多维随机向量函数的协方差

定义 0.56 设二维随机向量 (X,Y) 的期望 $\mathbb{E}[(X-\mathbb{E}[X])(Y-\mathbb{E}[Y])]$ 存在, 则称其为*X 与 Y 的协方差*, 记为

$$\mathrm{Cov}(X,Y)=\mathbb{E}[(X-\mathbb{E}[X])(Y-\mathbb{E}[Y])]=\mathbb{E}[XY]-\mathbb{E}[X]\mathbb{E}[Y].$$

从协方差的定义可以看出, 它是 X 的偏差 "$X-\mathbb{E}[X]$" 与 Y 的偏差 "$Y-\mathbb{E}[Y]$" 乘积的数学期望, 由于偏差可正可负, 故协方差也可正可负, 也可为零.

协方差的性质

- 对任意随机变量 X 与 Y, 有

$$\mathrm{Cov}(X,X)=\mathbb{VAR}(X) \quad \text{和} \quad \mathbb{VAR}(X\pm Y)=\mathbb{VAR}(X)+\mathbb{VAR}(Y)\pm 2\mathrm{Cov}(X,Y)$$

- 对任意随机变量 X 与 Y 和常数 c, 有

$$\mathrm{Cov}(X,c)=0 \qquad \text{和} \qquad \mathrm{Cov}(X,Y)=\mathrm{Cov}(Y,X)$$

- 对任意随机变量 X_1、X_2 和 Y, 有

$$\mathrm{Cov}(X_1+X_2,Y)=\mathrm{Cov}(X_1,Y)+\mathrm{Cov}(X_2,Y)$$

- 若随机变量 X 与 Y 相互独立, 则有 $\mathrm{Cov}(X,Y)=0$, 但反之不成立;
- 对任意随机变量 X 与 Y 有

$$(\mathrm{Cov}(X,Y))^2\le \mathbb{VAR}(X)\cdot\mathbb{VAR}(Y)$$

等号成立的充要条件是 $Y=aX+b$ 几乎处处成立, 即 X 与 Y 之间几乎处处存在线性关系. (可证)

多维随机向量函数的协方差：例 0.100

例 0.100 设随机变量 (X, Y) 的联合概率密度为

$$f(x,y) = \begin{cases} (x+y)/8, & 0 \le x \le 2, 0 \le y \le 2 \\ 0, & \text{其它} \end{cases}$$

求协方差 $\mathrm{Cov}(X, Y)$ 和方差 $\sigma(X+Y)$.

解答：例 0.100

题目: 如上所述.

解答:

- 根据协方差的定义 $\mathrm{Cov}(X,Y)=\mathbb{E}[XY]-\mathbb{E}[X]\mathbb{E}[Y]$, 计算

$$\mathbb{E}[X]=\mathbb{E}[Y]=\int_0^2\int_0^2\frac{x(x+y)}{8}\,dxdy=\frac{7}{6},\quad \mathbb{E}[XY]=\int_0^2\int_0^2\frac{xu(x+y)}{8}\,dxdy=\frac{4}{3}$$

  由此可得 $\mathrm{Cov}(X,Y)=-1/36$.

- 根据方差的定义 $\sigma(X)=\mathbb{E}[X^2]-(\mathbb{E}[X])^2$, 计算

$$\mathbb{E}[X^2]=\mathbb{E}[Y^2]=\int_0^2\int_0^2 x^2(x+y)/8dxdy=5/3$$

  得 $\sigma(X)=\sigma(Y)=11/36$. 最后得到

$$\sigma(X+Y)=\sigma(X)+\sigma(Y)+2\mathrm{Cov}(X,Y)=5/9.$$

多维随机向量函数的协方差：例 0.101

例 0.101 有 n 对夫妻参加一次聚会, 将所有参会人员任意分成 n 组, 每组一男一女, 用 X 表示夫妻两人被分到一组的对数, 求 X 的期望和方差.

解答：例 0.101

题目: 有 n 对夫妻参加一次聚会, 将所有参会人员任意分成 n 组, 每组一男一女, 用 X 表示夫妻两人被分到一组的对数, 求 X 的期望和方差.

解答:

- 用 X_i 表示第 i 对夫妻是否被分到一组, 即

$$X_i = \begin{cases} 1, & \text{第 } i \text{ 对夫妻被分到一组} \\ 0, & \text{否则} \end{cases}$$

则 $X = X_1, X_2, \ldots, X_n$. 随机变量 X_i 得分布列为

$$P(X_i = 1) = (n-1)!/n! = 1/n, \qquad \text{和} \qquad P(X_i = 0) = 1 - 1/n$$

于是得到期望

$$\mathbb{E}[X] = \mathbb{E}(X_1, X_2, \ldots, X_n) = \mathbb{E}(X_1) + \mathbb{E}(X_2) \cdots + \mathbb{E}(X_n) = 1.$$

- 对任意 $i \neq j$, 有

$$P(X_i = 1, X_j = 1) = (n-2)!/n! = 1/n(n-1),$$

由此得到

$$\mathrm{Cov}(X_i, X_j) = \mathbb{E}[X_i X_j] - \mathbb{E}[X_i]\mathbb{E}[X_j] = 1/n^2(n-1),$$

最后根据协方差的性质有

$$\sigma(X) = \sum_{i=1}^{n} \sigma(X_i) + 2\sum_{i \neq j} \mathrm{Cov}(X_i, X_j) = 1.$$

二维正态分布的协方差

定理 0.32 若随机向量 $(X,Y) \sim \mathcal{N}(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$, 则

$$\mathrm{Cov}(X,Y) = \rho\, \sigma_x \sigma_y$$

推论 若随机向量 $(X,Y) \sim \mathcal{N}(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$, 则 X 与 Y 相互独立的充要条件是 $\mathrm{Cov}(X,Y) = 0$.

可证.

证明：二维正态分布的协方差

二维正态分布的密度函数为

$$f(x,y)=\frac{1}{2\pi\sqrt{1-\rho^2}\sigma_x\sigma_y}\exp\left(-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_x)^2}{\sigma_x^2}+\frac{(y-\mu_y)^2}{\sigma_y^2}-\frac{2\rho(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y}\right]\right)$$

这里用到了坐标变换 (归一化做法)

$$f(u,v)=f(x,y)\left|\mathbf{J}\right|,\quad (u,v)=\left(\frac{x-\mu_x}{\sigma_x},\frac{y-\mu_y}{\sigma_y}\right),\quad \left|\mathbf{J}\right|=\sigma_x\sigma_y\,.$$

则有

$$\begin{aligned}
\mathrm{Cov}(X,Y)&=\mathbb{E}[(X-\mathbb{E}[X])(Y-\mathbb{E}[Y])]\\
&=\int_{-\infty}^{+\infty}\int_{-\infty}^{+\infty}(x-\mu_x)(y-\mu_y)f(x,y)\,dxdy\\
&=\int_{-\infty}^{+\infty}\int_{-\infty}^{+\infty}\frac{\sigma_x\sigma_y}{2\pi\sqrt{1-\rho^2}}\,uv\exp\left(-\frac{u^2+v^2-2\rho uv}{2(1-\rho^2)}\right)\,dudv\\
&=\frac{\sigma_x\sigma_y}{2\pi\sqrt{1-\rho^2}}\int_{-\infty}^{+\infty}v\exp\left(-\frac{v^2}{2}\right)\left[\int_{-\infty}^{+\infty}u\exp\left(-\frac{(u-\rho v)^2}{2(1-\rho^2)}\right)du\right]dv\\
&=\frac{\sigma_x\sigma_y}{\sqrt{2\pi}}\int_{-\infty}^{+\infty}\rho v^2\exp\left(-\frac{v^2}{2}\right)\,dv=\rho\sigma_x\sigma_y
\end{aligned}$$

协方差与方差

- 方差. 衡量单变量自身的波动性或者偏离性.

$$\mathbb{VAR}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2]$$

- 协方差. 衡量变量间的偏离性

$$\mathrm{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y].$$

- 可以定义矩阵 $\boldsymbol{\Sigma}$ 用以衡量多变量的偏离程度

$$\boldsymbol{\Sigma} = \begin{pmatrix} \mathbb{VAR}(X) & \mathrm{Cov}(X, Y) \\ \mathrm{Cov}(X, Y) & \mathbb{VAR}(Y) \end{pmatrix}$$

插播: 线性运算的基本性质

- 回忆: 矩阵的特征值和特征向量. 以二维为例, 矩阵 $\mathbf{A}$ 拥有特征值 λ_1 和 λ_2, 分别对应特征向量 $\boldsymbol{u}_1, \boldsymbol{u}_2$. 则有

$$\mathbf{A}\boldsymbol{u}_i = \boldsymbol{\Lambda}_i \boldsymbol{u}_i \ , \quad i = 1, 2$$

  进而有 $\mathbf{A} = \mathbf{U}^\top \boldsymbol{\Lambda} \mathbf{U}$ with $\mathbf{U}^\top = \mathbf{U}^{-1}$, 即

$$\begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} u_{11} & u_{21} \\ u_{12} & u_{22} \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} \begin{pmatrix} u_{11} & u_{12} \\ u_{21} & u_{22} \end{pmatrix}$$

- 几何性质. For the case of $\mathbf{A}\boldsymbol{v}$ given any $\boldsymbol{v}$,
  - 矩阵 $\mathbf{U}$ 负责对 $\boldsymbol{v}$ 进行旋转
  - 矩阵 $\boldsymbol{\Lambda}$ 负责对 $\boldsymbol{v}$ 进行放缩

插播: 线性运算的基本性质

如果我们面对一个运算 $\mathbf{A}\boldsymbol{x} + \boldsymbol{b}$,

- $\boldsymbol{b}$ 是平移
- $\mathbf{U}$ 是旋转
- $\mathbf{\Lambda}$ 是放缩

随机向量的数学期望与协方差阵

n 维随机向量的数学期望及方差可以通过矩阵形式给出.

定义 0.57 设 n 维随机向量为 $\boldsymbol{X} = (X_1, X_2, \ldots, X_n)'$, 若每个分量的数学期望都存在, 则称

$$\mathbb{E}[\boldsymbol{X}] = (\mathbb{E}[X_1], \mathbb{E}[X_2], \ldots, \mathbb{E}[X_n])',$$

为 $\boldsymbol{X}$ 的数学期望向量, 简称 $\boldsymbol{X}$ 的数学期望. 而称

$$\begin{aligned}
&\mathbb{E}[(\boldsymbol{X} - \mathbb{E}[\boldsymbol{X}])(\boldsymbol{X} - \mathbb{E}[\boldsymbol{X}])'] \\
&= \begin{bmatrix}
\sigma_{X_1}^2 & \mathrm{Cov}(X_1, X_2) & \cdots & \mathrm{Cov}(X_1, X_n) \\
\mathrm{Cov}(X_2, X_1) & \sigma_{X_2}^2 & \cdots & \mathrm{Cov}(X_2, X_n) \\
\vdots & \vdots & & \vdots \\
\mathrm{Cov}(X_n, X_1) & \mathrm{Cov}(X_n, X_2) & \cdots & \sigma_{X_n}^2
\end{bmatrix}
\end{aligned}$$

为 $\boldsymbol{X}$ 的方差-协方差矩阵, 简称 $\boldsymbol{X}$ 的协方差阵.

随机向量的协方差阵的性质

通过定义 0.57 可以看到 n 维随机向量的各分量的方差构成了协方差阵对角线上的元素, 非对角线的元素为协方差.

定理 0.33 n 维随机向量的协方差阵 $\mathrm{Cov}(\boldsymbol{X}) = (\mathrm{Cov}(X_i, X_j))_{n\times n}$ 是一个对称的非负定矩阵.

Remarks:

- 这说明, 协方差矩阵的特征值是实数的、非负的.
- 多维随机向量函数的协方差：例 0.102

例 0.102 设随机变量 $X_1, X_2, \ldots, X_n$ 相互独立且服从正态分布, 方差为 σ^2. 记 $\bar{X} = \sum_{i=1}^{n} X_i/n$, 讨论 $\bar{X}$ 和 $\bar{X} - X_i$ 的独立性.

解答：例 0.102

题目：设随机变量 $X_1, X_2, \ldots, X_n$ 相互独立且服从正态分布, 方差为 σ^2. 记 $\bar{X} = \sum_{i=1}^{n} X_i/n$, 讨论 $\bar{X}$ 和 $\bar{X} - X_i$ 的独立性.

解答:

- 根据正态分布的性质易知 $\bar{X}$ 和 $\bar{X} - X_i$ 都服从正态分布 (线性性), 根据定理 0.32 可知正态分布的独立性可通过协方差来研究. 根据协方差的性质有

$$\mathrm{Cov}(\bar{X}, \bar{X} - X_i) = \mathrm{Cov}(\bar{X}, \bar{X}) - \mathrm{Cov}(\bar{X}, X_i) = \sigma(\bar{X}) - \mathrm{Cov}\left(\sum_{j=1}^{n} \frac{X_j}{n}, X_i\right)$$

- 根据 $X_1, X_2, \ldots, X_n$ 相互独立有

$$\sigma(\bar{X}) = \frac{1}{n^2}\sigma\left(\sum_{i=1}^{n} X_i\right) = \frac{\sigma^2}{n} \qquad \text{和} \qquad \mathrm{Cov}(\sum_{j=1}^{n} \frac{X_j}{n}, X_i) = \frac{1}{n}\mathrm{Cov}(X_i, X_i) = \frac{\sigma^2}{n}$$

  于是得到 $\mathrm{Cov}(\bar{X}, \bar{X} - X_i) = 0$, 根据定理 0.32 的推论可知 $\bar{X}$ 和 $\bar{X} - X_i$ 相互独立.

多维随机向量函数的相关系数

两个随机变量之间的关系可以分为独立与非独立, 其中非独立关系中又可以分为线性关系和非线性关系, 线性相关程度通过线性相关系数来定义.

定义 0.58 设 (X,Y) 为二维随机向量, 如果它们的标准差 σ_x 和 σ_y 存在且都不为零, 则称

$$\rho_{XY}=\frac{\mathrm{Cov}(X,Y)}{\sqrt{\mathbb{VAR}(X)\,\mathbb{VAR}(Y)}}.$$

为 X 与 Y 的线性相关系数, 简称 相关系数.

相关系数的性质

- 对任意随机变量 X 与 Y, 有 $|\rho_{XY}| \leq 1$. 等号成立的充要条件是 $Y = aX + b$ 几乎处处成立, 即 X 与 Y 之间几乎处处存在线性关系.
  - 若 $\rho_{XY} = 0$, 称 X 与 Y 不相关. 不相关是指 X 与 Y 之间没有线性关系, 但 X 与 Y 之间可能存在其他的函数关系, 比如平方关系、对数关系等;
  - 若 $\rho_{XY} = 1$, 称 X 与 Y 完全正相关; 若 $\rho_{XY} = -1$, 称 X 与 Y 完全负相关;
  - 若 $0 < |\rho_{XY}| < 1$, 称 X 与 Y "有一定程度" 的线性关系; 若 $|\rho_{XY}|$ 越接近于 1, 则线性相关程度越高; 若 $|\rho_{XY}|$ 越接近于 0, 则线性相关程度越低.
- 若随机变量 X 与 Y 相互独立, 则 X 与 Y 不相关, 但反之不成立.

正态分布的相关系数

定理 0.34 若随机向量 $(X, Y) \sim \mathcal{N}(\mu_x, \mu_y, \sigma_x^2, \sigma_y^2, \rho)$, 则有

- X 与 Y 的线性相关系数 $\rho_{XY} = \rho$
- X 与 Y 相互独立充要条件是 X 与 Y 不相关, 即 $\rho = 0$.

Remarks: 独立与不相关的等价性仅限于正态分布随机变量, 对于其他类型不一定成立.

不相关的等价条件

定理 0.35 若随机变量 X 与 Y 的方差存在且都不为零, 以下几个条件相互等价:

- X 与 Y 独立 (仅限正态分布) ;
- X 与 Y 不相关, 即 $\rho_{XY} = 0$;
- 协方差 $\mathrm{Cov}(X, Y) = 0$;
- $\mathbb{E}[XY] = \mathbb{E}[X]\,\mathbb{E}[Y]$;
- $\mathbb{VAR}(X \pm Y) = \mathbb{VAR}(X) + \mathbb{VAR}(Y)$.

多维随机向量函数的相关系数：例 0.103

例 0.103 设随机变量 $X \sim \mathcal{N}(\mu, \sigma^2)$ 和 $Y \sim \mathcal{N}(\mu, \sigma^2)$ 相互独立, 求 $Z_1 = \alpha X + \beta Y$ 和 $Z_2 = \alpha X - \beta Y$ 的相关系数 $(\alpha, \beta \neq 1)$.

解答：例 0.103

题目: 设随机变量 $X \sim \mathcal{N}(\mu, \sigma^2)$ 和 $Y \sim \mathcal{N}(\mu, \sigma^2)$ 相互独立, 求 $Z_1 = \alpha X + \beta Y$ 和 $Z_2 = \alpha X - \beta Y$ 的相关系数 $(\alpha, \beta \neq 1)$.

解答:

- 根据相关系数的定义

$$\rho_{Z_1 Z_2} = \frac{\mathrm{Cov}(Z_1, Z_2)}{\sigma_{Z_1} \sigma_{Z_2}}$$

计算

$$\mathrm{Cov}(Z_1, Z_2) = \mathrm{Cov}(\alpha X + \beta Y, \alpha X - \beta Y) = (\alpha^2 - \beta^2)\sigma^2$$

$$\sigma_{Z_1}^2 = \mathrm{Cov}(\alpha X + \beta Y, \alpha X + \beta Y) = (\alpha^2 + \beta^2)\sigma^2$$

$$\sigma_{Z_2}^2 = \mathrm{Cov}(\alpha X - \beta Y, \alpha X - \beta Y) = (\alpha^2 + \beta^2)\sigma^2$$

由此可得

$$\rho_{Z_1 Z_2} = \frac{\alpha^2 - \beta^2}{\alpha^2 + \beta^2}\,.$$

多维随机向量函数的相关系数：例 0.104

例 0.104 设随机向量 $(X_1, X_2, \ldots, X_n)$ 服从多项分布 $M(m, p_1, p_2, \ldots, p_n)$, 对任意 $i \neq j$, 求 X_i 和 X_j 的相关系数.

解答：例 0.104

题目: 设随机向量 $(X_1, X_2, \ldots, X_n)$ 服从多项分布 $M(m, p_1, p_2, \ldots, p_n)$, 对任意 $i \neq j$, 求 X_i 和 X_j 的相关系数.

解答:

- 根据多项分布的性质, 有边缘分布

$$X_i \sim B(m, p_i) \qquad \text{和} \qquad X_j \sim B(m, p_j)$$

  由此可得 $\sigma(X_i) = mp_i(1-p_i)$ 和 $\sigma(X_j) = mp_j(1-p_j)$.

- 对每个 $k \in [m]$, 引入随机变量

$$Y_i^k = \begin{cases} 1, & \text{若第 } k \text{ 次实验的结果为 } i \\ 0, & \text{其它} \end{cases} \quad \text{和} \quad Y_j^k = \begin{cases} 1, & \text{若第 } k \text{ 次实验的结果为 } j \\ 0, & \text{其它} \end{cases}$$

  由此可得

$$X_i = Y_i^1 + Y_i^2 + \cdots + Y_i^m \quad \text{和} \quad X_j = Y_j^1 + Y_j^2 + \cdots + Y_j^m$$

- 根据第 k 次实验和第 l 次实验相互独立 $(k \neq l)$, 以及 $Y_i^k Y_j^l = 0$ 有

$$\mathrm{Cov}(Y_i^k, Y_j^l) = 0 \qquad \text{和} \qquad \mathrm{Cov}(Y_i^k, Y_j^k) = \mathbb{E}[Y_i^k Y_j^k] - \mathbb{E}[Y_i^k]\mathbb{E}[Y_j^k] = -p_i p_j$$

根据协方差的性质有

$$\mathrm{Cov}(X_i, X_j) = \sum_{k=1}^{m} \mathrm{Cov}(Y_i^k, Y_j^k) + \sum_{k \neq l} \mathrm{Cov}(Y_i^k, Y_j^l) = -m p_i p_j$$

由此可得 X_i 和 X_j 的相关系数

$$\rho = \frac{\mathrm{Cov}(X_i, X_j)}{\sqrt{\sigma(X_i)\sigma(X_j)}} = \frac{-m p_i p_j}{\sqrt{m p_i (1-p_i)}\sqrt{m p_j (1-p_j)}} = -\frac{p_i p_j}{\sqrt{p_i (1-p_i)}\sqrt{p_j (1-p_j)}}$$

二维正态分布的相关总结

二维随机变量 $(X,Y)\sim\mathcal{N}(\mu_x,\mu_y,\sigma_x^2,\sigma_y^2,\rho)$, 则随机变量 X 和 Y 的边缘分布为

$$f(x,y)=\frac{1}{2\pi\sqrt{1-\rho^2}\sigma_x\sigma_y}\exp\left(-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_x)^2}{\sigma_x^2}+\frac{(y-\mu_y)^2}{\sigma_y^2}-\frac{2\rho(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y}\right]\right)$$

- 边缘分布服从正态分布 $X\sim\mathcal{N}(\mu_x,\sigma_x^2)$ 和 $Y\sim\mathcal{N}(\mu_y,\sigma_y^2)$
- 条件分布服从正态分布

$$(X\mid Y=y)\sim\mathcal{N}\left(\mu_x+\rho(y-\mu_y)\frac{\sigma_x}{\sigma_y},(1-\rho^2)\sigma_x^2\right)$$

- 正态分布之和是正态分布

$$X+Y\sim\mathcal{N}\left(\mu_1+\mu_2,\sigma_1^2+\sigma_2^2\right)$$

- 协方差 $\mathrm{Cov}(X,Y)=\rho\,\sigma_x\sigma_y$
- 相关系数

$$\rho=\rho_{XY}=\frac{\mathrm{Cov}(X,Y)}{\sigma_x\sigma_y}$$

- X 与 Y 独立, 充要条件, $\mathrm{Cov}(X,Y)=0$ 或者 $\rho=\rho_{XY}=0$