(X); E(aX+b) = aE(X)+b$
- (4) $D(X) = E(X^2) - E^2(X)$
- (5) $D(X+Y) = D(X) + D(Y)$, 充分条件: X 和 Y 独立;

充要条件: X 和 Y 不相

关。

$$D(X \pm Y) = D(X) + D(Y) \pm 2E[(X-E(X))(Y-E(Y))], \text{ 无条件成立。}$$

$$E(X+Y) = E(X) + E(Y), \text{ 无条件成立。}$$

(3) 常见分布的数学期望和方差

分布名称	符号	均值	方差
0-1 分布	$B(1, p)$	p	$p(1-p)$
二项分布	$B(n, p)$	np	$np(1-p)$
泊松分布	$P(\lambda)$	λ	λ
几何分布	$G(p)$	$\frac{1}{p}$	$\frac{1-p}{p^2}$

超几何分布	$H(n, M, N)$	$\frac{nM}{N}$	$\frac{nM}{N} \left(1 - \frac{M}{N}\right) \left(\frac{N-n}{N-1}\right)$
均匀分布	$U(a, b)$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
指数分布	$e(\lambda)$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
正态分布	$N(\mu, \sigma^2)$	μ	σ^2

①0-1分布

X	0	1
	q	p

$E(X) = p, D(X) = pq$

②二项分布 $X \sim B(n, p), P_n(k) = C_n^k p^k q^{n-k}, (k=0, 1, 2, \dots, n)$

$E(X) = np, D(X) = npq$

③泊松分布 $P(\lambda) \quad P(X=k) = \frac{\lambda^k e^{-\lambda}}{k!}, k=0, 1, 2, \dots$

$E(X) = \lambda, D(X) = \lambda$

④超几何分布 $P(X=k) = \frac{C_M^k C_{N-M}^{n-k}}{C_N^n}$

$E(X) = \frac{nM}{N}$

⑤几何分布 $P(X=k) = pq^{k-1}, k=0, 1, 2, \dots$

$E(X) = \frac{1}{p}, D(X) = \frac{q}{p^2}$

⑥均匀分布 $X \sim U[a, b], f(x) = \frac{1}{b-a}, [a, b]$

$E(X) = \frac{a+b}{2}, D(X) = \frac{(b-a)^2}{12}$

⑦指数分布 $f(x) = \lambda e^{-\lambda x}, (x>0)$

$E(X) = \frac{1}{\lambda}, D(X) = \frac{1}{\lambda^2}$

⑧正态分布 $X \sim N(\mu, \sigma^2), f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$

$E(X) = \mu, D(X) = \sigma^2$

2、二维随机变量的数字特征

(1) 协方差和相关系数

对于随机变量 X 与 Y, 称它们的二阶混合中心矩 μ_{11} 为 X

与 Y 的协方差或相关矩, 记为 σ_{XY} 或 $\text{cov}(X, Y)$, 即

$$\sigma_{XY} = \mu_{11} = E[(X - E(X))(Y - E(Y))].$$

与记号 σ_{XY} 相对应, X 与 Y 的方差 D(X) 与 D(Y) 也

可分别记为 σ_{XX} 与 σ_{YY} 。

协方差有下面几个性质:

- (i) $\text{cov}(X, Y) = \text{cov}(Y, X)$;
- (ii) $\text{cov}(aX, bY) = ab \text{cov}(X, Y)$;
- (iii) $\text{cov}(X_1 + X_2, Y) = \text{cov}(X_1, Y) + \text{cov}(X_2, Y)$;
- (iv) $\text{cov}(X, Y) = E(XY) - (E(X))(E(Y))$.

对于随机变量 X 与 Y, 如果 $D(X) > 0, D(Y) > 0$, 则称

$$\frac{\sigma_{XY}}{\sqrt{D(X)}\sqrt{D(Y)}}$$

为 X 与 Y 的相关系数, 记作 ρ_{XY} (有时可简记为 ρ)。

$|\rho| \leq 1$, 当 $|\rho| = 1$ 时, 称 X 与 Y 安全相关:

完全相关 $\begin{cases} \text{正相关, 当 } \rho = 1 \text{ 时,} \\ \text{负相关, 当 } \rho = -1 \text{ 时,} \end{cases}$

而当 $\rho = 0$ 时, 称 X 与 Y 不相关。

与相关系数有关的几个重要结论

- (i) 若随机变量 X 与 Y 相互独立, 则 $\rho_{XY} = 0$;
反之不真。
- (ii) 若 $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$, 则 X
与 Y 相互独立的充要条件是 $\rho = 0$, 即 X 和 Y
不相关。
- (iii) 以下五个命题是等价的:

① $\rho_{XY} = 0$;

② $\text{cov}(X, Y) = 0$;

- ③ $E(XY) = E(X)E(Y)$;
- ④ $D(X+Y) = D(X) + D(Y)$;
- ⑤ $D(X-Y) = D(X) + D(Y)$.

(2) 二维随机变量函数的期望

$$E[G(X, Y)] = \begin{cases} \sum_i \sum_j G(x_i, y_j) p_{ij}, & (X, Y) \text{为离散型;} \\ \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} G(x, y) f(x, y) dx dy, & (X, Y) \text{为连续型.} \end{cases}$$

(3) 原点矩和中心矩

①对于正整数 k , 称随机变量 X 的 k 次幂的数学期望为 X 的 k 阶原点矩, 记为 v_k , 即

$$v_k = E(X^k), \quad k=1, 2, \dots$$

于是, 我们有

$$u_k = \begin{cases} \sum_i x_i^k p_i & \text{当 } X \text{ 为离散型时,} \\ \int_{-\infty}^{+\infty} x^k p(x) dx, & \text{当 } X \text{ 为连续型时.} \end{cases}$$

②对于正整数 k , 称随机变量 X 与 $E(X)$ 差的 k 次幂的数学期望为 X 的 k 阶中心矩, 记为 μ_k , 即

$$\mu_k = E(X - E(X))^k, \quad k=1, 2, \dots$$

于是, 我们有

$$u_k = \begin{cases} \sum_i (x_i - E(X))^k p_i & \text{当 } X \text{ 为离散型时,} \\ \int_{-\infty}^{+\infty} (x - E(X))^k p(x) dx, & \text{当 } X \text{ 为连续型时.} \end{cases}$$

③对于随机变量 X 与 Y , 如果有 $E(X^k Y^l)$ 存在, 则称之为 X

与 Y 的 $k+l$ 阶混合原点矩, 记为 u_{kl} , 即

$$u_{kl} = E[(X - E(X))^k (Y - E(Y))^l].$$

五. 大数定律和中心极限定理

1、切比雪夫不等式

设随机变量 X 具有数学期望 $E(X) = \mu$, 方差 $D(X) = \sigma^2$, 则对于任意正数 ε , 有下列切比雪夫不等式

$$P(|X - \mu| \geq \varepsilon) \leq \frac{\sigma^2}{\varepsilon^2}$$

切比雪夫不等式给出了在未知 X 的分布的情况下, 对概

率

$$P(|X - \mu| \geq \varepsilon)$$

的一种估计, 它在理论上具有重要意义。

2、大数定律

(1) 切比雪夫大数定律

(要求方差有界)

设随机变量 X_1, X_2, \dots 相互独立, 均具有有限方差, 且被同一常数 C 所界: $D(X_i) < C (i=1, 2, \dots)$, 则对于任意的正数 ε , 有

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n E(X_i)\right| < \varepsilon\right) = 1.$$

特殊情形: 若 X_1, X_2, \dots 具有相同的数学期望 $E(X_i) = \mu$, 则上式成为

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| < \varepsilon\right) = 1.$$

或者简写成:

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \mu| < \varepsilon) = 1.$$

切比雪夫大数定律指出, n 个相互独立, 且具有有限的相同的数学期望与方差的随机变量, 当 n 很大时, 它们的算术平均以很大的概率接近它们的数学期望。

(2) 伯努利大数定律

设 μ 是 n 次独立试验中事件 A 发生的次数, p 是事件 A 在每次试验中发生的概率, 则对于任意的正数 ε , 有

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{\mu}{n} - p\right| < \varepsilon\right) = 1.$$

伯努利大数定律说明, 当试验次数 n 很大时, 事件 A 发生的频率与概率有较大判别的可能性很小, 即

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{\mu}{n} - p\right| \geq \varepsilon\right) = 0.$$

这就以严格的数学形式描述了频率的稳定性。

(3) 辛钦大数定律

(不要求存在方差)

设 $X_1, X_2, \dots, X_n, \dots$ 是相互独立同分布的随机变量序列, 且 $E(X_n) = \mu$, 则对于任意的正数 ε 有

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| < \varepsilon\right) = 1.$$

3、中心极限定理

(1) 列维—林德伯格定理

设随机变量 X_1, X_2, \dots 相互独立, 服从同一分布, 且具有相同的数学期望和方差:

$$E(X_k) = \mu, D(X_k) = \sigma^2 \neq 0 (k=1,2,\Lambda), \text{ 则随机变量}$$

$$Y_n = \frac{\sum_{k=1}^n X_k - n\mu}{\sqrt{n}\sigma}$$

的分布函数 $F_n(x)$ 对任意的实数 x , 有

$$\lim_{n \rightarrow \infty} F_n(x) = \lim_{n \rightarrow \infty} P \left\{ \frac{\sum_{k=1}^n X_k - n\mu}{\sqrt{n}\sigma} \leq x \right\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt.$$

或者简写成: $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow \infty} N(0,1)$

此定理也称为**独立同分布**的中心极限定理。

(2) 棣莫弗—拉普拉斯定理

设随机变量 X_1, \dots, X_n 均为具有参数 $n, p (0 < p < 1)$ 的二项分布, 则对于任意实数 x , 有

$$= \lim_{n \rightarrow \infty} P \left\{ \frac{X_n - np}{\sqrt{np(1-p)}} \leq x \right\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt.$$

4、二项定理和泊松定理

(1) 二项定理

若当 $N \rightarrow \infty$ 时, $\frac{M}{N} \rightarrow p (n, k \text{ 不变})$, 则

$$\frac{C_M^K C_{N-M}^{n-k}}{C_N^n} \rightarrow C_n^k P^k (1-p)^{n-k} \quad (N \rightarrow \infty).$$

可见, 超几何分布的极限分布为二项分布。

(2) 泊松定理

若当 $n \rightarrow \infty$ 时, $np \rightarrow \lambda > 0$, 则

$$C_n^k P^k (1-p)^{n-k} \rightarrow \frac{\lambda^k}{k!} e^{-\lambda} \quad (n \rightarrow \infty).$$

其中 $k=0, 1, 2, \dots, n, \dots$ 。

六. 数理统计的基本概念

1、总体、个体和样本

(1) 总体与样本

总体 在数理统计中, 常把被考察对象的某一个(或多个)指标的全体称为总体(或母体); 而把总体中的每一个单元称为样品(或个体)。在以后的讨论中, 我们总是把总体看成一个具有分布的随机变量(或随机向量)。

(2) 样本函数与统计量

设 x_1, x_2, Λ, x_n 为总体的一个样本, 称

$$\varphi = \varphi(x_1, x_2, \Lambda, x_n)$$

为样本函数, 其中 φ 为一个连续函数。如果 φ 中不包含任何未知参数, 则称 $\varphi(x_1, x_2, \Lambda, x_n)$ 为一个统计量。

2、统计量

(1) 常用统计量

样本均值 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i.$

样本方差

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

(与概率论中的方差定义不同)

样本标准差

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

样本 k 阶原点矩

$$M_k = \frac{1}{n} \sum_{i=1}^n x_i^k, k=1,2,\Lambda.$$

样本 k 阶中心矩

$$M'_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k, k=2,3,\Lambda.$$

(二阶中心矩)

$$S^{*2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ 与概率论中的方差定义相同}$$

(2) 统计量的期望和方差

$$E(\bar{X}) = \mu, D(\bar{X}) = \frac{\sigma^2}{n},$$

$$E(S^2) = \sigma^2, \quad E(S^{*2}) = \frac{n-1}{n} \sigma^2,$$

其中 $S^{*2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$, 为二阶中心矩。

3、三个抽样分布 (χ^2 、t、F 分布)

(1) χ^2 分布

设 n 个随机变量 X_1, X_2, \dots, X_n 相互独立, 且服从**标准正态分布**, 可以证明: 它们的平方和

$$W = \sum_{i=1}^n X_i^2$$

的分布密度为

$$f(u) = \begin{cases} \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} u^{\frac{n}{2}-1} e^{-\frac{u}{2}} & u \geq 0, \\ 0, & u < 0. \end{cases}$$

我们称随机变量 W 服从自由度为 n 的 χ^2 分布, 记为 $W \sim$

$\chi^2(n)$, 其中

$$\Gamma\left(\frac{n}{2}\right) = \int_0^{+\infty} x^{\frac{n}{2}-1} e^{-x} dx.$$

所谓自由度是指独立正态随机变量的个数, 它是随机变量分布中的一个重要参数。

χ^2 分布满足可加性: 设

$$Y_i \sim \chi^2(n_i),$$

则

$$Z = \sum_{i=1}^k Y_i \sim \chi^2(n_1 + n_2 + \dots + n_k).$$

注意两个结果: $E(\chi^2) = n, D(\chi^2) = 2n$

(2) t 分布

设 X, Y 是两个相互独立的随机变量, 且

$$X \sim N(0,1), Y \sim \chi^2(n),$$

可以证明: 函数

$$T = \frac{X}{\sqrt{Y/n}}$$

的概率密度为

$$f(t) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi} \Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}} \quad (-\infty < t < +\infty).$$

我们称随机变量 T 服从自由度为 n 的 t 分布, 记为 $T \sim t(n)$ 。

注意两个结果: $E(T) = 0, D(T) = \frac{n}{n-2} (n > 2)$

(3) F 分布

设 $X \sim \chi^2(n_1), Y \sim \chi^2(n_2)$, 且 X 与 Y 独立, 可以证明:

$F = \frac{X/n_1}{Y/n_2}$ 的概率密度函数为

$$f(y) = \begin{cases} \frac{\Gamma\left(\frac{n_1+n_2}{2}\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} \left(\frac{n_1}{n_2}\right)^{\frac{n_1}{2}} y^{\frac{n_1}{2}-1} \left(1 + \frac{n_1}{n_2} y\right)^{-\frac{n_1+n_2}{2}}, \\ 0, \end{cases}$$

我们称随机变量 F 服从第一个自由度为 n_1 , 第二个自由度为 n_2 的 F 分布, 记为 $F \sim f(n_1, n_2)$ 。

正态分布 $\mu_{1-\alpha} = -\mu_\alpha$,

$$t_{1-\alpha}(n) = -t_\alpha(n),$$

$$F_{1-\alpha}(n_1, n_2) = \frac{1}{F_\alpha(n_2, n_1)}$$

4、正态总体下统计量的分布和性质

注意一个定理: \bar{X} 与 S^2 独立。

(1) 正态分布

设 x_1, x_2, \dots, x_n 为来自正态

总体 $N(\mu, \sigma^2)$ 的一个样本, 则样本函数

$$u \stackrel{\text{def}}{=} \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \sim N(0,1).$$

(2) t-分布

设 x_1, x_2, \dots, x_n 为来自正态总体

$N(\mu, \sigma^2)$ 的一个样本, 则样本函数

$$t \stackrel{\text{def}}{=} \frac{\bar{x} - \mu}{S / \sqrt{n}} \sim t(n-1),$$

其中 $t(n-1)$ 表示自由度为 $n-1$ 的 t 分布。

(3) κ^2 分布 设 x_1, x_2, Λ, x_n 为来自正态总

体 $N(\mu, \sigma^2)$ 的一个样本, 则样本函数

$$w \stackrel{\text{def}}{=} \frac{(n-1)S^2}{\sigma^2} \sim \kappa^2(n-1),$$

其中 $\kappa^2(n-1)$ 表示自由度为 $n-1$ 的 κ^2 分布。

(4) F 分布 设 x_1, x_2, Λ, x_n 为来自正态总体

$N(\mu, \sigma^2)$ 的一个样本, 而 y_1, y_2, Λ, y_n 为来自正态总体

$N(\mu, \sigma^2)$ 的一个样本, 则样本函数

$$F \stackrel{\text{def}}{=} \frac{S_1^2 / \sigma_1^2}{S_2^2 / \sigma_2^2} \sim F(n_1 - 1, n_2 - 1),$$

其中

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (x_i - \bar{x})^2, \quad S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (y_i - \bar{y})^2;$$

$F(n_1 - 1, n_2 - 1)$ 表示第一自由度为 $n_1 - 1$, 第二自由度为 $n_2 - 1$ 的 F 分布。

七. 参数估计

1、点估计的两种方法

(1) 矩法

所谓矩法就是利用样本各阶原点矩与相应的总体矩, 来建立估计量应满足的方程, 从而求得未知参数估计量的方法。

设总体 X 的分布中包含有未知数 $\theta_1, \theta_2, \Lambda, \theta_m$, 则其分布函数可以表成 $F(x; \theta_1, \theta_2, \Lambda, \theta_m)$. 显示它的 k 阶原点矩

$v_k = E(X^k) (k=1, 2, \Lambda, m)$ 中也包含了未知参数

$\theta_1, \theta_2, \Lambda, \theta_m$, 即 $v_k = v_k(\theta_1, \theta_2, \Lambda, \theta_m)$ 。又设

x_1, x_2, Λ, x_n 为总体 X 的 n 个样本值, 其样本的 k 阶原点矩为

$$\hat{v}_k = \frac{1}{n} \sum_{i=1}^n x_i^k \quad (k=1, 2, \Lambda, m).$$

这样, 我们按照“当参数等于其估计量时, 总体矩等于相应的样本矩”的原则建立方程, 即有

$$\begin{cases} v_1(\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m) = \frac{1}{n} \sum_{i=1}^n x_i, \\ v_2(\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m) = \frac{1}{n} \sum_{i=1}^n x_i^2, \\ \Lambda \Lambda \Lambda \Lambda \Lambda \Lambda \Lambda \Lambda \Lambda \\ v_m(\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m) = \frac{1}{n} \sum_{i=1}^n x_i^m. \end{cases}$$

由上面的 m 个方程中, 解出的 m 个未知参数 $(\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m)$ 即为参数 $(\theta_1, \theta_2, \Lambda, \theta_m)$ 的矩估计量。

(2) 最大似然法

所谓最大似然法就是当我们用样本的函数值估计总体参数时, 应使得当参数取这些值时, 所观测到的样本出现的概率为最大。

当总体 X 为连续型随机变量时, 设其分布密度为 $f(x; \theta_1, \theta_2, \Lambda, \theta_m)$, 其中 $\theta_1, \theta_2, \Lambda, \theta_m$ 为未知参数。

又设 x_1, x_2, Λ, x_n 为总体的一个样本, 称

$$L_n(\theta_1, \theta_2, \Lambda, \theta_m) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \Lambda, \theta_m)$$

为样本的似然函数, 简记为 L_n .

当总体 X 为离型随机变量时, 设其分布律为 $P\{X = x\} = p(x; \theta_1, \theta_2, \Lambda, \theta_m)$, 则称

$$L(x_1, x_2, \Lambda, x_n; \theta_1, \theta_2, \Lambda, \theta_m) = \prod_{i=1}^n p(x_i; \theta_1, \theta_2, \Lambda, \theta_m)$$

为样本的似然函数。

若似然函数 $L(x_1, x_2, \Lambda, x_n; \theta_1, \theta_2, \Lambda, \theta_m)$ 在 $\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m$ 处取到最大值, 则称 $\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m$ 分别为

$\theta_1, \theta_2, \Lambda, \theta_m$ 的最大似然估计值, 相应的统计量称为最大似然估计量。我们把使 L_n 达到最大的 $\hat{\theta}_1, \hat{\theta}_2, \Lambda, \hat{\theta}_m$ 分别作为 $\theta_1, \theta_2, \Lambda, \theta_m$ 的估计量的方法称为最大似然估计法。

由于 $\ln x$ 是一个递增函数, 所以 L_n 与 $\ln L_n$ 同时达到最大值。我们称

$$\left. \frac{\partial \ln L_n}{\partial \theta_i} \right|_{\theta_i = \hat{\theta}_i} = 0, i = 1, 2, \Lambda, m$$

为似然方程。由多元微分学可知, 由似然方程可以求出 $\hat{\theta}_i = \hat{\theta}_i(x_1, x_2, \Lambda, x_n) (i = 1, 2, \Lambda, m)$ 为 θ_i 的最大似然估计量。

容易看出, 使得 L_n 达到最大的 $\hat{\theta}_i$ 也可以使这组样本值出现的可能性最大。

2、估计量的评选标准

(1) 无偏性

设 $\hat{\theta} = \hat{\theta}(x_1, x_2, \Lambda, x_n)$ 为求知参数 θ 的估计量。若 E

$(\hat{\theta}) = \theta$, 则称 $\hat{\theta}$ 为 θ 的无偏估计量。

若总体 X 的均值 $E(X)$ 和方差 $D(X)$ 存在, 则样本均值 \bar{x} 和样本方差 S^2 分别为 $E(X)$ 和 $D(X)$ 的无偏估计, 即

$$E(\bar{x}) = E(X), \quad E(S^2) = D(X).$$

(2) 有效性

设 $\hat{\theta}_1 = \hat{\theta}_1(x_1, x_2, \Lambda, x_n)$ 和 $\hat{\theta}_2 = \hat{\theta}_2(x_1, x_2, \Lambda, x_n)$

是未知参数 θ 的两个无偏估计量。若 $D(\hat{\theta}_1) < D(\hat{\theta}_2)$, 则称

$\hat{\theta}_1$ 比 $\hat{\theta}_2$ 有效。

(3) 一致性 (相合性)

设 $\hat{\theta}_n$ 是 θ 的一串估计量, 如果对于任意的正数 ε , 都有

$$\lim_{n \rightarrow \infty} P(|\hat{\theta}_n - \theta| > \varepsilon) = 0,$$

则称 $\hat{\theta}_n$ 为 θ 的一致估计量 (或相合估计量)。

3、区间估计

(1) 置信区间和置信度

设总体 X 含有一个待估的未知参数 θ 。如果我们从样本 x_1, x_2, Λ, x_n 出发, 找出两个统计量

$$\theta_1 = \theta_1(x_1, x_2, \Lambda, x_n) \quad \text{与}$$

$$\theta_2 = \theta_2(x_1, x_2, \Lambda, x_n) \quad (\theta_1 < \theta_2),$$

使得区间 $[\theta_1, \theta_2]$ 以 $1 - \alpha (0 < \alpha < 1)$ 的概率包含这个待估参数 θ , 即

$$P\{\theta_1 \leq \theta \leq \theta_2\} = 1 - \alpha,$$

那么称区间 $[\theta_1, \theta_2]$ 为 θ 的置信区间, $1 - \alpha$ 为该区间的置信度 (或置信水平)。

(2) 单正态总体的期望和方差的区间估计

设 x_1, x_2, Λ, x_n 为总体 $X \sim N(\mu, \sigma^2)$ 的一个样本, 在置信度为 $1 - \alpha$ 下, 我们来确定 μ 和 σ^2 的置信区间 $[\theta_1, \theta_2]$ 。具体步骤如下:

- (i) 选择样本函数;
- (ii) 由置信度 $1 - \alpha$, 查表找分位数;
- (iii) 导出置信区间 $[\theta_1, \theta_2]$ 。

下面分三种情况来讨论。

① 已知方差, 估计均值

(i) 选择样本函数

设方差 $\sigma^2 = \sigma_0^2$, 其中 σ_0^2 为已知数。我们知道

$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ 是 μ 的一个点估计, 并且知道包含未知参数

μ 的样本函数。

$$u = \frac{\bar{x} - \mu}{\sigma_0 / \sqrt{n}} \sim N(0, 1).$$

(ii) 查表找分位数

对于给定的置信度 $1 - \alpha$, 查正态分布分位数表, 找出分位数 λ , 使得

$$P(|u| \leq \lambda) = 1 - \alpha.$$

即

$$P\left(-\lambda \leq \frac{\bar{x} - \mu}{\sigma_2 / \sqrt{n}} \leq \lambda\right) = 1 - \alpha.$$

(iii) 导出置信区间
由不等式

$$-\lambda \leq \frac{(\bar{x} - \mu)\sqrt{n}}{\sigma_2} \leq \lambda$$

推得

$$\bar{x} - \lambda \frac{\sigma_0}{\sqrt{n}} \leq \mu \leq \bar{x} + \lambda \frac{\sigma_0}{\sqrt{n}},$$

这就是说, 随机区间

$$\left[\bar{x} - \lambda \frac{\sigma_0}{\sqrt{n}}, \bar{x} + \lambda \frac{\sigma_0}{\sqrt{n}} \right]$$

以 $1 - \alpha$ 的概率包含 μ 。

② 未知方差, 估计均值

(i) 选择样本函数

设 x_1, x_2, \dots, x_n 为总体 $N(\mu, \sigma^2)$ 的一个样本, 由于

σ^2 是未知的, 不能再选取样本函数 u 。这时可用样本方差

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

来代替 σ^2 , 而选取样本函数

$$t = \frac{\bar{x} - \mu}{S / \sqrt{n}} \sim t(n-1).$$

(ii) 查表找分位数

对于给定的置信度 $1 - \alpha$, 查 t 分位数表, 找出分位数 λ , 使得

$$P(|u| \leq \lambda) = 1 - \alpha.$$

即

$$P\left(-\lambda \leq \frac{\bar{x} - \mu}{S / \sqrt{n}} \leq \lambda\right) = 1 - \alpha.$$

(iii) 导出置信区间
由不等式

$$-\lambda \leq \frac{(\bar{x} - \mu)\sqrt{n}}{\sigma_2} \leq \lambda$$

推得

$$\bar{x} - \lambda \frac{S}{\sqrt{n}} \leq \mu \leq \bar{x} + \lambda \frac{S}{\sqrt{n}},$$

这就是说, 随机区间

$$\left[\bar{x} - \lambda \frac{S}{\sqrt{n}}, \bar{x} + \lambda \frac{S}{\sqrt{n}} \right]$$

以 $1 - \alpha$ 的概率包含 μ 。

③ 方差的区间估计

(i) 选择样本函数

设 x_1, x_2, \dots, x_n 为来自总体 $N(\mu, \sigma^2)$ 的一个样本,

$$\text{我们知道 } S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

是 σ^2 的一个点估计, 并且知道包含未知参数 σ^2 的样本函数

$$\omega = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1).$$

(ii) 查表找分位数

对于给定的置信度 $1 - \alpha$, 查 χ^2 分布分位数表, 找出两个分位数 λ_1 与 λ_2 , 使得由于 χ^2 分布不具有对称性, 因此通常采取使得概率对称的区间, 即

$$P(\lambda_1 \leq \omega \leq \lambda_2) = 1 - \alpha.$$

于是有

$$P\left(\lambda_1 \leq \frac{(n-1)S^2}{\sigma^2} \leq \lambda_2\right) = 1 - \alpha.$$

(iii) 导出置信区间

$$\lambda_1 \leq \frac{(n-1)S^2}{\sigma^2} \leq \lambda_2$$

由不等式

$$\frac{(n-1)S^2}{\lambda_2} \leq \sigma^2 \leq \frac{(n-1)S^2}{\lambda_1}$$

以 $1 - \alpha$ 的概率包含 σ^2 , 而随机区间

$$\left[\sqrt{\frac{n-1}{\lambda_2}} S, \sqrt{\frac{n-1}{\lambda_1}} S \right]$$

以 $1 - \alpha$ 的概率包含 σ 。