



Modelos Probabilísticos em Engenharia Elétrica

Prof. Rodrigo C. de Lamare
CETUC, PUC-Rio
delamare@cetuc.puc-rio.br



IV. Valor esperado

- Neste capítulo, examina-se o conceito de valor esperado de v.a.s.
- Em particular, são estudados o valor esperado de:
 - uma v.a. real,
 - de um vetor aleatório,
 - condicional e
 - matrizes aleatórias.
- Além disso, são examinados os conceitos de
 - desigualdades e
 - funções características.



- O valor esperado de uma v.a. y é definido pela forma integral

$$E[y] = \int_{-\infty}^{\infty} Y p_y(Y) dY$$

em que o valor esperado $E[.]$ é um operador real, definido sobre o espaço \mathcal{F} das v.a.s reais, que associa a uma v.a. real $y \in \mathcal{F}$ o número real $E[y]$ dado pela definição acima.

- Desta forma, tem-se matematicamente

$$E[.]: \quad \mathcal{F} \rightarrow \mathbb{R}$$
$$y \rightarrow E[y]$$



A. Valor esperado de função de v.a. real

- Nesta seção, estuda-se o caso específico em que a v.a. y é função de uma outra v.a. real x , ou seja,

$$y = g(x)$$

em que um resultado importante é o Teorema Fundamental do Valor Esperado.

- Teorema Fundamental do Valor Esperado:

Se $y = g(x)$ então

$$E[y] = \int_{-\infty}^{\infty} Y p_y(Y) dY = \int_{-\infty}^{\infty} g(X) p_x(X) dX$$



Demonstração do Teorema Fundamental do Valor Esperado:

Considerando-se a propriedade

$$\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p_{x_1 \dots x_n}(U_1, \dots, X_j, \dots, U_n) dU_1 \dots dU_{j-1} dU_{j+1} \dots dU_n = p_{x_j}(X_j)$$

e a definição $E[y] = \int_{-\infty}^{\infty} Y p_y(Y) dY$ pode-se escrever

$$\begin{aligned} E[y] &= \int_{-\infty}^{\infty} Y \int_{-\infty}^{\infty} p_{xy}(X, Y) dXdY \\ &= \int_{-\infty}^{\infty} Y \int_{-\infty}^{\infty} p_{y|x=X}(Y) p_x(X) dXdY \end{aligned}$$

Como $y = g(x)$ quando a v.a. x assume o valor X , a v.a. y assume o valor $g(X)$.

Isto significa que, dado $x = X$, y passa a ser uma v.a. discreta que pode assumir um único valor $g(x)$



Logo, tem-se

$$p_{y|x=X}(Y) = \delta(Y - g(X))$$

Substituindo-se a expressão acima em $E[y]$ obtém-se:

$$E[y] = \int_{-\infty}^{\infty} p_x(X) \int_{-\infty}^{\infty} Y \delta(Y - g(X)) dY dX$$

Usando-se a propriedade das funções impulso $\int_{-\infty}^{\infty} f(x) \delta(x - a) dx = f(a)$ na expressão acima obtém-se

$$E[y] = E[g(x)] = \int_{-\infty}^{\infty} Y p_y(Y) dY = \int_{-\infty}^{\infty} g(X) p_x(X) dX$$

A expressão acima nos permite chegar à definição de quantidades importantes na teoria das v.a.s.



i. Média

- A média m_x de uma v.a. x é definida a partir de $\int_{-\infty}^{\infty} g(X)p_x(X)dX$ tomando-se $g(X) = x$.
- Logo, tem-se


$$m_x = E[x] = \int_{-\infty}^{\infty} Xp_x(X)dX$$



Exemplo 1

Calcule a média de uma v.a. uniforme cuja fdp é dada por

$$p_x(X) = \begin{cases} \frac{1}{b-a}, & a \leq X \leq b \\ 0, & \text{caso contrário} \end{cases}$$



Solução:


$$m_x = \int_{-\infty}^{\infty} X p_x(X) dX = \int_a^b X \frac{1}{b-a} dX = \frac{X^2}{2(b-a)} \Big|_a^b = \frac{b^2 - a^2}{2(b-a)} = \frac{a+b}{2}$$

Exemplo 2

Calcule a média de uma v.a. Gaussiana cuja fdp é dada por

$$p_x(X) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(X-m)^2}{2\sigma^2}}, m \in \mathbb{R}, \sigma > 0$$

Solução:



$$m_x = \int_{-\infty}^{\infty} X p_x(X) dX = \int_{-\infty}^{\infty} X \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(X-m)^2}{2\sigma^2}} dX$$

Fazendo-se uma mudança de variável com $\alpha = X - m$ na integral, obtém-se

$$m_x = m \underbrace{\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{\alpha^2}{2\sigma^2}} d\alpha}_1 + \underbrace{\int_{-\infty}^{\infty} \alpha \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{\alpha^2}{2\sigma^2}} d\alpha}_0 = m$$



Exemplo 3

Calcule a média de uma v.a. discreta x , que assume os valores $\{X_1, X_2, \dots\}$ com probabilidade $P(x = X_i), i = 1, 2, \dots$ e cuja fdp é dada por

$$p_x(X) = \sum_i P(x = X_i) \delta(X - X_i)$$

Solução:

A média é dada por

$$\begin{aligned} m_x &= \int_{-\infty}^{\infty} X p_x(X) dX = \int_{-\infty}^{\infty} X \sum_i P(x = X_i) \delta(X - X_i) dX \\ &= \sum_i P(x = X_i) \int_{-\infty}^{\infty} X \delta(X - X_i) dX = \sum_i X_i P(x = X_i) \end{aligned}$$



Observações

- Uma interpretação para a média de uma v.a. pode ser obtida fazendo-se uso do conceito de probabilidade como limite da frequência relativa.
- Considere uma v.a. discreta x que assume valores em $\Omega_x = \{X_1, X_2, \dots\}$ e suponha que a experiência associada a esta v.a. tenha sido realizada n vezes.
- Seja n_{X_i} o número de vezes dentre as n em que o evento $\{x = X_i\}$ ocorreu.
- De acordo com o conceito de probabilidade como o limite da frequência relativa, tem-se

$$P(x = X_i) = \lim_{n \rightarrow \infty} \frac{n_{X_i}}{n}$$

- Para a média tem-se

$$m_x = \lim_{n \rightarrow \infty} \sum_i \frac{X_i n_{X_i}}{n}$$



ii. Variância e desvio padrão

- A variância σ_x^2 de uma v.a. x é definida através de

$$E[y] = E[g(x)] = \int_{-\infty}^{\infty} g(X)p_x(X)dX$$

tomando-se $g(X) = (X - m_x)^2$.

- Logo, tem-se


$$\sigma_x^2 = E[(x - m_x)^2] = \int_{-\infty}^{\infty} g(X)p_x(X)dX = \int_{-\infty}^{\infty} (X - m_x)^2 p_x(X)dX$$

em que σ_x é o desvio padrão associado à dispersão em torno de sua média.

Exemplo 4

Calcule a variância de uma v.a. uniforme definida por

$$p_x(X) = \begin{cases} \frac{1}{b-a}, & a \leq X \leq b \\ 0, & \text{caso contrário} \end{cases}$$



Solução:

$$\sigma_x^2 = E[(x - m_x)^2] = \int_{-\infty}^{\infty} (X - m_x)^2 p_x(X) dX$$


$$= \int_{-\infty}^{\infty} \left(X - \underbrace{\frac{a+b}{2}}_{m_x} \right)^2 \frac{1}{b-a} dX = \frac{(b-a)^2}{12}$$

Exemplo 5

Calcule a variância de uma v.a. Gaussiana definida por

$$p_x(X) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}}, m \in \mathbb{R}, \sigma > 0$$

Solução:



$$\sigma_x^2 = E[(x - m_x)^2] = \int_{-\infty}^{\infty} (X - m_x)^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX$$

Como $\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = 1$ tem-se

$$\int_{-\infty}^{\infty} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = \sqrt{2\pi\sigma}$$



Derivando-se ambos os lados com relação a σ , obtém-se

$$\int_{-\infty}^{\infty} \frac{2(X - m)^2}{2\sigma^3} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = \sqrt{2\pi}$$
$$\int_{-\infty}^{\infty} (X - m)^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = \sigma^2$$

Logo, tem-se

$$\sigma_x^2 = \sigma^2$$



Exemplo 6

Calcule a variância de uma v.a. discreta x que assume os valores $\{X_1, X_2, \dots\}$ com probabilidade $P(x = X_i), i = 1, 2, \dots$ e cuja fdp é dada por

$$p_x(X) = \sum_i P(x = X_i) \delta(X - X_i)$$

Solução:

A variância é descrita por

$$\begin{aligned} \sigma_x^2 &= E[(x - m_x)^2] = \int_{-\infty}^{\infty} (X - m_x)^2 \sum_i P(x = X_i) \delta(X - X_i) dX \\ &= \sum_i P(x = X_i) \int_{-\infty}^{\infty} (X - m_x)^2 \delta(X - X_i) dX \end{aligned}$$

Usando-se a propriedade da função impulso obtém-se

$$\sigma_x^2 = \sum_i (X_i - m_x)^2 P(x = X_i)$$



Observações

- Considerando-se o conceito de probabilidade como o limite da frequência relativa, tem-se

$$P(x = X_i) = \lim_{n \rightarrow \infty} \frac{n_{X_i}}{n}$$

e

$$\sigma_x^2 = \lim_{n \rightarrow \infty} \sum_i \frac{(X_i - m_x)^2}{n} n_{X_i}$$



iii. Valor médio quadrático

- O valor médio quadrático $E[x^2]$ de uma v.a. x é definido através de

$$E[y] = E[g(x)] = \int_{-\infty}^{\infty} g(X)p_x(X)dX$$

tomando-se $g(x) = x^2$.

- Logo, tem-se


$$E[x^2] = \int_{-\infty}^{\infty} X^2 p_x(X) dX$$

- O conceito de valor médio quadrático é importante e bastante usado em problemas de otimização e estimação de parâmetros.

Exemplo 7

Calcule o valor médio quadrático de uma v.a. uniforme dada por

$$p_x(X) = \begin{cases} \frac{1}{b-a}, & a \leq X \leq b \\ 0, & \text{caso contrário} \end{cases}$$




Solução:

$$\begin{aligned} E[x^2] &= \int_{-\infty}^{\infty} X^2 p_x(X) dX = \int_{-\infty}^{\infty} X^2 \frac{1}{b-a} dX \\ &= \frac{b^3 - a^3}{3(b-a)} = \frac{a^2 + b^2 + ab}{3} \end{aligned}$$

Exemplo 8

Calcule o valor médio quadrático de uma v.a. Gaussiana dada por

$$p_x(X) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}}, m \in \mathbb{R}, \sigma > 0$$



Solução:

$$E[x^2] = \int_{-\infty}^{\infty} X^2 p_x(X) dX = \int_{-\infty}^{\infty} X^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX$$

Observe que $\int_{-\infty}^{\infty} (X^2 + m^2 - 2Xm) \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = \sigma^2$

$$\int_{-\infty}^{\infty} X^2 \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX = \sigma^2 + 2m \int_{-\infty}^{\infty} X \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX - m^2 \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX$$


$$E[x^2] = \sigma^2 + 2m^2 - m^2 = \sigma^2 + m^2$$



Exemplo 9

Considere o quantizador de 3 níveis cuja operação é ilustrada abaixo. A entrada do quantizador x é uma v.a. uniforme no Intervalo $(-1,1]$.

Determine o valor do parâmetro a que caracteriza 2 dos níveis de quantização de modo a minimizar o valor médio quadrático do erro de quantização dado por



$$e = x - q(x), \text{ em que } q(x) = \begin{cases} -a, & -\infty < X \leq -\frac{1}{2} \\ 0, & -\frac{1}{2} < X \leq \frac{1}{2} \\ a, & \frac{1}{2} < X < \infty \end{cases}$$



Solução:

$$\begin{aligned} E[e^2] &= E \left[(x - q(x))^2 \right] = \int_{-\infty}^{\infty} (X - q(X))^2 p_x(X) dX \\ &= \int_{-1}^{-\frac{1}{2}} \frac{1}{2} (X + a)^2 dX + \int_{-\frac{1}{2}}^{\frac{1}{2}} \frac{1}{2} X^2 dX + \int_{\frac{1}{2}}^1 \frac{1}{2} (X - a)^2 dX \\ &= \frac{1}{2} \left[a^2 - \frac{3}{2} a + \frac{2}{3} \right] \end{aligned}$$

O valor de a que minimiza $E[e^2]$ pode ser obtido calculando-se a derivada de $E[e^2]$ com relação a a .

$$\frac{dE[e^2]}{da} = \frac{d}{da} \frac{1}{2} \left[a^2 - \frac{3}{2} a + \frac{2}{3} \right] = a - \frac{3}{4} = 0 \rightarrow a = \frac{3}{4}$$



B. Valor esperado de função de vetor aleatório

- Nesta seção, estuda-se o conceito de valor esperado de uma v.a. y na situação em que y é uma função de várias v.a.s, ou seja,

$$y = g(\mathbf{x})$$

- O valor esperado de y pode ser calculado por

$$E[y] = E[g(\mathbf{x})] = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} g(\mathbf{X}) p_{\mathbf{x}}(\mathbf{X}) d\mathbf{X},$$

o que constitui o caso geral do Teorema Fundamental do Valor Esperado.



Demonstração:

Considera-se

$$E[y] = \int_{-\infty}^{\infty} Y \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p_{yx}(Y, X) dX dY = \int_{-\infty}^{\infty} Y \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p_{y|x=X}(Y) p_x(X) dX dY$$

Observando que $p_{y|x=X}(Y) = \delta(Y - g(X))$ obtém-se

$$E[y] = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p_x(X) \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} Y \delta(Y - g(X)) dY dX$$

Pela propriedade da função impulso, a integral em Y é igual a $g(X)$, o que resulta em

$$E[y] = E[g(x)] = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} g(X) p_x(X) dX$$



Propriedades

i) Valor esperado de uma constante

$$E[a] = a,$$

em que a é uma constante.

.



ii) Valor esperado de um operador linear

$$E[\sum_{i=1}^n a_i x_i] = \sum_{i=1}^n a_i E[x_i],$$

em que $\{x_i\}$ são v.a.s e $\{a_i\}$ são constantes reais.



Demonstração:

$$\begin{aligned} E \left[\sum_{i=1}^n a_i x_i \right] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left(\sum_{i=1}^n a_i X_i \right) p_{\mathbf{X}}(\mathbf{X}) d\mathbf{X} \\ &= \sum_{i=1}^n a_i \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} X_i p_{\mathbf{X}}(\mathbf{X}) d\mathbf{X} \\ &= \sum_{i=1}^n a_i \left[\int_{-\infty}^{\infty} X_i p_{X_i}(X_i) dX_i \right] \\ &= \sum_{i=1}^n a_i E[x_i] \end{aligned}$$



iii) Módulo do valor esperado

$$|E[x]| \leq E[|x|]$$



iv) Preservação da ordem do valor esperado

Sejam 2 v.a.s x e y tais que

$$x(\omega) \geq y(\omega), \quad \forall \omega \in \Omega$$

então

$$E[x] \geq E[y]$$



Demonstração:

Considere a v.a. $z = x - y$ e observe que, por hipótese, $z(\omega) \geq 0$ para qualquer $\omega \in \Omega$.

Sendo z uma v.a. sempre positiva, tem-se

$$E[z] = E[x - y] = \int_{-\infty}^{\infty} Z p_z(Z) dZ \geq 0$$

Finalmente, usando-se a propriedade da linearidade obtém-se

$$E[x] - E[y] \geq 0$$



v) Variáveis aleatórias estatisticamente independentes

No caso de n v.a.s estatisticamente independentes x_1, x_2, \dots, x_n tem-se para qualquer conjunto de funções $\{g_1, g_2, \dots, g_n\}$

$$E \left[\prod_{i=1}^n g_i(x_i) \right] = \prod_{i=1}^n E[g_i(x_i)]$$

Observe que

$$E \left[\prod_{i=1}^n g_i(x_i) \right] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left(\prod_{i=1}^n g_i(x_i) \right) p_{\mathbf{x}}(\mathbf{X}) d\mathbf{X}$$



Demonstração:

Como as v.a.s $\{x_1, x_2, \dots, x_n\}$ são estatisticamente independentes, tem-se

$$\begin{aligned} E \left[\prod_{i=1}^n g_i(x_i) \right] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left(\prod_{i=1}^n g_i(x_i) p_{x_i}(X_i) \right) dX_1 dX_2 \dots dX_n \\ &= \prod_{i=1}^n \int_{-\infty}^{\infty} g_i(x_i) p_{x_i}(X_i) dX_i = \prod_{i=1}^n E[g_i(x_i)] \end{aligned}$$



Correlação, covariância e coeficiente de correlação

- O Teorema Fundamental do Valor Esperado permite a definição de quantidades úteis como:
 - Correlação
 - Covariância
 - Coeficiente de correlação
- A estratégia para definir essas quantidades se baseia no uso do vetor aleatório $x = [x \ y]^T$ e no valor esperado dado por

$$E[g(x, y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(X, Y) p_{x,y}(X, Y) dXdY$$

- Essas quantidades (correlação, covariância e coeficiente de correlação) são usadas em inferência estatística.



i. Correlação

- A correlação r_{xy} entre 2 v.a.s x e y é definida tomando-se

$$g(x, y) = xy$$

na expressão

$$E[g(x, y)].$$

- Logo, tem-se

$$r_{xy} = E[xy] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} XY p_{x,y}(X, Y) dXdY$$



ii. Covariância

- A covariância k_{xy} entre 2 v.a.s x e y é definida tomando-se

$$g(x, y) = (x - m_x)(y - m_y),$$

em que m_x e m_y são as médias das v.a.s x e y , respectivamente, na expressão

$$k_{xy} = E[(x - m_x)(y - m_y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (X - m_x)(Y - m_y)p_{x,y}(X, Y)dXdY$$

- A correlação r_{xy} e a covariância k_{xy} entre 2 v.a.s são relacionadas por

$$k_{xy} = r_{xy} - m_x m_y$$



Demonstração de $k_{xy} = r_{xy} - m_x m_y$:

$$\begin{aligned}k_{xy} &= E[(x - m_x)(y - m_y)] = E[xy - ym_x - xm_y + m_x m_y] \\&= E[xy] - m_x E[y] - m_y E[x] + m_x m_y \\&= E[xy] - m_x m_y\end{aligned}$$

No caso em $x = y$, tem-se

$$\sigma_x^2 = E[x^2] - m_x^2$$



Observações

- A covariância entre 2 v.a.s indica o relacionamento estatístico entre 2 v.a.s .
- Quanto maior é o valor do módulo de k_{xy} mais forte é o relacionamento estatístico entre x e y .
- Emprega-se uma quantidade normalizada para avaliar a caracterização do relacionamento estatístico máximo entre 2 v.a.s.



iii. Coeficiente de correlação

- O coeficiente de correlação ρ_{xy} entre 2 v.a.s x e y , proposto pelo matemático britânico Carl Pearson (UCL), é definido por

$$\rho_{xy} = \frac{k_{xy}}{\sigma_x \sigma_y},$$

Em que σ_x e σ_y são os desvios padrões de x e y , respectivamente, e k_{xy} é a covariância entre eles.

- O coeficiente de correlação é adequado para indicar o grau de correlação entre 2 v.a.s.
- Propriedade:

$$|\rho_{xy}| \leq 1$$



Demonstração:

$$\begin{aligned} z = g(x, y) &= \left(\frac{x - m_x}{\sigma_x} \pm \frac{y - m_y}{\sigma_y} \right)^2 \\ &= \left(\frac{x - m_x}{\sigma_x} \right)^2 + \left(\frac{y - m_y}{\sigma_y} \right)^2 \pm 2 \frac{(x - m_x)(y - m_y)}{\sigma_x \sigma_y} \geq 0 \end{aligned}$$

Logo, o valor esperado de z é dado por

$$\begin{aligned} E[z] &= E[g(x, y)] \geq 0 \\ &= E \left[\underbrace{\left(\frac{x - m_x}{\sigma_x} \right)^2}_1 \right] + E \left[\underbrace{\left(\frac{y - m_y}{\sigma_y} \right)^2}_1 \right] \pm 2 E \left[\underbrace{\frac{(x - m_x)(y - m_y)}{\sigma_x \sigma_y}}_{\frac{k_{xy}}{\sigma_x \sigma_y} = \rho_{xy}} \right] \geq 0 \\ &= 2 \pm 2 \frac{k_{xy}}{\sigma_x \sigma_y} \geq 0 \Rightarrow -1 \leq \rho_{xy} \leq 1 \text{ ou } |\rho_{xy}| \leq 1 \end{aligned}$$



Variáveis aleatórias descorrelacionadas

- Definição 1:

Duas v.a.s x e y são ditas descorrelacionadas quando

$$\rho_{xy} = 0 \quad \text{ou} \quad k_{xy} = 0$$

- Note que com $k_{xy} = r_{xy} - m_x m_y$ é possível mostrar que $\rho_{xy} = 0$ e $k_{xy} = 0$ são equivalentes à condição

$$r_{xy} = m_x m_y$$

- É importante ressaltar que se as 2 v.a.s são estatisticamente independentes, elas são também descorrelacionadas já que

$$r_{xy} = E[xy] = E[x]E[y] = m_x m_y$$



- Entretanto, a recíproca não é verdadeira pois v.a.s descorrelacionadas não são, em geral, estatisticamente independentes.
- Considere um exemplo com 2 v.a.s x e $y = x^2$ em que x e y assumem os valores $\{-1,0,1\}$ e $\{0,1\}$, respectivamente, com probabilidades $\{\frac{1}{3}, \frac{1}{3}, \frac{1}{3}\}$ e $\{\frac{1}{3}, \frac{2}{3}\}$. As v.a.s x e y são correlacionadas? As v.a.s são estatisticamente independentes?

A covariância é dada por

$$k_{xy} = E[xy] - E[x]E[y] = E[x^3] - E[x]E[x^2] = 0 \rightarrow \text{v.a.s descorrelacionadas}$$

A probabilidade conjunta é dada por

$$P(x = 1, y = 0) = 0 \neq P(x = 1)P(y = 0) = \frac{1}{9} \rightarrow \text{v.a.s não são est. independentes}$$



Variáveis aleatórias ortogonais

- Definição 2:

Duas v.a.s são ditas ortogonais quando

$$r_{xy} = 0$$

- Note que devido a $r_{xy} = m_x m_y$ 2 v.a.s descorrelacionadas serão ortogonais se e somente se pelo menos uma delas tiver média nula.



Variância da soma de variáveis aleatórias descorrelacionadas

A soma de v.a.s identicamente distribuídas e descorrelacionadas é descrita por

$$y = \sum_{i=1}^n x_i,$$

com $k_{x_i x_j} = 0$, $i \neq j$ então tem-se

$$\sigma_y^2 = \sum_{i=1}^n \sigma_{x_i}^2$$



Demonstração:

$$\begin{aligned}\sigma_y^2 &= E \left[(y - m_y)^2 \right] \\ &= E \left[\left(\sum_{i=1}^n x_i - \sum_{i=1}^n m_{x_i} \right)^2 \right] = E \left[\sum_{i=1}^n (x_i - m_{x_i})^2 \right] \\ &= E \left[\sum_{i=1}^n \sum_{j=1}^n (x_i - m_{x_i}) (x_j - m_{x_j}) \right] = \sum_{i=1}^n \sum_{j=1}^n k_{x_i x_j}\end{aligned}$$

Como $k_{x_i x_j} = 0$, tem-se

$$\sigma_y^2 = \sum_{i=1}^n k_{x_i x_i} = \sum_{i=1}^n \sigma_{x_i}^2$$



iv. Momentos conjuntos

- Os momentos conjuntos de n v.a.s $\{x_1, x_2, \dots, x_n\}$ são definidos fazendo-se

$$g(\mathbf{x}) = x_1^{k_1} x_2^{k_2} \dots x_n^{k_n}$$

em que as potências k_1, k_2, \dots, k_n são números inteiros positivos ou iguais a zero.

- Os momentos conjuntos são então dados por

$$E \left[x_1^{k_1} x_2^{k_2} \dots x_n^{k_n} \right] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} X_1^{k_1} X_2^{k_2} \dots X_n^{k_n} p_{\mathbf{x}}(\mathbf{X}) d\mathbf{X}$$

- A soma $k_1 + k_2 + \dots + k_n$ é a ordem do momento conjunto.



Observações

- $E[x_1x_2x_n]$, $E[x_1x_2^2]$ and $E[x_3^3]$ são momentos de 3ª ordem.
- $E[x_1]$ é um momento de 1ª ordem.
- A correlação r_{xy} e a covariância k_{xy} entre 2 v.a.s x e y são momentos de 2ª ordem.



v. Momentos conjuntos centrais

- Os momentos conjuntos centrais de n v.a.s $\{x_1, x_2, \dots, x_n\}$ são definidos fazendo-se

$$g(x) = (x_1 - m_{x_1})^{k_1} (x_2 - m_{x_2})^{k_2} \dots (x_n - m_{x_n})^{k_n}$$

em que as potências k_1, k_2, \dots, k_n são números inteiros positivos ou iguais a zero.

- Os momentos conjuntos são então dados por

$$\begin{aligned} & E \left[(x_1 - m_{x_1})^{k_1} (x_2 - m_{x_2})^{k_2} \dots (x_n - m_{x_n})^{k_n} \right] \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} (X_1 - m_{x_1})^{k_1} (X_2 - m_{x_2})^{k_2} \dots (X_n - m_{x_n})^{k_n} p_x(\mathbf{X}) d\mathbf{X} \end{aligned}$$

- A soma $k_1 + k_2 + \dots + k_n$ é a ordem do momento conjunto central.
- A variância σ_x^2 e a covariância k_{xy} são momentos centrais de 2ª ordem.



C. Valor esperado de vetores e matrizes

- O valor esperado de um vetor $\mathbf{y} \in \mathbb{R}^n$ de comprimento n é definido como um vetor de mesma dimensão cujos componentes são os valores esperados das componentes de \mathbf{y}

$$E[\mathbf{y}] = \begin{bmatrix} E[y_1] \\ E[y_2] \\ \vdots \\ E[y_n] \end{bmatrix}$$

- De maneira análoga, o valor esperado de uma matriz $A \in \mathbb{R}^{n \times n}$ com dimensões $n \times n$ é definido como sendo uma matriz de mesma dimensão cujos elementos são os valores esperados dos elementos de A

$$E[A] = \begin{bmatrix} E[A_{11}] & \dots & E[A_{1n}] \\ \vdots & \ddots & \vdots \\ E[A_{n1}] & \dots & E[A_{nn}] \end{bmatrix}$$



i) Vetor média

- O vetor média \mathbf{m}_x de um vetor aleatório $\mathbf{x} = [x_1 \quad x_2 \quad \dots \quad x_n]^T$ é definido por

$$\mathbf{m}_x = E[\mathbf{x}]$$

$$= \begin{bmatrix} E[x_1] \\ E[x_2] \\ \vdots \\ E[x_n] \end{bmatrix} = \begin{bmatrix} m_{x_1} \\ m_{x_2} \\ \vdots \\ m_{x_n} \end{bmatrix}$$

ii) Matriz covariância

- A matriz covariância K_x de um vetor aleatório $x = [x_1 \quad x_2 \quad \dots \quad x_n]^T$ é definida por

$$\begin{aligned}
 K_x &= E[(x - m_x)(x - m_x)^T] \\
 &= \begin{bmatrix} E[(x_1 - m_{x_1})^2] & E[(x_1 - m_{x_1})(x_2 - m_{x_2})] & \dots & E[(x_1 - m_{x_1})(x_n - m_{x_n})] \\ E[(x_2 - m_{x_2})(x_1 - m_{x_1})] & E[(x_2 - m_{x_2})^2] & \dots & E[(x_2 - m_{x_2})(x_n - m_{x_n})] \\ \vdots & \vdots & \ddots & \vdots \\ E[(x_n - m_{x_n})(x_1 - m_{x_1})] & E[(x_n - m_{x_n})(x_2 - m_{x_2})] & \dots & E[(x_n - m_{x_n})^2] \end{bmatrix} \\
 &= \begin{bmatrix} \sigma_{x_1}^2 & k_{x_1x_2} & \dots & k_{x_1x_n} \\ k_{x_2x_1} & \sigma_{x_2}^2 & \dots & k_{x_2x_n} \\ \vdots & \vdots & \ddots & \vdots \\ k_{x_nx_1} & k_{x_nx_2} & \dots & \sigma_{x_n}^2 \end{bmatrix}
 \end{aligned}$$

em que a diagonal principal é formada pelas variâncias dos elementos de x e os demais correspondem às covariâncias entre pares de elementos de x .



Exemplo 10

Considere 2 v.a.s x e y com médias iguais a zero, variâncias iguais a σ^2 e correlação descrita por

$$r_{xy} = \int_{-\infty}^{\infty} \rho X^2 p_x(X) dX$$

em que ρ é um coeficiente de correlação.

Seja $\mathbf{u} = [x \ y]^T$ um vetor aleatório formado pelas 2 v.a.s, calcule o vetor média e a matriz covariância de \mathbf{u} .



Solução:

O vetor média e a matriz covariância de $\mathbf{u} = [x \ y]^T$ são dados por

$$\mathbf{m}_u = \begin{bmatrix} m_x \\ m_y \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \text{ e } \mathbf{K}_u = \begin{bmatrix} \sigma_x^2 & k_{xy} \\ k_{yx} & \sigma_y^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 & k_{xy} \\ k_{yx} & \sigma^2 \end{bmatrix}$$

Como as médias são iguais a zero tem-se

$$k_{xy} = k_{yx} = r_{xy} = \int_{-\infty}^{\infty} \rho X^2 p_x(X) dX = \rho E[x^2] = \rho \sigma^2$$

e

$$\mathbf{K}_u = \begin{bmatrix} \sigma^2 & \rho \sigma^2 \\ \rho \sigma^2 & \sigma^2 \end{bmatrix}$$



Valor esperado e transformações lineares

- Em aplicações é útil determinar o vetor média e a matriz covariância de um vetor aleatório y definido por uma transformação linear dada por

$$y = Ax + b,$$

em que a matriz $A \in \mathbb{R}^{n \times n}$ contém coeficientes constantes, o vetor $x \in \mathbb{R}^n$ é um vetor aleatório e o vetor $b \in \mathbb{R}^n$ é um vetor com coeficientes constantes.

- Nesse caso, o vetor média é dado por

$$\begin{aligned} m_y &= E[y] = E[Ax + b] \\ &= AE[x] + b = Am_x + b \end{aligned}$$



- No caso da matriz covariância, tem-se

$$\begin{aligned} K_y &= E[(\mathbf{y} - \mathbf{m}_y)(\mathbf{y} - \mathbf{m}_y)^T] \\ &= E[(\mathbf{A}\mathbf{x} + \mathbf{b} - \mathbf{A}\mathbf{m}_x - \mathbf{b})(\mathbf{A}\mathbf{x} + \mathbf{b} - \mathbf{A}\mathbf{m}_x - \mathbf{b})^T] \\ &= E[(\mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{m}_x)(\mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{m}_x)^T] \\ &= E[\mathbf{A}(\mathbf{x} - \mathbf{m}_x)(\mathbf{x} - \mathbf{m}_x)^T \mathbf{A}^T] \\ &= \mathbf{A}\mathbf{K}_x \mathbf{A}^T \end{aligned}$$



Descorrelacionamento de variáveis aleatórias

- Propriedade :

Dado um vetor aleatório x com matriz covariância K_x é possível fazer com que suas componentes fiquem descorrelacionadas duas a duas, através de uma transformação linear.

- Considere a transformação linear

$$y = Px$$

em que $P \in \mathbb{R}^{n \times n}$ é a matriz cujas colunas são os autovetores $\{e_1, e_2, \dots, e_n\}$ da matriz K_x normalizados.

- Os autovetores $\{e_1, e_2, \dots, e_n\}$ satisfazem às equações

$$K_x e_i = \lambda_i e_i \quad \text{e} \quad e_i^T e_i = 1, \quad i = 1, 2, \dots, n$$

em que $\{\lambda_i\}$ são os autovalores de K_x



- Como a matriz covariância K_x é uma matriz simétrica, sabe-se de álgebra linear, que seus autovetores são ortogonais, ou seja,

$$e_i^T e_j = 0, \quad i, j = 1, 2, \dots, n, \quad i \neq j$$

- Por outro lado, a matriz covariância do vetor y é dada por

$$K_y = E[(y - m_y)(y - m_y)^T] = PK_x P^T$$

- Em seguida, verifica-se que

$$K_y = PK_x P^T = PP^T \Lambda_x PP^T = \Lambda_x = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & \vdots \\ \vdots & \vdots & \ddots & 0 \\ 0 & \dots & 0 & \lambda_n \end{bmatrix}$$

o que considerando $e_i^T e_j = 0$ e $PK_x P^T$ permite escrever $k_{y_i y_j} = \begin{cases} \lambda_i, & i = j \\ 0 & i \neq j \end{cases} e$

mostra que as componentes de y são descorrelacionadas duas a duas.



Exemplo 10

Considere um vetor aleatório x com matriz covariância $K_x = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$.

- Calcule os autovalores e autovetores de K_x
- Calcule a matriz P da transformação linear $y = Px$ que pode descorrelacionar as variáveis aleatórias duas a duas e a matriz covariância K_y



Solução:

a) Os autovalores de K_x devem satisfazer

$$\det(\lambda I - K_x) = 0,$$

Que neste caso se reduz a

$$\lambda^2 - 4\lambda + 3 = 0 \rightarrow \text{Raízes: } \lambda_1 = 3 \text{ e } \lambda_2 = 1$$

Tem-se então os autovetores e_1 and e_2 de K_x que satisfazem

$$K_x e_1 = \lambda_1 e_1$$

$$K_x e_2 = \lambda_2 e_2$$

Obtém-se então os autovetores normalizados

$$e_1 = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ 1 \\ \frac{1}{\sqrt{2}} \end{bmatrix} \quad e \quad e_2 = \begin{bmatrix} -1 \\ \frac{1}{\sqrt{2}} \\ 1 \end{bmatrix}$$



b) A matriz P da transformação linear que transforma o vetor aleatório x em y com componentes descorrelacionados é descrita por

$$P = [e_1 \ e_2] = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix}$$

Verificando-se o efeito de P , obtém-se

$$K_y = PK_x P^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 3 & 0 \\ 0 & 1 \end{bmatrix}$$



D. Valor esperado condicional

- O conceito de valor esperado pode ser estendido para situações em que a v.a. y é condicionada a um evento M .
- Neste caso, a fdp a ser usada deve ser a fdp condicional $p_{y|M}(Y)$.
- Desta forma, o valor esperado de y condicionado ao evento M é dado por

$$E[y|M] = \int_{-\infty}^{\infty} Y p_{y|M}(Y) dY$$



- O Teorema Fundamental do Valor Esperado origina expressões para o valor esperado condicional de funções do tipo $y = g(x)$ de v.a.s
- No caso de uma função de v.a. real $y = g(x)$, tem-se

$$E[g(x)|M] = \int_{-\infty}^{\infty} g(X) p_{x|M}(X) dX$$

- No caso de uma função $y = g(x)$ de um vetor aleatório, obtém-se

$$E[\mathbf{g}(\mathbf{x})|M] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \mathbf{g}(\mathbf{X}) p_{\mathbf{x}|M}(\mathbf{X}) d\mathbf{X}$$

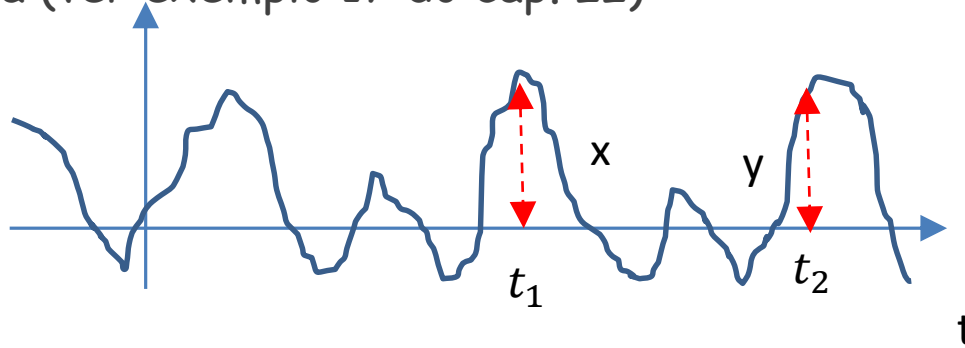


Observações

- O valor esperado condicional $E[g(x)|M]$ permite a definição dos conceitos
 - média condicional $m_{x|M}$,
 - variância condicional $\sigma_{x|M}^2$ e
 - valor médio quadrático $\lambda_x = E[x^2|M]$.
- Além disso, $E[g(x)|M]$ origina os conceitos de correlação condicional $r_{xy|M}$ e covariância condicional $k_{xy|M}$.

Exemplo 11

Considere um sinal obtido em um circuito eletrônico com a seguinte característica (ver exemplo 17 do cap. II):



Os valores nos instantes de tempo t_1 e t_2 podem ser caracterizados por 2 v.a.s x e y conjuntamente Gaussianas, que resulta em

$$p_{xy}(X, Y) = \frac{1}{2\pi\sigma^2\sqrt{1-\rho^2}} e^{-\frac{X^2-2\rho XY+Y^2}{2\sigma^2(1-\rho^2)}}$$

Neste caso, a média e a variância da v.a. y são $m_y = 0$ e $\sigma_y^2 = \sigma^2$. Determine:

- A média condicional $m_{y|M}$ com relação ao evento $M = \{x = X\}$.
- A variância condicional $\sigma_{y|M}^2$ com relação ao evento $M = \{x = X\}$.



Solução:

Neste caso, tem-se

$$m_{y|M} = \int_{-\infty}^{\infty} Y p_{y|x=X}(Y) dY$$

$$\sigma_{y|M}^2 = \int_{-\infty}^{\infty} (Y - m_{y|M})^2 p_{y|x=X}(Y) dY$$

Calculando-se $p_{y|x=X}(Y) = \frac{p_{xy}(X,Y)}{p_x(X)} = \frac{1}{\sqrt{2\pi\sigma\sqrt{1-\rho^2}}} e^{-\frac{(Y-\rho X)^2}{2\sigma^2(1-\rho^2)}}$, obtém-se

$$\text{a) } m_{y|M} = \int_{-\infty}^{\infty} Y p_{y|x=X}(Y) dY = \int_{-\infty}^{\infty} Y \frac{1}{\sqrt{2\pi\sigma\sqrt{1-\rho^2}}} e^{-\frac{(Y-\rho X)^2}{2\sigma^2(1-\rho^2)}} dY = \rho X$$

$$\begin{aligned} \text{b) } \sigma_{y|M}^2 &= \int_{-\infty}^{\infty} (Y - m_{y|M})^2 p_{y|x=X}(Y) dY = \sigma_{y|M}^2 \\ &= \int_{-\infty}^{\infty} (Y - m_{y|M})^2 \frac{1}{\sqrt{2\pi\sigma\sqrt{1-\rho^2}}} e^{-\frac{(Y-\rho X)^2}{2\sigma^2(1-\rho^2)}} dY = \sigma^2(1-\rho^2) \end{aligned}$$



Observações

- O valor esperado condicional permite a determinação de valores esperados que envolvem cálculos complexos de forma simples.
- No caso de uma função de 2 variáveis, é possível mostrar que $E[g(x, y)]$ pode ser obtido por

$$E[g(x, y)] = E[f(x)],$$

em que $f(x)$ é uma função definida por

$$f(X) = E[g(X, y)|x = X]$$

- Para demonstrar $E[g(x, y)]$ e $f(X)$ considera-se

$$E[g(x, y)] = \int_{-\infty}^{\infty} p_x(X) \underbrace{\left[\int_{-\infty}^{\infty} g(X, Y) p_{y|x=X}(Y) dY \right]}_{f(X)} dX = \int_{-\infty}^{\infty} p_x(X) f(X) dX$$



Exemplo 12

Considere o Exemplo 11 com $g(x, y) = xy$

Solução:

Usando $f(X) = E[g(X, y)|x = X]$ tem-se

$$f(X) = E[XY|x = X] = XE[y|x = X] = X\rho X = \rho X^2$$

Considerando-se $m_{y|x=X}$, obtém-se

$$f(X) = \rho X^2$$

Isto significa que $f(x) = \rho x^2$ e obtém-se

$$r_{xy} = E[f(x)] = \rho E[x^2] = \rho\sigma^2$$



E. Desigualdades

- Em situações em que o cálculo de probabilidades é difícil ou muito trabalhoso, uma solução de compromisso consiste em obter limitantes superiores ou inferiores para as probabilidades, ou seja, desigualdades.
- As desigualdades aqui apresentadas decorrem da desigualdade fundamental descrita por

$$P(x \in I) \leq \frac{E[f(x)]}{a},$$

em que se requer que $f(x) \geq 0$ para todo x e $f(x) \geq a$ em que $a > 0$ para todo $x \in I, I \subset \mathcal{R}$.



- Para mostrar a desigualdade fundamental escreve-se

$$E[f(x)] = \int_{-\infty}^{\infty} f(X)p_x(X)dX = \int_I f(X)p_x(X)dX + \int_{\bar{I}} f(X)p_x(X)dX$$

- Como por hipótese $f(x) \geq 0$, tem-se

$$E[f(x)] \geq \int_I f(X)p_x(X)dX$$

- E como $f(x) \geq a > 0$ para $x \in I$, obtém-se

$$E[f(x)] \geq a \int_I p_x(X)dX = aP(x \in I)$$

e

$$P(x \in I) \leq \frac{E[f(x)]}{a}$$



Exemplo 13

Considere uma v.a. x com média nula e variância σ^2 . Com estes dados, deseja-se avaliar o valor de $P(x \geq b)$, em que b é uma constante positiva.

Solução:

Neste caso, define-se (de forma arbitrária)

$$f(x) = \left(x + \frac{\sigma^2}{b}\right)^2, b \geq 0$$

e toma-se $I = \{x: x \geq b\}$. Deste modo, a partir de $P(x \in I) \leq \frac{E[f(x)]}{a}$, tem-se


$$P(x \in I) \leq \frac{E\left[\left(x + \frac{\sigma^2}{b}\right)^2\right]}{a}$$

em que para satisfazer $f(x) \geq a > 0$ em I escolhe-se $a = \left(\frac{b^2 + \sigma^2}{b}\right)^2$ e tem-se

$$P(x \geq b) \leq \frac{\sigma^2}{a^2 + b^2}$$

Desigualdade de Tchebyshev

- A partir da desigualdade fundamental, é possível estabelecer algumas desigualdades notáveis.
- Considere uma função par qualquer $f(x)$, não negativa e crescente com $x > 0$, conforme ilustrado abaixo.



- Para este caso particular, tem-se a desigualdade de Tchebyshev generalizada:

$$P(x \in I) \leq \frac{E[f(x)]}{f(\epsilon)}$$



Desigualdade de Markov

- Formas particulares da função par $f(x)$ conduzem a outras desigualdades.
- Por exemplo, quando $f(x) = |x|^r$, obtém-se a desigualdade de Markov:

$$P(x \in I) \leq \frac{E[f(x)]}{f(\epsilon)} = \frac{|x|^r}{\epsilon^r}$$

- Finalmente, tomando-se $r = 2$ na desigualdade de Markov tem-se a desigualdade de Tchebyshev em sua forma usual:

$$P(x \in I) \leq \frac{|x|^2}{\epsilon^2}$$



Lei dos grande números

- Considere uma sequência de v.a.s independentes e identicamente distribuídas de média m e variância σ^2 dada por $\{x_1, x_2, \dots, x_n\}$.
- A sequência de v.a.s $\{x_n\}$ converge estocasticamente para um valor a se para um $\epsilon > 0$ tem-se

$$\lim_{n \rightarrow \infty} P(|x_n - a| < \epsilon) = 1$$

ou de forma equivalente

$$\lim_{n \rightarrow \infty} P(|x_n - a| \geq \epsilon) = 0, \quad \forall \epsilon > 0$$

- A lei (fraca) dos grandes números mostra que para um número suficientemente grande n , x_n converge para a com alta probabilidade.



- Propõe-se mostrar que a média empírica dada por

$$M_n = \frac{1}{n} \sum_{i=1}^n x_i$$

converge estocasticamente para o valor m , ou seja,

$$\lim_{n \rightarrow \infty} P(|M_n - m| \geq \epsilon) = 0, \quad \forall \epsilon > 0$$

- Para isto, observando-se que

$$E[M_n] = \frac{1}{n} \sum_{i=1}^n \underbrace{E[x_i]}_m = m$$

e

$$\sigma_{M_n}^2 = E[|M_n - m|^2] = \frac{1}{n^2} \sum_{i=1}^n \underbrace{E[\sigma_{x_i}^2]}_{\sigma^2} = \frac{\sigma^2}{n}$$



- Com os resultados anteriores, obtém-se a desigualdade de Tchebyshev

$$P(|M_n - m| \geq \epsilon) \leq \frac{E[|M_n - m|^2]}{\epsilon^2} = \frac{\sigma_{M_n}^2}{\epsilon^2}$$

- Calculando-se o limite quando $n \rightarrow \infty$ tem-se

$$\begin{aligned} \lim_{n \rightarrow \infty} P(|M_n - m| \geq \epsilon) &\leq \lim_{n \rightarrow \infty} E[|M_n - m|^2]/\epsilon^2 \\ &= \lim_{n \rightarrow \infty} \frac{\sigma^2}{n\epsilon^2} = 0, \end{aligned}$$

- A lei (forte) dos grandes números difere ligeiramente e é dada por

$$P\left(\lim_{n \rightarrow \infty} M_n = m\right) = 1,$$

o que indica que a sequência M_n converge com probabilidade 1 para m .



Exemplo 14

Para estimar a probabilidade de um evento A , $P(A)$, calcula-se a frequência relativa do evento A que consiste em uma sequência de v.a.s de Bernoulli.

Qual deve ser o número de experimentos n para que se tenha uma probabilidade igual a 0,95 de que a frequência relativa esteja dentro de uma tolerância $\epsilon = 0,01$ da probabilidade $P(A)$?



Solução:

A probabilidade associada à média m de uma sequência de v.a.s de Bernoulli é $p = 1/2$ enquanto que a variância é dada por $\sigma^2 = p(1 - p) = 1/4$.

A probabilidade do evento A , $P(A)$, pode ser estimada por

$$P(|f(A) - m| \geq \epsilon) \leq \frac{\sigma^2}{n\epsilon^2} = \frac{1}{4n\epsilon^2}$$

ou

$$P(|f(A) - m| < \epsilon) \geq 1 - \frac{\sigma^2}{n\epsilon^2} = 1 - \frac{1}{4n\epsilon^2}$$

Para uma precisão de $\epsilon = 0,01$ tem-se

$$1 - P(|f(A) - m| < \epsilon) = \frac{\sigma^2}{n\epsilon^2}$$

$$1 - 0.95 = \frac{1}{4n\epsilon^2} = 0.05 \rightarrow n = 50000 \text{ experimentos}$$



F. Funções características

- Nesta seção, estuda-se o conceito de funções características que são uma ferramenta importante para cálculos com v.a.s.
- Em particular, as funções características são úteis na solução de problemas com múltiplas v.a.s.
- A função característica de uma v.a. real x é definida por

$$\begin{aligned}M_x(v) &= E[e^{jvx}] \\ &= \int_{-\infty}^{\infty} e^{jvX} p_x(X) dX,\end{aligned}$$

em que $M_x(v)$ é uma função da variável real v e toma valores no conjunto dos números complexos.



Cálculo de funções características

1) Função característica de uma v.a. uniforme

$$p_x(X) = \begin{cases} \frac{1}{b-a}, & a \leq X \leq b \\ 0 & \text{caso contrário} \end{cases}$$

$$\begin{aligned} M_x(v) &= E[e^{jvx}] \\ &= \int_{-\infty}^{\infty} e^{jvX} \frac{1}{b-a} dX = \frac{e^{jvX}}{jv(b-a)} \Big|_a^b \\ &= \frac{1}{jv(b-a)} (e^{jvb} - e^{jva}) \end{aligned}$$



2) Função característica de uma v.a. exponencial

$$p_x(X) = ae^{-aX}u(X), \quad a > 0$$

$$\begin{aligned} M_x(v) &= E[e^{jvx}] \\ &= \int_0^{\infty} e^{jvX} ae^{-aX} dX = \frac{a}{jv-a} e^{-(a-jv)X} \Big|_0^{\infty} \\ &= \frac{a}{a-jv} \end{aligned}$$



3) Função característica de uma v.a. de Poisson

$$p_x(X) = \sum_{k=0}^{\infty} \frac{a^k e^{-a}}{k!} \delta(X - k), \quad k = 0, 1, 2, \dots$$

$$M_x(v) = E[e^{jvX}]$$

$$\begin{aligned} &= \int_0^{\infty} e^{jvX} \sum_{k=0}^{\infty} \frac{a^k e^{-a}}{k!} \delta(X - k) dX \\ &= \sum_{k=0}^{\infty} \frac{a^k e^{-a}}{k!} \underbrace{\int_0^{\infty} e^{jvX} \delta(X - k) dX}_{e^{jvk}} = e^{-a} \sum_{k=0}^{\infty} \frac{(ae^{jv})^k}{k!} \end{aligned}$$

Como $\sum_{k=0}^{\infty} \frac{u^k}{k!} = e^u$ tem-se

$$M_x(v) = e^{-a} e^{ae^{jv}} = e^{-a(1-e^{jv})}$$



4) Função característica de uma v.a. Gaussiana

$$p_x(X) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}}, m \in \mathbb{R}, \sigma > 0$$

$$M_x(v) = E[e^{jvx}]$$

$$= \int_{-\infty}^{\infty} e^{jvX} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-m)^2}{2\sigma^2}} dX$$

$$= e^{-\frac{\sigma^2 v^2}{2}} e^{jvm} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(X-(m+\sigma^2 jv))^2}{2\sigma^2}} dX$$

$$= e^{-\frac{\sigma^2 v^2}{2}} e^{jvm}$$



Funções características e a transformada de Fourier

- Para evitar manipulações algébricas trabalhosas com a função característica pode-se usar a transformada de Fourier para auxiliar os cálculos.
- Salvo uma mudança de variáveis, $M_x(v)$ coincide com a transformada de Fourier de $p_x(X)$ descrita por

$$\mathfrak{F}\{p_x(X)\} = \int_{-\infty}^{\infty} p_x(X)e^{-2\pi fX} dX,$$

- Logo, chega-se à relação

$$M_x(v) = \mathfrak{F}\{p_x(X)\} \Big|_{f = -\frac{v}{2\pi}}$$



- De forma análoga, conhecida $M_x(v)$, é possível obter a sua fdp $p_x(X)$ usando-se a transformada inversa de Fourier dada por

$$\begin{aligned} p_x(X) &= \int_{-\infty}^{\infty} \mathfrak{F}\{p_x(X)\} e^{2\pi f X} df \\ &= \mathfrak{F}^{-1} \left\{ M_x(v) \Big|_{v = -2\pi f} \right\} \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} M_x(v) e^{-jvX} dv, \end{aligned}$$

em que $\mathfrak{F}^{-1}\{\}$ caracteriza a transformada inversa de Fourier.



Pares de funções e transformadas

	Função	Transformada
1.	$e^{-ab}u(t)$	$\frac{1}{a+j2\pi f}$
2.	$te^{-ab}u(t)$	$\frac{1}{(a+j2\pi f)^2}$
3.	$ t $	$\frac{-2}{(j2\pi f)^2}$
4.	$\delta(t)$	1
5.	$u(t)$	$\frac{1}{2}\delta(f) + \frac{1}{2\pi f}$
6.	$\cos(2\pi f_c + \theta)$	$\frac{1}{2}[e^{j\theta}\delta(f - f_c) + e^{j\theta}\delta(f - f_c)]$
7.	$\text{sinc}(2\omega t)$	$\frac{1}{2\omega}\text{ret}_{2\omega}(f)$
8.	$\text{ret}_T(t)$	$T\text{sinc}(fT)$



Propriedades da transformada de Fourier

Operação	Função	Transformada
1. Linearidade	$ag(t) + bh(t)$	$aG(f) + bH(f)$
2. Translação no tempo	$g(t - t_0)$	$G(f)e^{-j2\pi ft_0}$
3. Escala	$g(at)$	$\frac{1}{ a } G\left(\frac{f}{a}\right)$
4. Conjugado	$g^*(t)$	$G^*(-f)$
5. Translação na frequência	$g(t)e^{j2\pi f_0 t}$	$G(f - f_0)$
6. Modulação	$g(t)\cos(2\pi f_c + \theta)$	$\frac{1}{2}[e^{j\theta}G(f - f_c) + e^{j\theta}G(f - f_c)]$
7. Convolução	$g(t) * h(t)$	$G(f)H(f)$
8. Multiplicação	$g(t)h(t)$	$G(f) * H(f)$



Propriedades

1) $M_x(0) = 1$ (resulta da definição)

2) $|M_x(v)| \leq 1$

Demonstração:

A 3ª propriedade do valor esperado ($|E[x]| \leq E[|x|]$) permite escrever

$$|E[e^{jvx}]| \leq E[|e^{jvx}|]$$

Usando o fato de que $|e^{jvx}| = 1$, tem-se

$$|M_x(v)| \leq 1$$



3) Se $y = ax + b$ então $M_y(v) = e^{jvb} M_x(av)$

Demonstração:

$$\begin{aligned} M_y(v) &= E[e^{jvy}] \\ &= E[e^{jv(ax+b)}] \\ &= e^{jvb} E[e^{jvax}] = e^{jvb} M_x(av) \end{aligned}$$



4) Se $\{x_1 \ x_2 \ \dots \ x_n\}$ são v.a.s estatisticamente independentes e

$$y = \sum_{i=1}^n x_i$$

então

$$M_y(v) = \prod_{i=1}^n M_{x_i}(v)$$

Demonstração:

$$M_y(v) = E[e^{jvy}] = E\left[\prod_{i=1}^n e^{jvx_i}\right]$$

Como as v.a.s $\{x_1 \ x_2 \ \dots \ x_n\}$ são estatisticamente independentes usando-se $E[\sum_{i=1}^n a_i x_i] = \sum_{i=1}^n a_i E[x_i]$ tem-se

$$M_y(v) = \prod_{i=1}^n E[e^{jvx_i}] = \prod_{i=1}^n M_{x_i}(v)$$



$$5) E[x^k] = (-j)^k \frac{d^k}{dv^k} M_x(v) \Big|_{v=0}$$

Demonstração: Derivando-se $M_x(v)$ k vezes com relação a v , obtém-se

$$\frac{d^k}{dv^k} M_x(v) = \int_{-\infty}^{\infty} (jX)^k e^{jvX} p_x(X) dX$$

Fazendo-se $v = 0$, chega-se a

$$\begin{aligned} \frac{d^k}{dv^k} M_x(v) \Big|_{v=0} &= \int_{-\infty}^{\infty} (jX)^k p_x(X) dX \\ &= E[(jx)^k] = j^k E[x^k] \end{aligned}$$



Exemplo 15

Sejam x e y 2 v.a.s estatisticamente independentes, ambas com fdp uniforme no intervalo $(-1,1]$.

Determine a função característica e a fdp da v.a. $z = x + y$



Solução:

Observando-se que a partir da propriedade 4 tem-se

$$z = x + y \quad \text{e} \quad M_z(v) = M_x(v)M_y(v)$$

As expressões de $M_x(v)$ e $M_y(v)$ são obtidas por

$$M_x(v) = M_y(v) = \mathfrak{F} \left\{ \frac{1}{2} \text{ret}_2(X) \right\} \Big|_f = -\frac{v}{2\pi} = \text{sinc} \left(\frac{v}{\pi} \right)$$

Logo, tem-se

$$M_z(v) = \left(\text{sinc} \left(\frac{v}{\pi} \right) \right)^2$$

A fdp de $z = x + y$ é dada por

$$p_z(Z) = \mathfrak{F}^{-1} \left\{ \left(\text{sinc} \left(\frac{v}{\pi} \right) \right)^2 \right\} = \frac{1}{2} \text{tri}_4(Z)$$



Exemplo 16

Considere x e y 2 v.a.s estatisticamente independentes, ambas com fdp de Poisson de parâmetro a .

Determine a função característica e a fdp da v.a. $z = x + y$



Solução:

Observando-se que a partir da propriedade 4 tem-se

$$z = x + y \quad \text{e} \quad M_z(v) = M_x(v)M_y(v)$$

As expressões de $M_x(v)$ e $M_y(v)$ são obtidas por

$$M_x(v) = M_y(v) = e^{-a(1-e^{jv})}$$

Logo, tem-se

$$M_z(v) = M_x(v)M_y(v) = \left(e^{-a(1-e^{jv})}\right)^2 = e^{-2a(1-e^{jv})}$$

A fdp de $z = x + y$ é dada por

$$p_z(Z) = \sum_{i=0}^{\infty} \frac{(2a)^i e^{-2a}}{i!} \delta(X - i)$$



Exemplo 17

Considere uma v.a. x com fdp exponencial.

Determine $E[x]$, $E[x^2]$ e $E[x^3]$



Solução:

A função característica da v.a. x exponencial é dada por

$$M_x(v) = \frac{a}{a - jv}$$

Calculando-se as derivadas, obtém-se

$$\begin{aligned}\frac{d}{dv} M_x(v) &= \frac{d}{dv} \frac{a}{a - jv} = \frac{ja}{(a - jv)^2} \\ \frac{d^2}{dv^2} M_x(v) &= \frac{d^2}{dv^2} \frac{a}{a - jv} = \frac{-2a}{(a - jv)^3} \\ \frac{d^3}{dv^3} M_x(v) &= \frac{d^3}{dv^3} \frac{a}{a - jv} = \frac{-6ja}{(a - jv)^4}\end{aligned}$$



Usando-se $E[x^k] = (-j)^k \frac{d^k}{dv^k} M_x(v) \Big|_{v=0}$ para $k = 1, 2, 3$, obtém-se

$$E[x] = (-j) \frac{j}{a} = \frac{1}{a}$$

$$E[x^2] = (-j)^2 \frac{(-2)}{a^2} = \frac{2}{a^2}$$

$$E[x^3] = (-j)^3 \frac{(-6j)}{a^3} = \frac{6}{a^3}$$



Teorema do limite central

- O teorema do limite central é um resultado fundamental que mostra que a soma de um número muito grande de v.a.s tende a uma v.a. Gaussiana.
- Seja y_n uma v.a. definida por

$$y_n = \sum_{i=1}^n x_i,$$

em que $\{x_1, x_2, \dots, x_n\}$ são v.a.s estatisticamente independentes, identicamente distribuídas, todas com média m e variância σ^2 .

- Então a v.a. z_n que caracteriza a soma normalizada descrita por

$$z_n = \frac{y_n - m_{y_n}}{\sigma_{y_n}}$$

é tal que

$$\lim_{n \rightarrow \infty} p_{z_n}(Z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$



Demonstração:

Usando $E[\sum_{i=1}^n a_i x_i] = \sum_{i=1}^n a_i E[x_i]$ para $y_n = \sum_{i=1}^n x_i$, obtém-se

$$m_{y_n} = n.m \text{ e } \sigma^2_{y_n} = n.\sigma^2$$

Logo, a soma normalizada pode ser escrita como

$$z_n = \frac{y_n - m_{y_n}}{\sigma_{y_n}} = \frac{y_n - n.m}{\sqrt{n} \sigma} = \frac{1}{\sqrt{n}} \sum_{i=1}^n w_i,$$

em que $w_i = \frac{x_i - m}{\sigma}$.

Note que $m_{w_i} = 0$, $i = 1, 2, \dots, n$ e $\sigma^2_{w_i} = 1$, $i = 1, 2, \dots, n$



Como as v.a.s $\{x_1, x_2, \dots, x_n\}$ são estatisticamente independentes, as v.a.s $\{w_1, w_2, \dots, w_n\}$ também o são. Tem-se então

$$M_{z_n}(v) = E \left[e^{jv \frac{1}{\sqrt{n}} \sum_{i=1}^n w_i} \right] = \prod_{i=1}^n E \left[e^{jv \frac{1}{\sqrt{n}} w_i} \right] = \left(E \left[e^{jv \frac{1}{\sqrt{n}} w_i} \right] \right)^n$$

Por outro lado, a expansão em série

$$e^{jv \frac{1}{\sqrt{n}} w_i} = \sum_{k=0}^{\infty} \frac{\left(jv \frac{1}{\sqrt{n}} w_i \right)^k}{k!}$$

Permite escrever

$$E \left[e^{jv \frac{1}{\sqrt{n}} w_i} \right] = 1 + \frac{jv}{\sqrt{n}} m_{w_i} - \frac{v^2}{2n} \sigma_{w_i}^2 - j \frac{v^3}{6n^{\frac{3}{2}}} E[w_i^3] + \dots$$



Considerando-se $m_{w_i} = 0$ e $\sigma^2_{w_i} = 1$, tem-se

$$E[e^{jv\frac{1}{\sqrt{n}}w_i}] = 1 - \frac{v^2}{2n} - \frac{R_n}{n},$$

em que R_n caracteriza o resto da série a partir do termo de 3ª ordem e satisfaz

$$\lim_{n \rightarrow \infty} R_n = 0$$

A partir de $M_{z_n}(v)$ pode-se escrever

$$\ln M_{z_n}(v) = n \ln E[e^{jv\frac{1}{\sqrt{n}}w_i}] = n \ln \left(1 - \frac{v^2}{2n} - \frac{R_n}{n} \right)$$

Considerando-se a série dada por

$$\ln(1 - x) = \sum_{k=1}^{\infty} \frac{-x^k}{k}$$

Pode-se reescrever $\ln M_{z_n}(v)$ como

$$\ln M_{z_n}(v) = -\frac{v^2}{2} - R_n - \frac{\left(\frac{v^2}{2n} + \frac{R_n}{n}\right)^2}{2n} - \frac{\left(\frac{v^2}{2n} + \frac{R_n}{n}\right)^3}{3n^2} + \dots$$



Logo, obtém-se

$$\lim_{n \rightarrow \infty} \ln M_{z_n}(v) = -\frac{v^2}{2}$$

ou

$$\lim_{n \rightarrow \infty} M_{z_n}(v) = e^{-\frac{v^2}{2}}$$

Finalmente, obtém-se

$$\begin{aligned} \lim_{n \rightarrow \infty} p_{z_n}(Z) &= \lim_{n \rightarrow \infty} \frac{1}{2\pi} \int_{-\infty}^{\infty} M_{z_n}(v) e^{-jvX} dX \\ &= \frac{1}{2\pi} \lim_{n \rightarrow \infty} \int_{-\infty}^{\infty} M_{z_n}(v) e^{jvX} dX \\ &= \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} \end{aligned}$$



Função característica de um vetor aleatório

- A função característica de um vetor aleatório x de dimensão n é definida por

$$\begin{aligned}M_x(\mathbf{v}) &= E \left[e^{j\mathbf{v}^T \mathbf{x}} \right] \\ &= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} e^{j\mathbf{v}^T \mathbf{x}} p_x(\mathbf{X}) d\mathbf{X}\end{aligned}$$

- Observe que $M_x(\mathbf{v})$ é uma função das n variáveis $\{v_1, v_2, \dots, v_n\}$ que caracterizam o vetor \mathbf{v} e toma valores no conjunto dos n . complexos.
- No caso de vetores aleatórios, a fdp conjunta do vetor x pode ser obtida a partir de sua função característica.



Propriedades

1) $M_x(\mathbf{0}) = 1$

2) $|M_x(\mathbf{v})| \leq 1$

3) Se $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{b}$

então $M_y(\mathbf{v}) = e^{j\mathbf{v}^T \mathbf{b}} M_x(\mathbf{A}^T \mathbf{v})$



- Demonstração:

$$M_y(\mathbf{v}) = E \left[e^{j\mathbf{v}^T \mathbf{y}} \right] = E \left[e^{j\mathbf{v}^T (\mathbf{A}\mathbf{x} + \mathbf{b})} \right] = e^{j\mathbf{v}^T \mathbf{b}} E \left[e^{j\mathbf{v}^T \mathbf{A}\mathbf{x}} \right]$$

Como $\mathbf{v}^T \mathbf{A} = (\mathbf{A}^T \mathbf{v})^T$ tem-se

$$M_y(\mathbf{v}) = e^{j\mathbf{v}^T \mathbf{b}} M_x(\mathbf{A}^T \mathbf{v})$$



4) Se as componentes $\{x_1, x_2, \dots, x_n\}$ do vetor aleatório x são estatisticamente independentes então

$$M_x(\mathbf{v}) = \prod_{i=1}^n M_{x_i}(v_i)$$



Demonstração:

$$\begin{aligned}M_x(\mathbf{v}) &= E \left[e^{j\mathbf{v}^T \mathbf{x}} \right] = E \left[e^{j \sum_{i=1}^n v_i x_i} \right] \\&= E \left[\prod_{i=1}^n e^{j v_i x_i} \right] = \prod_{i=1}^n E \left[e^{j v_i x_i} \right] \\&= \prod_{i=1}^n M_{x_i}(v_i)\end{aligned}$$



$$5) E \left[x_1^{k_1} x_2^{k_2} \dots x_n^{k_n} \right] = (-j)^{k_1+k_2+\dots+k_n} \frac{\partial^{k_1+k_2+\dots+k_n}}{\partial v_1^{k_1} \partial v_2^{k_2} \dots \partial v_n^{k_n}} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}}$$



Exemplo 18

Seja x um vetor aleatório com função característica dada por

$$M_x(\mathbf{v}) = e^{-(2v_1^2 + 2v_2^2 + v_1v_2)}$$

em que $\mathbf{v} = [v_1 \ v_2]^T$

Deseja-se determinar o vetor médio \mathbf{m}_x e a matriz covariância \mathbf{K}_x do vetor aleatório x .



Solução:

Usando-se a prop. $E \left[x_1^{k_1} x_2^{k_2} \dots x_n^{k_n} \right] = (-j)^{k_1+k_2+\dots+k_n} \frac{\partial^{k_1+k_2+\dots+k_n}}{\partial v_1^{k_1} \partial v_2^{k_2} \dots \partial v_n^{k_n}} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}}$
tem-se

$$E[x_1] = (-j) \frac{\partial}{\partial v_1} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = (-j) (-4v_1 - v_2) M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = 0$$

$$E[x_2] = (-j) \frac{\partial}{\partial v_2} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = (-j) (-4v_2 - v_1) M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = 0$$

Logo, tem-se

$$\mathbf{m}_x = \begin{bmatrix} m_{x_1} \\ m_{x_2} \end{bmatrix} = \begin{bmatrix} E[x_1] \\ E[x_2] \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$



A mesma prop. 5 permite escrever

$$\begin{aligned}k_{x_1x_2} &= E[x_1x_2] = E[x_2x_1] = (-j)^2 \frac{\partial^2}{\partial v_1 \partial v_2} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = \\ &= (-1)[(4v_1 + v_2)(4v_2 - v_1) - 1] M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = 1\end{aligned}$$

Além disso, tem-se

$$\begin{aligned}E[x_1^2] &= (-j)^2 \frac{\partial^2}{\partial v_1^2} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} \\ &= (-1)[(4v_1 + v_2)^2 - 4] M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = 4\end{aligned}$$

$$\begin{aligned}E[x_2^2] &= (-j)^2 \frac{\partial^2}{\partial v_2^2} M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} \\ &= (-1)[(4v_2 + v_1)^2 - 4] M_x(\mathbf{v}) \Big|_{\mathbf{v} = \mathbf{0}} = 4\end{aligned}$$

Como $\mathbf{m}_x = \mathbf{0}$ tem-se $E[x_1^2] = \sigma_{x_1}^2 = 4$, $E[x_2^2] = \sigma_{x_2}^2 = 4$ e

$$\mathbf{K}_x = \begin{bmatrix} \sigma_{x_1}^2 & k_{x_1x_2} \\ k_{x_1x_2} & \sigma_{x_2}^2 \end{bmatrix} = \begin{bmatrix} 4 & 1 \\ 1 & 4 \end{bmatrix}$$