

概率与统计

随机变量的常见分布·记1.2

一维常见分布

符号

分布

$E(X)$ $D(X)$

1. 离散型

$$\textcircled{1} \quad 0-1\text{分布(两点分布)} \quad X \sim B(1, p) \quad P(X=k) = p^k q^{1-k} \quad (k=0,1) \quad p \quad pq$$

$$\textcircled{2} \quad \text{二项分布} \quad X \sim B(n, p) \quad P(X=k) = C_n^k p^k q^{n-k} \quad (k=0,1,\dots,n) \quad np \quad npq$$

用于有放回抽样

P 先上升后下降, 当 $[n+1]p$ 为整数时, 在 $k=[n+1]p, [n+1]p-1$ 时最大;

$[n+1]p$ 不为整数时, 在 k 为 $[n+1]p$ 的整数部分时最大

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

若 $X \sim P(\lambda_1), Y \sim P(\lambda_2)$ 相互独立, 则 $X+Y \sim P(\lambda_1+\lambda_2)$

$$\textcircled{4} \quad \text{几何分布} \quad X \sim G(p) \quad P(X=k) = q^{k-1} p \quad (k=1,2,\dots) \quad \frac{1}{p} \quad \frac{q}{p^2}$$

性质: 无记忆性, 即 $P: X \sim G(p) \Rightarrow P\{X > n+m | X > n\} = P\{X > m\}$

$$\textcircled{5} \quad \text{超几何分布} \quad X \sim H(n, N, M) \quad P(X=k) = \frac{C_m^k C_{N-m}^{n-k}}{C_N^n} \quad (k=0,1,\dots, \lfloor \frac{nM}{N} \rfloor) \quad X$$

用于不放回抽样 抽样数, 产品总数, 次品数 $(l = \min\{n, M\})$

定理: 若 $\lim_{N \rightarrow \infty} \frac{M}{N} = p, 0 < p < 1$, 则 $\lim_{N \rightarrow \infty} \frac{C_m^k C_{N-m}^{n-k}}{C_N^n} = C_n^k p^k (1-p)^{n-k} \quad (k=0,1,\dots,n)$

2. 连续型:

$$\textcircled{1} \quad \text{均匀分布} \quad X \sim U[a,b], \quad f(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b \\ 0, & \text{其他} \end{cases} \quad F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & b \leq x \end{cases} \quad \frac{a+b}{2} \quad \frac{(b-a)^2}{12}$$

$$\textcircled{2} \quad \text{指数分布} \quad X \sim E(\lambda) \quad f(x) = \begin{cases} \lambda e^{-\lambda x}, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad F(x) = \begin{cases} 1 - e^{-\lambda x}, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad \frac{1}{\lambda} \quad \frac{1}{\lambda^2}$$

性质: 无记忆性, 即 $P(X \sim E(\lambda)) \Rightarrow P\{X > n+m | X > n\} = P\{X > m\}$

$$\textcircled{3} \quad \text{正态分布} \quad X \sim N(\mu, \sigma^2), \quad f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad x \in R \quad \mu \quad \sigma^2$$

$$\Rightarrow \int_{-\infty}^{+\infty} e^{-\frac{t^2}{2}} dt = \sqrt{2\pi}$$

$$\text{标准正态分布 } X \sim N(0,1) \quad \varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad x \in R, \quad \Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt, \quad x \in R$$

$$\Rightarrow \varphi(-x) = \varphi(x), \quad \Phi(-x) + \Phi(x) = 1$$

性质: 对于 $X \sim N(\mu, \sigma^2)$, 有 $F_x(x) = \Phi(\frac{x-\mu}{\sigma})$

$$\Rightarrow P(x < X \leq x_2) = F_x(x_2) - F_x(x_1) = \Phi(\frac{x_2-\mu}{\sigma}) - \Phi(\frac{x_1-\mu}{\sigma})$$

常用: 对 $X \sim N(0,1)$ 有 $E(X)=0, D(X)=1 \Rightarrow E(X^2)=1, E(|X|)=\sqrt{\frac{2}{\pi}}, D(|X|)=1-\frac{2}{\pi}$

性质：正态随机变量的线性函数仍为正态随机变量

$$\text{若 } X \sim N(\mu, \sigma^2), \text{ 则 } Y = aX + b \sim N(a\mu + b, a^2\sigma^2)$$

二维正态分布： $(X, Y) \sim N(\mu_1, \mu_2; \sigma_1^2, \sigma_2^2; \rho)$, $\Rightarrow X \sim N(\mu_1, \sigma_1^2)$ $Y \sim N(\mu_2, \sigma_2^2)$

特别地，当 $\rho = 0$ 时。 $(X, Y) \sim N(\mu_1, \mu_2; \sigma_1^2, \sigma_2^2; 0)$

此时 $f(x, y) = f_X(x)f_Y(y)$, X, Y 独立，即

$$\rho = 0 \Leftrightarrow X, Y \text{ 独立} \Leftrightarrow \rho_{XY} = 0, \text{ 即 } X, Y \text{ 不相关}$$

性质：多个相互独立的正态变量的线性组合仍是正态变量

$$X_i \sim N(\mu_i, \sigma_i^2), (i=1, 2, \dots, n) \text{ 且 } X_i \text{ 独立, 则}$$

$$\sum_{i=1}^n X_i = X_1 + X_2 + \dots + X_n \sim N\left(\sum_{i=1}^n \mu_i, \sum_{i=1}^n \sigma_i^2\right)$$

随机变量的和的分布

① X_1, X_2, \dots, X_n 相互独立且 $X_i \sim P(\lambda_i)$ $i=1, 2, \dots, n, R$

$$X_1 + X_2 + \dots + X_n \sim P(\lambda_1 + \lambda_2 + \dots + \lambda_n)$$

② X_1, X_2, \dots, X_n 相互独立且 $X_i \sim B(1, p), R$

$$X_1 + X_2 + \dots + X_n \sim B(n, p)$$

③ X_1, X_2, \dots, X_k 相互独立且 $X_i \sim B(n_i, p)$, $i=1, 2, \dots, k, R$

$$X_1 + X_2 + \dots + X_k \sim B(n_1 + n_2 + \dots + n_k, p)$$

常用表述·记1.2

1. 概率的公理化定义

称实数 $P(A)$ 为事件 A 的概率, 当

① 规范性 $P(\Omega) = 1$ ② $P(A) \geq 0$

③ 可列可加性: 对互斥事件 $A_1, A_2, \dots, A_n, \dots$ 有

$$P(A_1 + A_2 + \dots + A_n + \dots) = P(A_1) + P(A_2) + \dots + P(A_n) + \dots$$

2. 分布函数

某一函数 $F(x)$ 满足: ① $0 \leq F(x) \leq 1, \forall x \in R$ ② $F(x)$ 单调非减

③ $F(-\infty) = 0, F(+\infty) = 1$ ④ $F(x)$ 右连续

\Leftrightarrow 存在随机变量 X 以 $F(x)$ 为其分布函数

3. 分布列

某一数列 $\{P_k\}$ 满足: ① $P_k \geq 0, k=1, 2, \dots$ ② $\sum_k P_k = 1$

\Leftrightarrow 存在离散型 $-X$ 以 $\{P_k\}$ 为其分布列

4. 概率密度

某一函数 $f(x)$ 满足: ① $f(x) \geq 0$ ② $\int_{-\infty}^{+\infty} f(x) dx = 1$

\Leftrightarrow 存在 X 以 $f(x)$ 为概率密度

5. 二维分布函数

某一二维函数 $F(x, y)$ 满足 ① $0 \leq F(x, y) \leq 1, \forall x, y \in R$ ② $F(x, y)$ 对 x, y 都是单调非减

③ $F(-\infty, y) = F(x, -\infty) = F(-\infty, -\infty) = 0, F(+\infty, +\infty) = 1$

④ $F(x, y)$ 关于 x, y 都是右连续的

⑤ $F(x_2, y_2) - F(x_2, y_1) - F(x_1, y_2) + F(x_1, y_1) \geq 0, \forall x_1 \leq x_2, y_1 \leq y_2$

\Leftrightarrow 存在 (X, Y) 以 $F(x, y)$ 为其分布函数

6. 切比雪夫不等式

任意 X , 若 $D(X)$ 存在, 则 $\forall \varepsilon > 0$, 有 $P\{|X - E(X)| \geq \varepsilon\} \leq \frac{D(X)}{\varepsilon^2}$

$$P\{|X - E(X)| < \varepsilon\} \geq 1 - \frac{D(X)}{\varepsilon^2}$$

7. 伯努利大数定律

设在 n 重伯努利试验中成功次数记为 Y_n , 每次试验的成功概率为 $p, (0 < p < 1)$

$\forall \varepsilon > 0$, 有 $\lim_{n \rightarrow \infty} P\left\{ \left| \frac{Y_n}{n} - p \right| \geq \varepsilon \right\} = 0$ $\lim_{n \rightarrow \infty} P\left\{ \left| \frac{Y_n}{n} - p \right| < \varepsilon \right\} = 1$

S1:S2- 機率論

8. 独立同分布的中心极限定理

若随机变量 $X_1, X_2, \dots, X_n, \dots$ 独立同分布, 且 $E(X_i) = \mu, D(X_i) = \sigma^2 > 0$ 有限, 则

$\forall x \in R$, 有 $\lim_{n \rightarrow \infty} P\left\{ \frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n}\sigma} \leq x \right\} = \Phi(x)$

$$\text{其中 } \Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$$

9. 棣莫弗-拉普拉斯定理

设在 n 重伯努利试验中, $\dots Y_n \dots, p, q = 1-p, P(Y_i = 1)$

$\forall x \in R$, 有 $\lim_{n \rightarrow \infty} P\left\{ \frac{Y_n - np}{\sqrt{npq}} \leq x \right\} = \Phi(x)$

第1章 随机事件与概率

一、随机事件

1. 称满足以下三个条件的试验为随机试验，简称试验，用 E 表示。

① 试验可在相同条件下重复进行

② 试验的所有可能结果不止一个，且所有可能结果是事先已知的

③ 每次试验总是恰好出现这些可能结果之一，但究竟是哪个结果无法提前预言

2. 基本事件（样本点）：随机试验的每一个可能结果，用 e 表示。

3. 样本空间：样本点的全体，记为 S

4. 事件：基本事件的集合。

当事件 A 当中的某一基本事件出现时称事件 A 发生；否则称事件 A 不发生

5. S 是必然事件，空集 \emptyset 是不可能事件

二、事件的关系与运算

1. 对立事件一定是互斥的，互斥事件不一定是对立的

2. 若 $A \subset B$ ，则有 $AB = A$, $A \cup B = B$

3. 若 A 与 B 互斥，则记 $A \cup B$ 为 $A+B$

4. $A-B = A\bar{B} = A - AB = A \cup B - B$

5. 多画图

6. 事件的运算性质：

(i) 交换律： $A \cup B = B \cup A$, $AB = BA$

(ii) 结合律： $(A \cup B) \cup C = A \cup (B \cup C)$; $(AB)C = A(BC)$

(iii) 分配律： $(A \cup B) \cap C = AC \cup BC$; $(A \cap B) \cup C = (A \cup C) \cap (B \cup C)$

(iv) 德·摩根律（对偶原理）

$$\overline{\bigcup_{i=1}^n A_i} = \bigcap_{i=1}^n \overline{A_i} = \overline{A_1 \cup A_2 \cup \dots \cup A_n}$$

事件的和的对立等于对立事件的积

$$\overline{\bigcap_{i=1}^n A_i} = \bigcup_{i=1}^n \overline{A_i} = \overline{A_1 \cap A_2 \cap \dots \cap A_n}$$

事件的积的对立等于对立事件的和

三、概率率

1. 概率率的概念与计算

① 古典概率型：其样本空间 S 只含有有限个基本事件，且每个基本事件是等可能的

$$P(A) = \frac{A \text{ 包含的基本事件的个数}}{\text{基本事件的总数}}$$

② 几何概率型：无限性、等可能性

$$P(A) = \frac{\text{子区域 } A \text{ 的度量}}{\text{样本空间 } S \text{ 的度量}} \quad \text{其中度量可能为长度、面积...}$$

③ 统计概率率：概率率是频率的极限

2. 概率率的性质

三个公理 $\begin{cases} (i) \text{ 对任一事件 } A, \text{ 有 } 0 \leq P(A) \leq 1 \\ (ii) \text{ 规范性: } P(S) = 1 \\ (iii) \text{ 可列可加性: 若 } A_1, A_2, \dots, A_n, \dots \text{ 互斥, 则有 } P(A_1 + A_2 + \dots + A_n + \dots) = P(A_1) + P(A_2) + \dots + P(A_n) + \dots \end{cases}$

$$(iv) \quad P(\bar{A}) + P(A) = 1 \quad (v) \quad P(\emptyset) = 0$$

$$(vi) \quad \text{对任意两事件 } A, B, \quad P(A\bar{B}) = P(A - B) = P(A) - P(AB) \Rightarrow P(A) = P(AB) + P(A\bar{B})$$

若 $A \subset B$, 则 $P(A) \leq P(B)$ 且 $P(B-A) = P(B) - P(A)$

$$(vii) \quad \text{一般概率率加法公式: } P(A \cup B) = P(A) + P(B) - P(AB)$$

$$\text{推广} \Rightarrow P(A_1 \cup A_2 \cup \dots \cup A_n) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i; A_j) + \sum_{1 \leq i < j < k \leq n} P(A_i; A_j; A_k) + \dots$$

$$+ (-1)^{n-1} P(A_1; A_2; \dots; A_n)$$

3. 排列与组合

$$\text{排列 } A_n^k = n(n-1)\dots(n-k+1) = \frac{n!}{(n-k)!}$$

$$\text{当 } k=n \text{ 时称为全排列 } A_n^n = n(n-1)\dots2 \cdot 1 = n!$$

$$\text{组合 } C_n^k = \binom{n}{k} = \frac{A_n^k}{k!} = \frac{n!}{k!(n-k)!} = C_n^{n-k} \quad A_n^k = C_n^k \cdot k!$$

4. 常用概率率不等式

$$\text{事件 } A, B, \text{ 有 } P(AB) \leq P(B), P(A) \leq P(A \cup B)$$

第2章 条件概率与独立性

一、条件概率

1. 定义：设 A, B 为两个事件，满足 $P(B) > 0$ ，称比值 $\frac{P(AB)}{P(B)}$ 为事件 A 在事件 B 已发生的条件下的条件概率，记作 $P(A|B) = \frac{P(AB)}{P(B)}$

条件概率也是概率，满足前述概率的性质

$$(i) P(A|B) \geq 0 \quad (ii) P(S|B) = 1$$

$$(iii) \text{若 } A_1, A_2, \dots \text{互不相容, 则 } P((A_1 + A_2 + \dots)|B) = P(A_1|B) + P(A_2|B) + \dots$$

$$(iv) P(\bar{A}|B) + P(A|B) = 1 \quad (v) P(\emptyset|B) = 0$$

$$(vi) P((A_1 - A_2)|B) = P(A_1|B) - P(A_1, A_2|B) \quad \text{当 } A_1 > A_2 \text{ 时, } P(A_1|B) \geq P(A_2|B)$$

$$(vii) P(A_1 \cup A_2|B) = P(A_1|B) + P(A_2|B) - P(A_1, A_2|B)$$

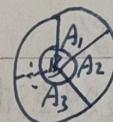
2. 乘法定理： $P(AB) = P(A|B)P(B) = P(B|A)P(A)$

$$\text{推广: } P(A_1, A_2, \dots, A_n) = P(A_1)P(A_2|A_1)P(A_3|A_1, A_2) \dots P(A_n|A_1, A_2, \dots, A_{n-1})$$

二、全概率公式

设事件 A_1, A_2, \dots, A_n 互不相容, 且 $P(A_i) > 0, (i=1, 2, \dots, n)$ 若对事件 B 有 $B \subset A_1 + A_2 + \dots + A_n$,

$$\text{则 } P(B) = \sum_{i=1}^n P(A_i)P(B|A_i)$$



三、贝叶斯公式

引出：在试验中 B 发生了，问引起 B 发生的原因是 A_i 的概率有多大？哪个原因发生的可能性最大？

设事件 A_1, A_2, \dots, A_n 互不相容, 且 $P(A_i) > 0, (i=1, 2, \dots, n)$, 若对事件 B 有 $B \subset A_1 + A_2 + \dots + A_n$ 且 $P(B) > 0$,

$$\text{则 } P(A_i|B) = \frac{P(A_iB)}{P(B)} = \frac{P(A_i)P(B|A_i)}{\sum_{j=1}^n P(A_j)P(B|A_j)} \quad (i=1, 2, \dots, n)$$

$P(A_i)$ 称先验概率，一般是在试验前就已知的。 $P(A_i|B)$ 为后验概率
贝叶斯公式就是根据先验概率求后验概率的公式

四、事件的独立性

1. 定义：设A, B为两个事件，称A与B是相互独立的，当 $P(A \cap B) = P(A)P(B)$ 等价于 $P(B|A) = P(B)$

2. 定理：若A与B相互独立，则 A 与 \bar{B} , \bar{A} 与 B , A 与 \bar{B} 也分别相互独立

3. 性质：若 A 与 B 中有一个的概率为0（或为1），则 A , B 相互独立

若 $0 < P(A), P(B) < 1$ ，则“ A , B 相互独立”与“ A , B 互斥”不能同时成立

注：在实际问题中，对事件 A , B ，常常根据其实际意义来看彼此是否有影响，从而

判断它们是否独立，若独立，则可使用 $P(AB) = P(A)P(B)$

4. 多个事件的独立性

定义：设 A , B , C 为三个事件，称 A , B , C 两两独立，当

$$P(AB) = P(A)P(B) \quad P(BC) = P(B)P(C) \quad P(AC) = P(A)P(C)$$

称 A , B , C 相互独立，当 上三式满足且 $P(ABC) = P(A)P(B)P(C)$ 相互独立 \Rightarrow 两两独立

定理：若事件 A_1, A_2, \dots, A_n 相互独立，则将其中任意一个事件换成其对立事件后，这些事件仍相互独立

五、重复独立试验

1. n 次重复独立试验：进行 n 次试验，在每次试验中，任一事件出现的概率与其他各次结果无关

2. 伯努利试验：试验的结果只有两个 A 和 \bar{A}

3. n 重伯努利试验：伯努利试验的 n 次重复独立试验。

4. 二项概率公式：在 n 重伯努利试验中，设每次试验的成功概率为 $p (0 < p < 1)$,

则成功恰好发生 k 次的概率为 $P_n(k) = C_n^k p^k q^{n-k}$

5. 二项概率的泊松逼近：

当试验次数很多，成功概率很小时，令 $\lambda = np$ ，有 $P_n(k) \approx \frac{\lambda^k}{k!} e^{-\lambda}$

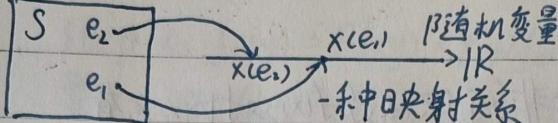
注：二项展开式： $1 = (p+q)^n = \sum_{k=0}^n C_n^k p^k q^{n-k} = \sum_{k=0}^n P_n(k)$

第3章 随机变量及其分布

一、随机变量

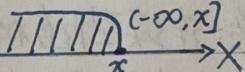
1. 概念：设 E 是随机试验，其样本空间是 S ，若对 S 中每一个基本事件 e_i ，都有唯一的实数值 $X(e_i)$ 与之对应，则称 $X=X(e)$ 为随机变量。

随机变量是对随机事件结果的数字化表示。



2. 随机变量的分布函数

定义：设 X 为一随机变量，称 $F(x)=P(X \leq x)$ 为 X 的分布函数，其中 x 为任意实数。
所有随机变量都有其分布函数



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

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

$$P(X=a) = P(X \leq a) - P(X < a) = F(a) - F(a^-)$$

$$P(X > b) = 1 - P(X \leq b) = 1 - F(b); \quad P(X \geq b) = 1 - F(b^-)$$

性质：(i) $0 \leq F(x) \leq 1$ (ii) $F(x)$ 是单调非减的，即 $\forall x_1 < x_2$, 有 $F(x_1) \leq F(x_2)$

$$(iii) F(-\infty) = \lim_{x \rightarrow -\infty} F(x) = 0 \quad F(+\infty) = \lim_{x \rightarrow +\infty} F(x) = 1$$

(iv) $F(x)$ 是右连续的，即 $P(F(x) = F(x^+))$

3. 随机变量的分类

{ 离散型：有限个或可列无穷多个 \rightarrow 有分布列
非离散型 { 连续型：所取的值连续地充满一个区间 \rightarrow 有概率密度

二、离散型随机变量

1. 概念：只能取有限多个或可列无穷多个值的随机变量 X 称离散型随机变量

设 X 所有可能取值 $x_1, x_2, \dots, x_k, \dots$ ，设事件“ $X=x_k$ ”的概率为 p_k ，则

X 的分布列 $P(X=x_k) = p_k \quad (k=1, 2, \dots)$

其表格形式	X	x_1	x_2	\cdots	x_k	\cdots
	P	p_1	p_2	\cdots	p_k	\cdots

2. 性质 (i) $p_k \geq 0$ (ii) $\sum p_k = 1$ 作用：求分布列中缺少的数据

3. 分布列与分布函数

$$F(x) = P(X \leq x) = \sum_{x_i \leq x} P(X = x_i)$$

已知分布列求分布函数：用 X 的取值来划分实数轴的区间，并注意 $F(x)$ 的右连续性

已知分布函数求分布列：利用 $F(x)$ 在 $x=x_i$ 处的跳跃值， $P(X=x_i) = F(x_i) - F(x_i^-)$

三、连续型随机变量

1. 定义：设 $F(x)$ 为 X 的分布函数，若存在一个非负可积函数 $f(x)$ ，对 $\forall x \in R$ ，有

$$F(x) = \int_{-\infty}^x f(t) dt$$

则称 X 为连续型，称 $f(x)$ 为 X 的概率密度

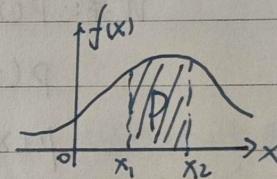
2. 性质：连续型随机变量的分布函数 $F(x)$ 一定是连续的，但不一定是可导的

对于 $f(x)$ 的连续点，有 $F'(x) = f(x)$

3. 性质：(i) $f(x) \geq 0$ (ii) $\int_{-\infty}^{+\infty} f(x) dx = F(+\infty) = 1$

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

(iv) X 为连续型，则 $\forall x \in R$ ， $P(X=x) = 0$



从而 $P(x_1 \leq X \leq x_2) = P(x_1 < X < x_2) = P(x_1 < X \leq x_2) = P(x_1 \leq X < x_2)$

从而 事件 A $P(A)=1 \Rightarrow A$ 是必然事件； $P(A)=0 \Rightarrow A$ 是不可能事件

四、随机变量函数的分布

设 $g(x)$ 是定义在随机变量 X 的一切可能值 x 的集合上的函数。若随机变量 Y 随着 X 取 x 的值而取 $y=g(x)$ 的值，则称随机变量 Y 为随机变量 X 的函数，记作 $Y=g(X)$

问题：对 $Y=g(X)$ ，如何根据已知的随机变量 X 的分布寻求随机变量 Y 的分布

此处的“分布”对离散型来说是分布列，对连续型来说是概率密度

一、 X 为离散型 逐点代入合方法

P	P_1, \dots, P_n		Y	y_1, y_2, \dots, y_n
x	x_1, \dots, x_n	合并相同的 y_i 概率直接相加	P	P'_1, P'_2, \dots, P'_n
$y=g(x)$	y_1, \dots, y_n			

二、 X 为连续型

1. 分布函数求导法

Step 1. 已知 $F_X(x)$, 根据分布函数定义, 求 $Y=g(X)$ 的分布函数

$$F_Y(y) = P(Y \leq y) \xrightarrow{\text{代入}} P(g(X) \leq y) \xrightarrow{\text{反解出 } X} P(X \leq \varphi(y)) = F_X(\varphi(y))$$

$$\text{Step 2. } f_Y(y) = F'_Y(y) = \varphi'(y) f_X(\varphi(y))$$

要点: 把 Y 的分布函数 $F_Y(y)$ 用 X 的分布函数来表示 不同随机变量的分布函数相互表示

注: 注意复合函数求导 \Rightarrow 用概率率 P 作桥梁

上述布与聚只是表示, 使用时注意分段, 或直接使用公式法

2. 公式法

设连续型 X 有 $f_X(x)$, 又设 $y=g(x)$, 在 (a, b) 上严格单调可微, 其反函数为 $x=h(y)$, 有

$$f_Y(y) = \begin{cases} f_X(h(y)) |h'(y)| & A < y < B \\ 0 & \text{其他} \end{cases}$$

其中 $A = \min\{g(a), g(b)\}$, $B = \max\{g(a), g(b)\}$

若 $g(x)$ 在不重叠的区间 I_1, I_2, \dots 上逐段严格单调可微, 其反函数分别为 $h_1(y), h_2(y) \dots$ 有

$$f_Y(y) = f_X(h_1(y)) |h_1'(y)| + f_X(h_2(y)) |h_2'(y)| + \dots$$

注: 若 $f_X(x)$ 的表达式是分段的, 则代入 $f_X(h_i(y))$ 时应代入对应的段

第4章 多维随机变量及其分布

一、多维随机变量

1. 根概念: 若 $X_1(e), X_2(e), \dots, X_n(e)$ 是定义在同一个样本空间 S 上的 n 个随机变量, $e \in S$, 则由它们构成的一个 n 维向量 $(X_1(e), X_2(e), \dots, X_n(e))$ 称为 n 维随机变量

例: 研究某班学生的发育情况, 对每人测其身高 H 、体重 W

$$S = \{e\} = \{\text{某班全部学生}\} \quad e \xrightarrow{H(e)} H(e)$$

则 $(H(e), W(e))$ 为二维随机变量

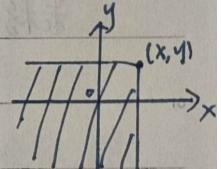
2. 二维随机变量的分布函数

定义: 设 (X, Y) 为二维随机变量, 称 $F(x, y) = P(X \leq x, Y \leq y)$ ($x, y \in \mathbb{R}$)

为 (X, Y) 的分布函数, 或称为 X 和 Y 的联合分布函数

其中 $P(X \leq x, Y \leq y)$ 是事件 $\{X \leq x\}, \{Y \leq y\}$ 同时成立的概率

“联合”即把 (X, Y) 看作一个整体来研究



计算: $P(x_1 < X \leq x_2, y_1 < Y \leq y_2) = F(x_2, y_2) - F(x_2, y_1) - F(x_1, y_2) + F(x_1, y_1)$

性质: (i) 有界性: $\forall x, y \in \mathbb{R}$, $0 \leq F(x, y) \leq 1$

(ii) $\forall y$, $x_1 < x_2$, 有 $F(x_1, y) \leq F(x_2, y)$ 即 $F(x, y)$ 对每个自变量都是单调不减的

$\forall x$, $y_1 < y_2$, 有 $F(x, y_1) \leq F(x, y_2)$

(iii) $\forall x, y$, 有 $F(-\infty, y) = F(x, -\infty) = F(-\infty, -\infty) = 0$

$F(+\infty, +\infty) = 1$ ← 无穷矩形域扩展至整个平面

注: $F(+\infty, y)$ 和 $F(x, +\infty)$ 无法确定

(iv) $F(x, y)$ 对每个自变量都是右连续的, 即

$$F(x, y) = F(x^+, y) \quad F(x, y) = F(x, y^+)$$

3. 二维随机变量的边缘分布函数

$$F_x(x) = F(x, +\infty) \quad F_y(y) = F(+\infty, y)$$

“边缘”即把 (X, Y) 中的 X 和 Y 分开来单独研究

二、二维离散型随机变量

1. 定义: (X, Y) 的所有可能取值是有限对或可列无穷多对 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n), \dots$

2. 联合分布列: $P_{ij} = P(X=x_i, Y=y_j) \quad (i, j=1, 2, \dots)$

3. 1) 性质: (i) $P_{ij} \geq 0 \quad (i, j=1, 2, \dots)$

$$(ii) \quad P(X=x_i) = \sum_{j=1}^{\infty} P_{ij} \triangleq P_{i\cdot}$$

$$P(Y=y_j) = \sum_{i=1}^{\infty} P_{ij} \triangleq P_{\cdot j}$$

称 $P_{i\cdot}, P_{\cdot j}$ 为 (X, Y) 的边缘分布列

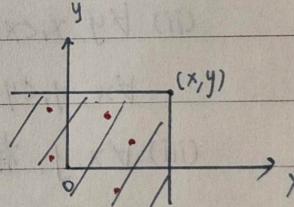
$$(iii) \quad \sum P_{i\cdot} = \sum P_{\cdot j} = \sum \sum P_{ij} = 1$$

表格形式

X	Y	$P_{\cdot j}$	$P_{i\cdot}$ <small>$\leftarrow X$ 的边缘分布</small>
x_1	$p_{11}, p_{12}, \dots, p_{1j}, \dots$	$p_{1\cdot}$	
x_2	$p_{21}, p_{22}, \dots, p_{2j}, \dots$	$p_{2\cdot}$	
\vdots	\vdots	\vdots	
x_i	$p_{i1}, p_{i2}, \dots, p_{ij}, \dots$	$p_{i\cdot}$	
	$P_{\cdot j}$	$P_{\cdot 1}, P_{\cdot 2}, \dots, P_{\cdot j}, \dots$	1

4. 分布列与分布函数

$$F(x, y) = P(X \leq x, Y \leq y) = \sum_{x_i \leq x} \sum_{y_j \leq y} P_{ij}$$



三、二维连续型随机变量

1. 定义: 设 (X, Y) 的分布函数为 $F(x, y)$, 若存在非负可积函数 $f(x, y)$, 对 $\forall x, y \in R$, 有

$$F(x, y) = \int_{-\infty}^y \int_{-\infty}^x f(u, v) du dv$$

则称 (X, Y) 为 ~, 称 $f(x, y)$ 为 (X, Y) 的概率密度, 或称 X 与 Y 的联合概率密度

2. 意义: $f(x, y)$ 相当于质量的面密度, $F(x, y)$ 相当于无穷矩形域上的质量

3. 性质: 对 $f(x, y)$ 的连续点 (x, y) , 有 $\frac{\partial^2 F(x, y)}{\partial x \partial y} = f(x, y)$

4. 性质: (i) $f(x, y) \geq 0$ (ii) $F(+\infty, +\infty) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = 1$

(iii) 设 G 是 xOy 面上的一个区域, 则点 (X, Y) 落在 G 内的概率

$$P((X, Y) \in G) = \iint_G f(x, y) dx dy$$

5. 边缘概率密度

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

称 $f_X(x), f_Y(y)$ 为 (X, Y) 的边缘概率密度

总结:

$$\begin{array}{c} \xrightarrow{\text{二重积分}} \\ f(x,y) \end{array} \xrightarrow{\text{对 } x \text{ 作 } +\infty} F(x,y) \xrightarrow{\text{求导}} \begin{array}{c} F_X(x), F_Y(y) \\ \downarrow \\ f_X(x), f_Y(y) \end{array}$$

对另一变量作一重积分

联合分布 $\xrightarrow{\text{唯一确定}}_x$ 边缘分布

$$\begin{array}{ll} F(x,y), P_{ij}, f(x,y) & F_X(x), P_i, f_X(x) \\ F_Y(y), P_j, f_Y(y) & \end{array}$$

四、随机变量的独立性

定义: 两个随机变量 X, Y 独立, 当且仅当 X, Y 的联合分布等于边缘分布的乘积, 即

$$F(x,y) = F_X(x)F_Y(y), \quad \forall x, y \in \mathbb{R}$$

$$\text{or } f(x,y) = f_X(x)f_Y(y), \quad \forall x, y \in \mathbb{R}$$

或 $P_{ij} = P_i \cdot P_j$ 注: 若 $i=1, 2, \dots, n$, $j=1, 2, \dots, m$, 则该式要求 $m \times n$ 个等式同时成立

定理: 设随机变量 X, Y 独立, 设 $g(x)$ 是 x 的一元函数, $h(y)$ 是 y 的一元函数, 则随机变量 $g(X)$ 与 $h(Y)$ 独立

五、推广至 n 维随机变量

设 (X_1, X_2, \dots, X_n) 为 n 维随机变量, x_1, x_2, \dots, x_n 为 n 个任意实数

(1) 分布函数: $F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$

关于 X_i 的边缘分布函数 $F_{X_i}(x_i) = F(+\infty, +\infty, \dots, x_i, \dots, +\infty)$

(2) 概率密度: $f(x_1, x_2, \dots, x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f(t_1, t_2, \dots, t_n) dt_1 dt_2 \dots dt_n$

关于 X_i 的边缘概率密度 $f_{X_i}(x_i) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_{i-1} dx_{i+1} \dots dx_n$

(3) n 个随机变量的独立性

X_1, X_2, \dots, X_n 是独立的 $\Leftrightarrow F(x_1, x_2, \dots, x_n) = F_{X_1}(x_1)F_{X_2}(x_2) \dots F_{X_n}(x_n)$

对于连续型随机变量 $\Leftrightarrow f(x_1, x_2, \dots, x_n) = f_{X_1}(x_1)f_{X_2}(x_2) \dots f_{X_n}(x_n)$

六、条件分布

两个事件的条件概率 $\xrightarrow{\text{推广}}$ 两个随机变量的条件分布

定义：离散型 (X, Y) $P(X=x_i | Y=y_j) = \frac{P(X=x_i, Y=y_j)}{P(Y=y_j)} = \frac{P_{ij}}{P_{\cdot j}}$ 称 X 在条件 $Y=y_j$ 下的条件分布列
 \downarrow 相当于固定的， $i=1, 2, \dots$

连续型 (X, Y) $f_{X|Y}(x|y) = \frac{f(x,y)}{f_Y(y)}$, $f_Y(y) > 0$ 为 $Y=y$ 条件下 X 的条件概率密度

$$F_{X|Y}(x|y) = \int_{-\infty}^x f_{X|Y}(u|y) du$$

注：联合分布 $\xrightarrow{\text{唯一确定}}$ 边缘分布
 $\frac{\text{条件分布}}{\text{联合分布}} = \frac{\text{边缘分布}}{\text{联合分布}}$

七、二维随机变量的函数的分布

公式法：设 $(X, Y) \sim f(x, y)$, 给定函数 $Z=g(X, Y)$, 使 $z=g(x, y)$, 若能反解出 $y=h(x, z)$, 则

$$f_Z(z) = \int_{-\infty}^{+\infty} f(x, h(x, z)) \left| \frac{\partial h(x, z)}{\partial z} \right| dx$$

$$\text{或反解出 } x=\varphi(y, z), \text{ 则 } f_Z(z) = \int_{-\infty}^{+\infty} f(\varphi(y, z), y) \left| \frac{\partial \varphi(y, z)}{\partial z} \right| dy$$

Step 1. 用上述定理表示 $f_Z(z)$

Step 2. 注意可能有独立性, 使 $f(x, h(x, z)) = f_X(x) \cdot f_Y(h(x, z))$

Step 3. 注意 $f_Z(z)$ 只为 Z 的函数, 故只能对 Z 分段讨论

注意对 Z 讨论的目的是想找出使被积函数 $f(x, h(x, z))$ 非零的 Z 的范围

2. 若无法反解, 如瑞利分布 $Z=\sqrt{X^2+Y^2}$, 则用基本方法: 分布函数求导法

3. 对于离散型随机变量, 基本方法: 逐点代入合并法

4. 特殊分布——分布函数法

① $Z = \max\{X, Y\}$, 且 X, Y 相互独立: $F_Z(z) = F_X(z) \cdot F_Y(z)$

且 X, Y 同分布: $F_Z(z) = [F(z)]^2 \Rightarrow f_Z(z) = 2F(z)f(z)$ 注意左右不同

\Rightarrow 推广 $Z = \max\{X_1, \dots, X_n\}$, 且 X_1, \dots, X_n 相互独立: $F_Z(z) = F_{X_1}(z)F_{X_2}(z)\dots F_{X_n}(z)$

且 X_1, \dots, X_n 同分布: $F_Z(z) = [F(z)]^n$

② $Z = \min\{X, Y\}$, 且 X, Y 相互独立: $F_Z(z) = 1 - [1 - F_X(z)][1 - F_Y(z)]$

且 X, Y 同分布: $F_Z(z) = 1 - [1 - F(z)]^2$

Campus 注: 此处的 $F(z)$, $f(z)$ 指的是 X_1, X_2, \dots, X_n 的分布, 并把自变量换成 Z

第5章 随机变量的数字特征

一、数学期望 mathematical expectation

1. 定义：离散型 X 其分布列 $P(X=x_i)=p_i$ ($i=1, 2, \dots$) 则 X 的数学期望

$$E(X) = \sum_{i=1}^{\infty} x_i p_i$$

要求 $\sum_{i=1}^{\infty} |x_i| p_i < +\infty$

连续型 X 其概率密度 $f(x)$ 则 X 的数学期望

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

要求 $\int_{-\infty}^{+\infty} |x| f(x) dx < +\infty$

注：1. 只需要在被积函数 $f(x)$ 非零的区间积分

2. $E(X)$ 的物理意义：质量密度为 $f(x)$ 的一维连续质点系的重心坐标

2. 随机变量的函数的数学期望

\rightarrow 可以不求出随机变量的函数的分布，直接求其数学期望

定理：设 $Y=g(X)$, 其中 $g(x)$ 连续，则

(i) 若 X 为离散型，其分布列 $P(X=x_i)=p_i$ ($i=1, 2, \dots$)

$$E(Y) = E(g(X)) = \sum_{i=1}^{\infty} g(x_i) p_i \leftarrow \text{逐点代入 } g(x)$$

(ii) 若 X 为连续型，其概率密度 $f_X(x)$

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

注：对于取有限个值的离散型，也可用逐点代入法求 Y 的分布，再求 $E(Y)$

定理：设 $Z=g(X, Y)$, 其中 $g(x, y)$ 连续，则

(i) 若 (X, Y) 为二维离散型，其分布列 $P(X=x_i, Y=y_j)=p_{ij}$ \dots

$$E(Z) = E[g(X, Y)] = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} g(x_i, y_j) p_{ij}$$

同理

(ii) 若 (X, Y) 为二维连续型，其概率密度 $f(x, y)$

$$E(Z) = E[g(X, Y)] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x, y) f(x, y) dx dy$$

\Rightarrow 由 $(X, Y) \sim f(x, y)$ 求 X 与 Y 的数学期望：

$$E(X) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x f(x, y) dx dy \quad E(Y) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} y f(x, y) dx dy$$

3. 数学期望的性质

(i) 若 C 为常数，则 $E(C)=C$

(ii) 若 C 为常数，则 $E(CX)=CE(X)$

(iii) $E(X_1+X_2+\dots+X_n)=E(X_1)+E(X_2)+\dots+E(X_n)$

(iv) 若 X_1, X_2, \dots, X_n 相互独立，则 $E(X_1 X_2 \dots X_n)=E(X_1) E(X_2) \dots E(X_n)$

注：1. 线性性质： $E(aX+bY)=aE(X)+bE(Y)$

2. X_1, X_2 独立 $\Leftrightarrow E(X_1 X_2)=E(X_1) E(X_2)$

二、方差

1. 定义：设 X 为一随机变量，其方差 $D(X) = E\{[X - E(X)]^2\}$ 能反映 X 离开 $E(X)$ 的平均偏离大小
标准差(均方差) $\sigma_X = \sqrt{D(X)}$

注： $D(X)$ 是一个数且 $D(X) \geq 0$

→ 离散型 $D(X) = \sum_{i=1}^{\infty} [x_i - E(X)]^2 p_i$ 其中 $p_i = P(X=x_i)$ 为 X 的分布列

连续型 $D(X) = \int_{-\infty}^{+\infty} [x - E(X)]^2 f(x) dx$ 其中 $f(x)$ 为 X 的概率密度

2. 计算： $D(X) = E(X^2) - [E(X)]^2$

→ 离散型 $= \sum_{k=1}^{\infty} x_k^2 p_k - [\sum_{k=1}^{\infty} x_k p_k]^2$

连续型 $= \int_{-\infty}^{+\infty} x^2 f(x) dx - [\int_{-\infty}^{+\infty} x f(x) dx]^2$

3. 方差的性质

(i) 若 C 为常数，则 $D(C) = 0$

(ii) 若 C 为常数，则 $D(CX) = C^2 D(X)$

(iii) $D(X \pm Y) = D(X) + D(Y) \pm 2E\{[X - E(X)][Y - E(Y)]\} = D(X) + D(Y) \pm 2[E(XY) - E(X)E(Y)]$

(iv) 若 X_1, X_2, \dots, X_n 相互独立，则 $D(X_1 + X_2 + \dots + X_n) = D(X_1) + D(X_2) + \dots + D(X_n)$

注：反之不一定成立

(v) $D(X) = 0 \iff P(X = E(X)) = 1$

三、协方差和相关系数

研究二维随机变量 (X, Y) 时，协方差 $\text{Cov}(X, Y)$ 和 相关系数 ρ_{XY} 是刻画 X 与 Y 之间 线性相关的程度 的两个数字特征

1. 协方差

定义式 $\text{Cov}(X, Y) = E\{[X - E(X)][Y - E(Y)]\}$

计算式 $\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$

与方差的关系 $D(X \pm Y) = D(X) + D(Y) \pm 2\text{Cov}(X, Y) \Rightarrow D(X + Y + Z) = D(X) + D(Y) + D(Z) + 2\text{Cov}(X, Y) + 2\text{Cov}(X, Z) + 2\text{Cov}(Y, Z)$

性质：(i) $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ (ii) $\text{Cov}(X, X) = D(X)$ (iii) 对常数 c , $\text{Cov}(X, c) = 0$

(iv) 对常数 a, b $\text{Cov}(aX, bY) = ab \cdot \text{Cov}(X, Y)$

(v) $\text{Cov}(X_1 + X_2, Y) = \text{Cov}(X_1, Y) + \text{Cov}(X_2, Y) \Rightarrow \text{Cov}(X_1 + X_2, Y_1 + Y_2)$

Campus 注：协方差 $\text{Cov}(X, Y)$ 一般是有量纲的

2. (线性) 相关系数

定义: $\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}}$

注: ρ_{XY} 无量纲

定理; 有界性 $|\rho| \leq 1$

ii $|\rho|=1 \Leftrightarrow$ 存在常数 a, b , 使得 $P(Y=a+bX)=1$

即: 当 $|\rho|=1$ 时, X 与 Y 存在线性相关关系, 这个事件的概率为 1

特别地: 当 $\rho=1$ 时, $b>0$, 称 X, Y 为正相关

当 $\rho=-1$ 时, $b<0$, 称 X, Y 为负相关

定义: 若 $\rho_{XY}=0$, 则称 X 与 Y 不相关

X, Y 相互独立 $\xrightarrow[X]{\checkmark}$ X, Y 不相关
 $(X$ 与 Y 无任何关系) $\quad (X$ 与 Y 无线性相关关系)

X 与 Y 之间重要关系的判断:

X 与 Y 相互独立 $\Leftrightarrow F(x, y) = F_X(x)F_Y(y) \quad \forall x, y$

$$P_{ij} = P_i \cdot P_j \quad \forall i, j$$

$$f(x, y) = f_X(x)f_Y(y) \quad \forall x, y$$

X 与 Y 不相关 $\Leftrightarrow \rho_{XY}=0, \text{Cov}(X, Y)=0$

$$\Leftrightarrow D(X+Y) = D(X) + D(Y)$$

$$\Leftrightarrow E(XY) = E(X)E(Y) \text{: 最常用}$$

用随机变量的分布来描述

用随机变量的数字特征来描述

四、矩

1. 随机变量 X 的 k 阶原点矩 $\alpha_k = E(X^k)$

$$\text{若 } X \sim f(x), \text{ 则 } E(X^k) = \int_{-\infty}^{+\infty} x^k f(x) dx$$

1 阶原点矩 $E(X)$; 2 阶原点矩 $E(X^2)$

2. X 的 k 阶中心矩: $\beta_k = E\{[X-E(X)]^k\}$

$$\text{若 } X \sim f(x), \text{ 则 } E\{[X-E(x)]^k\} = \int_{-\infty}^{+\infty} [x-E(x)]^k f(x) dx$$

2 阶中心矩: $D(X)$

$$\text{注: } \beta_1 = E\{X-E(x)\} = 0$$

3. X, Y 的 $k+l$ 阶混合原点矩 $\alpha_{k+l} = E(X^k Y^l)$

4. X, Y 的 $k+l$ 阶混合中心矩 $\beta_{k+l} = E\{[X-E(X)]^k [Y-E(Y)]^l\}$

$|k+l|=1$ 时, 2 阶混合中心矩 $\text{Cov}(X, Y)$

随机变量 —— 概率分布(分布函数或分布列和概率密度)

完整地描述随机变量的统计规律

—— 数字特征(数学期望、方差、协方差、相关系数、矩)

集中地反映随机变量的某些统计特性

极限定理

1. 切比雪夫不等式

对任意随机变量 X , 方差为 $D(X)$, 对 $\forall \varepsilon > 0$, 有 $P\{|X - E(X)| \geq \varepsilon\} \leq \frac{D(X)}{\varepsilon^2}$

作用: 在 X 的概率分布未知的情况下, 用 $E(X)$ 和 $D(X)$ 估计 X 的概率分布

2. 定义: 设 $\{Z_n\}_{n=1,2,\dots}$ 是一个随机变量序列, a 是一个常数, 若 $\forall \varepsilon > 0$, 有

$$\lim_{n \rightarrow \infty} P\{|Z_n - a| < \varepsilon\} = 1$$

则称序列 $\{Z_n\}$ 依概率收敛于 a , 记为 $Z_n \xrightarrow{P} a$, ($n \rightarrow \infty$)

(只需理解)

3. 辛钦大数定律

设 $X_1, X_2, \dots, X_n, \dots$ 独立同分布, 其期望 $E(X_k) = \mu$, 则对 $\forall \varepsilon > 0$, 有: $\lim_{n \rightarrow \infty} P\left\{ \left| \frac{1}{n} \sum_{k=1}^n X_k - \mu \right| < \varepsilon \right\} = 1$

理解: $\frac{1}{n} \sum_{k=1}^n X_k$ 即随机变量 X 在 n 次重复独立试验中 n 个观测值的算术平均值

当试验次数足够多时, $\frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{P} \mu$, ($n \rightarrow \infty$) 实践: 用测量值的算术平均值作为近似值

4. 切比雪夫大数定律

设 $X_1, X_2, \dots, X_n, \dots$ 独立, 其期望 $E(X_k)$, $k=1, 2, \dots$, 则对 $\forall \varepsilon > 0$, 有 $\lim_{n \rightarrow \infty} P\left\{ \left| \frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n E(X_k) \right| < \varepsilon \right\} = 1$

理解: 当试验次数足够多时, $\frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{P} \frac{1}{n} \sum_{k=1}^n E(X_k)$, ($n \rightarrow \infty$)

称满足上式的随机变量序列 $\{X_k\}$ 服从大数定律

5. 伯努利大数定律

设 f_A 是 n 次独立重复试验中事件 A 发生的次数, p 是每次试验中事件 A 发生的概率, 则对 $\forall \varepsilon > 0$,

$$\lim_{n \rightarrow \infty} P\left\{ \left| \frac{f_A}{n} - p \right| < \varepsilon \right\} = 1 \quad \text{即 } \frac{f_A}{n} \xrightarrow{P} p(A) \quad (n \rightarrow \infty)$$

理论上: 当试验次数足够大时, 某事件发生的频率与概率之差可以无限小

实践上: 当试验次数很大时, 可以用事件的频率来近似代替事件的概率

中心极限定理

1. 标准化变量

对任意随机变量 X , 若 $E(X)=\mu$, $D(X)=\sigma^2 \neq 0$, 称 $X^* = \frac{X-\mu}{\sigma} = \frac{X-E(X)}{\sqrt{D(X)}}$ 为 X 的标准化变量,

则 X^* 满足 $E(X^*)=0$, $D(X^*)=1$

2. 独立同分布的中心极限定理

若随机变量序列 $\{X_n\}_{n=1,2,\dots}$ 独立同分布, 且 $E(X_i)=\mu$, $D(X_i)=\sigma^2 > 0$,

则随机变量之和 $\sum X_i$ 的 $E(\sum X_i) = n\mu$, $D(\sum X_i) = n\sigma^2$

其标准化变量 $Y_n = \frac{\sum X_i - E(\sum X_i)}{\sqrt{D(\sum X_i)}} = \frac{\sum X_i - n\mu}{\sqrt{n}\sigma}$ 的分布函数记为 $F_n(x)$

对 $\forall x \in R$, 满足 $\lim_{n \rightarrow \infty} F_n(x) = \Phi(x)$, 即

$\frac{\sum X_i - n\mu}{\sqrt{n}\sigma} \underset{\text{近似}}{\sim} N(0,1)$ 标准正态分布 公式: $\lim_{n \rightarrow \infty} P\left\{ \frac{\sum X_i - n\mu}{\sqrt{n}\sigma} \leq x \right\} = \Phi(x)$

理解: 若某被研究的随机变量是大量 ($n \rightarrow \infty$) 独立随机变量的和, 其中每个随机变量对总和

只起微小作用, 则可以认为这个随机变量近似服从于正态分布

变形: 随机变量 $\{X_n\}$ 的算术平均记为 $\bar{X} = \frac{1}{n} \sum X_i$, 记 $Y = \frac{\bar{X}-\mu}{\sigma}$ 近似 $N(0,1)$

$\Rightarrow \bar{X} = \frac{\sigma}{\sqrt{n}} Y + \mu \underset{\text{近似}}{\sim} N(\mu, \frac{\sigma^2}{n})$

题型: $\{X_n\}_{n=1,2,\dots}$ 独立同分布, 随机变量 $Z = \sum X_i$, 求 $P(|Z| \leq m)$

解法: 由 $\frac{Z - nm}{\sqrt{nm}} \sim N(0,1)$ 知 $P(|Z| \leq m) = P(-m \leq Z \leq m) = P\left(\frac{-m-n\mu}{\sqrt{nm}} \leq \frac{Z-n\mu}{\sqrt{nm}} \leq \frac{m-n\mu}{\sqrt{nm}}\right) = \Phi\left(\frac{m-n\mu}{\sqrt{nm}}\right) - \Phi\left(\frac{-m-n\mu}{\sqrt{nm}}\right)$ 可查表

3. 棣莫第一拉普拉斯定理

设 $Y_n (n=1,2,\dots)$ 服从参数为 n, p ($0 < p < 1$) 的二项分布, 即 $P(Y_n = k) = \binom{n}{k} p^k q^{n-k}$

则 Y_n 的标准化变量 $\frac{Y_n - np}{\sqrt{npq}} \underset{\text{近似}}{\sim} N(0,1)$

公式: $\lim_{n \rightarrow \infty} P\left\{ \frac{Y_n - np}{\sqrt{npq}} \leq x \right\} = \Phi(x)$

用法: 随机变量 $X \sim B(n, p)$, 当 n 充分大时, $\frac{X - np}{\sqrt{npq}} \sim N(0,1)$

总结: 二项分布 $X \sim B(n, p)$, 成功次数为 k 的概率 $P_n(k)$ 的计算

① n 很小时, 直接计算 $P_n(k) = P\{X=k\} = C_n^k p^k q^{n-k}$

② n 很大 p 很小时, (且 $\lambda = np < 10$), 用泊松逼近 $P_n(k) = P\{X=k\} = \frac{\lambda^k}{k!} e^{-\lambda}$

③ n 很大 p 不是很小时, $\frac{X - np}{\sqrt{npq}} \underset{\text{近似}}{\sim} N(0,1)$

切比雪夫不等式的证明 $P\{|X - E(X)| \geq \epsilon\} \leq \frac{D(X)}{\epsilon^2}$

$$P\{|X - E(X)| \geq \epsilon\} = \int_{|X - E(X)| \geq \epsilon} f(x) dx \leq \int_{|X - E(X)| \geq \epsilon} \frac{(X - E(X))^2}{\epsilon^2} f(x) dx \leq \frac{1}{\epsilon^2} \int_{-\infty}^{+\infty} (X - E(X))^2 f(x) dx = \frac{D(X)}{\epsilon^2}$$

例: 证明 $P\{|X - c| \geq \epsilon\} \leq \frac{E|X - c|}{\epsilon}$, 其中 c 为常数 $\epsilon > 0$

$$P\{|X - c| \geq \epsilon\} = \int_{|X - c| \geq \epsilon} f(x) dx \leq \int_{|X - c| \geq \epsilon} \frac{|X - c|}{\epsilon} f(x) dx \leq \frac{1}{\epsilon} \int_{-\infty}^{+\infty} |X - c| f(x) dx = \frac{E|X - c|}{\epsilon}$$

第6章 数理统计的基本概念

数理统计：以概率论为理论基础，根据试验或观测到的数据，研究如何利用有效的方法对这些数据进行整理、分析和推断，从而对研究对象的性质和统计规律作出合理的科学的估计和推断。

一、总体与样本

1. 总体：所研究的全体元素构成的集合

个体：组成总体的每个元素

总体分为有限总体和无限总体，容量很大的有限总体可以看作无限总体

总体和服从某个概率分布的随机变量 X 是一一对应的 \Rightarrow 总体 X 与随机变量 X 等同

2. 样本

把从总体 X 中随机抽检 n 个个体的试验称为抽样， n 称为容量

抽样结果是 n 个随机变量 x_1, x_2, \dots, x_n ，称为来自总体 X 的一个容量为 n 的样本

对于某次具体的抽样，结果是 n 个确定数值 x_1, x_2, \dots, x_n 称为样本的一个观测值（或一个实现）

3. 简单随机样本

若对总体 X 的 n 次观测是在相同条件下独立重复进行，则得到的样本 x_1, x_2, \dots, x_n 满足

(1) x_1, x_2, \dots, x_n 相互独立
 (2) x_1, x_2, \dots, x_n 与总体 X 同分布

} 样本 \Rightarrow 独立同分布

称为简单随机样本 \Rightarrow 只研究简单随机样本

4. 样本的分布

设总体 X 的分布函数为 $F(x)$ ，(有 $f(x)$ 或 $P\{X=a_i\}=p_i$) 样本 x_1, x_2, \dots, x_n 取自总体 X

① (x_1, x_2, \dots, x_n) 的联合分布函数

$$F(x_1, x_2, \dots, x_n) = F_{X_1}(x_1) F_{X_2}(x_2) \cdots F_{X_n}(x_n) \stackrel{\text{独立}}{=} \prod_{i=1}^n F(x_i) \quad \text{注意把 } X \text{ 换为 } x_i$$

② 对离散型样本 x_1, x_2, \dots, x_n ，联合分布列

$$P\{X_1=x_1, X_2=x_2, \dots, X_n=x_n\} = P\{X_1=x_1\} P\{X_2=x_2\} \cdots P\{X_n=x_n\} = \prod_{i=1}^n P\{X_i=x_i\}$$

③ 对连续型样本 x_1, x_2, \dots, x_n ，联合概率密度

$$f(x_1, x_2, \dots, x_n) = f_{X_1}(x_1) f_{X_2}(x_2) \cdots f_{X_n}(x_n) = \prod_{i=1}^n f(x_i)$$

二、直方图与经验分布函数

1. 直方图

可以估计概率密度曲线

作法：给定总体 X 的一个容量为 n 的样本观测值 x_1, x_2, \dots, x_n

Step 1. 找出样本观测值的最小值 $x_{(1)}$, 最大值 $x_{(n)}$

Step 2. 确定组数、组距、组限

选取 a (略小于 $x_{(1)}$) 和 b (略大于 $x_{(n)}$), 区间 $(a, b]$ 为作图区间

将 $(a, b]$ 等分为 m 个小区间, 分点为 $a = t_0 < t_1 < t_2 \dots < t_m = b$ 一组限

注意：某小区间内不能没有观测值；分点要比观测值多取一位小数

Step 3. 数出观测值落在区间 $(t_i, t_{i+1}]$ 中的个数 n_i , 计算 $\frac{n_i}{n}$

频数 频率

Step 4. 画图. 在横坐标上标出各分点 t_i , 以区间 $(t_i, t_{i+1}]$ 为底, 画出高度为 $\frac{n_i}{n \Delta t_i}$ 的矩形
分组区间 频率 组距

2. 经验分布函数

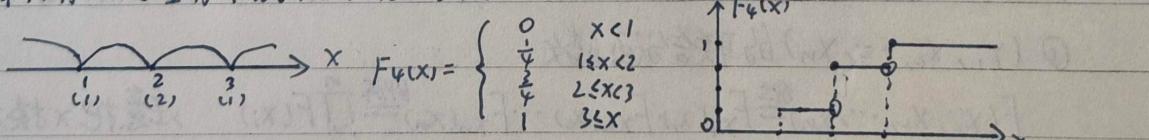
设总体 X 的一个容量为 n 的样本观测值 x_1, x_2, \dots, x_n .

经验分布函数 $F_n(x) = \frac{N_n(x)}{n}, (-\infty < x < +\infty)$

其中 $N_n(x)$ 为观测值 x_1, x_2, \dots, x_n 中不大于 x 的个数

定理: $\forall x, \lim_{n \rightarrow \infty} F_n(x) = F(x)$

e.g. 设总体 X 有一个容量为 4 的样本观测值 1, 2, 2, 3.



$\Rightarrow F_n(x)$ 分为多个左闭右开的小区间；图像是阶梯型曲线（很像离散型的分布函数）

三、统计量

定义：设 x_1, x_2, \dots, x_n 为总体 X 的容量为 n 的样本, $T(x_1, x_2, \dots, x_n)$ 是一个不依赖于未知参数的一个连续函数, 则称随机变量 $T(x_1, x_2, \dots, x_n)$ 为一个统计量

$$1. \text{ 样本均值 } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$$

$$\text{ 样本方差 } S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right) \leftarrow \begin{array}{l} \text{是总体方差的无偏估计} \\ \text{注意不是 } n \end{array}$$

$$\text{ 样本标准差 } S = \sqrt{S^2}$$

注: 若 x_1, x_2, \dots, x_n 是 X_1, X_2, \dots, X_n 的观测值, 代入上式即能得到对应的观测值 \bar{x}, S^2, S

$$2. \text{ 样本 } k \text{ 阶原点矩 } A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$$

$$\text{ 样本 } k \text{ 阶中心矩 } B_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$$

$$\text{ 样本均值即为样本 } 1 \text{ 阶原点矩 } A_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

$$\text{ 样本 } 2 \text{ 阶中心矩 } B_2 \triangleq S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = A_2 - A_1^2 \leftarrow \begin{array}{l} \text{是总体方差的矩估计} \\ \text{(有偏)} \end{array}$$

四、抽样分布

即统计量的分布 (即样本函数的分布)

三大抽样分布:

1. 卡方分布:

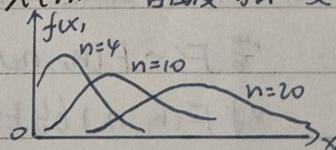
① 设 X_1, X_2, \dots, X_n 是来自于标准正态总体 $X \sim N(0,1)$ 的容量为 n 的样本

$$Y = \sum_{i=1}^n X_i^2 = X_1^2 + X_2^2 + \dots + X_n^2$$

则统计量 Y 的分布称为自由度为 n 的 χ^2 分布, 记为 $Y \sim \chi^2(n)$ 自由度: 独立变量的个数

特别地, 若 $X \sim N(0,1)$ 则 $X^2 \sim \chi^2(1)$

$\chi^2(n)$ 的概率密度是确定的, 无须记



② 卡方分布的数字特征:

对于 $Y \sim \chi^2(n)$, 有 $E(Y) = n$, $D(Y) = 2n$

③ 卡方分布关于自由度的可加性

设随机变量 $X \sim \chi^2(m)$, $Y \sim \chi^2(n)$ 相互独立, 则有: $X+Y \sim \chi^2(m+n)$

e.g. 已知总体 $X \sim N(0,1)$, X_1, X_2, X_3, X_4 为其样本

$$\textcircled{1} \quad X_1^2 + X_2^2 + X_3^2 \sim \chi^2(3) \quad \textcircled{2} \quad X_1^2 + \frac{1}{2}(X_2 + X_3)^2 \sim \chi^2(2)$$

解: 由于 $X_2 \sim N(0,1)$, $X_3 \sim N(0,1)$ 相互独立, $X_2 + X_3 \sim N(0,2)$

则标准化变量 $\frac{(X_2 + X_3) - 0}{\sqrt{2}} \sim N(0,1)$

$$X_1^2 + \frac{1}{2}(X_2 + X_3)^2 = X_1^2 + \left[\frac{(X_2 + X_3) - 0}{\sqrt{2}} \right]^2 \sim \chi^2(2)$$

2. t分布

① 设随机变量 X, Y 相互独立, 且 $X \sim N(0, 1)$, $Y \sim X^2(n)$, 则

$$T = \frac{X}{\sqrt{\frac{Y}{n}}} \quad \text{即 } P \left(\frac{N(0, 1)}{\sqrt{\frac{Y}{n}}} \right)$$

称 T 为服从自由度为 n 的 t 分布, 记为 $T \sim t(n)$

$t(n)$ 的概率密度也是确定的, 有以下性质:

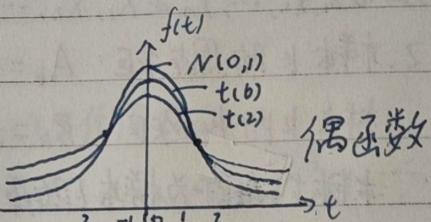
(1) $f(t)$ 关于 $t=0$ 对称

$$(2) \lim_{n \rightarrow \infty} f(t) = \frac{1}{\sqrt{\pi}} e^{-\frac{t^2}{2}}, \quad t \in (-\infty, +\infty)$$

$$\text{即 } P \text{ 当 } n \rightarrow \infty, \quad t(n) \text{ 近似 } N(0, 1)$$

(3) 称 $P(T > t_{\alpha}(n)) = \int_{t_{\alpha}(n)}^{+\infty} f(t) dt = \alpha$ 为 $t(n)$ 的上侧 α 分位数,

$$\text{由于对称性, } t_{1-\alpha}(n) = -t_{\alpha}(n)$$



3. F分布

① 设随机变量 X, Y 相互独立, 且 $X \sim X^2(n_1)$, $Y \sim X^2(n_2)$, 则

$$F = \frac{\frac{X}{n_1}}{\frac{Y}{n_2}} \quad \text{即 } P \left(\frac{\frac{X^2(n_1)}{n_1}}{\frac{Y^2(n_2)}{n_2}} \right)$$

称 F 为服从自由度 (n_1, n_2) 的 F 分布, 记为 $F \sim F(n_1, n_2)$

$F(n_1, n_2)$ 的概率密度也是确定的

② 性质: 若 $X \sim F(n_1, n_2)$ 则 $\frac{1}{X} \sim F(n_2, n_1)$

$$\text{对 } F(n_1, n_2) \text{ 的上侧 } \alpha \text{ 分位数 } F_{\alpha}(n_1, n_2), \text{ 有 } F_{1-\alpha}(n_1, n_2) = \frac{1}{F_{\alpha}(n_2, n_1)}$$

例: 利用抽样分布的定义证明分布

1. 设 $X \sim t(n)$, $Y = \frac{1}{X^2}$, 试证 $Y \sim F(n, 1)$

因为 $X \sim t(n)$, $X = \frac{V}{\sqrt{n}}$, 其中 $V \sim N(0, 1)$, $V \sim X^2(n)$ 且 V 与 V 独立

$$\text{故 } Y = \frac{1}{X^2} = \frac{V^2}{n} = \frac{V^2/n}{V^2/1} \sim F(n, 1), \text{ 其中 } V^2 \sim X^2(1)$$

五、一般总体的样本均值和样本方差

1. 定理: 设总体 X 的期望 $E(X) = \mu$, 方差 $D(X) = \sigma^2$, X_1, X_2, \dots, X_n 是来自总体 X 的样本, 则
 样本均值的期望 $E(\bar{X}) = \mu$, 方差 $D(\bar{X}) = \frac{\sigma^2}{n}$
 样本方差的期望 $E(S^2) = \sigma^2$

六、正态总体的样本均值和样本方差

1. 一个样本

定理: 设 X_1, X_2, \dots, X_n 为正态总体 $N(\mu, \sigma^2)$ 的一个样本, 则

$$\textcircled{1} \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N\left(\mu, \frac{\sigma^2}{n}\right) \quad \text{推论: } \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

\textcircled{2} 样本均值 \bar{X} 与样本方差 S^2 相互独立

$$\textcircled{3} \quad \frac{n-1}{\sigma^2} S^2 \sim \chi^2(n-1) \quad \text{注: 同理, } \frac{n}{\sigma^2} S^2 \sim \chi^2(n-1) \quad \text{这适用于求 } D(S^2)$$

$$\textcircled{4} \quad \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

2. 两个样本

定理: 设 X_1, X_2, \dots, X_{n_1} 和 Y_1, Y_2, \dots, Y_{n_2} 分别是来自正态总体 $N(\mu_1, \sigma_1^2)$ 和 $N(\mu_2, \sigma_2^2)$ 的两个样本, 它们相互独立, 则

$$\textcircled{1} \quad \frac{S_1^2 / \sigma_1^2}{S_2^2 / \sigma_2^2} \sim F(n_1-1, n_2-1)$$

$$\textcircled{2} \quad \text{当 } \sigma_1 = \sigma_2 = \sigma \text{ 时 } \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

$$\text{其中 } S_w = \sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}}$$

第7章 参数估计

在实际问题中，所研究的总体分布类型往往是已知的，但依赖于一个或几个未知参数。这时，从样本估计总体分布中的未知参数就是参数估计问题。

一、点估计

1. 点估计问题：

(1) 总体 X 的分布形式已知， θ 是总体 X 的未知参数，可以用 X 的样本 x_1, x_2, \dots, x_n 的一个统计量 $\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n)$ 来估计 θ ，称 $\hat{\theta}$ 为 θ 的估计量。

对具体的样本观测值 x_1, x_2, \dots, x_n ，估计量 $\hat{\theta}$ 的值 $\hat{\theta}(x_1, x_2, \dots, x_n)$ 称为 θ 的估计值。估计量（一个函数）和估计值（函数值）统称为估计。

注：若未知参数有多个， θ 可理解为向量 $\theta = (\theta_1, \theta_2, \dots, \theta_m)$

(2) 点估计的两种常用方法：

2. 矩估计法

(1) 理论基础出： $n \rightarrow \infty$ 时， $A_k = \frac{1}{n} \sum_{i=1}^n x_i^k \xrightarrow{P} \lambda_k = E(X^k) \quad k=1, 2, \dots$

(2) 矩估计法：用样本 k 阶原点矩 $A_k = \frac{1}{n} \sum_{i=1}^n x_i^k$ 估计总体 k 阶原点矩 $\lambda_k = E(X^k)$

(3) 矩估计求解步骤聚：设总体 X 的分布中有 m 个未知参数 $\theta_1, \theta_2, \dots, \theta_m$ (一般最多为 2 个)

Step 1. 求总体各阶原点矩 $E(X^k)$, $k=1, 2, \dots, m$ 这个一定是第一步

Step 2. 全样本的各阶原点矩等于总体各阶原点矩，得到含 m 个未知参数的 m 个方程

$$\begin{cases} A_1 = E(X) \\ A_2 = E(X^2) \\ \vdots \\ A_m = E(X^m) \end{cases}$$

Step 3. 解上述方程，得到 $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m$

注：总体有几个未知参数就建立几个方程；也可使用列 $E(X^k) \rightarrow$ 反解 $\theta_k \rightarrow$ 估计的步聚

(4) 矩估计常用公式： $E(X^2) = D(X) + E^2(X) \quad S^2 = A_2 - \bar{X}^2$

(5) 常用结论：对服从任何分布的 X ，均值 μ ，方差 σ^2 都存在且均未知，样本为 x_1, x_2, \dots, x_n ，则

μ, σ^2 的矩估计： $\hat{\mu} = \bar{X}$

$$\hat{\sigma}^2 = S^2 = A_2 - A_1^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2$$

样本 2 阶中心矩

\Rightarrow 总体方差的矩估计是有偏的

3. 最大似然估计法

(1) 思想: 设总体 X 的分布类型已知, 但分布中含有 m 个未知参数 $\theta_1, \theta_2, \dots, \theta_m$, X_1, X_2, \dots, X_n 为来自 X 的一个样本, x_1, x_2, \dots, x_n 为一个样本值,

$$\text{称 } L(x_1, x_2, \dots, x_n; \theta_1, \theta_2, \dots, \theta_m) = \prod_{i=1}^n P\{X=x_i\} \text{ 或 } \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \dots, \theta_m)$$

为样本的似然函数, 使得似然函数取到最大值的参数值 $\hat{\theta}_i(x_1, x_2, \dots, x_n)$ $i=1, 2, \dots, m$

称为 θ_i 的最大似然估计值, 相应的统计量 $\hat{\theta}_i(x_1, x_2, \dots, x_n)$ 称为最大似然估计量

(2) 解题步骤

Step 1: 若题目没给出样本值, 则设为 x_1, x_2, \dots, x_n

Step 2: 写出似然函数 L

$$\text{若 } X \text{ 为离散型 } L(x_1, x_2, \dots, x_n; \theta_1, \theta_2, \dots, \theta_m) = \prod_{i=1}^n P\{X=x_i\} \rightarrow \text{就是联合分布列}$$

$$\text{若 } X \text{ 为连续型 } L(x_1, x_2, \dots, x_n; \theta_1, \theta_2, \dots, \theta_m) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \dots, \theta_m) \rightarrow \text{联合概率密度}$$

Step 3: 求出对数似然函数 $\ln L$

$$\text{利用 } \ln(uv) = \ln u + \ln v, \quad \ln a^b = b \ln a$$

取对数方便求偏导数, 求最值点; 取对数不会改变最值点

$$\ln L(x_1, x_2, \dots, x_n; \theta_1, \theta_2, \dots, \theta_m) = \sum_{i=1}^n \ln P\{X=x_i\} \text{ 或 } \sum_{i=1}^n \ln f(x_i; \theta_1, \theta_2, \dots, \theta_m)$$

Step 4: 对数似然函数关于各未知参数求偏导数, 令其为0, 得到对数似然方程

$$\frac{\partial \ln L}{\partial \theta_i} = 0 \quad (i=1, 2, \dots, m)$$

Step 5: 求解上述方程组, 若有解, 则解 $\hat{\theta}_i$ 就是 $\theta_1, \theta_2, \dots, \theta_m$ 的最大似然估计量

若方程组无解, 则观察似然函数 L 达到最大值时的 θ , 即可

(3) 最大似然估计的不变性

设 $\hat{\theta}$ 是 X 的概率分布中参数 θ 的最大似然估计, 又假设 $u=u(\theta)$ 具有单值的反函数 $\theta=\theta(u)$, 则 $\hat{u}=u(\hat{\theta})$ 就是 u 的最大似然估计

例: 若已得到方差 σ^2 的最大似然估计量 $\hat{\sigma}^2$,

由 $\sigma=\sqrt{\sigma^2}$, 即 $P_u=u(\sigma^2)=\sqrt{\sigma^2}$ 为单值函数, $\sigma^2=u^2 (u \geq 0)$ 是单值的.

故标准差 σ 的最大似然估计为 $\hat{\sigma}=\sqrt{\hat{\sigma}^2}$

例：设总体 $X \sim U[a, b]$, a, b 为未知参数, 样本 x_1, x_2, \dots, x_n 来自 X , 求 a, b 的点估计。

1. 矩估计法：

$$\text{由 } X \sim U[a, b], f_X(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b \\ 0 & \text{其他} \end{cases} \quad E(X) = \frac{a+b}{2} \quad D(X) = \frac{(b-a)^2}{12}$$

因为 X 有两个未知参数 a, b , 故计算 X 的一阶、二阶原点矩

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

$$\begin{cases} A_1 = \bar{x} = E(X) \\ A_2 = \frac{1}{n} \sum_{i=1}^n x_i^2 = E(X^2) \end{cases} \quad \text{即} \quad \begin{cases} A_1 = \frac{a+b}{2} \\ A_2 = \frac{(b-a)^2}{12} + \left(\frac{a+b}{2}\right)^2 \end{cases} \quad \begin{array}{l} \text{①是关于 } a, b \text{ 的方程组} \\ \text{②} \end{array}$$

解法：先将①代入②，得 $(b-a)^2 = 12(A_2 - A_1^2) = 12S^2$

故 $b-a = 2\sqrt{3}S$ ，又由①有 $b+a=2\bar{x}$, 从而

$$a, b \text{ 的矩估计量为 } \hat{a} = \bar{x} - \sqrt{3}S \quad \hat{b} = \bar{x} + \sqrt{3}S$$

2. 最大似然估计法

$$\text{设样本值为 } x_1, x_2, \dots, x_n, \quad f(x_i) = \begin{cases} \frac{1}{b-a} & a \leq x_i \leq b \\ 0 & \text{其他} \end{cases}$$

$$\text{①似然函数 } L(a, b) = \prod_{i=1}^n f(x_i) = \begin{cases} \frac{1}{(b-a)^n} & a \leq x_1 \leq b, a \leq x_2 \leq b, \dots, a \leq x_n \leq b \\ 0 & \text{其他} \end{cases}$$

②对数似然函数，当 $a \leq x_1 \leq b, a \leq x_2 \leq b, \dots, a \leq x_n \leq b$ 时

$$\ln L(a, b) = -n \ln(b-a)$$

$$\text{③对数似然方程} \quad \begin{cases} \frac{\partial \ln L(a, b)}{\partial a} = \frac{n}{b-a} = 0 & \text{是无解的 (说明不能用求偏导的方式得到解, 不代表最大似然估计法失效)} \\ \frac{\partial \ln L(a, b)}{\partial b} = -\frac{n}{b-a} = 0 & \end{cases}$$

观察 $L(a, b) = \frac{1}{(b-a)^n}$ $a \leq x_1 \leq b, a \leq x_2 \leq b, \dots, a \leq x_n \leq b$, 要 $L(a, b)$ 最大, 则 b 应最小, a 应最大

a ; 满足 $a \leq x_1, x_2, \dots, x_n \Rightarrow a \leq \min\{x_1, x_2, \dots, x_n\} \Rightarrow \hat{a} = \min\{x_1, x_2, \dots, x_n\}$

b ; 满足 $x_1, x_2, \dots, x_n \leq b \Rightarrow b \geq \max\{x_1, x_2, \dots, x_n\} \Rightarrow \hat{b} = \max\{x_1, x_2, \dots, x_n\}$

$\Rightarrow a, b$ 的最大似然估计量 $\hat{a} = \min\{x_1, x_2, \dots, x_n\}$, $\hat{b} = \max\{x_1, x_2, \dots, x_n\}$

例. 已知离散型 X 的分布列如下, 其中 $\theta \in (0, \frac{1}{2})$ 未知, X 的一个样本值为 $3, 1, 3, 0, 3, 1, 2, 3$

求 θ 的点估计

X	0	1	2	3
P	θ^2	$2\theta(1-\theta)$	θ^2	$1-2\theta$

1. 矩估计法:

只有 1 个未知数 θ , 只需求一阶原点矩

$$\textcircled{1} E(X) = 0 \cdot \theta^2 + 1 \cdot 2\theta(1-\theta) + 2 \cdot \theta^2 + 3 \cdot (1-2\theta) = 3 - 4\theta$$

$$\textcircled{2} \text{令 } A_1 = \bar{x} = E(X), \text{ 有 } \bar{x} = 3 - 4\theta$$

$$\text{即 } \theta \text{ 的矩估计量 } \hat{\theta} = \frac{3-\bar{x}}{4}$$

$$\text{又 } \bar{x} = \frac{1}{8} \sum_{i=1}^8 x_i = 2, \text{ 可得 } \theta \text{ 的矩估计值 } \hat{\theta} = \frac{1}{4}$$

2. 最大似然估计法:

$$\textcircled{1} L(\theta) = P\{X_1=3, X_2=1, X_3=3, X_4=0, X_5=3, X_6=1, X_7=2, X_8=3\} = 4\theta^6(1-\theta)^2(1-2\theta)^4$$

$$\textcircled{2} \ln L(\theta) = \ln 4 + 6 \ln \theta + 2 \ln(1-\theta) + 4 \ln(1-2\theta)$$

$$\textcircled{3} \frac{d \ln L(\theta)}{d \theta} = \frac{6}{\theta} - \frac{2}{1-\theta} - \frac{8}{1-2\theta} = \frac{24\theta^2 - 28\theta + 6}{\theta(1-\theta)(1-2\theta)} = 0 \quad \text{解这个方程, 可得 } \theta_1 = \frac{7-\sqrt{13}}{12}, \theta_2 = \frac{7+\sqrt{13}}{12} > \frac{1}{2}$$

$$\text{故 } \theta \text{ 的最大似然估计值 } \hat{\theta} = \frac{7-\sqrt{13}}{12}$$

4. 估计量的评选标准

(1) 无偏性

引人: 估计量是一种统计量, 所以是随机变量, 对不同的样本观测值, 有不同的估计值, 希望这些估计值最好在待估参数的真值附近, 即:

定义: 设 $\hat{\theta} = \theta(X_1, X_2, \dots, X_n)$ 是 θ 的估计量, 若 $\hat{\theta}$ 满足 $E(\hat{\theta}) = \theta$, 则称 $\hat{\theta}$ 是 θ 的无偏估计

定理: 无论总体服从什么分布, 都有:

1. 样本 k 阶原点矩 $A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ 是总体 k 阶原点矩 $\alpha_k = E(X^k)$ 的无偏估计

特别地, 样本均值是总体的数学期望的无偏估计 (样本的组合系数和为1的线性组合也是)

2. 样本方差 $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ 是总体方差 $\sigma^2 = D(X)$ 的无偏估计

而样本二阶中心矩 $S^{*2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ 估计 σ^2 是有偏的

(2) 有效性

引人: 若 $E(\hat{\theta}_1) = \theta$, $E(\hat{\theta}_2) = \theta$, 两个无偏估计量如何评价?

若 $\hat{\theta}_1$ 的取值比 $\hat{\theta}_2$ 的取值更集中在 θ 附近, 则认为 $\hat{\theta}_1$ 比 $\hat{\theta}_2$ 更理想.

定义: 设 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 均为 θ 的无偏估计, 即 $E(\hat{\theta}_1) = E(\hat{\theta}_2) = \theta$, 若 $D(\hat{\theta}_1) \leq D(\hat{\theta}_2)$

则称 $\hat{\theta}_1$ 较 $\hat{\theta}_2$ 有效

(3) 相合性

引人: 无偏性、有效性都是在样本容量 n 固定的前提下讨论的, 则:

定义: 设 $\hat{\theta} = \theta(X_1, X_2, \dots, X_n)$ 是 θ 的估计量, 若 $\hat{\theta}$ 依概率收敛于 θ , 即 $\forall \varepsilon > 0, \lim_{n \rightarrow \infty} P\{|\hat{\theta} - \theta| \geq \varepsilon\} = 0$

则称 $\hat{\theta}$ 是 θ 的相合估计量

注: 相合性是对估计量的一个基本要求

性质: 1. 样本 k 阶原点矩 $A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ 是总体 k 阶原点矩 $\alpha_k = E(X^k)$ 的相合估计

2. 样本方差 S^2 与样本二阶中心矩 S^{*2} 都是总体方差 σ^2 的相合估计

定理: 若待估参数 $\theta = g(\alpha_1, \alpha_2, \dots, \alpha_k)$, 其中 g 为连续函数, 则 θ 的矩估计量 $\hat{\theta} = g(A_1, A_2, \dots, A_k)$ 是 θ 的相合估计

二、区间估计

—置信区间

—置信水平

引人：区间估计：给出未知参数的一个估计范围，并给出此范围包含参数 θ 真值的可信程度

1. 置信区间

定义：设总体 X 的分布函数为 $F(x; \theta)$, 含有一个未知参数 θ , $\theta \in \Theta$

对应给定值 α ($0 < \alpha < 1$) α 一般很小。若由来自 X 的样本 X_1, X_2, \dots, X_n 确定两个

统计量 $\underline{\theta} = \underline{\theta}(X_1, X_2, \dots, X_n)$, $\bar{\theta} = \bar{\theta}(X_1, X_2, \dots, X_n)$, $\underline{\theta} < \bar{\theta}$,

对于任意的 $\theta \in \Theta$, 满足 $P\{\underline{\theta} < \theta < \bar{\theta}\} = 1-\alpha$

则称随机区间 $(\underline{\theta}, \bar{\theta})$ 是 θ 的置信水平为 $1-\alpha$ 的置信区间。

$\underline{\theta}, \bar{\theta}$ 分别称为置信下限和置信上限

注：1. 由于统计量 $\underline{\theta}, \bar{\theta}$ 是随机变量，故 $(\underline{\theta}, \bar{\theta})$ 是一个随机区间

若反复抽样多次（样本容量均为 n ），每一个样本观测值确定一个区间 $(\underline{\theta}, \bar{\theta})$ ，这样的

区间要么包含真值（约占 $100(1-\alpha)\%$ ），要么不包含真值（约占 $100\alpha\%$ ）

e.g. 若 $\alpha = 0.01$ ，反复抽样 1000 次，则相应得到的 1000 个区间中包含 θ 真值的区间

约为 990 个，不包含 θ 真值的约为 10 个

2. 若 X 为连续型，给定 α ，利用 $P\{\underline{\theta} < \theta < \bar{\theta}\} = 1-\alpha$ 求置信区间。若 X 为离散型，则可为 \geq

2. 求未知参数 θ 的置信区间的方法

Step 1. 寻找一个样本 X_1, X_2, \dots, X_n 和 θ 的函数 $W = W(X_1, X_2, \dots, X_n; \theta)$

使 W 的分布不依赖于任何未知数，称函数 W 为区轴量

Step 2. 对于给定的置信水平 $1-\alpha$ ，定出两个常数 a, b ，使得 $P\{a < W(X_1, X_2, \dots, X_n; \theta) < b\} = 1-\alpha$

Step 3. 从 $a < W(X_1, X_2, \dots, X_n; \theta) < b$ 中反解得等价的不等式 $\underline{\theta} < \theta < \bar{\theta}$ ，

则 $(\underline{\theta}, \bar{\theta})$ 即为所求

注：区轴量 W 的构造方法：从 θ 的点估计着手构造，利用正态总体的样本均值和样本方差的性质

2. a, b 一般取 W 的上分位点，方便查表

3. 单个正态总体参数的区间估计

设总体 $X \sim N(\mu, \sigma^2)$, 设 x_1, x_2, \dots, x_n 是来自 X 的一个样本, 样本均值 \bar{x} , 样本方差 S^2 ,
下求的均为置信水平为 $1-\alpha$ 的置信区间

(1) 方差 σ^2 已知, 期望 μ 未知, 求 μ 的置信区间

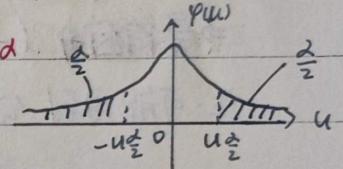
由单个正态总体的样本均值 $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ 知 $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

$P\{-U_{\frac{\alpha}{2}} < \frac{\bar{X}-\mu}{\sigma/\sqrt{n}} < U_{\frac{\alpha}{2}}\} = 1-\alpha$, 其中 $U_{\frac{\alpha}{2}}$ 为标准正态分布的上 $\frac{\alpha}{2}$ 分位点

由 $-U_{\frac{\alpha}{2}} < \frac{\bar{X}-\mu}{\sigma/\sqrt{n}} < U_{\frac{\alpha}{2}}$ 反解 μ , 得 $\bar{X} - U_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + U_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$

\Rightarrow 置信区间 $(\bar{X} - U_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{X} + U_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}})$ 用至 $|U_{\alpha}| = 1-\alpha \Rightarrow U_{\alpha}$

注: 置信水平为 $1-\alpha$ 的置信区间是无穷多的, 但由上述方法得到的区间长度是最短的

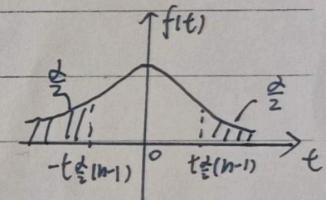


(2) 方差 σ^2 未知, 期望 μ 未知, 求 μ 的置信区间

由 $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \sim t(n-1)$ 知 $P\{-t_{\frac{\alpha}{2}}(n-1) < \frac{\bar{X}-\mu}{\sigma/\sqrt{n}} < t_{\frac{\alpha}{2}}(n-1)\} = 1-\alpha$

反解 μ , 得 $\bar{X} - t_{\frac{\alpha}{2}}(n-1) \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + t_{\frac{\alpha}{2}}(n-1) \frac{\sigma}{\sqrt{n}}$

\Rightarrow 置信区间 $(\bar{X} - t_{\frac{\alpha}{2}}(n-1) \frac{\sigma}{\sqrt{n}}, \bar{X} + t_{\frac{\alpha}{2}}(n-1) \frac{\sigma}{\sqrt{n}})$

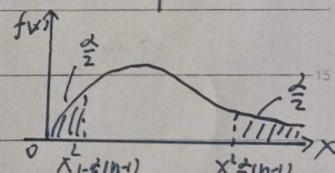


(3) 方差 σ^2 未知, 期望 μ 未知, 求 σ^2 的置信区间

由 $\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$ 知 $P\{\chi^2_{1-\frac{\alpha}{2}(n-1)} < \frac{(n-1)S^2}{\sigma^2} < \chi^2_{\frac{\alpha}{2}(n-1)}\} = 1-\alpha$

反解 σ^2 , 得 $\frac{(n-1)S^2}{\chi^2_{\frac{\alpha}{2}(n-1)}} < \sigma^2 < \frac{(n-1)S^2}{\chi^2_{1-\frac{\alpha}{2}(n-1)}}$

\Rightarrow 置信区间 $(\frac{(n-1)S^2}{\chi^2_{\frac{\alpha}{2}(n-1)}}, \frac{(n-1)S^2}{\chi^2_{1-\frac{\alpha}{2}(n-1)}})$



4. 两个正态总体参数的区间估计

设总体 $X \sim N(\mu_1, \sigma_1^2)$, $Y \sim N(\mu_2, \sigma_2^2)$ 相独立, 分别有样本 x_1, x_2, \dots, x_n 和 y_1, y_2, \dots, y_m

设样本均值分别为 \bar{X}, \bar{Y} , 样本方差分别为 S_1^2, S_2^2 , 求置信水平为 $1-\alpha$ 的置信区间

(1) σ_1^2, σ_2^2 均已知, 求 $\mu_1 - \mu_2$ 的置信区间

由 $\bar{X} \sim N(\mu_1, \frac{\sigma_1^2}{n})$, $\bar{Y} \sim N(\mu_2, \frac{\sigma_2^2}{m})$, \bar{X}, \bar{Y} 相独立知 $\bar{X} - \bar{Y} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m})$

得枢轴量 $U = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \sim N(0, 1)$ 由 $P\{-U_{\frac{\alpha}{2}} < U < U_{\frac{\alpha}{2}}\} = 1-\alpha$, 反解得

\Rightarrow 置信区间 $(\bar{X} - \bar{Y} - U_{\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}, \bar{X} - \bar{Y} + U_{\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}})$

(2) $\sigma_1^2 = \sigma_2^2 = \sigma^2$, 但 σ^2 未知, 求 $(\mu_1 - \mu_2)$ 的置信区间

$$\text{枢轴量 } t = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2) \quad \text{其中 } S_w^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

利用 $P\{-t_{1-\alpha/2}(n_1+n_2-2) < t < t_{1-\alpha/2}(n_1+n_2-2)\} = 1-\alpha$ 得

$$\Rightarrow \text{置信区间 } (\bar{X} - \bar{Y} - t_{1-\alpha/2}(n_1+n_2-2) S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}, \bar{X} - \bar{Y} + t_{1-\alpha/2}(n_1+n_2-2) S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}})$$

(3) μ_1, μ_2 未知, 求 $\frac{\sigma_1^2}{\sigma_2^2}$ 的置信区间

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

利用 $P\{F_{1-\alpha/2}(n_1-1, n_2-1) < F < F_{\alpha/2}(n_1-1, n_2-1)\} = 1-\alpha$

$$\Rightarrow \text{置信区间 } \left(\frac{S_1^2}{S_2^2} \frac{1}{F_{\alpha/2}(n_1-1, n_2-1)}, \frac{S_1^2}{S_2^2} \frac{1}{F_{1-\alpha/2}(n_1-1, n_2-1)} \right)$$

注: 可能用到公式: $F_{\alpha}(n_1, n_2) = \frac{1}{F_{\alpha}(n_2, n_1)}$