

# Expressões aproximadas e desigualdades

Tiago M. Magalhães

Departamento de Estatística - ICE-UFJF

Juiz de Fora, 08 de outubro de 2024



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância
- 4 Desigualdades
- 5 Referências bibliográficas



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância
- 4 Desigualdades
- 5 Referências bibliográficas



# Motivação

Nós já observamos que a fim de calcular  $\mathbb{E}(Z)$  ou  $\text{Var}(Z)$ , em que  $Z = H(X, Y)$ , não necessitamos achar a distribuição de probabilidades de  $Z$ , pois poderemos trabalhar diretamente com a distribuição de probabilidades de  $(X, Y)^T$ .



# Motivação

Se a função  $H$  for bem complicada, o cálculo das esperanças e variâncias pode conduzir a integrações (ou somatórios) que são bastante difíceis. Por isso, aproximações são muito úteis.



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância
- 4 Desigualdades
- 5 Referências bibliográficas



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma





# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n, \quad (1)$$



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n, \quad (1)$$

em que  $f$  é uma função conhecida,



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n, \quad (1)$$

em que  $f$  é uma função conhecida, derivável



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n, \quad (1)$$

em que  $f$  é uma função conhecida, derivável e  $f^{(n)}$  é a  $n$ -ésima derivada de  $f$ .



# Série de Taylor

A série de Taylor (1715) em torno do ponto  $x = a$  é uma série de funções expressa da seguinte forma

$$f(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n, \quad (1)$$

em que  $f$  é uma função conhecida, derivável e  $f^{(n)}$  é a  $n$ -ésima derivada de  $f$ .



# Série de Taylor

Observação

Em (1),

# Série de Taylor

## Observação

Em (1), quando  $a = 0$ ,



# Série de Taylor

## Observação

Em (1), quando  $a = 0$ , a série também é conhecida como série de Maclaurin.



# Série de Taylor

## Observação

Em (1), quando  $a = 0$ , a série também é conhecida como série de Maclaurin.



# Série de Taylor

Notem que, a série de Taylor (1715)



# Série de Taylor

Notem que, a série de Taylor (1715) pode ser reescrita da seguinte forma



# Série de Taylor

Notem que, a série de Taylor (1715) pode ser reescrita da seguinte forma

$$f(x) = P_n(x) + R_n(x), \quad (2)$$



# Série de Taylor

Notem que, a série de Taylor (1715) pode ser reescrita da seguinte forma

$$f(x) = P_n(x) + R_n(x), \quad (2)$$

em que



# Série de Taylor

Notem que, a série de Taylor (1715) pode ser reescrita da seguinte forma

$$f(x) = P_n(x) + R_n(x), \quad (2)$$

em que

$$P_n(x) = \sum_{i=0}^n \frac{f^{(i)}(a)}{i!} (x - a)^i \text{ e } R_n(x) = \sum_{i=n+1}^{\infty} \frac{f^{(i)}(a)}{i!} (x - a)^i.$$



# Série de Taylor

Notem que, a série de Taylor (1715) pode ser reescrita da seguinte forma

$$f(x) = P_n(x) + R_n(x), \quad (2)$$

em que

$$P_n(x) = \sum_{i=0}^n \frac{f^{(i)}(a)}{i!} (x - a)^i \text{ e } R_n(x) = \sum_{i=n+1}^{\infty} \frac{f^{(i)}(a)}{i!} (x - a)^i.$$



# Série de Taylor

$P_n(x)$  é denominado de polinômio de Taylor de grau  $n$  e  $R_n(x)$  é o resto da Série de Taylor.





# Série de Taylor

$P_n(x)$  é denominado de polinômio de Taylor de grau  $n$  e  $R_n(x)$  é o resto da Série de Taylor. Taylor também mostrou que



# Série de Taylor

$P_n(x)$  é denominado de polinômio de Taylor de grau  $n$  e  $R_n(x)$  é o resto da Série de Taylor. Taylor também mostrou que

$$R_n(x) = \frac{f^{(n+1)}(\tau)}{(n+1)!} (x-a)^n,$$



# Série de Taylor

$P_n(x)$  é denominado de polinômio de Taylor de grau  $n$  e  $R_n(x)$  é o resto da Série de Taylor. Taylor também mostrou que

$$R_n(x) = \frac{f^{(n+1)}(\tau)}{(n+1)!} (x-a)^n,$$

para algum valor de  $a \leq \tau \leq x$ .



# Série de Taylor

$P_n(x)$  é denominado de polinômio de Taylor de grau  $n$  e  $R_n(x)$  é o resto da Série de Taylor. Taylor também mostrou que

$$R_n(x) = \frac{f^{(n+1)}(\tau)}{(n+1)!} (x-a)^n,$$

para algum valor de  $a \leq \tau \leq x$ .



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância**
- 4 Desigualdades
- 5 Referências bibliográficas



# Expressões aproximadas da média e da variância

Seja  $X$  uma variável aleatória com  $\mathbb{E}(X) = \mu$  e  $\text{Var}(X) = \sigma^2$ . Suponham que  $Y = H(X)$ .



# Expressões aproximadas da média e da variância

Seja  $X$  uma variável aleatória com  $\mathbb{E}(X) = \mu$  e  $\text{Var}(X) = \sigma^2$ . Suponham que  $Y = H(X)$ . Então,

$$\mathbb{E}(Y) \approx H(\mu) + \frac{H^{(2)}(\mu)}{2} \sigma^2 \text{ e } \text{Var}(Y) \approx [H^{(1)}(\mu)]^2 \sigma^2. \quad (3)$$



# Expressões aproximadas da média e da variância

Seja  $X$  uma variável aleatória com  $\mathbb{E}(X) = \mu$  e  $\text{Var}(X) = \sigma^2$ . Suponham que  $Y = H(X)$ . Então,

$$\mathbb{E}(Y) \approx H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 \text{ e } \text{Var}(Y) \approx [H^{(1)}(\mu)]^2 \sigma^2. \quad (3)$$





# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1),



# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1), até o segundo termo



# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1), até o segundo termo e em torno de  $X = \mu$ ,



# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1), até o segundo termo e em torno de  $X = \mu$ , nós temos que



# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1), até o segundo termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} Y = H(X) &= \sum_{n=0}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{H^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{H^{(1)}(\mu)}{1!} (X - \mu)^1 \\ &+ \frac{H^{(2)}(\mu)}{2!} (X - \mu)^2 + \underbrace{\sum_{n=3}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_1}. \end{aligned}$$



# Expressões aproximadas da média e da variância

**Demonstração 1.** Usando (1), até o segundo termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} Y = H(X) &= \sum_{n=0}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{H^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{H^{(1)}(\mu)}{1!} (X - \mu)^1 \\ &+ \frac{H^{(2)}(\mu)}{2!} (X - \mu)^2 + \underbrace{\sum_{n=3}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_1}. \end{aligned}$$



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + \frac{H^{(2)}(\mu)}{2}(X - \mu)^2 + R_1.$$





# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + \frac{H^{(2)}(\mu)}{2}(X - \mu)^2 + R_1.$$

Aplicando a esperança,



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + \frac{H^{(2)}(\mu)}{2}(X - \mu)^2 + R_1.$$

Aplicando a esperança, nós temos que

$$\begin{aligned}\mathbb{E}(Y) &= \mathbb{E}\{H(\mu)\} + \mathbb{E}\{H^{(1)}(\mu)(X - \mu)\} \\ &+ \mathbb{E}\left\{\frac{H^{(2)}(\mu)}{2}(X - \mu)^2\right\} + \mathbb{E}\{R_1\}.\end{aligned}$$



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + \frac{H^{(2)}(\mu)}{2}(X - \mu)^2 + R_1.$$

Aplicando a esperança, nós temos que

$$\begin{aligned} \mathbb{E}(Y) &= \mathbb{E} \{ H(\mu) \} + \mathbb{E} \{ H^{(1)}(\mu)(X - \mu) \} \\ &+ \mathbb{E} \left\{ \frac{H^{(2)}(\mu)}{2}(X - \mu)^2 \right\} + \mathbb{E} \{ R_1 \}. \end{aligned}$$



# Expressões aproximadas da média e da variância

Agora,

$$\begin{aligned}\mathbb{E}(Y) &= H(\mu) + H^{(1)}(\mu)\mathbb{E}\{X - \mu\} + \frac{H^{(2)}(\mu)}{2}\mathbb{E}\{(X - \mu)^2\} + \mathbb{E}\{R_1\} \\ &= H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 + \mathbb{E}\{R_1\}.\end{aligned}$$



# Expressões aproximadas da média e da variância

Agora,

$$\begin{aligned}\mathbb{E}(Y) &= H(\mu) + H^{(1)}(\mu)\mathbb{E}\{X - \mu\} + \frac{H^{(2)}(\mu)}{2}\mathbb{E}\{(X - \mu)^2\} + \mathbb{E}\{R_1\} \\ &= H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 + \mathbb{E}\{R_1\}.\end{aligned}$$

Ignorando o termo  $\mathbb{E}\{R_1\}$ ,



# Expressões aproximadas da média e da variância

Agora,

$$\begin{aligned}\mathbb{E}(Y) &= H(\mu) + H^{(1)}(\mu)\mathbb{E}\{X - \mu\} + \frac{H^{(2)}(\mu)}{2}\mathbb{E}\{(X - \mu)^2\} + \mathbb{E}\{R_1\} \\ &= H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 + \mathbb{E}\{R_1\}.\end{aligned}$$

Ignorando o termo  $\mathbb{E}\{R_1\}$ , nós temos que,



# Expressões aproximadas da média e da variância

Agora,

$$\begin{aligned}\mathbb{E}(Y) &= H(\mu) + H^{(1)}(\mu)\mathbb{E}\{X - \mu\} + \frac{H^{(2)}(\mu)}{2}\mathbb{E}\{(X - \mu)^2\} + \mathbb{E}\{R_1\} \\ &= H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 + \mathbb{E}\{R_1\}.\end{aligned}$$

Ignorando o termo  $\mathbb{E}\{R_1\}$ , nós temos que,

$$\mathbb{E}(Y) \approx H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2.$$



# Expressões aproximadas da média e da variância

Agora,

$$\begin{aligned}\mathbb{E}(Y) &= H(\mu) + H^{(1)}(\mu)\mathbb{E}\{X - \mu\} + \frac{H^{(2)}(\mu)}{2}\mathbb{E}\{(X - \mu)^2\} + \mathbb{E}\{R_1\} \\ &= H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2 + \mathbb{E}\{R_1\}.\end{aligned}$$

Ignorando o termo  $\mathbb{E}\{R_1\}$ , nós temos que,

$$\mathbb{E}(Y) \approx H(\mu) + \frac{H^{(2)}(\mu)}{2}\sigma^2.$$





# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1),



# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1), até o primeiro termo



# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1), até o primeiro termo e em torno de  $X = \mu$ ,



# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1), até o primeiro termo e em torno de  $X = \mu$ , nós temos que



# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1), até o primeiro termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} Y = H(X) &= \sum_{n=0}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{H^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{H^{(1)}(\mu)}{1!} (X - \mu)^1 \\ &\quad + \underbrace{\sum_{n=2}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_2}. \end{aligned}$$



# Expressões aproximadas da média e da variância

**Demonstração 2.** Usando (1), até o primeiro termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} Y = H(X) &= \sum_{n=0}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{H^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{H^{(1)}(\mu)}{1!} (X - \mu)^1 \\ &\quad + \underbrace{\sum_{n=2}^{\infty} \frac{H^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_2}. \end{aligned}$$



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + R_2$$
$$\Rightarrow Y \approx H(\mu) + H^{(1)}(\mu)(X - \mu).$$





# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + R_2$$
$$\Rightarrow Y \approx H(\mu) + H^{(1)}(\mu)(X - \mu).$$

Aplicando a variância,



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + R_2$$
$$\Rightarrow Y \approx H(\mu) + H^{(1)}(\mu)(X - \mu).$$

Aplicando a variância, nós temos que

$$\text{Var}(Y) \approx \text{Var} \left\{ H(\mu) + H^{(1)}(\mu)(X - \mu) \right\}$$
$$\approx \left[ H^{(1)}(\mu) \right]^2 \text{Var}(X - \mu) = \left[ H^{(1)}(\mu) \right]^2 \sigma^2.$$



# Expressões aproximadas da média e da variância

Simplificando as expressões anteriores, nós temos que

$$Y = H(\mu) + H^{(1)}(\mu)(X - \mu) + R_2$$
$$\Rightarrow Y \approx H(\mu) + H^{(1)}(\mu)(X - \mu).$$

Aplicando a variância, nós temos que

$$\text{Var}(Y) \approx \text{Var} \left\{ H(\mu) + H^{(1)}(\mu)(X - \mu) \right\}$$
$$\approx \left[ H^{(1)}(\mu) \right]^2 \text{Var}(X - \mu) = \left[ H^{(1)}(\mu) \right]^2 \sigma^2.$$



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância
- 4 Desigualdades
- 5 Referências bibliográficas



# Desigualdade de Markov

Se  $X$  é uma variável aleatória que assume somente valores não negativos, então para qualquer  $\lambda > 0$ ,

$$\mathbb{P}(X \geq \lambda) \leq \frac{\mathbb{E}(X)}{\lambda}.$$



# Desigualdade de Markov

Se  $X$  é uma variável aleatória que assume somente valores não negativos, então para qualquer  $\lambda > 0$ ,

$$\mathbb{P}(X \geq \lambda) \leq \frac{\mathbb{E}(X)}{\lambda}.$$



# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ ,



# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ , seja





# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ , seja

$$I = \begin{cases} 1, & \text{se } X \geq \lambda; \\ 0, & \text{caso contrário.} \end{cases}$$

# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ , seja

$$I = \begin{cases} 1, & \text{se } X \geq \lambda; \\ 0, & \text{caso contrário.} \end{cases}$$

Notem que,



# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ , seja

$$I = \begin{cases} 1, & \text{se } X \geq \lambda; \\ 0, & \text{caso contrário.} \end{cases}$$

Notem que,  $\mathbb{E}(I) = \mathbb{P}(X \geq \lambda)$ .



# Desigualdade de Markov

**Prova.** Para  $\lambda > 0$ , seja

$$I = \begin{cases} 1, & \text{se } X \geq \lambda; \\ 0, & \text{caso contrário.} \end{cases}$$

Notem que,  $\mathbb{E}(I) = \mathbb{P}(X \geq \lambda)$ .



# Desigualdade de Markov

Notem também que,

$$I \leq \frac{X}{\lambda}.$$



# Desigualdade de Markov

Notem também que,

$$I \leq \frac{X}{\lambda}.$$

Tomando as esperanças da desigualdade acima,



# Desigualdade de Markov

Notem também que,

$$I \leq \frac{X}{\lambda}.$$

Tomando as esperanças da desigualdade acima,

$$\begin{aligned} \mathbb{E}(I) &\leq \mathbb{E}\left(\frac{X}{\lambda}\right) = \frac{\mathbb{E}(X)}{\lambda} \\ \Rightarrow \mathbb{P}(X \geq \lambda) &\leq \frac{\mathbb{E}(X)}{\lambda}. \end{aligned}$$



# Desigualdade de Markov

Notem também que,

$$I \leq \frac{X}{\lambda}.$$

Tomando as esperanças da desigualdade acima,

$$\begin{aligned} \mathbb{E}(I) &\leq \mathbb{E}\left(\frac{X}{\lambda}\right) = \frac{\mathbb{E}(X)}{\lambda} \\ \Rightarrow \mathbb{P}(X \geq \lambda) &\leq \frac{\mathbb{E}(X)}{\lambda}. \end{aligned}$$





# Desigualdade de Chebyshev

Seja  $X$  uma variável aleatória com média  $\mu < \infty$  (finita) e variância  $\sigma^2$ .

Então, para todo  $\lambda > 0$ ,

$$\mathbb{P}(|X - \mu| \geq \lambda) \leq \frac{\sigma^2}{\lambda^2}.$$



# Desigualdade de Chebyshev

Seja  $X$  uma variável aleatória com média  $\mu < \infty$  (finita) e variância  $\sigma^2$ .

Então, para todo  $\lambda > 0$ ,

$$\mathbb{P}(|X - \mu| \geq \lambda) \leq \frac{\sigma^2}{\lambda^2}.$$



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa,



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$





# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$  se e somente se  $|X - \mu| \geq \lambda$ ,



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$  se e somente se  $|X - \mu| \geq \lambda$ , dessa forma,



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$  se e somente se  $|X - \mu| \geq \lambda$ , dessa forma, a equação acima é equivalente a



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$  se e somente se  $|X - \mu| \geq \lambda$ , dessa forma, a equação acima é equivalente a

$$\mathbb{P} (|X - \mu| \geq \lambda) \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2} = \frac{\sigma^2}{\lambda^2}.$$



# Desigualdade de Chebyshev

**Prova.** Desde que  $(X - \mu)^2$  é uma variável aleatória não negativa, nós podemos aplicar a desigualdade de Markov para obter

$$\mathbb{P} \left[ (X - \mu)^2 \geq \lambda^2 \right] \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2}.$$

Observem que,  $(X - \mu)^2 \geq \lambda^2$  se e somente se  $|X - \mu| \geq \lambda$ , dessa forma, a equação acima é equivalente a

$$\mathbb{P} (|X - \mu| \geq \lambda) \leq \frac{\mathbb{E}[(X - \mu)^2]}{\lambda^2} = \frac{\sigma^2}{\lambda^2}.$$



# Desigualdades

A importância das desigualdades de Markov e Chebyshev é que elas nos permitem encontrar limites para as probabilidades quando **somente** a média ou ambas, a média e variância, da distribuição de probabilidades são conhecidas.



# Desigualdades

Claro, se a distribuição é conhecida, então a probabilidade desejada pode ser calculada de forma exata e nós não precisaríamos recorrer a esses limites (essas desigualdades).



# Desigualdade de Markov generalizada

Seja  $X$  uma variável aleatória qualquer. Para todo  $t > 0$ ,

$$\mathbb{P}(|X| \geq \lambda) \leq \frac{\mathbb{E}[|X|^t]}{\lambda^t}, \quad \forall \lambda > 0.$$



# Desigualdade de Markov generalizada

Seja  $X$  uma variável aleatória qualquer. Para todo  $t > 0$ ,

$$\mathbb{P}(|X| \geq \lambda) \leq \frac{\mathbb{E}[|X|^t]}{\lambda^t}, \quad \forall \lambda > 0.$$



# Limitantes de Chernoff

Para quaisquer variável aleatória  $X$  e constante  $a \in \mathbb{R}$ ,

$$\mathbb{P}(X \geq a) \leq e^{-ta} M_X(t), \quad \forall t > 0;$$

$$\mathbb{P}(X \leq a) \leq e^{-ta} M_X(t), \quad \forall t < 0;$$



# Limitantes de Chernoff

Para quaisquer variável aleatória  $X$  e constante  $a \in \mathbb{R}$ ,

$$\mathbb{P}(X \geq a) \leq e^{-ta} M_X(t), \quad \forall t > 0;$$

$$\mathbb{P}(X \leq a) \leq e^{-ta} M_X(t), \quad \forall t < 0;$$

em que  $M_X(t)$  é a função geradora de momentos de  $X$ , avaliada no ponto  $t$ .



# Limitantes de Chernoff

Para quaisquer variável aleatória  $X$  e constante  $a \in \mathbb{R}$ ,

$$\mathbb{P}(X \geq a) \leq e^{-ta} M_X(t), \quad \forall t > 0;$$

$$\mathbb{P}(X \leq a) \leq e^{-ta} M_X(t), \quad \forall t < 0;$$

em que  $M_X(t)$  é a função geradora de momentos de  $X$ , avaliada no ponto  $t$ . Uma vez que os limitantes de Chernoff valem para  $t \in \mathbb{R}$ ,



# Limitantes de Chernoff

Para quaisquer variável aleatória  $X$  e constante  $a \in \mathbb{R}$ ,

$$\mathbb{P}(X \geq a) \leq e^{-ta} M_X(t), \quad \forall t > 0;$$

$$\mathbb{P}(X \leq a) \leq e^{-ta} M_X(t), \quad \forall t < 0;$$

em que  $M_X(t)$  é a função geradora de momentos de  $X$ , avaliada no ponto  $t$ . Uma vez que os limitantes de Chernoff valem para  $t \in \mathbb{R}$ , nós obtemos o melhor limitante para  $\mathbb{P}(X \geq a)$  escolhendo  $t$  que minimiza  $e^{-ta} M_X(t)$ .



# Limitantes de Chernoff

Para quaisquer variável aleatória  $X$  e constante  $a \in \mathbb{R}$ ,

$$\mathbb{P}(X \geq a) \leq e^{-ta} M_X(t), \quad \forall t > 0;$$

$$\mathbb{P}(X \leq a) \leq e^{-ta} M_X(t), \quad \forall t < 0;$$

em que  $M_X(t)$  é a função geradora de momentos de  $X$ , avaliada no ponto  $t$ . Uma vez que os limitantes de Chernoff valem para  $t \in \mathbb{R}$ , nós obtemos o melhor limitante para  $\mathbb{P}(X \geq a)$  escolhendo  $t$  que minimiza  $e^{-ta} M_X(t)$ .



# Função convexa

## Definição

Uma função real e duas vezes diferenciável  $f(a)$  é dita ser convexa se  $f^{(2)}(a) \geq 0$ , para todo  $a$ .



# Função convexa

## Definição

Uma função real e duas vezes diferenciável  $f(a)$  é dita ser convexa se  $f^{(2)}(a) \geq 0$ , para todo  $a$ . Além disso, suas derivadas são monotonicamente não decrescentes.





# Função convexa

## Definição

Uma função real e duas vezes diferenciável  $f(a)$  é dita ser convexa se  $f^{(2)}(a) \geq 0$ , para todo  $a$ . Além disso, suas derivadas são monotonicamente não decrescentes.

**Observação.** De forma similar,  $f(a)$  é dita ser côncava se  $f^{(2)}(a) \leq 0$ .



# Função convexa

## Definição

Uma função real e duas vezes diferenciável  $f(a)$  é dita ser convexa se  $f^{(2)}(a) \geq 0$ , para todo  $a$ . Além disso, suas derivadas são monotonicamente não decrescentes.

**Observação.** De forma similar,  $f(a)$  é dita ser côncava se  $f^{(2)}(a) \leq 0$ .



# Desigualdade de Jensen

Seja  $f : \mathbb{R} \rightarrow \mathbb{R}$  uma função convexa. Se a variável aleatória  $X$  é integrável,



# Desigualdade de Jensen

Seja  $f : \mathbb{R} \rightarrow \mathbb{R}$  uma função convexa. Se a variável aleatória  $X$  é integrável, então

$$\mathbb{E}[f(X)] \geq f(\mathbb{E}[X]).$$



# Desigualdade de Jensen

Seja  $f : \mathbb{R} \rightarrow \mathbb{R}$  uma função convexa. Se a variável aleatória  $X$  é integrável, então

$$\mathbb{E}[f(X)] \geq f(\mathbb{E}[X]).$$

**Observação:** A Desigualdade de Jensen é válida se  $f$  é convexa em um intervalo  $(a, b)$  tal que  $\mathbb{P}(a < X < b) = 1$ , em que se admite a possibilidade de  $a = -\infty$  ou  $b = +\infty$ .



# Desigualdade de Jensen

Seja  $f : \mathbb{R} \rightarrow \mathbb{R}$  uma função convexa. Se a variável aleatória  $X$  é integrável, então

$$\mathbb{E}[f(X)] \geq f(\mathbb{E}[X]).$$

**Observação:** A Desigualdade de Jensen é válida se  $f$  é convexa em um intervalo  $(a, b)$  tal que  $\mathbb{P}(a < X < b) = 1$ , em que se admite a possibilidade de  $a = -\infty$  ou  $b = +\infty$ .



# Desigualdade de Jensen

**Demonstração.** Usando (2),



# Desigualdade de Jensen

**Demonstração.** Usando (2), até o segundo termo





# Desigualdade de Jensen

**Demonstração.** Usando (2), até o segundo termo e em torno de  $X = \mu$ ,



# Desigualdade de Jensen

**Demonstração.** Usando (2), até o segundo termo e em torno de  $X = \mu$ , nós temos que



# Desigualdade de Jensen

**Demonstração.** Usando (2), até o segundo termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} f(X) &= \sum_{n=0}^{\infty} \frac{f^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{f^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{f^{(1)}(\mu)}{1!} (X - \mu)^1 + \underbrace{\sum_{n=2}^{\infty} \frac{f^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_2(x)}. \end{aligned}$$



# Desigualdade de Jensen

**Demonstração.** Usando (2), até o segundo termo e em torno de  $X = \mu$ , nós temos que

$$\begin{aligned} f(X) &= \sum_{n=0}^{\infty} \frac{f^{(n)}(\mu)}{n!} (X - \mu)^n \\ &= \frac{f^{(0)}(\mu)}{0!} (X - \mu)^0 + \frac{f^{(1)}(\mu)}{1!} (X - \mu)^1 + \underbrace{\sum_{n=2}^{\infty} \frac{f^{(n)}(\mu)}{n!} (X - \mu)^n}_{R_2(x)}. \end{aligned}$$



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ ,



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ ,  
nós temos que



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ , nós temos que

$$f(X) = f(\mu) + f^{(1)}(\mu)(X - \mu) + \frac{f^{(2)}(\tau)}{2}(X - \mu)^2,$$



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ , nós temos que

$$f(X) = f(\mu) + f^{(1)}(\mu)(X - \mu) + \frac{f^{(2)}(\tau)}{2}(X - \mu)^2,$$

em que  $X \leq \tau \leq \mu$ .





# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ , nós temos que

$$f(X) = f(\mu) + f^{(1)}(\mu)(X - \mu) + \frac{f^{(2)}(\tau)}{2}(X - \mu)^2,$$

em que  $X \leq \tau \leq \mu$ . Como  $f$  é uma função convexa,



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ , nós temos que

$$f(X) = f(\mu) + f^{(1)}(\mu)(X - \mu) + \frac{f^{(2)}(\tau)}{2}(X - \mu)^2,$$

em que  $X \leq \tau \leq \mu$ . Como  $f$  é uma função convexa, nós temos que

$$f(X) \geq f(\mu) + f^{(1)}(\mu)(X - \mu).$$



# Desigualdade de Jensen

Simplificando as expressões anteriores e utilizando o resultado para  $R_2(x)$ , nós temos que

$$f(X) = f(\mu) + f^{(1)}(\mu)(X - \mu) + \frac{f^{(2)}(\tau)}{2}(X - \mu)^2,$$

em que  $X \leq \tau \leq \mu$ . Como  $f$  é uma função convexa, nós temos que

$$f(X) \geq f(\mu) + f^{(1)}(\mu)(X - \mu).$$



# Desigualdade de Jensen

Aplicando a esperança, nós temos que

$$\mathbb{E} [f (X)] \geq \mathbb{E} \{f(\mu)\} + \mathbb{E} \left\{ f^{(1)}(\mu)(X - \mu) \right\}.$$



# Desigualdade de Jensen

Aplicando a esperança, nós temos que

$$\mathbb{E} [f (X)] \geq \mathbb{E} \{f(\mu)\} + \mathbb{E} \left\{ f^{(1)}(\mu)(X - \mu) \right\} .$$

Agora,



# Desigualdade de Jensen

Aplicando a esperança, nós temos que

$$\mathbb{E} [f (X)] \geq \mathbb{E} \{f(\mu)\} + \mathbb{E} \left\{ f^{(1)}(\mu)(X - \mu) \right\}.$$

Agora,

$$\begin{aligned} \mathbb{E} [f (X)] &\geq f(\mu) + f^{(1)}(\mu)\mathbb{E} \{X - \mu\} \\ \Rightarrow \mathbb{E} [f (X)] &\geq f(\mu). \end{aligned}$$



# Desigualdade de Jensen

Aplicando a esperança, nós temos que

$$\mathbb{E} [f (X)] \geq \mathbb{E} \{f(\mu)\} + \mathbb{E} \left\{ f^{(1)}(\mu)(X - \mu) \right\}.$$

Agora,

$$\begin{aligned} \mathbb{E} [f (X)] &\geq f(\mu) + f^{(1)}(\mu)\mathbb{E} \{X - \mu\} \\ \Rightarrow \mathbb{E} [f (X)] &\geq f(\mu). \end{aligned}$$



# Desigualdade de Jensen

Lembrando que  $\mathbb{E}(X) = \mu$ , nós concluímos a demonstração.





# Desigualdade de Jensen

Lembrando que  $\mathbb{E}(X) = \mu$ , nós concluímos a demonstração.

Essa demonstração foi adaptada de Ross (2019, p. 427),



# Desigualdade de Jensen

Lembrando que  $\mathbb{E}(X) = \mu$ , nós concluímos a demonstração.

Essa demonstração foi adaptada de Ross (2019, p. 427), para uma forma alternativa,



# Desigualdade de Jensen

Lembrando que  $\mathbb{E}(X) = \mu$ , nós concluímos a demonstração.

Essa demonstração foi adaptada de Ross (2019, p. 427), para uma forma alternativa, ver Magalhães (2015, p. 224).



# Desigualdade de Jensen

Lembrando que  $\mathbb{E}(X) = \mu$ , nós concluímos a demonstração.

Essa demonstração foi adaptada de Ross (2019, p. 427), para uma forma alternativa, ver Magalhães (2015, p. 224).



# Desigualdade de Cauchy-Schwarz

Sejam  $X$  e  $Y$  variáveis aleatórias com esperanças finitas. Então

$$\mathbb{E}(|XY|) \leq \sqrt{\mathbb{E}(X^2) \mathbb{E}(Y^2)}.$$



# Desigualdade de Cauchy-Schwarz

Sejam  $X$  e  $Y$  variáveis aleatórias com esperanças finitas. Então

$$\mathbb{E}(|XY|) \leq \sqrt{\mathbb{E}(X^2) \mathbb{E}(Y^2)}.$$



# Roteiro

- 1 Motivação
- 2 Série de Taylor
- 3 Expressões aproximadas da média e da variância
- 4 Desigualdades
- 5 Referências bibliográficas



# Referências bibliográficas I

Magalhães, M. N. (2015), *Probabilidade e variáveis aleatórias*, 3 edn, Editora da Universidade de São Paulo, São Paulo.

Ross, S. (2019), *A first course in probability*, 10 edn. global edn, Pearson Education, Malaysia.

Taylor, B. (1715), *Methodus Incrementorum Directa et Inversa*, Typis Pearsonianis prostant apud Gul. Innys ad Insignia Principis in Coemeterio Paulino, Londini.





# Obrigado!

✉ `tiago.magalhaes@ufjf.br`

🌐 `ufjf.br/tiago_magalhaes`

🌍 Departamento de Estatística, Sala 319

