

# Esperanças e covariâncias

Tiago M. Magalhães

Departamento de Estatística - ICE-UFJF

Juiz de Fora, 17 de setembro de 2024



# Roteiro

- 1 Esperanças e covariâncias
- 2 Valor esperado condicionado
- 3 Regressão da média
- 4 Bibliografia



# Roteiro

- 1 Esperanças e covariâncias
- 2 Valor esperado condicionado
- 3 Regressão da média
- 4 Bibliografia



# Introdução

Seja  $(X, Y)^T$  uma variável aleatória (VA) bidimensional e  $g$  é uma função destas duas variáveis.



# Esperança

Se  $(X, Y)^T$  é uma VA discreta bidimensional, com função de probabilidade conjunta  $p(x_i, y_j)$ , então

$$\mathbb{E}[g(X, Y)] = \sum_{j=1}^{\infty} \sum_{i=1}^{\infty} g(x_i, y_j) p(x_i, y_j).$$



# Esperança

Se  $(X, Y)^T$  é uma VA discreta bidimensional, com função de probabilidade conjunta  $p(x_i, y_j)$ , então

$$\mathbb{E}[g(X, Y)] = \sum_{j=1}^{\infty} \sum_{i=1}^{\infty} g(x_i, y_j) p(x_i, y_j).$$



# Esperança

Se  $(X, Y)^T$  é uma VA contínua bidimensional, com função densidade de probabilidade (FDP) conjunta  $f(x, y)$ , então

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



# Esperança

Se  $(X, Y)^T$  é uma VA contínua bidimensional, com função densidade de probabilidade (FDP) conjunta  $f(x, y)$ , então

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



# Covariância

A covariância entre  $X$  e  $Y$ , denotada por  $\text{Cov}(X, Y)$ ,



# Covariância

A covariância entre  $X$  e  $Y$ , denotada por  $\text{Cov}(X, Y)$ , é definida por

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



# Covariância

A covariância entre  $X$  e  $Y$ , denotada por  $\text{Cov}(X, Y)$ , é definida por

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

Alternativamente,



# Covariância

A covariância entre  $X$  e  $Y$ , denotada por  $\text{Cov}(X, Y)$ , é definida por

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

Alternativamente, a covariância entre  $X$  e  $Y$  pode ser escrita como

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



# Covariância

A covariância entre  $X$  e  $Y$ , denotada por  $\text{Cov}(X, Y)$ , é definida por

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

Alternativamente, a covariância entre  $X$  e  $Y$  pode ser escrita como

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



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:

- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ ;



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:

- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ ;
- $\text{Cov}(X, X) = \text{Var}(X)$ ;



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:

- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ ;
- $\text{Cov}(X, X) = \text{Var}(X)$ ;
- $\text{Cov}(aX + b, cY + d) = ac\text{Cov}(X, Y)$ ;



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:

- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ ;
- $\text{Cov}(X, X) = \text{Var}(X)$ ;
- $\text{Cov}(aX + b, cY + d) = ac\text{Cov}(X, Y)$ ;
- $\text{Cov}\left(\sum_{i=1}^n X_i, \sum_{j=1}^m Y_j\right) = \sum_{i=1}^n \sum_{j=1}^m \text{Cov}(X_i, Y_j)$ .



# Covariância

Sejam  $a, b, c, d$  constantes, da definição de covariância, nós temos as seguintes propriedades:

- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$ ;
- $\text{Cov}(X, X) = \text{Var}(X)$ ;
- $\text{Cov}(aX + b, cY + d) = ac\text{Cov}(X, Y)$ ;
- $\text{Cov}\left(\sum_{i=1}^n X_i, \sum_{j=1}^m Y_j\right) = \sum_{i=1}^n \sum_{j=1}^m \text{Cov}(X_i, Y_j)$ .



# Covariância

Da definição e das propriedades da covariância, nós temos alguns resultados.

O primeiro é que, se  $X$  e  $Y$  são independentes,



# Covariância

Da definição e das propriedades da covariância, nós temos alguns resultados.

O primeiro é que, se  $X$  e  $Y$  são independentes, então

$$\mathbb{E}(XY) = \mathbb{E}(X) \times \mathbb{E}(Y),$$



# Covariância

Da definição e das propriedades da covariância, nós temos alguns resultados.

O primeiro é que, se  $X$  e  $Y$  são independentes, então

$$\mathbb{E}(XY) = \mathbb{E}(X) \times \mathbb{E}(Y),$$

isto é, se  $X$  e  $Y$  são independentes,  $\text{Cov}(X, Y) = 0$ .



# Covariância

Da definição e das propriedades da covariância, nós temos alguns resultados.

O primeiro é que, se  $X$  e  $Y$  são independentes, então

$$\mathbb{E}(XY) = \mathbb{E}(X) \times \mathbb{E}(Y),$$

isto é, se  $X$  e  $Y$  são independentes,  $\text{Cov}(X, Y) = 0$ .

**Observação:**  $\text{Cov}(X, Y) = 0$  não implica que  $X$  e  $Y$  são independentes.



# Covariância

Da definição e das propriedades da covariância, nós temos alguns resultados.

O primeiro é que, se  $X$  e  $Y$  são independentes, então

$$\mathbb{E}(XY) = \mathbb{E}(X) \times \mathbb{E}(Y),$$

isto é, se  $X$  e  $Y$  são independentes,  $\text{Cov}(X, Y) = 0$ .

**Observação:**  $\text{Cov}(X, Y) = 0$  não implica que  $X$  e  $Y$  são independentes.



# Covariância

No segundo, sejam  $X_1, X_2, \dots, X_n$  uma sequência de VAs, então

$$\text{Var} \left( \sum_{i=1}^n X_i \right) = \sum_{i=1}^n \text{Var} (X_i) + 2 \sum_{i \neq j} \sum \text{Cov}(X_i, X_j). \quad (1)$$



# Covariância

No segundo, sejam  $X_1, X_2, \dots, X_n$  uma sequência de VAs, então

$$\text{Var} \left( \sum_{i=1}^n X_i \right) = \sum_{i=1}^n \text{Var} (X_i) + 2 \sum_{i \neq j} \sum \text{Cov}(X_i, X_j). \quad (1)$$

Para o caso bidimensional  $(X, Y)^T$ ,



# Covariância

No segundo, sejam  $X_1, X_2, \dots, X_n$  uma sequência de VAs, então

$$\text{Var} \left( \sum_{i=1}^n X_i \right) = \sum_{i=1}^n \text{Var} (X_i) + 2 \sum_{i \neq j} \text{Cov}(X_i, X_j). \quad (1)$$

Para o caso bidimensional  $(X, Y)^T$ , nós temos que (1) resulta em

$$\text{Var} (X + Y) = \text{Var} (X) + \text{Var} (Y) + 2\text{Cov}(X, Y).$$



# Covariância

No segundo, sejam  $X_1, X_2, \dots, X_n$  uma sequência de VAs, então

$$\text{Var} \left( \sum_{i=1}^n X_i \right) = \sum_{i=1}^n \text{Var} (X_i) + 2 \sum_{i \neq j} \sum \text{Cov}(X_i, X_j). \quad (1)$$

Para o caso bidimensional  $(X, Y)^T$ , nós temos que (1) resulta em

$$\text{Var} (X + Y) = \text{Var} (X) + \text{Var} (Y) + 2\text{Cov}(X, Y).$$



# Covariância

Agora, se  $X_1, X_2, \dots, X_n$  é uma sequência de VAs independentes duas a duas, (1) resulta em

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



# Covariância

Agora, se  $X_1, X_2, \dots, X_n$  é uma sequência de VAs independentes duas a duas, (1) resulta em

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



# Correlação

Seja  $(X, Y)^T$  uma VA bidimensional. Nós definiremos  $\rho_{xy}$ , o coeficiente de correlação, entre  $X$  e  $Y$ , da seguinte forma:



# Correlação

Seja  $(X, Y)^T$  uma VA bidimensional. Nós definiremos  $\rho_{xy}$ , o coeficiente de correlação, entre  $X$  e  $Y$ , da seguinte forma:

$$\rho_{xy} = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$



# Correlação

Seja  $(X, Y)^T$  uma VA bidimensional. Nós definiremos  $\rho_{xy}$ , o coeficiente de correlação, entre  $X$  e  $Y$ , da seguinte forma:

$$\rho_{xy} = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$



# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;

# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;
- $-1 \leq \rho_{xy} \leq 1$ ;

# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;
- $-1 \leq \rho_{xy} \leq 1$ ;
- se  $X$  e  $Y$  são independentes, então  $\rho_{xy} = 0$ ;

# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;
- $-1 \leq \rho_{xy} \leq 1$ ;
- se  $X$  e  $Y$  são independentes, então  $\rho_{xy} = 0$ ;
- Se  $\rho_{xy}^2 = 1$ , então  $Y = aX + b$ , em que  $a$  e  $b$  são constantes;



# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;
- $-1 \leq \rho_{xy} \leq 1$ ;
- se  $X$  e  $Y$  são independentes, então  $\rho_{xy} = 0$ ;
- Se  $\rho_{xy}^2 = 1$ , então  $Y = aX + b$ , em que  $a$  e  $b$  são constantes;
- Se  $Y = aX + b$  e  $\rho_{xy}^2 = 1$ . Se  $a > 0$ ,  $\rho_{xy} = 1$ ,  $a < 0$ ,  $\rho_{xy} = -1$ .



# Correlação

- $\rho_{xy}$  é uma quantidade adimensional;
- $-1 \leq \rho_{xy} \leq 1$ ;
- se  $X$  e  $Y$  são independentes, então  $\rho_{xy} = 0$ ;
- Se  $\rho_{xy}^2 = 1$ , então  $Y = aX + b$ , em que  $a$  e  $b$  são constantes;
- Se  $Y = aX + b$  e  $\rho_{xy}^2 = 1$ . Se  $a > 0$ ,  $\rho_{xy} = 1$ ,  $a < 0$ ,  $\rho_{xy} = -1$ .

# Correlação

## Resultado

Se  $\rho_{xy}$  for o coeficiente de correlação entre  $X$  e  $Y$ ,

# Correlação

## Resultado

Se  $\rho_{xy}$  for o coeficiente de correlação entre  $X$  e  $Y$ , e se  $V = aX + b$  e  $W = cY + d$ ,

## Resultado

Se  $\rho_{xy}$  for o coeficiente de correlação entre  $X$  e  $Y$ , e se  $V = aX + b$  e  $W = cY + d$ , nas quais  $a, b, c, d$ ,  $a \neq 0$  e  $c \neq 0$  são constantes,

# Correlação

## Resultado

Se  $\rho_{xy}$  for o coeficiente de correlação entre  $X$  e  $Y$ , e se  $V = aX + b$  e  $W = cY + d$ , nas quais  $a, b, c, d$ ,  $a \neq 0$  e  $c \neq 0$  são constantes, então

$$\rho_{vw} = \frac{ac}{|ac|} \rho_{xy}.$$

# Correlação

## Resultado

Se  $\rho_{xy}$  for o coeficiente de correlação entre  $X$  e  $Y$ , e se  $V = aX + b$  e  $W = cY + d$ , nas quais  $a, b, c, d$ ,  $a \neq 0$  e  $c \neq 0$  são constantes, então

$$\rho_{vw} = \frac{ac}{|ac|} \rho_{xy}.$$

# Exemplo

Seja  $(X, Y)^T$  uma VA bidimensional, com FDP conjunta dada por:

$$\begin{aligned}f(x, y) &= 2 \mathbb{I}_{(0,1)}(x) \mathbb{I}_{(x,1)}(y) \\ &= 2 \mathbb{I}_{(0,1)}(y) \mathbb{I}_{(0,y)}(x).\end{aligned}$$

Encontre  $\rho_{xy}$ .



# Exemplo

Seja  $(X, Y)^T$  uma VA bidimensional, com FDP conjunta dada por:

$$\begin{aligned}f(x, y) &= 2 \mathbb{I}_{(0,1)}(x) \mathbb{I}_{(x,1)}(y) \\ &= 2 \mathbb{I}_{(0,1)}(y) \mathbb{I}_{(0,y)}(x).\end{aligned}$$

Encontre  $\rho_{xy}$ .



# Exemplo

As marginais de  $X$  e  $Y$  são dadas, respectivamente, por

$$f_X(x) = \int_x^1 2 \, dy = 2(1 - x) \mathbb{I}_{(0,1)}(x),$$

$$f_Y(y) = \int_0^y 2 \, dx = 2y \mathbb{I}_{(0,1)}(y).$$

# Exemplo

As marginais de  $X$  e  $Y$  são dadas, respectivamente, por

$$f_X(x) = \int_x^1 2 \, dy = 2(1 - x) \mathbb{I}_{(0,1)}(x),$$

$$f_Y(y) = \int_0^y 2 \, dx = 2y \mathbb{I}_{(0,1)}(y).$$

**Observação:**  $X \sim \text{beta}(1, 2)$  e  $Y \sim \text{beta}(2, 1)$ .



# Exemplo

As marginais de  $X$  e  $Y$  são dadas, respectivamente, por

$$f_X(x) = \int_x^1 2 \, dy = 2(1 - x) \mathbb{I}_{(0,1)}(x),$$

$$f_Y(y) = \int_0^y 2 \, dx = 2y \mathbb{I}_{(0,1)}(y).$$

**Observação:**  $X \sim \text{beta}(1, 2)$  e  $Y \sim \text{beta}(2, 1)$ .



# Exemplo

Agora, nós podemos calcular

$$\mathbb{E}(X) = \int_0^1 x \cdot 2(1-x) dx = \frac{1}{3}, \quad \mathbb{E}(X^2) = \int_0^1 x^2 \cdot 2(1-x) dx = \frac{1}{6},$$

$$\mathbb{E}(Y) = \int_0^1 y \cdot 2y dy = \frac{2}{3}, \quad \mathbb{E}(Y^2) = \int_0^1 y^2 \cdot 2y dy = \frac{1}{2},$$

$$\mathbb{E}(XY) = \int_0^1 \int_0^y xy \cdot 2 dx dy = \frac{1}{4}.$$



## Exemplo

Agora, nós podemos calcular

$$\mathbb{E}(X) = \int_0^1 x \cdot 2(1-x) dx = \frac{1}{3}, \quad \mathbb{E}(X^2) = \int_0^1 x^2 \cdot 2(1-x) dx = \frac{1}{6},$$

$$\mathbb{E}(Y) = \int_0^1 y \cdot 2y dy = \frac{2}{3}, \quad \mathbb{E}(Y^2) = \int_0^1 y^2 \cdot 2y dy = \frac{1}{2},$$

$$\mathbb{E}(XY) = \int_0^1 \int_0^y xy \cdot 2 dx dy = \frac{1}{4}.$$

Lembrando que,  $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}^2(X) = 1/18$  e  $\text{Var}(Y) = \mathbb{E}(Y^2) - \mathbb{E}^2(Y) = 1/18$ .



## Exemplo

Agora, nós podemos calcular

$$\mathbb{E}(X) = \int_0^1 x \cdot 2(1-x) dx = \frac{1}{3}, \quad \mathbb{E}(X^2) = \int_0^1 x^2 \cdot 2(1-x) dx = \frac{1}{6},$$

$$\mathbb{E}(Y) = \int_0^1 y \cdot 2y dy = \frac{2}{3}, \quad \mathbb{E}(Y^2) = \int_0^1 y^2 \cdot 2y dy = \frac{1}{2},$$

$$\mathbb{E}(XY) = \int_0^1 \int_0^y xy \cdot 2 dx dy = \frac{1}{4}.$$

Lembrando que,  $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}^2(X) = 1/18$  e  $\text{Var}(Y) = \mathbb{E}(Y^2) - \mathbb{E}^2(Y) = 1/18$ .



# Exemplo

Nós temos que

$$\rho_{xy} = \frac{\mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} = \frac{\frac{1}{4} - \frac{1}{3} \times \frac{2}{3}}{\sqrt{\frac{1}{18} \times \frac{1}{18}}} = \frac{\frac{1}{36}}{\frac{1}{18}} = \frac{1}{2}.$$



# Exemplo

Nós temos que

$$\rho_{xy} = \frac{\mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} = \frac{\frac{1}{4} - \frac{1}{3} \times \frac{2}{3}}{\sqrt{\frac{1}{18} \times \frac{1}{18}}} = \frac{\frac{1}{36}}{\frac{1}{18}} = \frac{1}{2}.$$

**Observação:** as esperanças e variâncias de  $X$  e  $Y$  poderiam ter sido calculadas a partir das definições da distribuição beta.



# Exemplo

Nós temos que

$$\rho_{xy} = \frac{\mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} = \frac{\frac{1}{4} - \frac{1}{3} \times \frac{2}{3}}{\sqrt{\frac{1}{18} \times \frac{1}{18}}} = \frac{\frac{1}{36}}{\frac{1}{18}} = \frac{1}{2}.$$

**Observação:** as esperanças e variâncias de  $X$  e  $Y$  poderiam ter sido calculadas a partir das definições da distribuição beta.



# Roteiro

- 1 Esperanças e covariâncias
- 2 Valor esperado condicionado
- 3 Regressão da média
- 4 Bibliografia



# Valor esperado condicionado

Tal como nós definimos o valor esperado de uma variável aleatória  $X$ , nós também podemos definir o **valor esperado condicionado** de uma VA.



# Valor esperado condicionado

Tal como nós definimos o valor esperado de uma variável aleatória  $X$ , nós também podemos definir o **valor esperado condicionado** de uma VA.



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA discreta bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y_j$ ,



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA discreta bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y_j$ , como

$$\mathbb{E}(X|Y = y_j) = \sum_{i=1}^{+\infty} x_i p_{X|Y}(x_i|y_j).$$



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA discreta bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y_j$ , como

$$\mathbb{E}(X|Y = y_j) = \sum_{i=1}^{+\infty} x_i p_{X|Y}(x_i|y_j).$$



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA contínua bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y$ ,



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA contínua bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y$ , como

$$\mathbb{E}(X|Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y}(x|y) dx.$$



# Valor esperado condicionado

Se  $(X, Y)^T$  for uma VA contínua bidimensional, nós definiremos o valor esperado condicionado de  $X$ , para um dado  $Y = y$ , como

$$\mathbb{E}(X|Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y}(x|y) dx.$$



# Valor esperado condicionado

De maneira geral, se  $(X, Y)^T$  for uma VA bidimensional e  $g$  é uma função de  $X$ , nós temos que

$$\begin{cases} \mathbb{E}[g(X)|Y = y_j] = \sum_{i=1}^{+\infty} g(x_i) p_{X|Y}(x_i|y_j), & \text{caso discreto,} \\ \mathbb{E}[g(X)|Y = y] = \int_{-\infty}^{+\infty} g(x) f_{X|Y}(x|y) dx, & \text{caso contínuo.} \end{cases}$$



# Valor esperado condicionado

De maneira geral, se  $(X, Y)^T$  for uma VA bidimensional e  $g$  é uma função de  $X$ , nós temos que

$$\begin{cases} \mathbb{E}[g(X)|Y = y_j] = \sum_{i=1}^{+\infty} g(x_i) p_{X|Y}(x_i|y_j), & \text{caso discreto,} \\ \mathbb{E}[g(X)|Y = y] = \int_{-\infty}^{+\infty} g(x) f_{X|Y}(x|y) dx, & \text{caso contínuo.} \end{cases}$$



# Observação

Em geral,  $\mathbb{E}(X|Y = y)$  é uma função de  $y$  e, por isso, é uma VA.



# Observação

Em geral,  $\mathbb{E}(X|Y = y)$  é uma função de  $y$  e, por isso, é uma VA. Estritamente falando,  $\mathbb{E}(X|Y = y)$  é o valor da VA  $\mathbb{E}(X|Y)$ .



# Observação

Em geral,  $\mathbb{E}(X|Y = y)$  é uma função de  $y$  e, por isso, é uma VA. Estritamente falando,  $\mathbb{E}(X|Y = y)$  é o valor da VA  $\mathbb{E}(X|Y)$ .



# Valor esperado condicionado

Um propriedade extremamente importante do valor esperado condicional é dada por

$$\mathbb{E}(X) = \mathbb{E}[\mathbb{E}(X|Y)]. \quad (2)$$

Semelhantemente,  $\mathbb{E}(Y) = \mathbb{E}[\mathbb{E}(Y|X)]$ .



# Valor esperado condicionado

Um propriedade extremamente importante do valor esperado condicional é dada por

$$\mathbb{E}(X) = \mathbb{E}[\mathbb{E}(X|Y)]. \quad (2)$$

Semelhantemente,  $\mathbb{E}(Y) = \mathbb{E}[\mathbb{E}(Y|X)]$ .



# Valor esperado condicionado

O resultado em (2) também continua válido para situações como

- $\mathbb{E}[g(X)] = \mathbb{E} \{ \mathbb{E}[g(X)|Y] \};$



# Valor esperado condicionado

O resultado em (2) também continua válido para situações como

- $\mathbb{E}[g(X)] = \mathbb{E} \{ \mathbb{E}[g(X)|Y] \};$
- $\mathbb{E}(XY) = \mathbb{E} [\mathbb{E}(XY|Y)].$



# Valor esperado condicionado

O resultado em (2) também continua válido para situações como

- $\mathbb{E}[g(X)] = \mathbb{E} \{ \mathbb{E}[g(X)|Y] \};$
- $\mathbb{E}(XY) = \mathbb{E} [ \mathbb{E}(XY|Y) ].$



# Valor esperado condicionado

Um outra propriedade extremamente importante do valor esperado condicional é dada por

$$\text{Var}(X) = \mathbb{E} [\text{Var}(X|Y)] + \text{Var} [\mathbb{E}(X|Y)].$$



# Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia.



# Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia. Se  $N$  for o número de peças da remessa,



# Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia. Se  $N$  for o número de peças da remessa, a distribuição de probabilidade da variável aleatória  $N$ ,



# Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia. Se  $N$  for o número de peças da remessa, a distribuição de probabilidade da variável aleatória  $N$ , será dada assim:

$N$	10	11	12	13	14	15
$\mathbb{P}(N)$	0,05	0,10	0,10	0,20	0,35	0,20

# Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia. Se  $N$  for o número de peças da remessa, a distribuição de probabilidade da variável aleatória  $N$ , será dada assim:

$N$	10	11	12	13	14	15
$\mathbb{P}(N)$	0,05	0,10	0,10	0,20	0,35	0,20

Com  $\mathbb{E}(N) = 13,3$ .



## Exemplo

Suponham que remessas, contendo um número variável de peças, chegue cada dia. Se  $N$  for o número de peças da remessa, a distribuição de probabilidade da variável aleatória  $N$ , será dada assim:

$N$	10	11	12	13	14	15
$\mathbb{P}(N)$	0,05	0,10	0,10	0,20	0,35	0,20

Com  $\mathbb{E}(N) = 13,3$ .



# Exemplo

A probabilidade de que qualquer peça em particular seja defeituosa é a mesma para todas as peças e igual a 0,10.



# Exemplo

A probabilidade de que qualquer peça em particular seja defeituosa é a mesma para todas as peças e igual a 0,10. Se  $X$  for o número de peças defeituosas que chegue cada dia, qual será o valor esperado de  $X$ ?



# Exemplo

A probabilidade de que qualquer peça em particular seja defeituosa é a mesma para todas as peças e igual a 0,10. Se  $X$  for o número de peças defeituosas que chegue cada dia, qual será o valor esperado de  $X$ ?



# Exemplo

Notem que, para um dado  $N$  igual a  $n$ ,  $X$  apresentará distribuição binomial,



# Exemplo

Notem que, para um dado  $N$  igual a  $n$ ,  $X$  apresentará distribuição binomial,

i.e,

$$X|N = n \sim \text{binomial}(n, p = 0,10).$$



# Exemplo

Notem que, para um dado  $N$  igual a  $n$ ,  $X$  apresentará distribuição binomial, i.e,

$$X|N = n \sim \text{binomial}(n, p = 0,10).$$

Como  $N$  é uma VA, nós podemos utilizar o resultado apresentado em (2),



## Exemplo

Notem que, para um dado  $N$  igual a  $n$ ,  $X$  apresentará distribuição binomial,

i.e.,

$$X|N = n \sim \text{binomial}(n, p = 0,10).$$

Como  $N$  é uma VA, nós podemos utilizar o resultado apresentado em (2),

i.e.,

$$\begin{aligned}\mathbb{E}(X) &= \mathbb{E}[\mathbb{E}(X|N)] = \mathbb{E}[0,10 \times N] = 0,10 \times \mathbb{E}[N] \\ &= 0,10 \times 13,3 = 1,33.\end{aligned}$$



## Exemplo

Notem que, para um dado  $N$  igual a  $n$ ,  $X$  apresentará distribuição binomial,

i.e.,

$$X|N = n \sim \text{binomial}(n, p = 0,10).$$

Como  $N$  é uma VA, nós podemos utilizar o resultado apresentado em (2),

i.e.,

$$\begin{aligned}\mathbb{E}(X) &= \mathbb{E}[\mathbb{E}(X|N)] = \mathbb{E}[0,10 \times N] = 0,10 \times \mathbb{E}[N] \\ &= 0,10 \times 13,3 = 1,33.\end{aligned}$$



# Roteiro

- 1 Esperanças e covariâncias
- 2 Valor esperado condicionado
- 3 Regressão da média
- 4 Bibliografia



# Regressão da média

Como nós já salientamos,  $\mathbb{E}(X|Y = y)$  é o valor da VA  $\mathbb{E}(X|Y)$  e é uma função de  $y$ . O gráfico dessa função de  $y$  é conhecido como a **curva de regressão** (da média) de  $X$  em  $Y$ .



# Regressão da média

Como nós já salientamos,  $\mathbb{E}(X|Y = y)$  é o valor da VA  $\mathbb{E}(X|Y)$  e é uma função de  $y$ . O gráfico dessa função de  $y$  é conhecido como a **curva de regressão** (da média) de  $X$  em  $Y$ . Para cada valor fixado  $y$ ,  $\mathbb{E}(X|Y = y)$  será o valor esperado da VA (unidimensional)  $X|Y = y$ .



# Regressão da média

Como nós já salientamos,  $\mathbb{E}(X|Y = y)$  é o valor da VA  $\mathbb{E}(X|Y)$  e é uma função de  $y$ . O gráfico dessa função de  $y$  é conhecido como a **curva de regressão** (da média) de  $X$  em  $Y$ . Para cada valor fixado  $y$ ,  $\mathbb{E}(X|Y = y)$  será o valor esperado da VA (unidimensional)  $X|Y = y$ .



# Teorema

Seja  $(X, Y)^T$  uma VA bidimensional e suponham que

$$\mathbb{E}(X) = \mu_X, \mathbb{E}(Y) = \mu_Y, \text{Var}(X) = \sigma_X^2 \text{ e } \text{Var}(Y) = \sigma_Y^2.$$



# Teorema

Seja  $(X, Y)^\top$  uma VA bidimensional e suponham que

$$\mathbb{E}(X) = \mu_X, \mathbb{E}(Y) = \mu_Y, \text{Var}(X) = \sigma_X^2 \text{ e } \text{Var}(Y) = \sigma_Y^2.$$



# Teorema

Seja  $\rho$  o coeficiente de correlação entre  $X$  e  $Y$ . Se a regressão de  $Y$  em  $X$  for linear,



# Teorema

Seja  $\rho$  o coeficiente de correlação entre  $X$  e  $Y$ . Se a regressão de  $Y$  em  $X$  for linear, nós teremos

$$\mathbb{E}(Y|X = x) = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X} (x - \mu_X).$$



# Teorema

Seja  $\rho$  o coeficiente de correlação entre  $X$  e  $Y$ . Se a regressão de  $Y$  em  $X$  for linear, nós teremos

$$\mathbb{E}(Y|X = x) = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X} (x - \mu_X).$$

Se a regressão de  $X$  em  $Y$  for linear,

# Teorema

Seja  $\rho$  o coeficiente de correlação entre  $X$  e  $Y$ . Se a regressão de  $Y$  em  $X$  for linear, nós teremos

$$\mathbb{E}(Y|X = x) = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X} (x - \mu_X).$$

Se a regressão de  $X$  em  $Y$  for linear, nós teremos

$$\mathbb{E}(X|Y = y) = \mu_X + \rho \frac{\sigma_X}{\sigma_Y} (y - \mu_Y).$$



# Teorema

Seja  $\rho$  o coeficiente de correlação entre  $X$  e  $Y$ . Se a regressão de  $Y$  em  $X$  for linear, nós teremos

$$\mathbb{E}(Y|X = x) = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X}(x - \mu_X).$$

Se a regressão de  $X$  em  $Y$  for linear, nós teremos

$$\mathbb{E}(X|Y = y) = \mu_X + \rho \frac{\sigma_X}{\sigma_Y}(y - \mu_Y).$$



# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;

# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ ,

# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ , então nós verificamos que  $\mathbb{E}(X|Y = y)$  não depende de  $y$ .

# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ , então nós verificamos que  $\mathbb{E}(X|Y = y)$  não depende de  $y$ . Se  $\rho \neq 0$ , o sinal de  $\rho$  determina o sinal da declividade da reta de regressão;



# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ , então nós verificamos que  $\mathbb{E}(X|Y = y)$  não depende de  $y$ . Se  $\rho \neq 0$ , o sinal de  $\rho$  determina o sinal da declividade da reta de regressão;
- Se ambas as funções de regressão forem lineares,



# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ , então nós verificamos que  $\mathbb{E}(X|Y = y)$  não depende de  $y$ . Se  $\rho \neq 0$ , o sinal de  $\rho$  determina o sinal da declividade da reta de regressão;
- Se ambas as funções de regressão forem lineares, nós verificamos que as retas de regressão se interceptam no “centro” da distribuição,  $(\mu_X, \mu_Y)$ .



# Observações

- É possível que uma das regressões da média seja linear, enquanto a outra não o seja;
- Se a regressão de  $X$  em  $Y$ , por exemplo, for linear e, se  $\rho = 0$ , então nós verificamos que  $\mathbb{E}(X|Y = y)$  não depende de  $y$ . Se  $\rho \neq 0$ , o sinal de  $\rho$  determina o sinal da declividade da reta de regressão;
- Se ambas as funções de regressão forem lineares, nós verificamos que as retas de regressão se interceptam no “centro” da distribuição,  $(\mu_X, \mu_Y)$ .



# Princípio dos mínimos quadrados

Embora as funções de regressão não precisem ser lineares, nós poderemos estar interessados em aproximar a curva de regressão com uma função linear.

Isto é usualmente feito recorrendo-se ao **princípio dos mínimos quadrados**.



# Princípio dos mínimos quadrados

Embora as funções de regressão não precisem ser lineares, nós poderemos estar interessados em aproximar a curva de regressão com uma função linear. Isto é usualmente feito recorrendo-se ao **princípio dos mínimos quadrados**.



# Princípio dos mínimos quadrados

No princípio dos mínimos quadrados, duas constantes  $a$  e  $b$  são escolhidas de modo que

$$\mathbb{E} \left\{ [\mathbb{E}(Y|X) - (aX + b)]^2 \right\}$$

se torne mínima.



# Princípio dos mínimos quadrados

No princípio dos mínimos quadrados, duas constantes  $a$  e  $b$  são escolhidas de modo que

$$\mathbb{E} \left\{ [\mathbb{E}(Y|X) - (aX + b)]^2 \right\}$$

se torne mínima. A reta  $y = ax + b$  é denominada a aproximação de mínimos quadrados à curva de regressão  $\mathbb{E}(Y|X = x)$ .



# Princípio dos mínimos quadrados

No princípio dos mínimos quadrados, duas constantes  $a$  e  $b$  são escolhidas de modo que

$$\mathbb{E} \left\{ [\mathbb{E}(Y|X) - (aX + b)]^2 \right\}$$

se torne mínima. A reta  $y = ax + b$  é denominada a aproximação de mínimos quadrados à curva de regressão  $\mathbb{E}(Y|X = x)$ .



# Teorema

Se  $y = ax + b$  for a aproximação de mínimos quadrados a  $\mathbb{E}(Y|X = x)$  e se  $\mathbb{E}(Y|X = x)$  for de fato uma função linear de  $x$ ,



# Teorema

Se  $y = ax + b$  for a aproximação de mínimos quadrados a  $\mathbb{E}(Y|X = x)$  e se  $\mathbb{E}(Y|X = x)$  for de fato uma função linear de  $x$ , isto é,

$$\mathbb{E}(Y|X = x) = a'x + b',$$

então  $a = a'$  e  $b = b'$ .



# Teorema

Se  $y = ax + b$  for a aproximação de mínimos quadrados a  $\mathbb{E}(Y|X = x)$  e se  $\mathbb{E}(Y|X = x)$  for de fato uma função linear de  $x$ , isto é,

$$\mathbb{E}(Y|X = x) = a'x + b',$$

então  $a = a'$  e  $b = b'$ .

**Observação:** de forma análoga, os resultados valem para  $\mathbb{E}(X|Y = y)$ .



# Teorema

Se  $y = ax + b$  for a aproximação de mínimos quadrados a  $\mathbb{E}(Y|X = x)$  e se  $\mathbb{E}(Y|X = x)$  for de fato uma função linear de  $x$ , isto é,

$$\mathbb{E}(Y|X = x) = a'x + b',$$

então  $a = a'$  e  $b = b'$ .

**Observação:** de forma análoga, os resultados valem para  $\mathbb{E}(X|Y = y)$ .



# Roteiro

- 1 Esperanças e covariâncias
- 2 Valor esperado condicionado
- 3 Regressão da média
- 4 Bibliografia



# Bibliografia

- Meyer, P. L. (2017), *Probabilidade: aplicações à Estatística*, 2 edn, Livros Técnicos e Científicos Editora Ltda, Rio de Janeiro.
- Ross, S. (2010), *Probabilidade: um curso moderno com aplicações*, 8 edn, Bookman, Porto Alegre.
- Ross, S. (2019), *A first course in probability*, 10 edn. global edn, Pearson Education, Malaysia.



# Obrigado!

✉ [tiago.magalhaes@ufjf.br](mailto:tiago.magalhaes@ufjf.br)

📄 [ufjf.br/tiago\\_magalhaes](https://ufjf.br/tiago_magalhaes)

🌐 Departamento de Estatística, Sala 319

