

# Aula 26: Teorema Central do Limite

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

- ▶ Propriedades de tipos de convergência.
- ▶ Teorema Central do Limite



# Funções contínuas e convergência

## Proposição 26.1

Sejam  $X, X_1, X_2, \dots$  variáveis aleatórias e  $g : \mathbb{R} \rightarrow \mathbb{R}$  contínua.

1. Se  $X_n \xrightarrow{q.c.} X$ , então  $g(X_n) \xrightarrow{q.c.} g(X)$ .
2. Se  $X_n \xrightarrow{P} X$ , então  $g(X_n) \xrightarrow{P} g(X)$ .
3. Se  $X_n \xrightarrow{D} X$ , então  $g(X_n) \xrightarrow{D} g(X)$ .

### Observação!

Para (3) usamos convergência das funções características. No que segue provamos (1), (2).



Prova da Proposição 26.1 (1). Se  $X_n \xrightarrow{q.c.} X$  e

$$A = \left\{ \omega \in \Omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega) \right\}$$

então  $P(A) = 1$ . Seja  $\omega \in A$  e note que, como

$$\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$$

e  $g$  é uma função contínua então

$$\lim_{n \rightarrow \infty} g(X_n(\omega)) = g(X(\omega)).$$

Isto é,

$$A \subset \left\{ \omega \in \Omega : \lim_{n \rightarrow \infty} g(X_n(\omega)) = g(X(\omega)) \right\}.$$

Portanto,

$$1 = P(A) \leq P\left(\lim_{n \rightarrow \infty} g(X_n) = g(X)\right) \leq 1,$$

e assim  $g(X_n) \xrightarrow{q.c.} g(X)$ .



Prova da Proposição 26.1 (2). Se  $X_n \xrightarrow{P} X$  então, para todo  $\delta > 0$ :

$$\lim_{n \rightarrow \infty} P(|X_n - X| < \delta) = 1. \quad (1)$$

Considere  $\epsilon > 0$  tal que, para  $m$  suficientemente grande

$$P\left(-\frac{m}{2} \leq X \leq \frac{m}{2}\right) > 1 - \epsilon \quad (2)$$

o que é possível pois  $\{-\frac{m}{2} \leq X \leq \frac{m}{2}\} \nearrow \Omega$ . De (1) e (2) temos:

$$\lim_{n \rightarrow \infty} P(\{|X| \leq m/2\} \cap \{|X_n - X| < \delta\}) = P(|X| \leq m/2) > 1 - \epsilon \quad (3)$$



... continuação da prova da Proposição 26.1 (2). Como  $g$  é uniformemente contínua em  $[-m, m]$ , existe  $0 < \delta < m/2$  tal que se  $\max\{|x|, |y|\} \leq m$  e  $|x - y| < \delta$  então

$$|g(x) - g(y)| < \epsilon. \quad (4)$$

Note que, para  $\delta < m/2$  temos que

$$\begin{aligned} \{|X| \leq m/2, |X_n - X| < \delta\} &\subset \{|X| \leq m, |X_n| \leq m, |X_n - X| < \delta\} \\ &\subset \{|g(X_n) - g(X)| \leq \epsilon\} \end{aligned}$$

De (3) concluímos que  $P(|g(X_n) - g(X)| \leq \epsilon) > 1 - \epsilon$  para  $n$  grande. Agora, se  $\xi \in (0, \epsilon)$  temos que, para  $n$  suficientemente grande:

$$P(|g(X_n) - g(X)| \leq \epsilon) > P(|g(X_n) - g(X)| \leq \xi) > 1 - \xi$$

e tomando  $\xi \rightarrow 0$  concluímos que

$$\lim_{n \rightarrow \infty} P(|g(X_n) - g(X)| \leq \epsilon) = 1.$$



# Teorema Central do Limite

## Teorema 26.1

Sejam  $X_1, X_2, \dots$  i.i.d. com  $\mu = E(X_1)$  e  $\sigma^2 = \text{Var}(X_1) < \infty$ . Então:

$$\frac{S_n - E(S_n)}{\sqrt{\text{Var}(S_n)}} \xrightarrow{D} Z \sim \mathcal{N}(0, 1).$$

Em outras palavras:

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \xrightarrow{D} Z \sim \mathcal{N}(0, 1),$$

ou

$$\lim_{n \rightarrow \infty} P\left(a \leq \frac{S_n - n\mu}{\sigma\sqrt{n}} \leq b\right) = \Phi(b) - \Phi(a),$$

ou

$$P\left(a \leq \frac{S_n - n\mu}{\sigma\sqrt{n}} \leq b\right) \approx \Phi(b) - \Phi(a), \text{ para } n \text{ suficientemente grande.}$$



# Teorema Central do Limite de Lindeberg

## Teorema 26.2

Sejam  $X_1, X_2, \dots$  variáveis aleatórias independentes tais que  $E(X_n) = \mu_n$  e  $\text{Var}(X_n) = \sigma_n^2$ , onde  $\sigma_n^2 < \infty$  e pelo menos um  $\sigma_n^2 > 0$ . Sejam

$$F_n := F_{X_n}, \quad S_n := \sum_{i=1}^n X_i, \quad s_n := \sqrt{\text{Var}(S_n)} = \sqrt{\sum_{i=1}^n \sigma_i^2}.$$

Se para todo  $\epsilon > 0$  vale que

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) = 0 \quad (5)$$

então

$$\frac{S_n - E(S_n)}{s_n} \xrightarrow{D} Z \sim \mathcal{N}(0, 1).$$





# Condição de Lindeberg

A condição (1), chamada condição de Lindeberg, pode ser lida da seguinte forma para os casos discreto e contínuo:

- ▶ Se  $X_k$  são discretas com  $P(X_k = x_i) = p_k(x_i)$ , então:

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \left\{ \sum_{i: |x_i - \mu_k| > \epsilon s_n} (x_i - \mu_k)^2 p_k(x_i) \right\} = 0.$$

- ▶ Se  $X_k$  são contínuas com densidade  $f_k(x)$ , então:

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \left\{ \int_{-\infty}^{\mu_k - \epsilon s_n} (x - \mu_k)^2 f_k(x) dx + \int_{\mu_k + \epsilon s_n}^{+\infty} (x - \mu_k)^2 f_k(x) dx \right\} = 0.$$



## Condição de Lindeberg: outra forma

A condição de Lindeberg pode ser escrita como: para todo  $\epsilon > 0$ ,

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x) = 1.$$

**Prova.** Resulta de observar que

$$\begin{aligned} \sigma_k^2 &= \int (x - \mu_k)^2 dF_k(x) \\ &= \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x) + \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x), \end{aligned}$$

isto é

$$\frac{\sigma_k^2}{s_n^2} = \frac{1}{s_n^2} \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x) + \frac{1}{s_n^2} \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x),$$



# Condição de Lindeberg: outra forma

Como

$$\sum_{k=1}^n \frac{\sigma_k^2}{s_n^2} = 1,$$

temos que

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x) = 1$$

se, e somente se,

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) = 0.$$



## Proposição 26.2

Sejam  $X_1, X_2, \dots$  variáveis aleatórias tais que  $E(X_n) = \mu_n$  e  $\text{Var}(X_n) = \sigma_n^2 < \infty$  para todo  $n$ . Se a sequência satisfaz a condição de Lindeberg, então:

$$\lim_{n \rightarrow \infty} \left\{ \max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \right\} = 0.$$

**Prova.** Note que, para  $k \in \{1, \dots, n\}$

$$\begin{aligned} \frac{\sigma_k^2}{s_n^2} &= \frac{1}{s_n^2} \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x) + \frac{1}{s_n^2} \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) \\ &\leq \frac{1}{s_n^2} \int_{|x - \mu_k| \leq \epsilon s_n} \epsilon^2 s_n^2 dF_k(x) + \frac{1}{s_n^2} \sum_{i=1}^n \int_{|x - \mu_i| > \epsilon s_n} (x - \mu_i)^2 dF_i(x) \\ &\leq \frac{1}{s_n^2} \int_{-\infty}^{\infty} \epsilon^2 s_n^2 dF_k(x) + \frac{1}{s_n^2} \sum_{i=1}^n \int_{|x - \mu_i| > \epsilon s_n} (x - \mu_i)^2 dF_i(x) \end{aligned}$$



... continuação da prova da Proposição 26.2. Logo,

$$\max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \leq \epsilon^2 + \frac{1}{s_n^2} \sum_{i=1}^n \int_{|x - \mu_i| > \epsilon s_n} (x - \mu_i)^2 dF_i(x).$$

Fazendo  $n \rightarrow \infty$  temos pela condição de Lindeberg que

$$\lim_{n \rightarrow \infty} \max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \leq \epsilon^2$$

e fazendo  $\epsilon \rightarrow 0$  concluímos o resultado.



# Recíproca do TCL de Lindeberg

## Teorema 26.3

Sejam  $X_1, X_2, \dots$  variáveis aleatórias independentes tais que  $E(X_n) = \mu_n$  e  $\text{Var}(X_n) = \sigma_n^2$ , onde  $\sigma_n^2 < \infty$  e pelo menos um  $\sigma_n^2 > 0$ . Suponha que

$$\lim_{n \rightarrow \infty} \max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} = 0.$$

Se

$$\frac{S_n - E(S_n)}{s_n} \xrightarrow{D} Z \sim \mathcal{N}(0, 1)$$

então, para todo  $\epsilon > 0$  vale que

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| > \epsilon s_n} (x - \mu_k)^2 dF_k(x) = 0.$$



## TCL de i.i.d. como corolário

Podemos obter o Teorema 26.1 do Teorema 26.2: Vamos verificar que vale a condição de Lindeberg. De fato, como  $s_n^2 = n\sigma^2$ , para  $\epsilon > 0$ , temos que

$$\frac{1}{s_n^2} \sum_{k=1}^n \int_{|x - \mu_k| \leq \epsilon s_n} (x - \mu_k)^2 dF_k(x)$$

é igual a

$$\frac{1}{\sigma^2} \int_{|x - \mu| \leq \epsilon \sigma \sqrt{n}} (x - \mu)^2 dF(x) = \frac{1}{\sigma^2} \int_{\mu - \epsilon \sigma \sqrt{n}}^{\mu + \epsilon \sigma \sqrt{n}} (x - \mu)^2 dF(x)$$

mas

$$\lim_{n \rightarrow \infty} \frac{1}{\sigma^2} \int_{\mu - \epsilon \sigma \sqrt{n}}^{\mu + \epsilon \sigma \sqrt{n}} (x - \mu)^2 dF(x) = \frac{1}{\sigma^2} \int_{-\infty}^{+\infty} (x - \mu)^2 dF(x) = \frac{\sigma^2}{\sigma^2} = 1.$$



Bom estudo!



UNIVERSIDADE  
FEDERAL  
DE PERNAMBUCO

**CCEN**

CENTRO DE CIÊNCIAS EXATAS  
E DA NATUREZA