

# Aula 15: Esperança

Disciplina: PGE950 - Probabilidade  
Programa de Pós-graduação em Estatística da UFPE

Prof. Pablo M. Rodriguez  
<http://www.pablo-rodriguez.org>



UNIVERSIDADE  
FEDERAL  
DE PERNAMBUCO

**CCEN**

CENTRO DE CIÊNCIAS EXATAS  
E DA NATUREZA

# Conteúdo desta aula

- ▶ Esperança matemática: propriedades e exemplos.



## Teorema 15.1

Sejam  $X \sim \mathcal{N}(0,1)$  e  $Y \sim \mathcal{N}(0,1)$  independentes. Então

$$U = \frac{X}{Y}$$

tem densidade dada por

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

### Observação!

Uma variável aleatória  $U$  tem distribuição de Cauchy padrão se sua densidade é dada por (1). Em geral, a distribuição de Cauchy com parâmetros  $\alpha$  e  $\beta$  é

dada pela densidade  $f(x) = \frac{1}{\pi\beta \left(1 + \left\{\frac{x-\alpha}{\beta}\right\}^2\right)}$ , para  $x \in \mathbb{R}$ .



*Demonstração do Teorema 15.1.* Primeiro usamos o método do Jacobiano para encontrar a densidade conjunta de:

$$U = g_1(X, Y) = \frac{X}{Y} \quad \text{e} \quad V = g_2(X, Y) = Y$$

onde usamos  $g : \mathbb{R}^2 \setminus \{(0, 0)\} \rightarrow \mathbb{R}^2 \setminus \{(0, 0)\}$ . Note que

$$P((X, Y) \in \mathbb{R}^2 \setminus \{(0, 0)\}) = 1.$$

Logo  $U$  e  $V$  assumem valores em  $\mathbb{R} \setminus \{0\}$ . Como

$$\begin{cases} u = g_1(x, y) = \frac{x}{y}, \\ v = g_2(x, y) = y \end{cases} \implies \begin{cases} x = h_1(u, v) = uv, \\ y = h_2(u, v) = v \end{cases}$$

$$\text{temos que } J(u, v) = \det \begin{bmatrix} v & u \\ 0 & 1 \end{bmatrix} = v \neq 0.$$



... *continuação da prova do Teorema 15.1.* Pelo método do Jacobiano temos:

$$f_{U,V}(u, v) = v f_{X,Y}(h_1(u, v), h_2(u, v)).$$

Então,

$$f_{U,V}(u, v) = \frac{1}{2\pi} v e^{-(1+u^2)v^2/2}, \quad u \in \mathbb{R} \text{ e } v \in \mathbb{R},$$

e a prova é finalizada fazendo  $f_U(u) = \int_{-\infty}^{\infty} f_{U,V}(u, v) dv$ .



# Esperança de uma v.a. discreta

A esperança de uma v.a. discreta  $X$ , com valores em  $\mathcal{S}$  e função de probabilidade  $p(x)$ , é dada por

$$E(X) := \sum_{x \in \mathcal{S}} x p(x) = \sum_{x \in \mathcal{S}: x < 0} x p(x) + \sum_{x \in \mathcal{S}: x \geq 0} x p(x),$$

... desde que pelo menos uma das somas seja finita. Caso contrário, dizemos que a esperança de  $X$  não existe.

## Observação!

Note que ambas as somas são finitas se  $\sum_{x \in \mathcal{S}} |x| p(x) < \infty$ .




► Se  $X \sim \text{Poisson}(\lambda)$  então

$$E(X) = \sum_{n=0}^{\infty} n \left\{ e^{-\lambda} \frac{\lambda^n}{n!} \right\} = \lambda e^{-\lambda} \sum_{n=1}^{\infty} \frac{\lambda^{n-1}}{(n-1)!} = \lambda e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = \lambda.$$

Observação!

Considere um Processo de Poisson de parâmetro  $\lambda$ :



Qual o papel de  $\lambda$ ?

Lembre que  $N(a, b) \sim \text{Poisson}(\lambda(b - a))$ .



## Exemplo 15.1

Seja  $X$  uma variável aleatória discreta com valores em  $\mathbb{Z} \setminus \{0\}$  tal que

$$p(i) = \frac{C}{i^2}, \quad i \in \mathbb{Z} \setminus \{0\}, \quad \text{com } C = \left\{ \frac{1}{2} \sum_{i=1}^{\infty} \frac{1}{i^2} \right\}^{-1}.$$

Então  $E(X)$  não existe pois:

$$- \sum_{i \in \mathbb{Z}_-} i p(i) = \sum_{i \in \mathbb{Z}_+} i p(i) = C \sum_{i=1}^{\infty} \frac{1}{i} = \infty$$





# Esperança de uma v.a. continua

A esperança de uma v.a. continua  $X$ , com densidade  $f(x)$ , é dada por

$$E(X) := \int_{-\infty}^{+\infty} x f(x) dx = \int_{-\infty}^0 x f(x) dx + \int_0^{+\infty} x f(x) dx,$$

... desde que pelo menos uma das integrais seja finita. Caso contrário, dizemos que a esperança de  $X$  não existe.

## Observação!

*Note que ambas as integrais são finitas se  $\int_{-\infty}^{\infty} |x| f(x) dx < \infty$ .*



- ▶ Se  $X \sim \text{Gama}(\alpha, \lambda)$  então

$$E(X) = \int_0^{\infty} x \left\{ \frac{\lambda e^{-\lambda x} (\lambda x)^{\alpha-1}}{\Gamma(\alpha)} \right\} dx = \frac{1}{\lambda \Gamma(\alpha)} \underbrace{\int_0^{\infty} \lambda e^{-\lambda x} (\lambda x)^{\alpha} dx}_{=\Gamma(\alpha+1)}$$

e portanto  $E(X) = \frac{\alpha}{\lambda}$ .

- ▶ Se  $\alpha = 1$  então  $X \sim \text{Exp}(\lambda)$  e  $E(X) = 1/\lambda$ .

**Observação!**

Voltando ao Processo de Poisson de parâmetro  $\lambda$ :



$T_i$ 's i.i.d. com  $T_1 \sim \text{Exp}(\lambda)$

Qual o papel do  $\lambda$ ?

$$S_5 = \sum_{i=1}^5 T_i \sim (5, \lambda)$$



## Exemplo 15.2

Seja  $X$  uma variável aleatória Cauchy padrão. Isto é, com densidade:

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

Então  $E(X)$  não existe. De fato,

$$E(X) = \int_{-\infty}^{\infty} \frac{x}{\pi(1+x^2)} dx = \int_0^{\infty} \frac{x}{\pi(1+x^2)} dx + \int_{-\infty}^0 \frac{x}{\pi(1+x^2)} dx$$

mas

$$-\int_{-\infty}^0 \frac{x}{\pi(1+x^2)} dx = \int_0^{\infty} \frac{x}{\pi(1+x^2)} dx = \frac{1}{2\pi} \int_1^{\infty} \frac{dt}{t} = \infty$$

$t = 1 + x^2$



# A esperança como uma integral

Se  $X$  é uma variável aleatória com função de distribuição  $F$ , então:

$$E(X) = \int_{-\infty}^{\infty} x dF(x),$$

quando a integral imprópria de Riemann-Stieljes está bem definida.

## Integral de Riemann-Stieljes

Se  $\varphi$  é contínua e definida em  $[a, b]$  e  $F$  é uma função de distribuição, então

$$\int_a^b \varphi(x) dF(x) := \lim_{n \rightarrow \infty} \sum_{i=1}^n \varphi(y_i) (F(x_{i+1}) - F(x_i)), \text{ onde } a = x_1 < \dots < x_n = b$$

definem uma partição de  $[a, b]$ ,  $y_i \in [x_i, x_{i+1}]$ ,  $\max_i \{x_{i+1} - x_i\} \rightarrow 0$  se  $n \rightarrow \infty$ .

Além disto,  $\int_{-\infty}^{\infty} \varphi(x) dF(x) := \lim_{\substack{a \rightarrow -\infty \\ b \rightarrow \infty}} \int_a^b \varphi(x) dF(x)$ , se o limite existe.



## Proposição 15.1

$$E(X) = \int_0^{\infty} (1 - F(x)) dx - \int_{-\infty}^0 F(x) dx$$

*Prova.* Ver Proposição 3.1 do livro de Barry James.

## Corolário 15.1

Se  $X \geq 0$  então  $E(X) = \int_0^{\infty} P(X > x) dx$ .

## Corolário 15.2

Se  $X$  assume valores inteiros não-negativos:  $E(X) = \sum_{n=1}^{\infty} P(X \geq n)$ .



- ▶ Se  $X \sim \text{Exp}(\lambda)$  então

$$E(X) = \int_0^{\infty} P(X > x) dx = \int_0^{\infty} e^{-\lambda x} dx = \frac{1}{\lambda}$$

- ▶ Se  $X \sim \text{Geom}(p)$  então

$$E(X) = \sum_{n=1}^{\infty} P(X \geq n) = \sum_{n=1}^{\infty} (1-p)^{n-1} = \sum_{n=0}^{\infty} (1-p)^n = \frac{1}{p}.$$



# Propriedades

## Observação!

No que segue, consideramos variáveis aleatórias tais que sua esperança existe.

1. Se  $X = c$  então  $E(X) = c$ .

*Prova.* Como  $X$  é discreta temos que  $E(X) = cP(X = c) = c$ .

2. Se  $X \leq Y$  então  $E(X) \leq E(Y)$ .

*Prova.* Como  $\{Y \leq a\} \subset \{X \leq a\}$  então  $F_Y(a) \leq F_X(a)$ . Da Prop.15.1 temos:

$$\begin{aligned} E(Y) &= \int_0^{\infty} (1 - F_Y(a)) da - \int_{-\infty}^0 F_Y(a) da \\ &\geq \int_0^{\infty} (1 - F_X(a)) da - \int_{-\infty}^0 F_X(a) da \\ &= E(X). \end{aligned}$$



## 3. Linearidade.

$$E(cX + Y) = cE(X) + E(Y),$$

se  $c$  é uma constante, quando os termos à direita tem sentido.

Em geral, se  $X_1, \dots, X_n$  são v.a. e  $c_1, \dots, c_n$  são constantes, então:

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i).$$

*Prova.* Será realizada após considerar a esperança de uma função de um vetor aleatório.



### Exemplo 15.3

Sejam  $X_1, X_2, \dots, X_n$  i.i.d. com função de distribuição  $F$  e seja  $\mu := E(X_1)$ . Dizemos que esta sequência é uma amostra de  $F$  e

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

é a média amostral pois


$$E\left(\frac{X_1 + \dots + X_n}{n}\right) = \frac{1}{n}E(X_1 + \dots + X_n) = \frac{E(X_1) + \dots + E(X_n)}{n}$$

e portanto


$$E(\bar{X}) = \mu.$$




# O passeio aleatório em $\mathbb{Z}$




# O passeio aleatório em $\mathbb{Z}$




# O passeio aleatório em $\mathbb{Z}$



# O passeio aleatório em $\mathbb{Z}$



# O passeio aleatório em $\mathbb{Z}$



# O passeio aleatório em $\mathbb{Z}$

## Exemplo 15.4

A cada passo, independentemente, a partícula pula à direita com probabilidade  $p$ , ou à esquerda com probabilidade  $1 - p$ . Definimos:

$Y_n =$  posição da partícula logo após o  $n$  - ésimo pulo,

para  $n \in \{0, 1, 2, \dots\}$ , e supomos que  $Y_0 = 0$ . Podemos escrever

$$Y_n = \sum_{i=1}^n X_i,$$

onde  $X_1, X_2, \dots$  são v.a. i.i.d. tais que

$$P(X_i = 1) = p = 1 - P(X_i = -1).$$



... *continuação do Exemplo 15.4.* Note que

$$E(Y_n) = E(X_1 + X_2 + \cdots + X_n) = n E(X_1) = n(2p - 1).$$

Logo,

- ▶ se  $p = 1/2$  então  $E(Y_n) = 0$  para todo  $n$ ;
- ▶ se  $p = 1/2 + \epsilon$  com  $\epsilon > 0$  então  $E(Y_n) = 2\epsilon n \rightarrow \infty$ ;
- ▶ se  $p = 1/2 - \epsilon$  com  $\epsilon > 0$  então  $E(Y_n) = -2\epsilon n \rightarrow -\infty$ .





# Soma de variáveis aleatórias indicadoras e esperança

## Proposição 15.2

Se  $A_1, \dots, A_n$  são eventos aleatórios, então  $P\left(\bigcup_{i=1}^n A_i\right) \leq \sum_{i=1}^n P(A_i)$ .

*Prova.* Para cada  $i \in \{1, 2, \dots, n\}$  seja

$$X_i = \begin{cases} 1, & \text{se o evento } A_i \text{ ocorrer,} \\ 0, & \text{caso contrário.} \end{cases}$$

Seja  $X = \sum_{i=1}^n X_i$ . Então

$$E(X) = \sum_{i=1}^n E(X_i) = \sum_{i=1}^n P(A_i). \quad (3)$$



... continuação da prova da Prop.15.2. Por outro lado, se

$$Y = \begin{cases} 1, & \text{se } X \geq 1, \\ 0, & \text{caso contrário,} \end{cases}$$

então  $P(X \geq Y) = 1$  e portanto

$$E(X) \geq E(Y). \quad (4)$$

Mas

$$E(Y) = P(Y = 1) = P(X \geq 1) = P\left(\bigcup_{i=1}^n A_i\right). \quad (5)$$

De (3), (4) e (5) obtemos o resultado.



**Bom estudo!**



UNIVERSIDADE  
FEDERAL  
DE PERNAMBUCO

**CCEN**

CENTRO DE CIÊNCIAS EXATAS  
E DA NATUREZA