

PROBABILIDADES, VARIÁVEIS ALEATÓRIAS E PROCESSOS  
ESTOCÁSTICOS  
– REVISÃO –

**Profa GABRIELA W GABRIEL**

IEE-S / ITA – Sala 195 – Ramal 5991

São José dos Campos, 26 de Agosto de 2021



















































# VARIÁVEIS ALEATÓRIAS CONTÍNUAS

- Função Densidade de Probabilidade

**FUNÇÃO DENSIDADE DE PROBABILIDADES** (pdf) de uma variável aleatória contínua  $x$  tendo uma função distribuição  $F_x$  é qualquer função não negativa  $f_x$  definida em  $\mathbb{R}$  com a propriedade de que

$$F_x(\alpha) = \mathcal{P}(x \in (-\infty, \alpha]) = \int_{-\infty}^{\alpha} f_x(\gamma) d\gamma$$

para todo  $\alpha \in \mathbb{R}$ , com  $f_x(\alpha) \geq 0$ ,  $\forall \alpha \in \mathbb{R}$ .

$$- \exists \frac{dF_x(\alpha)}{d\alpha} \Rightarrow f_x(\alpha) = \frac{dF_x(\alpha)}{d\alpha}$$

$$- \mathcal{P}(x \in \mathbb{R}) = \mathcal{P}(S) = \int_{-\infty}^{\infty} f_x(\gamma) d\gamma = 1$$

$$- \mathcal{P}(\alpha \leq x \leq \alpha + d\alpha) = \int_{\alpha}^{\alpha+d\alpha} f_x(\gamma) d\gamma = f_x(\alpha) d\alpha, \text{ para } d\alpha \rightarrow 0$$

$$- \mathcal{P}(x = \alpha) = 0 \text{ e } \mathcal{P}(x \leq \alpha) = \mathcal{P}(x < \alpha)$$

# VARIÁVEIS ALEATÓRIAS CONTÍNUAS

- VA Contínuas Especiais

- VA UNIFORME CONTÍNUA

$$f_x(\alpha) = \begin{cases} 0 & \alpha \notin [a, b] \\ \frac{1}{b-a} & \alpha \in [a, b] \end{cases}$$

- VA EXPONENCIAL

$$f_x(\alpha) = \begin{cases} \lambda e^{-\lambda\alpha} & \alpha \geq 0 \\ 0 & \alpha < 0 \end{cases}$$

com parâmetro  $\lambda > 0$ .

# VARIÁVEIS ALEATÓRIAS CONTÍNUAS

- VA Contínuas Especiais (CONT.)

## – VA NORMAL

$$f_x(\alpha) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\alpha-\mu)^2}{2\sigma^2}}$$

com parâmetros  $\mu$  (média) e  $\sigma^2$  (variância).

$x$  definida por  $x \sim N(\mu, \sigma^2)$  é dita gaussiana.

## OUTRAS FUNÇÕES DE VA

**FUNÇÃO DISTRIBUIÇÃO CONJUNTA** é a função distribuição decorrente da **interseção de dois eventos distintos**. Assim sejam duas variáveis aleatórias  $x_1$  e  $x_2$ , definidas no espaço de probabilidade  $(\mathcal{S}, \mathcal{F}, \mathcal{P})$  em que o conjunto

$$\begin{aligned}\{x_1 \leq \alpha_1\} \cap \{x_2 \leq \alpha_2\} &= \{x_1 \leq \alpha_1, x_2 \leq \alpha_2\} \\ &= \{\xi \in \mathcal{S} : x_1(\xi) \leq \alpha_1 \text{ e } x_2(\xi) \leq \alpha_2\}\end{aligned}$$

Por definição, estes conjuntos são eventos de  $\mathcal{F}$  e portanto  $\{x_1 \leq \alpha_1, x_2 \leq \alpha_2\}$  também é um evento de  $\mathcal{F}$ . Logo, a função distribuição conjunta é dada por

$$F_{x_1, x_2}(\alpha_1, \alpha_2) = \mathcal{P}(x_1 \leq \alpha_1, x_2 \leq \alpha_2)$$

Suas propriedades são análogas ao caso unidimensional!

## OUTRAS FUNÇÕES DE VA

**FUNÇÃO DENSIDADE DE PROBABILIDADE CONJUNTA** associada às variáveis aleatórias  $x_1$  e  $x_2$  é definida como

$$f_{x_1 x_2}(\alpha_1, \alpha_2) = \int_{-\infty}^{\alpha_1} \int_{-\infty}^{\alpha_2} f_{x_1 x_2}(\beta_1, \beta_2) d\beta_1 d\beta_2$$

tal que  $f_{x_1 x_2}(\alpha_1, \alpha_2) \geq 0, \forall \alpha_1, \alpha_2 \in \mathbb{R}$ .

**FUNÇÃO DISTRIBUIÇÃO CONDICIONAL**  $F_{x_1|x_2}$  de uma variável aleatória  $x_1$  dado o evento  $\{x_2 \leq \alpha_2\}$  é definido como

$$F_{x_1|x_2}(\alpha_1|\alpha_2) \triangleq \mathcal{P}\{x_1 \leq \alpha_1 | x_2 \leq \alpha_2\} = \frac{F_{x_1 x_2}(\alpha_1, \alpha_2)}{F_{x_2}(\alpha_2)}$$

para todo  $\alpha_1 \in \mathbb{R}^n$  e  $\alpha_2 \in \mathbb{R}^m$ .

## OUTRAS FUNÇÕES DE VA

**FUNÇÃO DENSIDADE DE PROBABILIDADE CONDICIONAL**  $f_{x_1|x_2}$  de uma variável aleatória  $x_1$  dado o evento  $\{x_2 = \alpha_2\}$  é definido como

$$f_{x_1|x_2}(\alpha_1|\alpha_2) = \frac{f_{x_1x_2}(\alpha_1, \alpha_2)}{f_{x_2}(\alpha_2)}$$

para todo  $\alpha_1 \in \mathbb{R}^n$  e  $\alpha_2 \in \mathbb{R}^m$ .

**VARIÁVEIS ALEATÓRIAS INDEPENDENTES.** Duas variáveis aleatórias  $x_1$  e  $x_2$  são independentes se os eventos  $\{x_1 \leq \alpha_1\}$  e  $\{x_2 \leq \alpha_2\}$  forem independentes para qualquer  $\alpha_1$  e  $\alpha_2$ , ou seja,

$$\mathcal{P}(x_1 \leq \alpha_1, x_2 \leq \alpha_2) = \mathcal{P}(x_1 \leq \alpha_1)\mathcal{P}(x_2 \leq \alpha_2)$$

## OUTRAS FUNÇÕES DE VA

**N VARIÁVEIS ALEATÓRIAS INDEPENDENTES.** N variáveis aleatórias  $x_1, x_2, \dots, x_N$  são independentes se os eventos  $\{x_1 \leq \alpha_1\}, \{x_2 \leq \alpha_2\}, \dots, \{x_N \leq \alpha_N\}$  forem independentes para quaisquer escolhas de  $\alpha_1, \alpha_2, \dots, \alpha_N$ , ou seja,

$$\mathcal{P}(x_1 \leq \alpha_1, \dots, x_N \leq \alpha_N) = \mathcal{P}(x_1 \leq \alpha_1) \cdots \mathcal{P}(x_N \leq \alpha_N)$$

## OUTRAS FUNÇÕES DE VA

**VALOR ESPERADO (VALOR MÉDIO)(MÉDIA)(ESPERANÇA)** denotado por  $\mathcal{E}(x)$ ,  $\mu$  ou  $\mu_x$ , de uma v.a.  $x$  com densidade de probabilidade  $f_x$  é definido por

$$\mathcal{E}(x) = \int_{-\infty}^{\infty} \alpha f_x(\alpha) d\alpha$$

caso a integral exista.

O  **$k$ -ÉSIMO MOMENTO** de uma v.a.,  $k = 0, 1, 2, \dots$ , também dito momento de ordem  $k$ , é denotado

$$m_{x^k} = \int_{-\infty}^{\infty} \alpha^k f_x(\alpha) d\alpha$$

caso a integral exista.

Notação utilizada:  $m_{x^k}$  ou simplesmente  $m_k$ .

## OUTRAS FUNÇÕES DE VA

O  $k$ -ésimo **MOMENTO CENTRAL** de uma v.a.,  $k = 0, 1, 2, \dots$ , é o momento calculado em relação à sua média, ao invés de calculado em relação a zero, portanto, é denotado por

$$\eta_{x^k} = \int_{-\infty}^{\infty} (\alpha - \mu)^k f_x(\alpha) d\alpha$$

caso a integral exista.

Notação utilizada:  $\eta_{x^k}$  ou simplesmente  $\eta_k$ .

A **ESPERANÇA CONDICIONAL** de uma v.a.  $x$ , dada uma v.a.  $y = \beta$ , é

$$\mathcal{E}(x|y = \beta) = \int_{-\infty}^{\infty} \alpha f_{x|y}(\alpha|\beta) d\alpha$$

caso a integral exista.

## OUTRAS FUNÇÕES DE VA

Duas v.a.  $x$  e  $y$  são **DESCORRELACIONADAS** se

$$\mathcal{E}(xy) = \mathcal{E}(x)\mathcal{E}(y)$$

caso a integral exista.

Duas v.a.  $x$  e  $y$  são **ORTOGONAIS** se

$$\mathcal{E}(xy) = 0$$

caso a integral exista.

## VETOR DE VARIÁVEIS ALEATÓRIAS

Um **vetor aleatório**  $x = \{x_1, \dots, x_n\}$  é uma coleção de v.a.  $x_i$ , definidas para  $\alpha = \{\alpha_1, \dots, \alpha_n\}$ . Assim,

$$\mathcal{P}(x \in D) = \int_D f_x(\alpha) d\alpha$$

A **densidade de probabilidade conjunta** das v.a.  $x_i$ :

$$f_x(\alpha) = f_{x_1, \dots, x_n}(\alpha_1, \dots, \alpha_n) = \frac{\partial^n F_{x_1, \dots, x_n}(\alpha_1, \dots, \alpha_n)}{\partial \alpha_1 \cdots \partial \alpha_n}$$

onde a **função distribuição conjunta** é dada por:

$$F_x(\alpha) = F_{x_1, \dots, x_n}(\alpha_1, \dots, \alpha_n) = \mathcal{P}(x_1 \leq \alpha_1, \dots, x_n \leq \alpha_n)$$

## VETOR DE VARIÁVEIS ALEATÓRIAS

A **MÉDIA DE UMA FUNÇÃO**  $g(x)$  é dada por

$$\mathcal{E}(g(x)) = \int_{-\infty}^{\infty} g(\alpha_1, \dots, \alpha_n) f_{x_1, \dots, x_n}(\alpha_1, \dots, \alpha_n) d\alpha$$

Chamaremos de

- $V_{ij}$ , a **matriz de covariância** entre  $x_i$  e  $x_j$
- $R_{ij}$  é a **matriz de correlação** entre  $x_i$  e  $x_j$ .

Assim,

$$V_{ij} = \mathcal{E}((x_i - \mu_i)(x_j - \mu_j)) = \mathcal{E}(x_i x_j) - \mu_i \mu_j = R_{ij} - \mu_i \mu_j$$

$$\sigma_i^2 = V_{ii} = \mathcal{E}((x_i - \mu_i)^2) = \mathcal{E}(x_i^2) - (\mathcal{E}(x_i))^2$$

Duas v.a. são **MUTUAMENTE DESCORRELACIONADAS** se  $V_{ij} = 0$  para todo  $i \neq j$ .

## SEQUÊNCIA DE MEDIDAS

Seja  $x = \{x_1, \dots, x_n\}$  uma **sequência de medidas** de  $\chi$ .

As componentes de  $x$

- são **independentes e identicamente distribuídos (iid)**
- possuem mesma distribuição de  $\chi$ .

Definiremos a **média das amostras**  $M_n$

$$M_n = \frac{1}{n} \sum_{j=1}^n x_j = \frac{S_n}{n}$$

## SEQUÊNCIA DE MEDIDAS

Um bom **estimador** para  $\chi$  deve satisfazer:

1. Na média, o estimador  $\mu = \mathcal{E}(\chi) = \mathcal{E}(M_n)$ ;
2.  $\mathcal{E}((M_n - \mu)^2)$  deve ser pequena.

De fato,

$$\mathcal{E}(M_n) = \mathcal{E}\left(\frac{1}{n} \sum_{j=1}^n x_j\right) = \frac{1}{n} \sum_{j=1}^n \mathcal{E}(x_j) = \mu$$

com  $\mathcal{E}(x_j) = \mu, \forall j \in \{1, \dots, n\}$ .

A média das amostras é um **ESTIMADOR** não polarizado de  $\mu$ .

## SEQUÊNCIA DE MEDIDAS

Por outro lado,

$$\mathcal{E}((M_n - \mu)^2) = \mathcal{E}((M_n - \mathcal{E}(M_n))^2) = \text{var}(M_n)$$

e que

$$\begin{aligned} \text{var}(S_n) &= \text{var}(x_1 + x_2 + \cdots + x_n) \\ &= \text{var}(x_1) + \text{var}(x_2) + \cdots + \text{var}(x_n) = n \times \text{var}(X) = n\sigma^2 \end{aligned}$$

Como consequência,

$$\text{var}(M_n) = 1/n^2 \times \text{var}(S_n) = \sigma^2/n$$

Assim,

$$\mathcal{P}(\mathcal{E}(M_n) = \mu) \rightarrow 1 \text{ quando } n \rightarrow \infty$$

## LEI DOS GRANDES NÚMEROS

**LEI DOS GRANDES NÚMEROS (Fraca):** sejam  $x_1, x_2, \dots$  uma sequência de iid variáveis aleatórias com média finita  $\mathcal{E}(x) = \mu$ , então para  $\varepsilon > 0$ ,

$$\lim_{n \rightarrow \infty} \mathcal{P}(|M_n - \mu| < \varepsilon) = 1$$

que depende da média de  $\chi$ . E,

**LEI DOS GRANDES NÚMEROS (Forte):** sejam  $x_1, x_2, \dots$  uma sequência de iid variáveis aleatórias com média finita  $\mathcal{E}(x) = \mu$  e variância finita, então

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

As duas definições embutem o conceito de **convergência** de uma **sequência** de VA.

# SEQUÊNCIAS DE V.A.

Uma **SEQUÊNCIA DE VA** é uma função que atribui uma quantidade infinita, porém contável, de valores reais ao evento  $\xi$  associado a cada resultado de um determinado espaço amostral  $\mathcal{S}$ . Representaremos esta sequência como

$$\{x_n\} = \{x_n(\xi)\} = \{x_1(\xi), \dots, x_n(\xi), \dots\}$$

Todo elemento  $x_i$ ,  $i = 1, \dots, n$ , é definido para o mesmo evento  $\xi$ .

## DEFINIÇÕES DE CONVERGÊNCIA DE SEQUÊNCIAS

A **sequência**  $\{x_n\}$  **CONVERGE** para  $x$  se, dado qualquer  $\varepsilon > 0$ , nós podemos especificar um inteiro  $N$ , tal que, para todos os valores de  $n$  maiores que  $N$ , podemos garantir que  $|x_n - x| < \varepsilon$ .

Esta definição pressupõe o conhecimento do valor verdadeiro  $x$ .

A **sequência**  $\{x_n\}$  **CONVERGE se e somente se**, dado qualquer  $\varepsilon > 0$ , nós podemos especificar um inteiro  $N'$ , tal que, para  $n$  e  $m$  maiores que  $N'$ , teremos que  $|x_n - x_m| < \varepsilon$ .

Das definições acima podemos estabelecer as seguintes definições de convergência de v.a.

## DEFINIÇÕES DE CONVERGÊNCIA DE SEQUÊNCIAS DE V.A.

**CONVERGÊNCIA NO SENTIDO CERTO.** Neste caso, dizemos que a variável aleatória  $\{x_n(\xi)\}$  converge no sentido certo para a variável aleatória  $x(\xi)$ , se a sequência de funções  $x_n(\xi)$ , calculada no ponto  $\xi$ , convergem para a função  $x(\xi)$  quando  $n \rightarrow \infty$  para todo evento  $\xi \in \mathcal{S}$ , em outras palavras,

$$X_n(\xi) \rightarrow X(\xi), \text{ quando } n \rightarrow \infty \forall \xi \in \mathcal{S}$$

Em cada ponto  $\xi$  a sequência converge para um valor  $x(\xi)$ .

## DEFINIÇÕES DE CONVERGÊNCIA DE SEQUÊNCIAS DE V.A.

**CONVERGÊNCIA NO SENTIDO QUASE CERTO.** Uma sequência de v.a.  $\{x_n(\xi)\}$  converge quase certamente para outra variável aleatória  $x(\xi)$  se a sequência de funções  $x_n(\xi)$  converge para a função  $x(\xi)$  quando  $n \rightarrow \infty$ , para todo  $\xi \in \mathcal{S}$ , exceto possivelmente para um conjunto de eventos cuja probabilidade da convergência é nula, ou seja,

$$\mathcal{P}(\xi : X_n(\xi) \rightarrow X(\xi), \text{ quando } n \rightarrow \infty) = 1$$

Nesta última definição, podemos ter algum evento  $\xi$ , para o qual sua sequência não converge, porém, este evento deve pertencer ao conjunto de probabilidade nula.



## CONVERGÊNCIA DE V.A.

**CONVERGÊNCIA EM DISTRIBUIÇÃO.** A sequência de v.a.  $\{x_n(\xi)\}$  com funções distribuição de probabilidades  $\{F_n(x)\}$  converge em distribuição para uma v.a.  $x(\xi)$  com função distribuição  $F(x)$ , se

$$F_n(x) \rightarrow F(x), \text{ quando } n \rightarrow \infty$$

para todo  $x$  para o qual  $F(x)$  é contínua.









## PROBABILIDADES CONJUNTAS DE P.E.

**FUNÇÃO DENSIDADE DE SEGUNDA ORDEM** (uma vez que relacional o comportamento de  $x(t)$  em dois instantes distintos de tempo) associada a um processo estocástico  $x(\xi, t)$  como qualquer função  $f_{x(t_1)x(t_2)}$  definida em  $\mathbb{R}^n$  que satisfaça

$$F_{x(t_1)x(t_2)}(\alpha_1, \alpha_2, t_1, t_2) = \int_{-\infty}^{\alpha_1} \int_{-\infty}^{\alpha_2} f_{x(t_1)x(t_2)}(\beta_1, \beta_2, t_1, t_2) d\beta_2 d\beta_1$$

para todo  $t_1, t_2 \in \mathcal{T}$  e todo  $\alpha_1, \alpha_2 \in \mathbb{R}^n$  e  $f_{x(t_1)x(t_2)}(\beta_1, \beta_2, t_1, t_2) \geq 0$  para todo  $\beta_1, \beta_2 \in \mathbb{R}^n$  e todo  $t_1, t_2 \in \mathcal{T}$ .





# ESPERANÇA E MOMENTOS DE P.E.

A **MÉDIA** de um processo estocástico  $x(\xi, t)$  é dado por

$$\mu_x(t) = \mathcal{E}(x(t)) = \int_{-\infty}^{\infty} \alpha f_{x(t)}(\alpha, t) d\alpha$$

que, no geral, são funções do tempo.

O **VALOR MÉDIO QUADRÁTICO** de um processo estocástico  $x(\xi, t)$  é, para o caso vetorial,

$$P_x(t) = \mathcal{E}(x(t)x(t)') = \int_{-\infty}^{\infty} \alpha\alpha' f_{x(t)}(\alpha, t) d\alpha$$







# ESPERANÇA E MOMENTOS DE P.E.

Dois p.e.  $x(t)$  e  $y(t)$  são ditos **MUTUAMENTE ORTOGONAIS** se

$$R_{xy}(t_1, t_2) = 0, \text{ para toda escolha de } t_1, t_2$$

e um p.e. é **DESCORRELACIONADO** se

$$V_{xy}(t_1, t_2) = 0, \text{ para toda escolha de } t_1, t_2$$

Dizemos que um p.e.  $x(t)$  é um **RUÍDO BRANCO** se os valores de  $x(t_i)$  e de  $x(t_j)$  são descorrelacionadas para todo  $t_i$  e  $t_j \neq t_i$ .

$$V_{xx}(t_1, t_2) = 0, \text{ para toda escolha de } t_1, t_2$$





## DENSIDADE ESPECTRAL DE UM P.E.

A **POTÊNCIA ESPECTRAL** (ou **DENSIDADE ESPECTRAL**) de um p.e. WSS,  $x(t)$ , real ou complexo, é a Transformada de Fourier  $S(\omega)$  da sua autocorrelação  $R_{x(t+\tau)x(t)}(\tau) = \mathcal{E}(x(t+\tau)x^*(t))$

$$S(\omega) = \int_{-\infty}^{\infty} R_{x(t+\tau)x(t)}(\tau) e^{-j\omega\tau} d\tau$$



## PROCESSO ESTOCÁSTICO ERGÓDICO

Dizemos que um p.e.  $x(t)$  é **ERGÓDICO** se sua média temporal é idêntica a sua média estocástica, ou seja,

$$\lim_{T \rightarrow \infty} \langle g(x(t)) \rangle_T = \mathcal{E}(g(x(t)))$$

com probabilidade 1, para qualquer  $g(\cdot)$  para a qual a integral acima exista. O símbolo  $\langle \cdot \rangle_T$  denota a média temporal de  $(\cdot)$  em  $T$ ,

$$\langle y(t) \rangle_T = \frac{1}{2T} \int_{-T}^T y(t) dt$$











## CONVERGÊNCIA DA CADEIA DE MARKOV

- A cadeia de Markov entra em processo estacionário para  $n \rightarrow \infty$ , quando

$$p_{ij}(n) \rightarrow \pi_j, \forall i$$

em consequência,  $P^n$  convergir equivale ao estado da cadeia de Markov convergir. Neste caso dizemos que a cadeia entrou em **estado permanente** ou em **equilíbrio** com

$$\pi = \pi P$$