

## 1. TÓPICO 1

### 1.1. Introdução. Convergência de Sequências de Eventos.

**Definição 1.1.** Em relação a uma sequência de números reais,  $(a_n)_{n \geq 1}$ , definimos o limite superior de  $(a_n)_{n \geq 1}$  ao número real  $\bar{a} = \limsup a_n$ , com

$$\bar{a} = \inf_{n \geq 1} \sup_{k \geq n} a_k$$

e definimos o limite inferior de  $(a_n)_{n \geq 1}$  ao número real  $\underline{a} = \liminf a_n$ , com

$$\underline{a} = \sup_{n \geq 1} \inf_{k \geq n} a_k.$$

Se  $\bar{a} = \underline{a} = a$  definimos o valor comum,  $a$ , como sendo o limite da sequência  $(a_n)_{n \geq 1}$  e denotamos  $a = \lim a_n = \lim_{n \uparrow \infty} a_n$ .

**Exemplo 1.2.** Assim, se consideramos  $a_n = \frac{1}{n}, n \geq 1$ , temos

$$\bar{a} = \inf_{n \geq 1} \sup \left\{ \frac{1}{n}, \frac{1}{n+1}, \frac{1}{n+2}, \dots \right\} = \inf \left\{ 1, \frac{1}{2}, \frac{1}{3}, \dots, \frac{1}{n}, \dots \right\} = 0$$

e

$$\underline{a} = \sup_{n \geq 1} \inf \left\{ \frac{1}{n}, \frac{1}{n+1}, \frac{1}{n+2}, \dots \right\} = \sup \{0\} = 0.$$

Portanto  $\lim_{n \uparrow \infty} \frac{1}{n} = 0$

**Exemplo 1.3.** Se consideramos a sequência  $a_n = (-1)^n \left(1 + \frac{1}{n}\right)$  temos

$$\bar{a} = \inf_{n \geq 1} \sup \left\{ (-1)^n \left(1 + \frac{1}{n}\right), (-1)^{n+1} \left(1 + \frac{1}{n+1}\right), (-1)^{n+2} \left(1 + \frac{1}{n+2}\right), \dots \right\} =$$

$$\inf_{n \geq 1} \sup \left\{ \left(1 + \frac{1}{2n}\right), \left(1 + \frac{1}{2n+2}\right), \dots \right\} = \inf \left\{ \left(1 + \frac{1}{2}\right), \left(1 + \frac{1}{4}\right), \dots, \left(1 + \frac{1}{2n}\right), \dots \right\} = 1$$

e

$$\underline{a} = \sup_{n \geq 1} \inf \left\{ (-1)^n \left(1 + \frac{1}{n}\right), (-1)^{n+1} \left(1 + \frac{1}{n+1}\right), (-1)^{n+2} \left(1 + \frac{1}{n+2}\right), \dots \right\} =$$

$$\sup_{n \geq 1} \inf \left\{ -\left(1 + \frac{1}{2n+1}\right), -\left(1 + \frac{1}{2n+3}\right), \dots \right\} =$$

$$\sup \left\{ -\left(1 + \frac{1}{3}\right), -\left(1 + \frac{1}{5}\right), \dots, -\left(1 + \frac{1}{2n+1}\right), \dots \right\} = -1.$$

Portanto  $\bar{a} = 1 \neq -1 = \underline{a}$  e dizemos que o limite não existe.

*Observação 1.4.* Analiticamente, podemos colocar uma condição necessária e suficiente para que  $a = \lim a_n = \lim_{n \uparrow \infty} a_n$  exista:

$$\forall \varepsilon > 0, \exists n_0 \mid \text{se } n \geq n_0 \rightarrow |a_n - a| < \varepsilon.$$

Estamos interessados em estudar o limite de seqüências de conjuntos aleatórios (variáveis aleatórias) e devemos fixar um espaço de probabilidade,  $(\Omega, \mathfrak{S}, P)$ , onde serão definidas as operações de interesse. Resumindo, a probabilidade é uma função de conjuntos e para defini-la em um espaço amostral,  $\Omega$ , consideramos  $\mathfrak{S}$ , a classe de todos os eventos de  $\Omega$  fechada pelas operações de reunião, intersecção, complementar, em um número infinito de eventos. Definimos  $P$  em  $\mathfrak{S}$  satisfazendo os Axiomas de Kolmogorov:

**Definição 1.5.**

$$\begin{aligned} P : \mathfrak{S} &\rightarrow [0, 1] \\ A &\mapsto P(A) \end{aligned}$$

satisfazendo

- a)  $P(\Omega) = 1$
- b)  $P(\bigcup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$  quando os  $A_i$  são disjuntos dois a dois, isto é,  $A_i \cap A_j = \emptyset \quad \forall i \neq j$ .

**Definição 1.6.** Em relação a uma seqüência de conjuntos  $(A_n)_{n \geq 1}$ , definimos o limite superior de  $(A_n)_{n \geq 1}$  ao conjunto  $\overline{A} = \limsup A_n$  com

$$\overline{A} = \bigcap_{n \geq 1} \bigcup_{k \geq n} A_k$$

e definimos o limite inferior de  $(A_n)_{n \geq 1}$  o conjunto  $\underline{A} = \liminf A_n$ , com

$$\underline{A} = \bigcup_{n \geq 1} \bigcap_{k \geq n} A_k.$$

Se  $\overline{A} = \underline{A} = A$  definimos o conjunto  $A$  como sendo o limite da seqüência  $(A_n)_{n \geq 1}$  e denotamos  $A = \lim A_n = \lim_{n \uparrow \infty} A_n$ .

Se consideramos a seqüência de conjuntos  $A_n = (\frac{-1}{n}, \frac{n}{n+1}]$  temos

$$\underline{A} = \bigcup_{n \geq 1} \left\{ \left( \frac{-1}{n}, \frac{n}{n+1} \right] \cap \left( \frac{-1}{n+1}, \frac{n+1}{n+2} \right] \cap \dots \right\} = \bigcup_{n \geq 1} \left[ 0, \frac{n}{n+1} \right] = [0, 1).$$

e

$$\overline{A} = \bigcap_{n \geq 1} \left\{ \left( \frac{-1}{n}, \frac{n}{n+1} \right] \cup \left( \frac{-1}{n+1}, \frac{n+1}{n+2} \right] \cup \dots \right\} = \bigcap_{n \geq 1} \left( \frac{-1}{n}, 1 \right) = [0, 1).$$

Portanto  $\underline{A} = \overline{A} = \lim A_n = [0, 1)$ .

*Observação 1.7.* Podemos interpretar o limite inferior de uma sequência de conjuntos  $(A_n)_{n \geq 1}$ , como sendo o conjunto dos elementos que pertencem a todos os  $A_n$ , a menos de um número finito de índices. O limite superior é o conjunto de elementos que pertencem a um número infinito dos  $A_n$ .

Obviamente temos

$$\liminf A_n \subseteq \limsup A_n$$

de forma que

$$P(\liminf A_n) \leq P(\limsup A_n).$$

É conveniente observar as Leis de Morgan:

$$\left(\bigcap_{n \geq 1} \bigcup_{k \geq n} A_k\right)^c = \bigcup_{n \geq 1} \bigcap_{k \geq n} A_k^c,$$

$$\left(\bigcup_{n \geq 1} \bigcap_{k \geq n} A_k\right)^c = \bigcap_{n \geq 1} \bigcup_{k \geq n} A_k^c$$

e portanto, se o limite existe,  $(\lim A_n)^c = \lim A_n^c$ .

**Definição 1.8.** Uma sequência de conjuntos  $(A_n)_{n \geq 1}$  é crescente ( decrescente) se, e somente se,  $A_n \subseteq A_{n+1}, \forall n \geq 1$  ( $A_n \supseteq A_{n+1}, \forall n \geq 1$ ).

**Lema 1.9.** Se a sequência de conjuntos  $(A_n)_{n \geq 1}$  é crescente ( decrescente), então  $\lim A_n = \bigcup_{n \geq 1} A_n$  ( $\lim A_n = \bigcap_{n \geq 1} A_n$ ).

*Prova*

Se  $(A_n)_{n \geq 1}$  é crescente,  $A_n \subseteq A_{n+1}, \forall n \geq 1$  temos

$$\liminf A_n = \bigcup_{n \geq 1} \bigcap_{k \geq n} A_k = \bigcup_{n \geq 1} A_n$$

e

$$\limsup A_n = \bigcap_{n \geq 1} \bigcup_{k \geq n} A_k = \bigcup_{n \geq 1} A_n$$

Consequentemente  $\lim_{n \uparrow \infty} A_n = \bigcup_{n \geq 1} A_n$

Se  $(A_n)_{n \geq 1}$  é decrescente, então  $(A_n^c)_{n \geq 1}$  é crescente, e

$$(\lim A_n)^c = \lim A_n^c = \bigcup_{n \geq 1} A_n^c = \left(\bigcap_{n \geq 1} A_n\right)^c$$

e portanto  $\lim_{n \uparrow \infty} A_n = \bigcap_{n \geq 1} A_n$ .

## 1.2. Convergência e continuidade de medidas de probabilidades. Lema de Borel Cantelli.

*Observação 1.10.* Uma função  $f(x)$  definida no conjunto dos números reais a valores reais, é contínua em um número real  $a$  se, e somente se,  $\lim_{x \rightarrow a} f(x) = f(a)$ , isto é

$$\forall \varepsilon > 0, \exists \delta > 0 \mid \text{se } |x - a| < \delta \rightarrow |f(x) - f(a)| < \varepsilon.$$

Uma condição equivalente em termos de sequência de números reais é:

$$\lim_{x \rightarrow a} f(x) = f(a) \leftrightarrow \lim_{n \rightarrow \infty} f(a_n) = f(a), \forall (a_n)_{n \geq 1}, \lim_{n \rightarrow \infty} a_n = a,$$

isto é

$$\forall \varepsilon > 0, \exists n_0 \mid \text{se } n \geq n_0 \rightarrow |f(a_n) - f(a)| < \varepsilon.$$

**Exemplo 1.11.** Seja  $X$  uma variável aleatória com distribuição exponencial de parâmetro  $\lambda$ . Defina os eventos  $A_n = \{X \in [0, \frac{n}{n+1}]\}$ . Note que  $(A_n)_{n \geq 1}$  é crescente e que  $\lim A_n = \bigcup_{n \geq 1} A_n = \{X \in [0, 1)\}$ . Portanto

$$P(\lim A_n) = \int_0^1 \lambda e^{-\lambda x} dx = 1 - e^{-\lambda}.$$

Por outro lado,

$$P(A_n) = \int_0^{\frac{n}{n+1}} \lambda e^{-\lambda x} dx = 1 - e^{-\frac{n\lambda}{n+1}}$$

e

$$\lim P(A_n) = \lim_{n \rightarrow \infty} P(A_n) = \lim_{n \rightarrow \infty} 1 - e^{-\frac{n\lambda}{n+1}} = 1 - e^{-\lambda} = P(\lim A_n).$$

e podemos pensar que a medida de probabilidade é uma função conjuntos, que é contínua. Este fato é verdadeiro.

**Teorema 1.12.** *Seja  $(\Omega, \mathfrak{S}, P)$  um espaço de probabilidade e  $(A_n)_{n \geq 1}$  uma sequência de eventos em  $\mathfrak{S}$ , Se o limite da sequência  $(A_n)_{n \geq 1}$  existe, então*

$$P(\lim A_n) = \lim P(A_n).$$

### Prova

Se  $(A_n)_{n \geq 1}$  é uma sequência crescente de eventos,  $\lim A_n = \bigcup_{n=1}^{\infty} A_n$ . Definimos  $B_1 = A_1$  e  $B_n = A_n - A_{n-1}$  de forma que

$$\bigcup_{n=1}^{\infty} A_n = \bigcup_{n=1}^{\infty} B_n.$$

Portanto

$$\begin{aligned}
P(\lim A_n) &= P\left(\bigcup_{n=1}^{\infty} A_n\right) = P\left(\bigcup_{n=1}^{\infty} B_n\right) = \sum_{n=1}^{\infty} P(B_n) = P(B_1) + \sum_{n=2}^{\infty} P(B_n) = \\
&P(A_1) + \sum_{n=2}^{\infty} P(A_n - A_{n-1}) = P(A_1) + \sum_{n=2}^{\infty} [P(A_n) - P(A_{n-1})] = \\
&P(A_1) + \lim_{m \rightarrow \infty} \sum_{n=2}^m [P(A_n) - P(A_{n-1})] = \lim_{m \rightarrow \infty} P(A_m)
\end{aligned}$$

No caso em que a seqüência  $(A_n)_{n \geq 1}$  é decrescente,  $\lim A_n = \bigcap_{n=1}^{\infty} A_n$  e  $(A_n^c)_{n \geq 1}$  é uma seqüência crescente de eventos e  $\lim A_n^c = \bigcup_{n=1}^{\infty} A_n^c = \left(\bigcap_{n=1}^{\infty} A_n\right)^c$ .

Portanto

$$\begin{aligned}
P(\lim A_n) &= P\left(\bigcap_{n=1}^{\infty} A_n\right) = 1 - P\left(\left(\bigcap_{n=1}^{\infty} A_n\right)^c\right) = 1 - P\left(\bigcup_{n=1}^{\infty} A_n^c\right) = \\
1 - P(\lim A_n^c) &= 1 - \lim_{n \rightarrow \infty} P(A_n^c) = \lim_{n \rightarrow \infty} (1 - P(A_n^c)) = \lim_{n \rightarrow \infty} P(A_n).
\end{aligned}$$

No caso geral temos

$$\begin{aligned}
P(\limsup A_n) &= P\left(\bigcap_{n \geq 1} \bigcup_{k \geq n} A_k\right) = P\left(\lim_{n \rightarrow \infty} \bigcup_{k \geq n} A_k\right) = \\
&\lim_{n \rightarrow \infty} P\left(\bigcup_{k \geq n} A_k\right) = \limsup_{k \geq n} P\left(\bigcup_{k \geq n} A_k\right) \geq \\
\limsup P(A_n) &\geq \liminf P(A_n) \geq \liminf P\left(\bigcap_{k \geq n} A_k\right) = \lim_{k \geq n} P\left(\bigcap_{k \geq n} A_k\right) = \\
&P\left(\lim_{k \geq n} \bigcap_{k \geq n} A_k\right) = P\left(\bigcup_{n \geq 1} \bigcap_{k \geq n} A_k\right) = P(\liminf A_n).
\end{aligned}$$

Contudo, como por hipótese  $\lim A_n$  existe,  $P(\limsup A_n) = P(\lim A_n) = P(\liminf A_n)$ . Considerando tais igualdades e as desigualdades acima concluímos

$$P(\lim A_n) = \limsup P(A_n) = \liminf P(A_n) = \lim P(A_n).$$

**Exemplo 1.13.** Seja  $X$  uma variável aleatória com função de distribuição contínua  $F$ . Então  $P(X = x) = 0, \forall x$ .

Considere a seqüência decrescente de intervalos, de

$$A_n = \left(x - \frac{1}{n}, x + \frac{1}{n}\right]$$

de forma que

$$\{x\} = \bigcap_{n=1}^{\infty} \left(x - \frac{1}{n}, x + \frac{1}{n}\right]$$

e

$$P(X \in \{x\}) = P\left(X \in \bigcap_{n=1}^{\infty} \left(x - \frac{1}{n}, x + \frac{1}{n}\right]\right) = \lim_{n \rightarrow \infty} P\left(X \in \left(x - \frac{1}{n}, x + \frac{1}{n}\right]\right) =$$

$$\lim_{n \rightarrow \infty} P\left(x - \frac{1}{n} < X \leq x + \frac{1}{n}\right) = \lim_{n \rightarrow \infty} [F(x + \frac{1}{n}) - F(x - \frac{1}{n})] = F(x^+) - F(x^-) = 0.$$

**Exemplo 1.14.** Seja  $X$  uma variável aleatória. Então ,

$$\forall \varepsilon > 0, \exists k \in \mathbb{N} \mid P(|X| > k) < \varepsilon.$$

Prova

Como  $X$  assume valores nos reais,  $P(|X| = \infty) = 0$ . Considere a sequência decrescente  $\{|X| > n\}$ , de forma que

$$\{|X| = \infty\} = \bigcap_{n=1}^{\infty} \{|X| > n\}$$

Portanto

$$0 = P(|X| = \infty) = P\left(\bigcap_{n=1}^{\infty} \{|X| > n\}\right) = P\left(\lim_{n \rightarrow \infty} \{|X| > n\}\right) = \lim_{n \rightarrow \infty} P(|X| > n).$$

Então,  $\forall \varepsilon > 0, \exists k \in \mathbb{N} \mid$  se  $n \geq k \rightarrow P(|X| > n) < \varepsilon$ . Em particular tomamos  $n = k$ .

**Exemplo 1.15.** Seja  $(A_n)_{n \geq 1}$  uma sequência de eventos no espaço de probabilidade  $(\Omega, \mathfrak{F}, P)$ . Então

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = 1 \Leftrightarrow \forall n, P(A_n) = 1.$$

Prova A condição necessária é óbvia.

Provemos a condição suficiente por indução em  $n$ . Para  $n = 2$  a prova é óbvia pois

$$P(A_1 \cap A_2) = P(A_1) + P(A_2) - P(A_1 \cup A_2).$$

Por hipótese de indução, suponha que a prova vale para  $n$ , isto

$$\forall m, P(A_m) = 1, 1 \leq m \leq n \Rightarrow P\left(\bigcap_{m=1}^n A_m\right) = 1.$$

Provemos para  $n + 1$ :  $P\left(\bigcap_{m=1}^{n+1} A_m\right) = P\left(\bigcap_{m=1}^n A_m \cap A_{n+1}\right) = 1$ , quando  $P\left(\bigcap_{m=1}^n A_m\right) = 1$  e  $P(A_{n+1}) = 1$ , o que ocorre, por hipótese de indução quando  $P(A_m) = 1, \forall m, 1 \leq m \leq n$ .

Conseqüentemente

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = P\left(\bigcap_{n=1}^{\infty} \bigcap_{i=1}^n A_i\right) = P\left(\lim_{n \rightarrow \infty} \bigcap_{i=1}^n A_i\right) =$$

$$\lim_{n \rightarrow \infty} P\left(\bigcap_{i=1}^n A_i\right) = \lim_{n \rightarrow \infty} 1 = 1.$$

**Teorema 1.16. Lema de Borel Cantelli** *Seja  $(A_n)_{n \geq 1}$  uma seqüência de eventos no espaço de probabilidade  $(\Omega, \mathfrak{S}, P)$ . Então*

I) *Se  $\sum P(A_n) < \infty \Rightarrow P(\limsup A_n) = P(A_n i.v.) = 0$ .*

II) *Se  $\sum P(A_n) = \infty$  e os  $A_n$  são independentes,  $\Rightarrow P(\limsup A_n) = P(A_n i.v.) = 1$ .*

*Prova Provemos a parte I.*

$$P(\limsup A_n) = P\left(\bigcap_{n \geq 1} \bigcup_{k \geq n} A_k\right) = P\left(\lim_{n \rightarrow \infty} \bigcup_{k \geq n} A_k\right) =$$

$$\lim_{n \rightarrow \infty} P\left(\bigcup_{k \geq n} A_k\right) \leq \lim_{n \rightarrow \infty} \sum_{k=n}^{\infty} P(A_k) = 0$$

*pois  $\sum P(A_n) < \infty$ . A desigualdade é devido a Bonferroni.*

*Provemos a parte II.*

*Devemos provar que  $P(\bigcap_{n \geq 1} \bigcup_{k \geq n} A_k) = 1$  que, pelo exemplo, é equivalente provar que  $P(\bigcup_{k \geq n} A_k) = 1, \forall n \geq 1$  ou seja  $P(\bigcap_{k \geq n} A_k^c) = 0, \forall n \geq 1$ .*

$$P\left(\bigcap_{k \geq n} A_k^c\right) = P\left(\lim_{m \rightarrow \infty} \bigcap_{k=n}^m A_k^c\right) = \lim_{m \rightarrow \infty} P\left(\bigcap_{k=n}^m A_k^c\right) =$$

$$\lim_{m \rightarrow \infty} \pi_{k=n}^m P(A_k^c) = \lim_{m \rightarrow \infty} \pi_{k=n}^m (1 - P(A_k)) \leq$$

$$\lim_{m \rightarrow \infty} \pi_{k=n}^m e^{-P(A_k)} = \lim_{m \rightarrow \infty} e^{-\sum_{k=n}^m P(A_k)} = e^{-\sum_{k=n}^{\infty} P(A_k)} = 0.$$

**Observação 1.17.** Observe que, se os eventos são independentes,  $P(A_n i.v.)$  é 0 ou 1.

**Exemplo 1.18.** Contudo, considere o espaço  $((0, 1), \mathfrak{F}, P)$  onde  $P$  é uniforme no intervalo  $(0, 1)$ .

Defina a variável aleatória

$$X_n(w) = 2^n \quad \text{se } w \in (0, \frac{1}{n}) \quad \text{e } 0 \quad \text{c.c.}$$

Observe que,

$$P(\lim_{n \rightarrow \infty} X_n(w) = 0) = 1 \text{ e}$$

$$\sum_{n=1}^{\infty} P(|X_n| > \varepsilon) = \sum_{n=1}^{\infty} P(X_n = 2^n) = \sum_{n=1}^{\infty} \frac{1}{n} = \infty.$$

Contudo as variáveis  $X_n$  não são independentes pois  $X_n = 2^n \rightarrow X_{n-1} = 2^{n-1}$  e o Lema de Borel Cantelli não vale.

**Exemplo 1.19.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição exponencial padrão e seja a variável aleatória  $Y_n = \frac{X_n}{\ln n}$ . Note que

$$P(|Y_n| > \varepsilon) = P\left(\frac{X_n}{\ln n} > \varepsilon\right) = P(X_n > \varepsilon \ln n) = e^{-\ln n^\varepsilon} = \frac{1}{n^\varepsilon},$$

e portanto  $\sum_{n=1}^{\infty} P(|Y_n| > \varepsilon) = \sum_{n=1}^{\infty} \frac{1}{n^\varepsilon}$ , que converge se  $\varepsilon > 1$  ( $P(A_n i.v.) = 0$ ) e diverge se  $\varepsilon \leq 1$  ( $P(A_n i.v.) = 1$ )

**Exemplo 1.20.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, 1)$ .

Sejam  $A_n = \{X_n \in (0, \frac{1}{n}]\}$  e  $B_n = \{X_n \in (0, \frac{1}{n^2}]\}$ . Assim  $P(A_n) = \frac{1}{n}$  e  $P(B_n) = \frac{1}{n^2}$ .

$P(A_n i.v.) = 1$  pois os  $A_n$  são independentes e  $\sum_{n=1}^{\infty} P(A_n) = \sum_{n=1}^{\infty} \frac{1}{n} = \infty$ , (série harmônica).

$P(B_n i.v.) = 1$  pois os  $B_n$  são tais que  $\sum_{n=1}^{\infty} P(B_n) = \sum_{n=1}^{\infty} \frac{1}{n^2} < \infty$ , (Série de Dirichlet).

### 1.3. Convergência quase certa e em probabilidade. Propriedades.

**Definição 1.21.** Seja  $(\Omega, \mathfrak{F}, P)$  um espaço de probabilidade e  $X$  uma variável aleatória definida em  $\Omega$  com valores em  $\mathfrak{R}$ , isto é, para cada  $w \in \Omega$ ,  $X(w) \in \mathfrak{R}$ , é um número real.

Seja  $(X_n)_{n \geq 1}$ , uma sequência de variáveis aleatórias. Para cada realização  $w$ ,  $(X_n(w))_{n \geq 1}$  é uma sequência de números reais que pode (ou não) convergir para um valor real  $X(w)$ .



Seja

$$N^c = \{w \in \Omega \mid X_n(w) \rightarrow X(w)\}.$$

Se  $P(N^c) = 1$  dizemos que  $(X_n)_{n \geq 1}$  converge quase certamente para  $X$ . Denotamos  $X_n \rightarrow^{qc} X$ .

Observe que  $P(N) = 1 - P(N^c) = 0$  e também dizemos que  $(X_n)_{n \geq 1}$  converge quase certamente para  $X$  a menos de um conjunto de medida nula.

*Observação 1.22.* O limite é único. Suponha que exista uma outra variável aleatória  $Y$ , tal que  $X_n \rightarrow^{qc} Y$ , isto é, existe  $M^c$  com  $P(M^c) = 1$

$$M^c = \{w \in \Omega \mid X_n(w) \rightarrow Y(w)\}.$$

Mas  $P(N^c \cap M^c) = 1$  e em  $N^c \cap M^c$  temos  $X(w) = Y(w)$ .

**Exemplo 1.23.** Seja  $X$  uma variável aleatória com distribuição uniforme no intervalo  $(0, 1)$ ,  $X \sim U(0, 1)$ .

Defina

$$X_n = \sum_{k=1}^n (1 - X)^{k-1}.$$

Para cada  $w$ ,  $0 < X(w) < 1$ , temos

$$\lim_{n \uparrow \infty} X_n(w) = \sum_{k=1}^{\infty} (1 - X(w))^{k-1} = \frac{1}{X(w)}$$

com

$$P(\lim_{n \uparrow \infty} X_n(w) = \frac{1}{X(w)}) = P(0 < X < 1) = 1$$

e  $X_n \rightarrow^{qc} \frac{1}{X}$ .

Defina

$$Y_n = \sum_{k=1}^n \left(\frac{5 \cdot X}{3}\right)^k.$$

Para cada  $w$ ,  $0 < X(w) < 1$ , temos

$$\lim_{n \uparrow \infty} Y_n(w) = \sum_{k=1}^{\infty} \left(\frac{5 \cdot X(w)}{3}\right)^k = \frac{1}{1 - \frac{5 \cdot X(w)}{3}},$$

se  $\frac{5 \cdot X(w)}{3} < 1$ , isto é,  $X(w) < \frac{3}{5}$ . Então

$$P(\lim_{n \uparrow \infty} Y_n(w) = Y(w) = \frac{1}{1 - \frac{5 \cdot X(w)}{3}}) = P(X < \frac{3}{5}) = \frac{3}{5}$$

e  $Y_n \rightarrow^{qc} Y$ .

*Observação 1.24.* Seja  $(a_n)_{n \geq 1}$  uma seqüência de números reais. Uma condição equivalente para que  $\lim_{n \uparrow \infty} a_n = a$  é

$$\forall \varepsilon > 0, \exists n \in \mathbb{N} \mid \forall k, k \geq n, \quad |a_k - a| < \varepsilon,$$

que, por sua vez, é equivalente a

$$\forall m \in \mathbb{N}, \exists n \in \mathbb{N} \mid \forall k, k \geq n, \quad |a_k - a| < \frac{1}{m}.$$

Sejam  $X$  uma variável aleatória e  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias tais que  $X_n \rightarrow^{qc} X$ . Então

$$\begin{aligned} N^c &= \{w \mid \lim_{n \uparrow \infty} X_n(w) = X(w)\} = \\ &= \{w \mid \forall m \in \mathbb{N}, \exists n \in \mathbb{N} \mid \forall k, k \geq n, \quad |X_k(w) - X(w)| < \frac{1}{m}\} = \\ &= \bigcap_{m \geq 1} \bigcup_{n \geq 1} \bigcap_{k \geq n} \{w \mid |X_k(w) - X(w)| < \frac{1}{m}\}. \end{aligned}$$

Portanto  $P(N^c) = 1$  se, e somente se,

$$P\left(\bigcup_{n \geq 1} \bigcap_{k \geq n} \{w \mid |X_k(w) - X(w)| < \frac{1}{m}\}\right) = 1, \quad \forall m \geq 1$$

que é equivalente a

$$P(\liminf\{w \mid |X_k(w) - X(w)| < \frac{1}{m}\}) = 1, \quad \forall m \geq 1$$

ou

$$P(\limsup\{w \mid |X_k(w) - X(w)| > \frac{1}{m}\}) = 0, \quad \forall m \geq 1.$$

**Corolário 1.25.** *Sejam  $X$  uma variável aleatória e  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias, e os eventos*

$$A_k = \{w \mid |X_k(w) - X(w)| > \frac{1}{m}\}.$$

*Se  $\sum_{k=1}^{\infty} P(A_k) < \infty$ ,  $\forall m \geq 1$ , então  $X_n \rightarrow^{qc} X$ .*

**Prova:** *Segue do Lema de Borel Cantelli.*

**Exemplo 1.26.** Seja  $(X_n)_{n \geq 1}$  uma seqüência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d) com distribuição exponencial padrão. Defina as variáveis aleatórias  $Y_n = \frac{X_n}{\ln n}$  de maneira que

$$P(|Y_n| > \frac{1}{m}) = P\left(\left|\frac{X_n}{\ln n}\right| > \frac{1}{m}\right) = P(X_n > (\ln n) \frac{1}{m}) = e^{-(\ln n) \frac{1}{m}} = \frac{1}{n^{\frac{1}{m}}}$$

e  $\sum_{n=1}^{\infty} \frac{1}{n^{\frac{1}{m}}} = \infty$  se  $m \geq 1$ .

Concluimos, pelo lema de Borel Cantelli, que  $P(\limsup |Y_n - 0| > \frac{1}{m}) = 1$  and  $Y_n \xrightarrow{qc} 0$ .

**Exemplo 1.27.** Considere o espaço  $((0, 1), \mathfrak{S}, P)$  onde  $P$  é uniforme no intervalo  $(0, 1)$ .

Defina a variável aleatória

$$X_n(w) = 2^n \quad \text{se } w \in (0, \frac{1}{n}) \quad \text{e } 0 \quad \text{c.c.}$$

Observe que,

$$P(\lim_{n \rightarrow \infty} X_n(w) = 0) = P(\bigcup_{n=1}^{\infty} (\frac{1}{n}, 1)) = 1 \text{ e } X_n \xrightarrow{qc} 0.$$

Contudo

$$\sum_{n=1}^{\infty} P(|X_n| > \varepsilon) = \sum_{n=1}^{\infty} P(X_n = 2^n) = \sum_{n=1}^{\infty} \frac{1}{n} = \infty.$$

mas as variáveis  $X_n$  não são independentes pois  $X_n = 2^n \rightarrow X_{n-1} = 2^{n-1}$  e o Lema de Borel Cantelli não vale.

### Operações com limites

P.1 - Se  $X_n \xrightarrow{qc} X$  e  $f$  é uma função real contínua, então

$$f(X_n) \xrightarrow{qc} f(X).$$

**Prova:**

pois

$$N^c = \{w \in \Omega \mid X_n(w) \rightarrow X(w)\} = \{w \in \Omega \mid f(X_n(w)) \rightarrow f(X(w))\}$$

e  $P(N^c) = 1$ .

P.2 - Se  $X_n \xrightarrow{qc} X$  e  $Y_n \xrightarrow{qc} Y$ , Então

$$X_n \pm Y_n \xrightarrow{qc} X \pm Y;$$

$$X_n \cdot Y_n \xrightarrow{qc} X \cdot Y;$$

$$\frac{X_n}{Y_n} \xrightarrow{qc} \frac{X}{Y}, \quad \text{quando bem definida.}$$

**Prova:**

Sejam

$$N_X^c = \{w \in \Omega \mid X_n(w) \rightarrow X(w)\} \text{ e } N_Y^c = \{w \in \Omega \mid Y_n(w) \rightarrow Y(w)\}$$

, com  $P(N_X^c) = 1$ ,  $P(N_Y^c) = 1$ , o que é equivalente a  $P(N_X^c \cap N_Y^c) = 1$ .

Se  $w \in N_X^c \cap N_Y^c$ , temos:

$$(X_n \pm Y_n)(w) \xrightarrow{qc} (X \pm Y)(w);$$

$$(X_n \cdot Y_n)(w) \xrightarrow{qc} (X \cdot Y)(w);$$

$$\left(\frac{X_n}{Y_n}\right)(w) \xrightarrow{qc} \left(\frac{X}{Y}\right)(w), \text{ quando bem definida.}$$

### Convergência em probabilidade

**Definição 1.28.** Sejam  $(X_n)_{n \geq 1}$ , uma sequência de variáveis aleatórias e  $X$  uma variável aleatória definidas em um mesmo espaço de probabilidade. Considere a sequência de números  $(P(|X_n - X| > \varepsilon))_{n \geq 1}$ . Se  $\lim_{n \uparrow \infty} P(|X_n - X| > \varepsilon) = 0$ , dizemos que  $X_n$  converge em probabilidade para  $X$  e denotamos por  $X_n \rightarrow^P X$ .

*Observação 1.29.* Observe que convergência em probabilidade não é concernente à convergência pontual de  $X_n(w)$  para  $X(w)$ . A interpretação é que, para valores grandes de  $n$ , as variáveis aleatórias  $X_n$  e  $X$  são aproximadamente iguais com probabilidade bem alta.

*Observação 1.30.* O limite em probabilidade é único: Sejam  $(X_n)_{n \geq 1}$ , uma sequência de variáveis aleatórias e  $X, Y$  variáveis aleatórias definidas em um mesmo espaço de probabilidade, tais que  $X_n \rightarrow^P X$  e  $X_n \rightarrow^P Y$ . Observe que

$$|X - Y| = |X - X_n + X_n - Y| \leq |X_n - X| + |X_n - Y|$$

e portanto

$$\{|X - Y| > \varepsilon\} \subset \{|X_n - X| > \frac{\varepsilon}{2}\} \cup \{|X_n - Y| > \frac{\varepsilon}{2}\}.$$

Temos que

$$P(|X - Y| > \varepsilon) \leq P(|X_n - X| > \frac{\varepsilon}{2}) + P(|X_n - Y| > \frac{\varepsilon}{2})$$

Então  $\forall \varepsilon > 0$

$$P(|X - Y| > \varepsilon) = \lim_{n \uparrow \infty} P(|X - Y| > \varepsilon) \leq$$

$$\lim_{n \uparrow \infty} P(|X_n - X| > \frac{\varepsilon}{2}) + \lim_{n \uparrow \infty} P(|X_n - Y| > \frac{\varepsilon}{2}) = 0.$$

Portanto  $\forall \varepsilon > 0$  temos  $P(|X - Y| > \varepsilon) = 0$  e  $P(X = Y) = 1$ .

**Exemplo 1.31.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d) com distribuição exponencial padrão. Defina as variáveis aleatórias  $Y_n = \frac{X_n}{\ln n}$  de maneira que

$$P(|Y_n| > \varepsilon) = P\left(\left|\frac{X_n}{\ln n}\right| > \varepsilon\right) = P(X_n > (\ln n)^\varepsilon) = e^{-(\ln n)^\varepsilon} = \frac{1}{n^\varepsilon}.$$

Portanto  $\lim_{n \uparrow \infty} P(|Y_n| > \varepsilon) = 0$  e  $Y_n \rightarrow^P 0$ .

Contudo

$$\sum_{n=1}^{\infty} P(|Y_n| > \varepsilon) = \sum_{n=1}^{\infty} \frac{1}{n^\varepsilon} = \infty \text{ se } \varepsilon \leq 1.$$

Como o  $Y_n$  são independentes concluímos que pelo Lema de Borel Cantelli que

$$P(\limsup\{|Y_n| > \varepsilon\}) = 1$$

e  $Y_n \rightarrow^P 0$  mas  $Y_n \not\rightarrow^{qc} 0$ .

**Teorema 1.32.** *Sejam  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias e  $X$  uma variável aleatória tal que  $X_n \rightarrow^{qc} X$ . Então  $X_n \rightarrow^P X$ .*

**Prova:**

*Se  $X_n \rightarrow^{qc} X$ , então*

$$P\left(\bigcap_{n \geq 1} \bigcup_{k \geq n} \left\{w \mid |X_k(w) - X(w)| > \frac{1}{m}\right\}\right) = 0, \quad \forall m \geq 1 \leftrightarrow$$

$$P\left(\lim_{n \uparrow \infty} \bigcup_{k \geq n} \left\{w \mid |X_k(w) - X(w)| > \frac{1}{m}\right\}\right) = 0, \quad \forall m \geq 1 \leftrightarrow$$

$$\lim_{n \uparrow \infty} P\left(\bigcup_{k \geq n} \left\{w \mid |X_k(w) - X(w)| > \frac{1}{m}\right\}\right) = 0, \quad \forall m \geq 1.$$

*Como*

$$0 \leq P(|X_n - X| > \frac{1}{m}) \leq P\left(\bigcup_{k \geq n} \left\{w \mid |X_k(w) - X(w)| > \frac{1}{m}\right\}\right), \quad \forall m \geq 1$$

*temos  $\lim_{n \uparrow \infty} P(|X_n - X| > \frac{1}{m}) = 0 \forall m \geq 1$  e  $X_n \rightarrow^P X$ .*

No exemplo 1.11 observamos que a condição suficiente do teorema não vale. Pode-se provar que se  $X_n \rightarrow^P X$ , existe uma subsequência de  $(X_n)_{n \geq 1}$ , digamos  $(X_{n_k})_{k \geq 1}$  tal que  $X_{n_k} \rightarrow^{qc} X$ . Para provar tal fato usaremos o seguinte lema:

**Lema 1.33.** *Sejam  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias e  $X$  uma variável aleatória. Se  $P(|X_n - X| \geq \varepsilon_n) \leq \delta_n$  para alguma seqüência não negativa  $(\varepsilon_n)_{n \geq 1}$  com  $\lim_{n \uparrow \infty} \varepsilon_n = 0$  e alguma seqüência  $(\delta_n)_{n \geq 1}$ , com  $\sum_{n=1}^{\infty} \delta_n < \infty$ , então,  $X_n \rightarrow^{qc} X$ .*

**Prova:**

*Por hipótese temos*

$$\sum_{n=1}^{\infty} P(|X_n - X| \geq \varepsilon_n) \leq \sum_{n=1}^{\infty} \delta_n < \infty$$

*e pelo Lema de Borel Cantelli concluímos que  $P(|X_n - X| \geq \varepsilon_n, \text{ iv}) = 0$ . Seja  $N = \{|X_n - X| \geq \varepsilon_n, \text{ iv}\}$ , então  $P(N) = 0$ .*

*Se  $w \in N^c$ ,  $\exists n(w) \in \mathbb{N}$ ,  $\mid \forall n \geq n(w), |X_n - X| \leq \varepsilon_n$ . Como  $P(N^c) = 1$  e  $\lim_{n \uparrow \infty} \varepsilon_n = 0$ , temos  $X_n \rightarrow^{qc} X$ .*

**Teorema 1.34.** *Sejam  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias e  $X$  uma variável aleatória tal que  $X_n \rightarrow^P X$ . Então existe uma subseqüência de  $(X_n)_{n \geq 1}$ , digamos  $(X_{n_k})_{k \geq 1}$  tal que  $X_{n_k} \rightarrow^{qc} X$ .*

**Prova:**

Por hipótese  $\lim_{n \uparrow \infty} P(|X_n - X| \geq \varepsilon) = 0, \quad \forall \varepsilon > 0$ . Portanto

$$\forall \frac{1}{2^k} > 0, \quad \exists n_o(k), \quad | \text{ se } n \geq n(k) \rightarrow P(|X_n - X| \geq \frac{1}{k}) < \frac{1}{2^k},$$

em particular  $P(|X_{n_k} - X| \geq \frac{1}{k}) < \frac{1}{2^k}$ .

Assim, para provar o teorema tomamos  $\varepsilon_k = \frac{1}{k}$ ,  $\delta_k = \frac{1}{2^k}$  e aplicarmos o lemma 1.13.

**Exemplo 1.35.** Seja  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias com distribuição uniforme no intervalo  $(0, 1)$ . Seja  $Y_n = \min\{X_1, \dots, X_n\}$ . Então  $Y_n \rightarrow^P 0$  pois

$$\begin{aligned} P(|Y_n| > \varepsilon) &= P(\min\{X_1, \dots, X_n\} > \varepsilon) = P(X_1 > \varepsilon, \dots, X_n > \varepsilon) = \\ &= \pi_{i=1}^n P(X_i > \varepsilon) = \pi_{i=1}^n (1 - \varepsilon) = (1 - \varepsilon)^n \rightarrow 0 \end{aligned}$$

quando  $n \rightarrow \infty$ .

### Operações com limites

P1 - Sejam  $(X_n)_{n \geq 1}$ , uma seqüência de variáveis aleatórias,  $X$  uma variável aleatória tal que  $X_n \rightarrow^P X$  e  $g$  uma função real contínua. Então  $g(X_n) \rightarrow^P g(X)$ .

**Prova:**

Para a prova, usaremos o fato provado : Se  $X$  é uma variável aleatória, então, para todo  $\varepsilon > 0$ , existe  $k$  tal que  $P(|X| > k) < \varepsilon$ .

Se  $g$  é contínua, então

$$\forall \varepsilon > 0, \quad \exists \delta(\varepsilon) > 0, \quad | \text{ se } |x - y| < \delta(\varepsilon) \rightarrow |g(x) - g(y)| < \varepsilon.$$

Em um intervalo fechado,  $g$  é uniformemente contínua e  $\delta$  não depende de  $\varepsilon$ . Portanto

$$\{|g(X_n) - g(X)| < \varepsilon\} \supset \{|X_n - X| < \delta\} \cap \{|X| \leq k\}$$

e

$$\{|g(X_n) - g(X)| > \varepsilon\} \subset \{|X_n - X| > \delta\} \cap \{|X| > k\}$$

e

$$P(|g(X_n) - g(X)| > \varepsilon) \leq P(|X_n - X| > \delta) + P(|X| > k) \leq \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon.$$

P2 - Sejam  $(X_n)_{n \geq 1}$  e  $(Y_n)_{n \geq 1}$  seqüências de variáveis aleatórias,  $X$  e  $Y$  variáveis aleatórias tais que  $X_n \xrightarrow{P} X$  e  $Y_n \xrightarrow{P} Y$ . Então  $X_n \pm Y_n \xrightarrow{P} X \pm Y$ .

**Prova:**

Da desigualdade modular temos

$$|(X_n \pm Y_n) - (X \pm Y)| = |(X_n - X) \pm (Y_n - Y)| \leq |X_n - X| + |Y_n - Y|$$

de forma que

$$\{|(X_n \pm Y_n) - (X \pm Y)| > \varepsilon\} \subset \{|X_n - X| > \frac{\varepsilon}{2}\} \cup \{|Y_n - Y| > \frac{\varepsilon}{2}\}$$

e

$$P(|(X_n \pm Y_n) - (X \pm Y)| > \varepsilon) \leq P(|X_n - X| > \frac{\varepsilon}{2}) + P(|Y_n - Y| > \frac{\varepsilon}{2}) \rightarrow 0,$$

quando  $n \rightarrow \infty$ .

P3 - Sejam  $(X_n)_{n \geq 1}$  e  $(Y_n)_{n \geq 1}$  seqüências de variáveis aleatórias,  $X$  e  $Y$  variáveis aleatórias tais que  $X_n \xrightarrow{P} X$  e  $Y_n \xrightarrow{P} Y$ . Então  $X_n \cdot Y_n \xrightarrow{P} X \cdot Y$ .

**Prova:**

A prova terá três partes:

A) Se  $a$  e  $b$  são constantes tais que  $X_n \xrightarrow{P} a$  e  $Y_n \xrightarrow{P} b$ , então  $X_n \cdot Y_n \xrightarrow{P} a \cdot b$ , pois

$$\frac{X_n \cdot Y_n - a \cdot b}{4} = \frac{(X_n + Y_n)^2 - (X_n - Y_n)^2}{4} \xrightarrow{P} \frac{(a + b)^2 - (a - b)^2}{4} = a \cdot b.$$

B) Se  $X_n \xrightarrow{P} X$  e  $Y$  é uma variável aleatória, então  $X_n \cdot Y \xrightarrow{P} X \cdot Y$ .

Relembro o resultado do exercício 1.5 da aula 2: Seja  $Y$  uma variável aleatória, então

$$\forall \varepsilon > 0, \exists k > 0 \mid P(|Y| > k) < \frac{\varepsilon}{2}.$$

Portanto  $P(|X_n \cdot Y_n - X \cdot Y| > \varepsilon) =$

$$P(\{|X_n \cdot Y_n - X \cdot Y| > \varepsilon\} \cap \{|Y| > k\}) + P(\{|X_n \cdot Y_n - X \cdot Y| > \varepsilon\} \cap \{|Y| \leq k\}) \leq$$

$$\frac{\varepsilon}{2} + P(\{|X_n - X| \cdot |Y| > \varepsilon\}) \cap \{|Y| \leq k\} \leq$$

$$\frac{\varepsilon}{2} + P(|X_n - X| > \frac{\varepsilon}{k}) < \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon$$

para  $n$  grande.

C) Como  $X_n - X \xrightarrow{P} 0$  e  $Y_n - Y \xrightarrow{P} 0$ , temos pela parte A) que  $(X_n - X) \cdot (Y_n - Y) \xrightarrow{P} 0$ . Contudo  $X_n \cdot Y_n - X \cdot Y = (X_n - X) \cdot Y_n + X \cdot (Y_n - Y) \xrightarrow{P} 0$ ,  $X \cdot Y_n \xrightarrow{P} X \cdot Y$  e  $X_n \cdot Y \xrightarrow{P} X \cdot Y$  temos o resultado que  $X_n \cdot Y_n \xrightarrow{P} X \cdot Y$ .

1.4. **Exercícios.** 1) Seja  $X$  uma variável aleatória absolutamente contínua com função densidade de probabilidade

$$f(x) = \exp[-(x - \theta)], \quad \text{se } x \geq \theta \quad 0 \quad \text{se } x < \theta$$

e seja  $(X_n)_{n \geq 1}$  é uma sequência de variáveis aleatórias independentes e idênticas a  $X$ .

a) Qual o limite em probabilidade de

$$\min\{X_1, \dots, X_n\} - \theta?$$

b) Qual o limite quase certo de  $\min\{X_1, \dots, X_n\}$ ?

2) Seja  $X$  uma variável aleatória com função de distribuição absolutamente contínua  $F$  e seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e idênticas a  $X$ . Defina  $Y_n = n[1 - F(M_n)]$ , onde  $M_n = \max\{X_1, \dots, X_n\}$ .

a) Qual a função de distribuição  $G_n(y)$  de  $Y_n$ ?

b) Calcule  $\lim_{n \rightarrow \infty} G_n(y)$ .

3) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias tal que  $E[X_n]$  converge para a constante  $c$  e  $Var(X_n)$  converge para 0 quando  $n$  converge para  $\infty$ . Prove que  $(X_n)_{n \geq 1}$  converge em probabilidade para  $c$ .

4) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, \theta)$ . Prove que  $\max\{X_1, \dots, X_n\}$  converge em probabilidade para  $\theta$ .

5) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que  $P(X_n = 1) = \frac{1}{n}$  e  $P(X_n = 0) = 1 - \frac{1}{n}$ . Mostre que  $(X_n)_{n \geq 1}$  converge em probabilidade para 0 mas não converge quase certamente.

6) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que  $P(X_n = n^2) = \frac{1}{n^2}$  e  $P(X_n = 0) = 1 - \frac{1}{n^2}$ . Prove que  $(X_n)_{n \geq 1}$  converge quase certamente e ache o limite  $X$ . Mostre que  $E[X_n^k]$  não converge para  $E[X^k]$  para  $k = 1, 2, 3, \dots$

7) Verifique, nos casos abaixo, se a sequência de variáveis aleatórias  $(X_n)_{n \geq 1}$  converge. Em caso afirmativo, qual o tipo de convergência e qual a distribuição limite:

a)  $X_n = \log\left\{\frac{1}{1 - X + \frac{1}{\sqrt{n}}}\right\}$ , onde  $X \sim U(0, 1)$ .

b)  $X_n = \sum_{k=1}^n \left|\frac{1}{2} - X\right|^{k-1}$ , onde  $X \sim U(0, 2)$ .

c)  $X_n = Y_n \cdot Y_{n+1}$  onde  $(Y_n)_{n \geq 1}$  é uma sequência de variáveis aleatórias com  $P(Y_n = 1) = \frac{1}{n}$  e  $P(Y_n = 0) = 1 - \frac{1}{n}$ .



8) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com segundo momento finito. Defina

$$Y_n = \frac{2}{n(n+1)} \sum_{i=1}^n iX_i.$$

Calcule  $E[X_1]$  e use a desigualdade de Chebyshev para provar que  $Y_n \xrightarrow{P} E[X_1]$ .

9) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com segundo momento finito. Defina

$$Z_n = (\prod_{i=1}^n X_i)^{\frac{1}{n}}.$$

Prove que  $Z_n \xrightarrow{P} c$  e descubra o valor de  $c$ .

**1.5. Leis dos Grandes Números.** Consideremos a variável aleatória  $X$  que representa o valor numérico de um experimento aleatório e seja  $X_1, X_2, \dots, X_n$  uma amostra aleatória de  $X$ , isto é, cópias i.i.d. de  $X$ , de tamanho  $n$ , grande. A Lei dos Grandes Números afirma que a média aritmética dos  $n$  valores observados é aproximadamente igual à média de  $X$ ,  $\mu = E[X]$ , quando  $n$  é grande, isto é

$$\overline{X}_n(w) = \frac{\sum_{i=1}^n X_i(w)}{n} \xrightarrow{n \rightarrow \infty} \mu$$

onde  $w = (w_1, \dots, w_n)$ ,  $X_n(w) = X(w_n)$ ,  $w_n$  são os ensaios sucessivos e  $w$  é o experimento composto.

**Exemplo 1.36.** Considere que nas repetições independentes de um experimento estamos interessados nas ocorrências de um evento  $A$ . Definimos a sequência de variáveis aleatórias  $(X_n)_{n \geq 1}$

$$X_n = 1 \text{ se } A \text{ ocorreu na } n\text{-ésima realização; } X_n = 0 \text{ c.c.}$$

Desta maneira  $P(X_n = 1) = P(A)$ . Na  $n$ -ésima repetição do experimento calculamos a frequência relativa do evento  $A$ , isto é

$$F_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{q.c.} P(A) = E[X_n].$$

O exemplo justifica o conceito frequêntista de probabilidade.

Se a convergência é quase certa dizemos que a Lei é Forte, se a convergência é em probabilidade dizemos que a Lei é Fraca. Claramente, a Lei Forte implica a Lei Fraca dos Grandes Números.

### A Lei Fraca dos Grandes Números

Para provarmos a Lei Fraca dos Grandes Números usaremos a Desigualdade de Markov:

**Lema 1.37.** *Seja  $X$  uma variável aleatória. Para todo  $\varepsilon$  e  $r$ , números reais positivos com  $E[|X|^r] < \infty$ , temos*

$$P(|X| \geq \varepsilon) \leq \frac{E[|X|^r]}{\varepsilon^r}.$$

**Prova:**

$$\begin{aligned} E[|X|^r] &= \int_{-\infty}^{\infty} |x|^r dF(x) = \int_{\{|X| > \varepsilon\}} |x|^r dF(x) + \int_{\{|X| \leq \varepsilon\}} |x|^r dF(x) \geq \\ &\int_{\{|X| > \varepsilon\}} |x|^r dF(x) \geq \varepsilon^r \int_{\{|X| > \varepsilon\}} dF(x) = \varepsilon^r P(|X| \geq \varepsilon). \end{aligned}$$

**Corolário 1.38.** *Desigualdade de Tchebyshev.* Se  $X$  uma variável aleatória com média  $E[X] = \mu$  e variância  $\sigma^2 < \infty$ ,  $\forall \varepsilon > 0$  temos

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

**Prova:** Segue da desigualdade de Markov

**Teorema 1.39.** *Lei Fraca dos Grandes Números de Tchebyshev*

Se  $(X_n)_{n \geq 1}$  é uma sequência de variáveis aleatórias independentes com médias  $\mu$  e variâncias  $\sigma^2 < \infty$ , comuns, então

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{P} \mu.$$

**Prova:** Segue da desigualdade de Tchebyshev, desde que  $E[\frac{\sum_{i=1}^n X_i}{n}] = \mu$  e  $Var(\frac{\sum_{i=1}^n X_i}{n}) = \frac{\sigma^2}{n}$ .

**Teorema 1.40.** *Lei Fraca dos Grandes Números para variáveis aleatórias não correlacionadas.*

Se  $(X_n)_{n \geq 1}$  é uma sequência de variáveis aleatórias não correlacionadas, isto é,  $cov(X_i, X_j) = 0, \forall i, j$ , com médias  $\mu$  e variâncias  $\sigma^2 < \infty$ , comuns, então

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{P} \mu.$$

**Prova:**

Sabemos que  $E[\frac{\sum_{i=1}^n X_i}{n}] = \mu$ .

$$Var(\overline{X}_n) = E[(\overline{X}_n - \mu)^2] = E[(\frac{\sum_{i=1}^n X_i}{n} - \mu)^2] = E[(\frac{\sum_{i=1}^n X_i - n\mu}{n})^2] =$$

$$\frac{1}{n^2} E[(\sum_{i=1}^n X_i - n\mu)^2] = \frac{1}{n^2} E\{[\sum_{i=1}^n (X_i - \mu)] \cdot [\sum_{j=1}^n (X_j - \mu)]\} =$$

$$\frac{1}{n^2} E[\sum_{i=1}^n (X_i - \mu)^2 + \sum_{i < j} (X_i - \mu) \cdot (X_j - \mu)] = \frac{1}{n^2} \{ \sum_{i=1}^n E[(X_i - \mu)^2] +$$

$$\sum_{i < j} E[(X_i - \mu) \cdot (X_j - \mu)] \} = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 + 0 = \frac{\sigma^2}{n}.$$

Assim, pela Desigualdade de Tchebyshev

$$P(|\overline{X}_n - \mu| > \varepsilon) = P((\overline{X}_n - \mu)^2 > \varepsilon^2) \leq \frac{E[(\overline{X}_n - \mu)^2]}{\varepsilon^2} = \frac{\sigma^2}{n\varepsilon^2} \rightarrow 0$$

quando  $n \rightarrow \infty$ .

Na realidade, somente é necessário que os  $X_i$ 's sejam não correlacionados assintoticamente no sentido:  $\lim_{|i-j| \rightarrow \infty} \text{cov}(X_i, X_j) = 0$ .

**Teorema 1.41.** *Lei Fraca dos Grandes Números para variáveis aleatórias assintoticamente não correlacionadas.*

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias assintoticamente não correlacionadas, com média comum  $\mu$  e variâncias  $\text{Var}(X_i) = \sigma_i^2 < c$ , uniformemente limitadas por uma constante  $c$ . Então

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{P} \mu.$$

**Prova:** Pela desigualdade de Tchebyshev temos

$$P(|\overline{X}_n - \mu| > \varepsilon) \leq \frac{\text{Var}(\overline{X}_n)}{\varepsilon^2}, \forall \varepsilon > 0.$$

Portanto é suficiente provar que  $\lim_{n \rightarrow \infty} \text{Var}(\overline{X}_n) = 0$ .

Pela desigualdade de Schwarz temos que  $\forall i, j$ ,

$$\begin{aligned} |\text{cov}(X_i, X_j)| &= |E[(X_i - \mu) \cdot (X_j - \mu)]| \leq \\ &\sqrt{E[(X_i - \mu)^2] \cdot E[(X_j - \mu)^2]} = \sigma_i \sigma_j \leq c. \end{aligned}$$

Como  $\lim_{|i-j| \rightarrow \infty} \text{cov}(X_i, X_j) = 0$  temos que

$$\forall \delta > 0, \exists m \in \mathbb{N} \mid \text{se } |i - j| > m \rightarrow |\text{cov}(X_i, X_j)| < \frac{\delta}{2}.$$

Sabemos que

$$\begin{aligned} \text{Var}(\overline{X}_n) &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_i, X_j) \leq \\ &\frac{1}{n^2} \left[ \sum_{|i-j| \leq m} nc + \sum_{|i-j| > m} |\text{cov}(X_i, X_j)| \right] \leq \\ &\frac{n \cdot m \cdot c}{n^2} + \frac{n(n-m)\delta}{2n^2} \leq \delta, \text{ para } n \geq \frac{2mc}{\delta}. \end{aligned}$$

**Teorema 1.42.** *Lei Fraca dos Grandes Números de Khintchin, para variáveis aleatórias independentes e identicamente distribuídas com média finita.*

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. com  $E[X_1] = \mu < \infty$ . Então

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{P} \mu.$$

**Prova:**

Devemos provar que  $\forall \varepsilon > 0$  e  $\forall \delta > 0$ ,  $P(|\overline{X}_n - \mu| > \varepsilon) \leq \delta$ .

Sejam  $\gamma = E[|X|]$  e  $\alpha = \frac{\delta \cdot \varepsilon^2}{12 \cdot \gamma}$ . Defina a sequência de variáveis aleatórias  $(Y_n)_{n \geq 1}$

$$Y_n = X_n \text{ se } -\alpha \cdot n \leq X_n \leq \alpha \cdot n \text{ e } 0 \text{ c.c.}$$

Então os  $Y_n$ 's são independentes com médias  $\mu_n = \int_{-\alpha \cdot n}^{\alpha \cdot n} y dF(y)$  e variância  $\sigma_n^2 = \int_{-\alpha \cdot n}^{\alpha \cdot n} y^2 dF(y) - \mu_n^2$ .

Claramente, se  $n \rightarrow \infty$ ,  $\alpha \cdot n \rightarrow \infty$  e  $\mu_n \rightarrow \mu$ , isto é

$$\exists n_0 \mid \forall n \geq n_0, \rightarrow |\mu_n - \mu| \leq \frac{\varepsilon}{2}.$$

Portanto

$$P(|\bar{X}_n - \mu| > \varepsilon) = P(|\bar{X}_n - \mu_n + \mu_n - \mu| > \varepsilon) \leq P(|\mu_n - \mu| > \frac{\varepsilon}{2}) +$$

$$P(|\bar{X}_n - \mu_n| > \frac{\varepsilon}{2}) \leq P(|\bar{X}_n - \mu_n| > \frac{\varepsilon}{2}) \leq$$

$$P(|\bar{X}_n - \mu_n| > \frac{\varepsilon}{2}, \bar{X}_n = \bar{Y}_n) + P(|\bar{X}_n - \mu_n| > \frac{\varepsilon}{2}, \bar{X}_n \neq \bar{Y}_n) \leq$$

$$P(|\bar{Y}_n - \mu_n| > \frac{\varepsilon}{2}) + P(\bar{X}_n \neq \bar{Y}_n).$$

Note que

$$\sigma_n^2 \leq \int_{-\alpha \cdot n}^{\alpha \cdot n} y^2 dF(y) \leq \alpha \cdot n \int_{-\alpha \cdot n}^{\alpha \cdot n} |y| dF(y) \leq \alpha \cdot n \cdot \gamma$$

e pela desigualdade de Tchebyshev temos

$$P(|\bar{Y}_n - \mu_n| > \frac{\varepsilon}{2}) \leq \frac{4\sigma_n^2}{n\varepsilon^2} = \frac{4\alpha \cdot \gamma}{\varepsilon^2} = \frac{\delta}{3}, \text{ para } \alpha = \frac{\delta \cdot \varepsilon^2}{12 \cdot \gamma}.$$

Em adição temos

$$P(\bar{X}_n \neq \bar{Y}_n) = \sum_{k=1}^n P(X_k \neq Y_k) = n \cdot P(|X_1| \geq n \cdot \alpha)$$

$$\leq n \int_{|X| > \alpha \cdot n} dF(x) \leq \alpha^{-1} \int_{|X| > \alpha \cdot n} |x| dF(x) \rightarrow 0$$

quando  $n \rightarrow \infty$ .

Assim  $\exists n_1 \mid P(\bar{X}_n \neq \bar{Y}_n) \leq \frac{\delta}{3}$ , se  $n \geq n_1$ .

Tomando  $n \geq \max\{n_0, n_1\}$ , temos  $P(|\bar{X}_n - \mu| > \varepsilon) \leq \delta$ .

## A Lei Forte dos Grandes Números

**Teorema 1.43.** *Lei Forte dos Grandes Números para variáveis aleatórias independente e identicamente distribuídas com média finita e existência do quarto momento central.*

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. com  $E[|X_1|] = \mu < \infty$  e  $E[(X - \mu)^4] = \gamma < \infty$ . Então

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{qc} \mu.$$

**Prova:**

Observe que

$$\begin{aligned} E[(\overline{X}_n - \mu)^4] &= E\left[\frac{1}{n^4} \left(\sum_{i=1}^n X_i - n \cdot \mu\right)^4\right] = E\left[\frac{1}{n^4} \left(\sum_{i=1}^n (X_i - \mu)\right)^4\right] = \\ &= \frac{1}{n^4} E\left\{ \sum_{i=1}^n (X_i - \mu)^4 + \sum_{i < j} (X_i - \mu)^3 \cdot (X_j - \mu) \right. \\ &+ \sum_{i < j} (X_i - \mu)^2 \cdot (X_j - \mu)^2 + \sum_{i < j < k} (X_i - \mu)^2 \cdot (X_j - \mu) \cdot (X_k - \mu) \\ &+ \left. \sum_{i < j < k < l} (X_i - \mu) \cdot (X_j - \mu) \cdot (X_k - \mu) \cdot (X_l - \mu) \right\} = \\ &= \frac{1}{n^4} \left\{ \sum_{i=1}^n \gamma + \sum_{i < j} 0 + \sum_{i < j} \sigma^2 \sigma^2 + \sum_{i < j < k} 0 + \sum_{i < j < k < l} 0 \right\} = \\ &= \frac{1}{n^4} \{n\gamma + n \cdot (n-1)\sigma^4\} = \frac{\gamma}{n^3} + \frac{(n-1)\sigma^4}{n^3} \leq \frac{\gamma}{n^3} + \frac{\sigma^4}{n^2}. \end{aligned}$$

Portanto, pela desigualdade de Markov temos

$$P(|\overline{X}_n - \mu| > \varepsilon) = P((\overline{X}_n - \mu)^4 > \varepsilon^4) \leq \frac{E[(X - \mu)^4]}{\varepsilon^4} \leq \frac{\gamma}{\varepsilon^4 n^3} + \frac{\sigma^4}{\varepsilon^4 n^2}$$

e

$$\sum_{n=1}^{\infty} P(|\overline{X}_n - \mu| > \varepsilon) \leq \sum_{n=1}^{\infty} \left( \frac{\gamma}{\varepsilon^4 n^3} + \frac{\sigma^4}{\varepsilon^4 n^2} \right) < \infty.$$

Pelo Lema de Borel Cantelli concluímos que

$$\overline{X}_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow{qc} \mu.$$

*Observação 1.44.* Observe que

$$(X - \mu)^4 = X^4 - 4 \cdot X^3 \cdot \mu + 6 \cdot X^2 \cdot \mu^2 - 4 \cdot X \cdot \mu^3 + \mu^4$$

e

$$E[(X - \mu)^4] = E[X^4] - 4 \cdot \mu \cdot E[X^3] + 6 \cdot \mu^2 \cdot E[X^2] - 4 \cdot \mu^3 \cdot E[X] + \mu^4.$$

**Exemplo 1.45.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. a  $X$ . Se  $X$  é uma variável aleatória de Bernoulli com parâmetro  $p, 0 < p < 1$ , então  $E[X^k] = p, \forall k$  e

$$E[(X - \mu)^4] = p - 4p^2 + 6p^3 - 4p^4 + p^4 < \infty$$

e  $\overline{X_n} \xrightarrow{qc} p$ .

**Exemplo 1.46.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. a  $X$ . Se  $X$  é uma variável aleatória com distribuição uniforme no intervalo  $(0, 1)$ , então

$$E[X^k] = \int_0^1 x^k dx = \frac{1}{k+1}$$

e

$$E[(X - 0,5)^4] = E[X^4] - 4 \cdot 0,5 \cdot E[X^3] + 6 \cdot 0,25 \cdot E[X^2] - 4 \cdot 0,125 \cdot E[X] + 0,0625 =$$

$$0,2 - 0,5 + 0,5 - 0,25 + 0,0625 = 0,0125 < \infty$$

e  $\overline{X_n} \xrightarrow{qc} 0,5$ .

**Exemplo 1.47.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. a  $X$ . Se  $X$  é uma variável aleatória com distribuição exponencial e parâmetro  $\lambda$  então

$$E[X^k] = \frac{k!}{\lambda^k} \int_0^\infty \frac{x^k \lambda^{k+1} e^{-\lambda x}}{k!} dx = \frac{k!}{\lambda^k}.$$

e

$$E[(X - \frac{1}{\lambda})^4] = \frac{4!}{\lambda^4} - 4 \cdot \frac{1}{\lambda} \cdot \frac{3!}{\lambda^3} + 6 \cdot (\frac{1}{\lambda})^2 \cdot \frac{2!}{\lambda^2} - 4 \cdot (\frac{1}{\lambda})^3 \cdot \frac{1}{\lambda} + (\frac{1}{\lambda})^4 = \frac{9}{\lambda^4} = \frac{9}{\lambda^4} < \infty$$

e  $\overline{X_n} \xrightarrow{qc} \frac{1}{\lambda}$ .

**Exemplo 1.48.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. a  $X$ . Se  $X$  é uma variável aleatória com distribuição normal de média  $\mu$  e variância  $\sigma^2$ , então  $E[(X - \mu)^{2n+1}] = 0$  e  $E[(X - \mu)^{2n}] = \sigma^{2n} \cdot [(2n-1) \cdot (2n-3) \cdot \dots \cdot 3 \cdot 1]$ . Assim  $E[(X - \mu)^4] = 3 \cdot \sigma^4$  e  $\overline{X_n} \xrightarrow{qc} \mu$ .

**Exemplo 1.49.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. a  $X$ , com  $E[(X - \mu)^4] = \gamma < \infty$  e  $E[(X - \mu)^2] = \sigma^2$ . Então

$$S_n^2 = \frac{\sum_{i=1}^n (X_i - \overline{X_n})^2}{n-1} \xrightarrow{qc} \sigma^2.$$

Note que  $S_n^2 = \frac{1}{n-1} (\sum_{i=1}^n X_i^2 - n \overline{X_n}^2)$ .

Por outro lado, pela Lei forte dos grandes números,

$$\frac{1}{n-1} \sum_{i=1}^n X_i^2 = \frac{n}{n-1} \frac{\sum_{i=1}^n X_i^2}{n} \xrightarrow{qc} 1 \cdot E[X^2] = \sigma^2 + \mu^2$$

e

$$\frac{n}{n-1} \overline{X_n^2} \xrightarrow{qc} 1 \cdot \mu^2 = \mu^2$$

pois  $x^2$  é uma função contínua de  $x$ .

Recordemos P.2 - Se  $X_n \xrightarrow{qc} X$  e  $Y_n \xrightarrow{qc} Y$ , Então

$$X_n \pm Y_n \xrightarrow{qc} X \pm Y.$$

Portanto

$$S_n^2 = \frac{1}{n-1} (\sum_{i=1}^n X_i^2 - n \overline{X_n^2}) \xrightarrow{qc} (\sigma^2 + \mu^2) - \mu^2 = \sigma^2.$$

Em termos estatísticos estamos provando que  $S_n^2$  é um estimador consistente para  $\sigma^2$ , pois a convergência quase certa implica a convergência em probabilidade.

No que segue as Leis Fortes de Kolmogorov são enunciadas. O leitor encontrará as provas respectivas provas no livro Probabilidade: um curso em nível intermediário; Barry, R. James.

**Teorema 1.50.** *Primeira Lei Forte de Kolmogorov.*

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e integráveis e suponha que

$$\sum_{n=1}^{\infty} \frac{Var(X_n)}{n^2} < \infty.$$

Então

$$\frac{X_1 + \dots + X_n}{n} - \frac{E[X_1] + \dots + E[X_n]}{n} \xrightarrow{qc} 0$$

**Teorema 1.51.** *A Lei Forte de Kolmogorov.*

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes, identicamente distribuídas e integráveis com  $E[X_n] = \mu$ . Então

$$\frac{X_1 + \dots + X_n}{n} \xrightarrow{qc} \mu.$$

**Exemplo 1.52.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. com função densidade de probabilidade

$$f(x) = e^{-x+\theta} \text{ se } x \geq \theta \text{ e } 0 \text{ c.c.}$$

Prove que  $\frac{X_1 + \dots + X_n}{n} \xrightarrow{P} 1 + \theta$ .

Observe que

$$E[X] = \int_{\theta}^{\infty} x e^{-(x-\theta)} dx = \int_0^{\infty} (y + \theta) e^{-y} dy = 1 + \theta.$$

Pela Lei Fraca dos Grandes números concluímos o exercício.



**Exemplo 1.53.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d. com distribuição uniforme no intervalo  $(0, 1)$ . seja  $Z_n = (\prod_{i=1}^n X_i)^{\frac{1}{n}}$ , a média geométrica de  $X_1, \dots, X_n, 1 \leq n < \infty$ . Mostre que  $Z_n \rightarrow k$ . Qual o valor de  $k$ ?

Observe que  $-\ln Z_n = -\ln[(\prod_{i=1}^n X_i)^{\frac{1}{n}}] = \frac{\sum_{i=1}^n -\ln X_i}{n}$  e que  $-\ln X_i$  tem distribuição exponencial padrão. Portanto, pela Lei Fraca dos Grandes Números,  $-\ln Z_n \xrightarrow{P} 1$ .

Como a função exponencial, a inversa da função logaritmo neperiano, é contínua, concluímos que  $Z_n \xrightarrow{P} e$ .

**Exemplo 1.54.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d., com  $E[X_1] = Var(X_1) = 1$ , então

$$\frac{\sum_{i=1}^n X_i}{\sqrt{n \cdot \sum_{i=1}^n X_i^2}} \xrightarrow{qc} \frac{1}{\sqrt{2}}.$$

Observe que

$$\frac{\sum_{i=1}^n X_i}{\sqrt{n \cdot \sum_{i=1}^n X_i^2}} = \frac{\frac{\sum_{i=1}^n X_i}{n}}{\sqrt{\frac{n \cdot \sum_{i=1}^n X_i^2}{n^2}}}.$$

Pela Lei Forte dos Grandes Números temos  $\frac{\sum_{i=1}^n X_i}{n} \xrightarrow{qc} 1$  e  $\frac{\sum_{i=1}^n X_i^2}{n} \xrightarrow{qc} 2$ .

A convergência quase certa é fechada por quocientes (quando possível) e a raiz quadrada é função contínua.

**Exemplo 1.55.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias i.i.d., com distribuição normal com média  $\mu$  e variância  $\sigma^2$ . Qual o limite quase certo de

$$\sqrt{\frac{n \sum_{i=1}^n (X_i - \bar{X}_n)^2}{(\sum_{i=1}^n X_i)^2}}$$

1.6. **Exercícios.** 1) Arredonda-se vinte números para o inteiro mais próximo e soma-se os números resultantes. Suponha que os erros individuais de arredondamento são independentes e se distribuem uniformemente no intervalo  $(-\frac{1}{2}, \frac{1}{2})$ . Determine a probabilidade de que a soma obtida difira da soma dos vinte números originais por mais de 3.

2) Lança-se uma moeda equilibrada até observar 100 caras. Determine a probabilidade de que sejam necessários, no mínimo, 226 lançamentos.

3) Se  $X$  uma variável aleatória com distribuição de Cauchy padrão, defina

$$X_n = \sum_{k=1}^n \left( \frac{|X|}{1 + |X|} \right)^k, \quad n \geq 1.$$

Calcule, se existir,  $\lim_{n \rightarrow \infty} E[X_n]$ .

4) Seja  $X_n$  uma variável aleatória com função densidade de probabilidade

$$f_n(x) = \frac{n}{4(n-1)} 1_{(-1, \frac{-1}{n})}(x) + \frac{3n}{4(n-1)} 1_{(\frac{1}{n}, 1)}(x).$$

a) Obtenha a função característica de  $X_n$ ,  $\psi_n(t)$ .

b) Calcule  $\lim \psi_n(t)$ . O limite é uma função característica? Justifique.

5) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas. Qual o limite em distribuição de

$$\sqrt{n} \left( \frac{\bar{X}_n - \mu}{S_n} \right),$$

onde  $\bar{X}_n = \frac{\sum_{k=1}^n X_k}{n}$  e  $S_n^2 = \frac{\sum_{k=1}^n (X_k - \bar{X}_n)^2}{n}$ .

6) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que  $X_n$  tem distribuição de Poisson de parâmetro  $\sqrt{n}$ . Verifique se  $\frac{\sum_{k=1}^n X_k}{n}$  converge quase certamente.

7) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, 1)$ . Calcule o limite em probabilidade de  $\frac{\sum_{k=1}^n -\log X_k}{n}$ .

### 1.7. Convergência em distribuição e propriedades.

**Exemplo 1.56.** Uma variável aleatória  $Y$  é definida como degenerada se  $Y = \theta$  com probabilidade 1 ( $\theta$ : número real)

A sua função de distribuição é

$$F_Y(y) = \begin{cases} 0 & \text{se } y < \theta \\ 1 & \text{se } y \geq \theta \end{cases}$$

**Exemplo 1.57.** Sejam  $X_1, X_2, \dots$  iid com distribuição uniforme no intervalo  $(0, \theta)$

, isto é,  $X_1 \sim U(0, \theta)$  e defina  $(Y_n)_{n \geq 1}$  por

$Y_n = \max \{X_1, X_2, \dots\}$ . Portanto

$$F_{Y_n}(y) = P(Y_n \leq y) = P(X_1 \leq y)^n = \begin{cases} 0 & \text{se } y < 0 \\ \left(\frac{y}{\theta}\right)^n & \text{se } 0 \leq y < \theta \\ 1 & \text{se } y \geq \theta \end{cases}$$

e

$$\lim_{n \rightarrow \infty} F_{Y_n}(y) = \begin{cases} 0 & \text{se } y < \theta \\ 1 & \text{se } y \geq \theta \end{cases} = F_Y(y).$$

que é uma função de distribuição

**Exemplo 1.58.** Seja  $(Y_n)_{n \geq 1}$  uma sequência de variáveis aleatórias tais que  $P(Y_n = n) = 1$

$$F_{Y_n}(y) = \begin{cases} 0 & \text{se } y < n \\ 1 & \text{se } y \geq n \end{cases}$$

$\lim_{n \rightarrow \infty} F_{Y_n}(y) = 0$ , que não é uma função de distribuição.

**Exemplo 1.59.** Sejam  $(X_n)_{n \geq 1}$  tais que  $P(X_n = \frac{1}{n}) = 1$

Observe que  $X_n \xrightarrow{qc} 0$  e  $X_n \xrightarrow{P} 0$ . A função de distribuição de  $X_n$  é

$$F_{X_n}(x) = \begin{cases} 0 & \text{se } x < \frac{1}{n} \\ 1 & \text{se } x \geq \frac{1}{n} \end{cases}$$

e

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases} \quad \text{que não é função de distribuição}$$

contudo

$$F_X(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad \text{é função de distribuição.}$$

Tais considerações motivam a seguinte definição

**Definição 1.60.** Seja  $(F_n)_{n \geq 1}$  uma sequência de funções de distribuições e  $F$  uma função de distribuição tal que, para todo número real  $x$  em que  $F$  é contínua em  $x$ , temos

$$\lim_{n \rightarrow \infty} F_n(x) = F(x).$$

Então dizemos que  $(F_n)_{n \geq 1}$  converge em distribuição para  $F$ .  $F_n \rightarrow^D F$ .

Se  $X_n$  é v.a. com função de distribuição  $F_n$  e  $X$  é v.a. com função de distribuição  $F$  e  $F_n \rightarrow^D F$ , dizemos também que  $X_n \rightarrow^D X$ .

**Teorema 1.61.** *Seja  $(X_n)_{n \geq 1}$  sequência de v.a.(s) com funções de distribuições absolutamente contínuas com funções de densidade de probabilidade  $f_n(x)$ .*

*Seja  $X$  v.a. com função de distribuição absolutamente contínua com função de densidade  $f(x)$ .*

$$\text{Se } \lim_{n \rightarrow \infty} f_n(x) = f(x),$$

então

$$F_n \rightarrow^D F.$$

**Prova:** *Primeiramente lembramos que se  $f_n(x)$  é uniformemente contínua, então  $\int \lim_{n \rightarrow \infty} f_n(x) dx = \lim_{n \rightarrow \infty} \int f_n(x) dx$ .*

*Sejam  $F_n(y)$  e  $F(y)$  as funções de distribuições de  $X_n$  e  $X$ , respectivamente. Então*

$$\begin{aligned} \lim_{n \rightarrow \infty} F_n(y) &= \lim_{n \rightarrow \infty} \int_{-\infty}^y f_n(x) dx = \lim_{n \rightarrow \infty} \lim_{a \rightarrow -\infty} \int_a^y f_n(x) dx = \\ & \lim_{a \rightarrow -\infty} \int_a^y \lim_{n \rightarrow \infty} f_n(x) dx = \lim_{a \rightarrow -\infty} \int_a^y f(x) dx = \int_{-\infty}^y f(x) dx = F(y). \end{aligned}$$

**Exemplo 1.62.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias com  $X_n \sim U(0, 1 - \frac{1}{n})$

$$f_n(x) = \begin{cases} \frac{1}{1-1/n} & \text{se } 0 < x < 1 - \frac{1}{n} \\ 0 & \text{cc} \end{cases}$$

$$\lim_{n \rightarrow \infty} f_n(x) = \begin{cases} 1 & \text{se } 0 < x < 1 \\ 0 & \text{cc} \end{cases}$$

é a função densidade de uma v.a. com distribuição uniforme no intervalo  $(0, 1)$ . Assim  $F_n \rightarrow^D F$  e  $X \sim U(0, 1)$ .

**Teorema 1.63.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de v.a.(s) discretas que assumem valores no conjunto dos números naturais*

$$P(X_n = k) = p_n(k), \quad k = 0, 1, \dots$$

e seja  $X$  uma v.a. que também assume valores em  $\mathbb{N}$

$$\text{com } P(X = k) = p(k), \quad k = 0, 1, \dots$$

Então  $\lim_{n \rightarrow \infty} p_n(k) = p(k)$  se e só se  $F_n \rightarrow^D F$ .

**Prova:** Observe que a função de distribuição de  $X_n$  é  $F_n(y) = \sum_{k \leq [y]} p_n(k)$  e a função de distribuição de  $X$  é  $F(y) = \sum_{k \leq [y]} p(k)$ . Portanto

$$\lim_{n \rightarrow \infty} F_n(y) = \lim_{n \rightarrow \infty} \sum_{k \leq [y]} p_n(k) =$$

$$\sum_{k \leq [y]} \lim_{n \rightarrow \infty} p_n(k) = \sum_{k \leq [y]} p(k) = F(y).$$

e a condição é necessária. (A segunda igualdade acima é devido ao teorema da convergência dominada).

Por outro lado, a condição é suficiente pois:

$$\lim_{n \rightarrow \infty} p_n(k) = \lim_{n \rightarrow \infty} (F_n(k) - F_n(k^-)) = F(k) - F(k^-) = p(k).$$

*Observação 1.64.* Se os valores de  $X_n$  não forem isolados o teorema pode não valer: Sejam  $(X_n)_{n \geq 1}$  uma sequência de v.a.(s) discretas com  $P(X_n = \frac{1}{n}) = 1$  e  $X$  uma variável aleatória com  $P(X = 0) = 1$ . A função de distribuição de  $X_n$  é

$$F_{X_n}(x) = \begin{cases} 0 & \text{se } x < \frac{1}{n} \\ 1 & \text{se } x \geq \frac{1}{n} \end{cases}$$

e a função de distribuição de  $X$  é

$$F_X(x) = \begin{cases} 0 & \text{se } x < 0 \\ 1 & \text{se } x \geq 0 \end{cases}$$

de maneira que  $X_n \rightarrow^D X$ . Mas  $P_n(0) = 0$  e  $p(0) = 1$  de maneira que  $p_n(k) \not\rightarrow p(k)$ .

**Exemplo 1.65.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias tais que  $X_n : 1, 2, 3, \dots, n$  com

$$P(X_n = k) = \frac{a}{2^k}$$

O valor de  $a$  é definido por:

$$1 = \sum_{k=1}^n P(X_n = k) = \sum_{k=1}^n \frac{a}{2^k} = a \frac{1 - \frac{1}{2^n}}{1 - \frac{1}{2}} = a \left(1 - \frac{1}{2^n}\right) \therefore a = \frac{1}{1 - \frac{1}{2^n}}$$

Portanto

$$P(X_n = k) = \frac{1}{1 - \frac{1}{2^n}} \frac{1}{2^k}$$

e

$$\lim_{n \rightarrow \infty} P(X_n = k) = \frac{1}{2^k} \quad k \in \mathbb{N}$$

Observe que  $X : 1, 2, \dots$ , isto é, o suporte de  $X$  é  $\mathbb{N}$ ,

$$P(X = k) = \frac{1}{2^k} \Rightarrow \sum_{k=1}^{+\infty} P(X = k) = \sum_{k=1}^{+\infty} \frac{1}{2^k} = \frac{1}{1 - \frac{1}{2}} = 1 \quad e \quad X_n \rightarrow^D X.$$

**Teorema 1.66.** *Sejam  $(X_n)_{n \geq 1}$  uma seqüência de variáveis aleatórias e  $X$  uma variável aleatória. Se  $X_n \rightarrow^P X$  então  $X_n \rightarrow^D X$ .*

**Prova:**

$F_n$  : função de distribuição de  $X_n$

$F$  : função de distribuição de  $X$

$x$  : ponto de continuidade de  $F$

$\{X \leq X_n + \epsilon\}$  ou  $\{X > X_n + \epsilon\}$  é verdade.

Em  $\{X_n \leq x\}$  temos  $\{X \leq x + \epsilon\}$  ou  $\{X - X_n > \epsilon\}$

$$\{X_n \leq x\} \subset \{X \leq x + \epsilon\} \text{ ou } \{|X - X_n| > \epsilon\}$$

$$P(X_n \leq x) \leq P\{X \leq x + \epsilon\} + P\{|X - X_n| > \epsilon\}$$

$$F_n(x) \leq F(x + \epsilon) + P\{|X - X_n| > \epsilon\}. \quad (1)$$

Com argumento semelhante

$\{X_n \leq X + \epsilon\}$  ou  $\{X_n > X + \epsilon\}$  é verdade.

Em  $\{X \leq x - \epsilon\}$  temos  $\{X_n \leq x\}$  ou  $\{X_n - X > \epsilon\}$

$$\{X \leq x - \epsilon\} \subset \{X_n \leq x\} \cup \{|X_n - X| > \epsilon\}$$

$$P\{X \leq x - \epsilon\} \leq P\{X_n \leq x\} + P\{|X_n - X| > \epsilon\}$$

$$F(x - \epsilon) \leq F_n(x) + P\{|X_n - X| > \epsilon\}. \quad (2)$$

Combinando (1) e (2) temos

$$F(x - \epsilon) - P\{|X_n - X| > \epsilon\} \leq F_n(x) \leq F(x + \epsilon) + P\{|X_n - X| > \epsilon\}$$

fazendo  $n \rightarrow \infty$

$$F(x - \epsilon) \leq \liminf F_n(x) \leq \limsup F_n(x) \leq F(x + \epsilon)$$

como  $x$  é ponto de continuidade, fazendo  $\epsilon \rightarrow 0$

$$F(x) \leq \lim F_n(x) \leq F(x).$$

**Exemplo 1.67.** Sejam  $X_1, X_2, \dots$  variáveis aleatórias identicamente distribuídas como  $X$ , em que

$X / X_n$	0	1	
0	0	$\frac{1}{2}$	$\frac{1}{2}$
1	$\frac{1}{2}$	0	$\frac{1}{2}$
	$\frac{1}{2}$	$\frac{1}{2}$	

Assim  $X_n \rightarrow^D X$  pois  $X_n$  e  $X$  tem mesma função de distribuição.  
Contudo ( $\epsilon < 1$ ),

$$\begin{aligned} P\{|X_n - X| > \epsilon\} &= P\{|X_n - X| = 1\} \\ &= P\{X_n = 0 \text{ e } X = 1\} + P\{X_n = 1 \text{ e } X = 0\} = \frac{1}{2} + \frac{1}{2} = 1 \neq 0 \\ &\therefore X_n \not\rightarrow^P X \end{aligned}$$

Assim convergência em distribuição não implica convergência em probabilidade.

Contudo temos o teorema

**Teorema 1.68.** Sejam  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias e  $k$  uma constante. Se  $X_n \rightarrow^D k$  então  $X_n \rightarrow^P k$ .

**Prova:**

$$(hipótese) \lim_{n \rightarrow \infty} F_n(x) = \begin{cases} 1 & \text{se } x \geq k \\ 0 & \text{se } x < k \end{cases}$$

Contudo ( $\epsilon < 1$ ),

$$\begin{aligned} P\{|X_n - k| \leq \epsilon\} &= P\{k - \epsilon \leq X_n \leq k + \epsilon\} \geq \\ &= P\{k - \epsilon < X_n \leq k + \epsilon\} = F_n(k + \epsilon) - F_n(k - \epsilon). \end{aligned}$$

Assim

$$\begin{aligned} \lim_{n \rightarrow \infty} P\{|X_n - k| \leq \epsilon\} &\geq \\ \lim_{n \rightarrow \infty} F_n(k + \epsilon) - \lim_{n \rightarrow \infty} F_n(k - \epsilon) &= 1 - 0 = 1. \end{aligned}$$

**Teorema 1.69. Teorema de Slutsky**

Sejam  $(X_n)_{n \geq 1}$  e  $(Y_n)_{n \geq 1}$ ,  $X$ , v.a.(s) tais que  $X_n \rightarrow^D X$ ,  $Y_n \rightarrow^P k$  então:

- (1)  $X_n \pm Y_n \rightarrow^D X \pm k$
- (2)  $X_n Y_n \rightarrow^D kX$
- (3) Se  $k \neq 0$  e  $P(Y_n \neq 0) = 1$

$$\frac{X_n}{Y_n} \rightarrow^D \frac{X}{k}$$

**Exemplo 1.70.** Seja  $(Z_n)_{n \geq 1}$  sequência de v.a.(s) tais que

$$P(Z_n = n) = \frac{1}{n} \qquad P(Z_n = 0) = 1 - \frac{1}{n}$$

Será que  $Z_n$  converge em distribuição ?

**Exemplo 1.71.** Seja  $(X_n)_{n \geq 1}$  iid com distribuição  $U(0, 1)$ . Seja  $Y_n = n \min\{X_1, \dots, X_n\}$ . Qual o limite em distribuição de  $Y_n$ ?

**Exemplo 1.72.** Qual o limite em distribuição de  $Z_n + Y_n$  onde  $Z_n$  e  $Y_n$  são como acima?

**Exemplo 1.73.**  $X_1, X_2, \dots$ , v.a.(s) com funções de distribuição dadas por

$$F_n(x) = \begin{cases} 0 & \text{se } x < -n \\ \frac{x+n}{2n} & \text{se } -n \leq x < n \\ 1 & \text{se } x \geq n \end{cases}$$

$X_n \xrightarrow{D} ?$

$$\lim_{n \rightarrow \infty} F_n(x) = \lim_{n \rightarrow \infty} \frac{x+n}{2n} = \lim_{n \rightarrow \infty} \left( \frac{x}{2n} + \frac{n}{2n} \right) = \frac{1}{2} \quad \forall x \in \mathbb{R}$$



consequentemente não é função de distribuição e  $X_n$  não converge em distribuição.

**Exemplo 1.74.** Sejam  $X_1, X_2, \dots$ , v.a.(s) iid  $N(0, 1)$  e  $Y_n = \bar{X}_n = \sum_{i=1}^n X_i/n$ .  $Y_n \rightarrow^D?$

**Exemplo 1.75.** Sejam  $X_1, X_2, \dots$ , v.a.(s) iid  $N(0, 1)$

$$U_n = \left\{ \frac{X_1}{X_2} + \frac{X_3}{X_4} + \dots, + \frac{X_{2n-1}}{X_{2n}} \right\} \text{ (para todo } n \text{ par) e } V_n = X_1^2 + X_2^2 + \dots + X_n^2.$$

Defina  $Z_n = \frac{U_n}{V_n}$ .  $Z_n$  converge em distribuição?

Obs:  $\frac{X_1}{X_2}$  tem distribuição de *Cauchy*(0, 1).

### 1.8. Funções Características.

Se  $a$  e  $b$  são constantes reais,  $z = a + ib$ , onde  $i = \sqrt{-1}$  define um número complexo. O conjugado de  $z$   $\bar{z} = a - ib$ . O produto  $z\bar{z} = a^2 + b^2$  e  $|z| = \sqrt{z\bar{z}}$  define a norma de  $z$ .

Se uma função real tem expansão em série de potência com raio de convergência positivo, podemos usar série de potência para definir uma função de variável complexa.

O desenvolvimento de Taylor, em torno de um ponto  $a$ , de uma função  $g(\cdot)$  infinitamente diferenciável é

$$g(t) = \sum_{n=0}^{\infty} g^{(n)}(a) \frac{(t-a)^n}{n!}.$$

O desenvolvimento da função exponencial,  $g(t) = e^t$ , em torno do ponto 0 é

$$e^t = \sum_{n=0}^{\infty} \frac{t^n}{n!}$$

e definimos

$$e^z = \sum_{n=0}^{\infty} \frac{z^n}{n!},$$

para qualquer número complexo  $z$ . Temos  $e^{z_1}e^{z_2} = e^{z_1+z_2}$  para quaisquer números complexos  $z_1$  e  $z_2$ . em particular se  $z = e^{it}$

$$\begin{aligned} e^{it} &= \sum_{n=0}^{\infty} \frac{(it)^n}{n!} = 1 + it - \frac{t^2}{2} - \frac{it^3}{3!} + \frac{t^4}{4!} + \frac{it^5}{5!} \dots \\ &= \left(1 - \frac{t^2}{2} + \frac{t^4}{4!} - \dots\right) + i \left(t - \frac{t^3}{3!} + \frac{t^5}{5!} - \dots\right) = \cos(t) + i\sin(t). \end{aligned}$$

Observe que se  $f(t) = \cos(t)$  então  $f(0) = 1$ ,

$$\begin{array}{cccc} f'(t) = -\sin(t) & f''(t) = -\cos(t) & f'''(t) = \sin(t) & f^{(4)}(t) = \cos(t) \\ f'(0) = 0 & f''(0) = -1 & f'''(0) = 0 & f^{(4)}(0) = 1 \end{array}$$

e a série de Taylor em torno do ponto 0 é

$$\cos(t) = \left(1 - \frac{t^2}{2} + \frac{t^4}{4!} - \dots\right)$$

assim

$$\cos(t) = \frac{e^{it} + e^{-it}}{2} \quad \text{e} \quad \text{sen}(t) = \frac{e^{it} - e^{-it}}{2i}.$$

Temos também que

$$|e^{it}| = \sqrt{e^{it}e^{-it}} = \sqrt{(\cos(t) + i\text{sen}(t))(\cos(t) - i\text{sen}(t))} = \sqrt{\cos^2(t) + \text{sen}^2(t)} = 1.$$

Se  $f(t)$  e  $g(t)$  são funções de  $t$  a valores reais então  $h(t) = f(t) + ig(t)$  define uma função complexa em  $t$  com  $h'(t) = f'(t) + ig'(t)$ .

**Exemplo 1.76.**

$$e^{zt} = e^{at+ibt}.$$

**Exemplo 1.77.**

$$\begin{aligned} (e^{zt})' &= (e^{at+ibt})' = (e^{at}e^{ibt})' = (e^{at}(\cos(bt) + i\text{sen}(bt)))' = (e^{at}\cos(bt) + ie^{at}\text{sen}(bt))' \\ &= (ae^{at}\cos(bt) - be^{at}\text{sen}(bt)) + i(ae^{at}\text{sen}(bt) + be^{at}\cos(bt)) \\ &= e^{at}[a(\cos(bt) + i\text{sen}(bt)) + ib(\cos(bt) + i\text{sen}(bt))] \\ &= e^{at}[(a + ib)e^{ibt}] = (a + ib)e^{at+ibt} = ze^{zt}, \end{aligned}$$

ou seja,  $(e^{zt})' = ze^{zt}$ .

**Exemplo 1.78.**

$$(e^{it})' = ie^{it}.$$

Se  $\int_a^b f(t)dt$  e  $\int_a^b g(t)dt$  existem, temos

$$\int_a^b h(t)dt = \int_a^b f(t)dt + i \int_a^b g(t)dt.$$

$$\int_a^b e^{zt}dt = \left. \frac{e^{zt}}{z} \right|_a^b = \frac{e^{zb} - e^{za}}{z},$$

pelo teorema fundamental do cálculo. Como consequência,

$$\int_a^b e^{it}dt = \frac{e^{ib} - e^{ia}}{i}.$$

Note que

$$\begin{aligned} \int_a^b e^{it}dt &= \int_a^b \cos(t) + i\text{sen}(t)dt = \int_a^b \cos(t)dt + i \int_a^b \text{sen}(t)dt \\ &= \text{sen}(t)\Big|_a^b - i \cos(t)\Big|_a^b = (\text{sen}(b) - \text{sen}(a)) - i(\cos(b) - \cos(a)) \\ &= \frac{\cos(b) - \cos(a) + i\text{sen}(b) - i\text{sen}(a)}{i} = \frac{e^{ib} - e^{ia}}{i}. \end{aligned}$$

Se  $X$  e  $Y$  são variáveis aleatórias (reais), podemos escrever uma v.a. complexa como  $Z = X + iY$ .

**Definição 1.79.**

$$E[Z] = E[X] + iE[Y],$$

sempre que  $E[X]$  e  $E[Y]$  estão bem definidas.  $Z$  tem esperana finita se e só se  $E[Z] < \infty$  e neste caso  $|E[Z]| \leq E[|Z|]$ .

$$E[a_1Z_1 + a_2Z_2] = a_1E[Z_1] + a_2E[Z_2],$$

é válida onde  $a_1$  e  $a_2$  so números complexos e  $Z_1$  e  $Z_2$  so variáveis aleatórias complexas com esperanças finitas.

**Definição 1.80.** Seja  $X$  uma v.a. (real),  $t \in \mathbb{R}$ , ento  $|e^{itX}| = 1$  e  $\varphi_X(t) = E[e^{itX}]$ ,  $-\infty < t < \infty$  existe.

Definiremos a função característica de  $X$  por  $\varphi_X(t) = E[e^{itX}]$ . Note que:

P1:  $\varphi_X(0) = 1$

$$|\varphi_X(t)| = |E[e^{itX}]| \leq E[|e^{itX}|] = E[1] = 1.$$

P2: Se  $X$  degenerada em  $\theta$ , isto é,  $P(X = \theta) = 1$ , temos

$$\varphi_X(t) = e^{it\theta},$$

se  $\theta = 0$  então  $\varphi_X(t) = 1$ .

P3:  $X$  é simétrica, em torno de 0, se  $f(x) = f(-x)$

$$P(X \leq x) = P(X \geq -x) = P(-X \leq x) \leftrightarrow X \stackrel{D}{=} -X$$

então

$$\begin{aligned} \overline{\varphi_X(t)} &= \overline{E[e^{itX}]} = E[\overline{\cos(tX) - i\sin(tX)}] = E[\cos(t(-X)) + i\sin(t(-X))] \\ &= \varphi_{-X}(t) = \varphi_X(t) \leftrightarrow \text{a parte imaginária é zero.} \end{aligned}$$

Portanto  $X$  é simétrica em torno de zero se e só se  $\varphi_X(t)$  é real.

P4: Se  $X$  uma v.a. e  $a, b$  são constantes reais, então

$$\varphi_{a+bX}(t) = E[e^{it(a+bX)}] = e^{ita} E[e^{itbX}] = e^{ita} \varphi_X(bt)$$

**Exemplo 1.81.** Se  $X \sim \exp(\lambda)$ , então

$$\varphi_X(t) = \lambda \int_0^{\infty} e^{itx} e^{-\lambda x} dx = \lambda \int_0^{\infty} e^{-(\lambda-it)x} dx = \frac{\lambda}{\lambda-it} \cdot e^{-(\lambda-it)x} \Big|_0^{\infty} = \frac{\lambda}{\lambda-it}$$

Observe que  $\lim_{x \rightarrow \infty} e^{-(\lambda-it)x} = 0$  pois  $\lim_{x \rightarrow \infty} e^{-\lambda x} = 0$  e  $e^{-itx}$  é limitado em  $x$ .

**Exemplo 1.82.**  $Y \sim U(-1, 1)$

$$\varphi_Y(t) = \int_{-1}^1 \frac{e^{itx}}{2} dx = \frac{1}{2} \frac{e^{itX}}{it} \Big|_{-1}^1 = \frac{1}{2} \left( \frac{e^{it} - e^{-it}}{it} \right) = \frac{\text{sen}}{t}.$$

**Exemplo 1.83.**  $Y_1, Y_2, \dots, Y_n$  são iid com distribuição de  $Y \sim \text{Cauchy}$

$$E[e^{itY}] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{1}{1+x^2} \cos(tx) dx = e^{-|t|}$$

e

$$E[e^{it \frac{\sum_{i=1}^n Y_i}{n}}] = E[\prod_{i=1}^n e^{i \frac{t}{n} Y_i}] = \prod_{i=1}^n E[e^{i \frac{t}{n} Y_i}] = \prod_{i=1}^n e^{-\frac{t}{n}} = e^{-|t|}$$

então  $\bar{Y}_n \sim \text{Cauchy}$  e  $\bar{Y}_n \stackrel{D}{=} Y$ .

**Teorema 1.84.** Se  $E[|X^n|] < \infty$ , então  $\varphi_X(t)$  possui  $n$  derivadas contínuas e

$$\varphi_X^{(k)}(t) = \int_{-\infty}^{\infty} (ix)^k e^{itx} dF_X(x), \quad k = 1, \dots, n$$

e em particular  $\varphi_X^k(0) = i^k E[X^k]$

*Prova:*

$n = 1$

$$\begin{aligned} \frac{\varphi(t+h) - \varphi(t)}{h} &= \int \left( \frac{e^{i(t+h)x} - e^{itx}}{h} \right) dF(x) \\ &= \int e^{itx} \left( \frac{e^{ihx} - 1}{h} \right) f(x) dx = E \left[ e^{itx} \frac{(e^{ihx} - 1)}{h} \right], \end{aligned}$$

contudo,

$$\lim_{h \rightarrow 0} e^{itx} \frac{(e^{ihx} - 1)}{h} = e^{itx} ix$$

e

$$\left| e^{itx} \frac{(e^{ihx} - 1)}{h} \right| = |e^{itx}| \cdot \left| \frac{\int_0^h ix e^{isx} ds}{h} \right| \leq |x| \left| \frac{\int_0^h e^{isx} ds}{h} \right| \leq |x|$$

e  $E[|X|] < \infty$ .

Pelo teorema da convergência dominada,

$$\lim_{h \rightarrow 0} \frac{\varphi(t+h) - \varphi(t)}{h} = E[e^{itX} iX] = \int ix e^{itx} f(x) dx$$

e o mesmo vale para outros momentos.

**Observação 1.85.** (Convergência Dominada) Se  $\lim X_n = X$ ,  $E[X]$  está bem definida,  $|X_n| \leq Y, \forall n$  e  $E[Y] < \infty$ , então

$$\lim_{n \rightarrow \infty} E[X_n] = E[\lim_{n \rightarrow \infty} X_n] = E[X].$$

**Teorema 1.86.**  $\varphi_X(t)$  é uniformemente contínua, isto é,

$$\forall \epsilon > 0, \exists \delta > 0 \text{ tal que se } |t - s| < \delta \Rightarrow |\varphi_X(t) - \varphi_X(s)| < \epsilon.$$

*Prova:*

$$|\varphi_X(t) - \varphi_X(s)| \leq \int |e^{itx} - e^{isx}| f(x) dx = \int |e^{i(t-s)x} - 1| f(x) dx = h(t-s),$$

$h(u) = E[|e^{iux} - 1|]$ ,  $0 \leq |e^{iux} - 1| \leq 2$  e pelo teorema da convergência dominada

$$\lim_{u \rightarrow 0} E[|e^{iux} - 1|] = E[\lim_{u \rightarrow 0} |e^{iux} - 1|] = 0.$$

Como  $h(\cdot)$  uma função contínua definida num intervalo compacto (limitado e fechado) então  $h(\cdot)$  é uniformemente contínua.

**Teorema 1.87.** Se  $X$  uma v.a. e  $Y = a + bX$ , e  $a, b \in \mathfrak{R}$  então

$$\varphi_Y(t) = E[e^{i(a+bX)t}] = E[e^{iat} e^{ibXt}] = e^{iat} E[e^{ibXt}] = e^{iat} \varphi_X(bt).$$

Um resultado importante é

$$\varphi_X(t) = E[e^{itX}] = E\left[\sum_{n=0}^{\infty} \frac{(itX)^n}{n!}\right] = \sum_{n=0}^{\infty} \frac{i^n E[X^n] t^n}{n!}.$$

**Exemplo 1.88.**  $X \sim N(0, \sigma^2)$ , então

$$E[X^{2k+1}] = 0 \quad \text{e} \quad E[X^{2k}] = \frac{\sigma^{2k} (2k)!}{2^k k!}$$

$$\varphi_X(t) = \sum_{k=0}^{\infty} \frac{i^{2k} E[X^{2k}] t^{2k}}{(2k)!} = \sum_{k=0}^{\infty} \frac{(-\sigma^2 t^2 / 2)^k}{k!} = e^{-\frac{\sigma^2 t^2}{2}}.$$

Se  $Y \sim N(\mu, \sigma^2)$

$$X = Y - \mu \sim N(0, \sigma^2)$$

$$Y = X + \mu$$

$$\varphi_Y(t) = e^{it\mu} \varphi_X(t) = e^{it\mu} e^{-\frac{\sigma^2 t^2}{2}} = \exp\left(it\mu - \frac{\sigma^2 t^2}{2}\right)$$

**Exemplo 1.89.**  $X \sim P(\lambda)$ , logo,  $\varphi_X(t) = e^{\lambda(e^{it}-1)}$

$$\varphi'_X(t) = \lambda e^{it} e^{\lambda(e^{it}-1)}$$

$$\varphi'_X(0) = \lambda i = iE[X] \leftrightarrow E[X] = \lambda$$

$$\begin{aligned}\varphi_X''(t) &= \lambda i^2 e^{it} e^{\lambda(e^{it}-1)} + \lambda e^{it} i^2 \lambda e^{it} e^{\lambda(e^{it}-1)} \\ \varphi_X''(0) &= \lambda i^2 + \lambda^2 i^2 = (\lambda + \lambda^2) i^2 \\ i^2 E[X^2] &= (\lambda + \lambda^2) i^2 \leftrightarrow E[X^2] = (\lambda + \lambda^2)\end{aligned}$$

## 2. FÓRMULA DA INVERSÃO

**Teorema 2.1.** *Seja  $X$  uma v.a. com valores nos inteiros,  $(\varphi_X(t) = E[e^{itX}] = \sum_{j=-\infty}^{\infty} e^{itj} P(X = j))$ . Então*

$$P(X = k) = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} \varphi_X(t) dt$$

**Prova:**

$$\begin{aligned}\frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} \varphi_X(t) dt &= \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} \left( \sum_{j=-\infty}^{\infty} e^{itj} P(X = j) \right) dt \\ &= \frac{1}{2\pi} \sum_{j=-\infty}^{\infty} P(X = j) \int_{-\pi}^{\pi} e^{i(j-k)t} dt\end{aligned}$$

Ocorre que

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} e^{i(j-k)t} dt = \begin{cases} 1 & \text{se } j = k \\ 0 & \text{se } j \neq k \end{cases}.$$

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} e^{i(j-k)t} dt = \frac{e^{i(j-k)t}}{i(j-k)} \Big|_{-\pi}^{\pi} = \frac{e^{i(j-k)\pi} - e^{-i(j-k)\pi}}{2\pi i(j-k)} = \frac{\text{sen}((j-k)\pi)}{\pi(j-k)} = 0$$

e portanto

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} \varphi_X(t) dt = P(X = k).$$

**Exemplo 2.2.** Considere uma variável aleatória  $X$  com valores inteiros e com função característica  $\varphi_X(t) = (pe^{it} + 1 - p)^n$ . Qual a sua função de probabilidade.

Utilizando o teorema acima temos que

$$\begin{aligned}P(X = k) &= \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} (pe^{it} + 1 - p)^n dt = \\ &= \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} \sum_{j=1}^n \binom{n}{j} (pe^{it})^j (1-p)^{n-j} dt = \\ &= \sum_{j=1}^n \binom{n}{j} (p)^j (1-p)^{n-j} \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ikt} e^{itj} dt = \binom{n}{k} (p)^k (1-p)^{n-k}.\end{aligned}$$

**Teorema 2.3.** Se  $X$  e  $Y$  são independentes e  $Z = X + Y$ ,

$$\varphi_Z(t) = E[e^{it(X+Y)}] = E[e^{itX}]E[e^{itY}] = \varphi_X(t)\varphi_Y(t).$$

**Teorema 2.4. Fórmula da Inversão**

Se  $X$  é uma variável aleatória contínua com função característica  $\varphi_X(t)$  integrável

$$\int_{-\infty}^{\infty} |\varphi_X(t)| dt < \infty.$$

Então sua função densidade de probabilidade é

$$f_X(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi_X(t) dt.$$

**Exemplo 2.5.** Seja  $X$  é uma variável aleatória com função densidade de probabilidade

$$f_X(x) = \frac{1}{2} e^{-|x|} \quad -\infty < x < \infty.$$

Estamos interessados em calcular sua função característica  $\varphi_X(t)$ :

$$\begin{aligned} \varphi_X(t) &= \int_{-\infty}^{\infty} e^{itx} \frac{1}{2} e^{-|x|} dx = \\ &= \int_{-\infty}^0 e^{itx} \frac{1}{2} e^x dx + \int_0^{\infty} e^{itx} \frac{1}{2} e^{-x} dx = \int_0^{\infty} e^{-itx} \frac{1}{2} e^{-x} dx + \int_0^{\infty} e^{itx} \frac{1}{2} e^{-x} dx = \\ &= \int_0^{\infty} e^{-x} \left( \frac{e^{-itx} + e^{itx}}{2} \right) dx = \int_0^{\infty} e^{-x} \cos tx dx. \end{aligned}$$

Contudo, integrando por partes obtemos

$$\int_0^{\infty} e^{-x} \cos tx dx = 1 - t^2 \int_0^{\infty} e^{-x} \cos tx dx$$

e concluímos que

$$\int_0^{\infty} e^{-x} \cos tx dx = \frac{1}{1+t^2} = \varphi_X(t).$$

Usando a fórmula da inversão, do teorema anterior, temos

$$\frac{1}{2} e^{-|x|} = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \frac{1}{1+t^2} dt.$$

$$e^{-|x|} = \int_{-\infty}^{\infty} e^{-itx} \frac{1}{\pi} \frac{1}{1+t^2} dt.$$

$$e^{-|x|} = \int_{-\infty}^{\infty} e^{itx} \frac{1}{\pi} \frac{1}{1+t^2} dt.$$



e concluímos que a distribuição de Cauchy padrão tem função característica  $\varphi_X(t) = e^{-|t|}$ .

**Exemplo 2.6.** Se  $X$  é uma variável aleatória com distribuição  $N(0, \sigma^2)$ , a sua função característica é  $\varphi_X(t) = e^{-\frac{\sigma^2 t^2}{2}}$ , isto é

$$e^{-\frac{\sigma^2 t^2}{2}} = \int_{-\infty}^{\infty} e^{itx} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}} dx.$$

Se, na expressão acima, substituirmos  $t$  por  $-t$  e  $\sigma$  por  $\frac{1}{\sigma}$ , temos

$$e^{-\frac{t^2}{2\sigma^2}} = \int_{-\infty}^{\infty} e^{-itx} \frac{\sigma}{\sqrt{2\pi}} e^{-\frac{\sigma^2 x^2}{2}} dx,$$

isto é

$$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{t^2}{2\sigma^2}} = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} e^{-\frac{\sigma^2 x^2}{2}} dx.$$

*Observação 2.7.* Seja  $Y$  uma variável aleatória com distribuição normal padrão e  $c$  uma constante real a função característica de  $cY$  é  $\varphi_{cY}(t) = e^{-\frac{c^2 t^2}{2}}$ . Seja  $X$  uma variável aleatória, independente de  $Y$ , com função característica  $\varphi_X(t)$ .

A função característica de  $Z = X + cY$  é

$$\varphi_Z(t) = \varphi_X(t) \cdot e^{-\frac{c^2 t^2}{2}}.$$

Como  $\varphi_Z(t)$  é integrável, aplicamos o teorema acima e obtemos

$$f_Z(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi_X(t) e^{-\frac{c^2 t^2}{2}} dt.$$

se integramos a expressão acima sobre o intervalo  $(a, b]$  e aplicamos o teorema de Fubini temos

$$\begin{aligned} P(a < X + cY \leq b) &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_a^b e^{-itx} dx \right) \varphi_X(t) e^{-\frac{c^2 t^2}{2}} dt = \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \frac{e^{-ibt} - e^{-iat}}{-it} \right) \varphi_X(t) e^{-\frac{c^2 t^2}{2}} dt. \end{aligned}$$

Fazendo  $c$  convergir para 0 e  $a$  convergir para  $-\infty$  na expressão acima, obtemos a função de distribuição de  $X$  que, pela expressão à direita, depende exclusivamente da função característica de  $X$ . O resultado é enunciado abaixo.

### **Teorema 2.8. Teorema da Unicidade**

*Se duas variáveis aleatórias tem mesma função característica, então tem mesma função de distribuição.*

**Exemplo 2.9.** Seja  $X$  uma variável aleatória com distribuição binomial de parâmetros  $n$  e  $p$ ,  $0 < p < 1$  e seja  $Y$  uma variável aleatória, independente de  $X$ , com distribuição binomial de parâmetros  $m$  e  $p$ ,  $0 < p < 1$ . As funções características de  $X$  e  $Y$  são

$$\varphi_X(t) = (q + pe^{it})^n \quad e \quad \varphi_Y(t) = (q + pe^{it})^m$$

respectivamente, onde  $q = 1 - p$ .

Portanto  $\varphi_{X+Y}(t) = (q + pe^{it})^{n+m}$  e concluímos que  $X + Y$  tem distribuição binomial de parâmetros  $n + m$  e  $p$ ,  $0 < p < 1$ .

**Exemplo 2.10.** Se  $X$  é uma variável aleatória com função característica  $\varphi_X(t) = \cos^2(t)$ , qual sua função de probabilidade?

Observe que a função característica é real, isto é  $\varphi_X(t) = E[\cos Xt]$ .

Podemos, também, escrever que

$$\varphi_X(t) = \cos^2(t) = \frac{1 + \cos 2t}{2} = \frac{1}{2} + \frac{1}{2} \cos 2t.$$

Se definimos  $X = 0$  com probabilidade  $P(X = 0) = \frac{1}{2}$  e  $X = 2$  com probabilidade  $P(X = 2) = \frac{1}{2}$  obtemos, pelo teorema da unicidade, o resultado.

No que segue enunciaremos os teoremas que relacionam a convergência em distribuição com a convergência das respectivas funções características.

**Teorema 2.11. Teorema de Helly-Bray**

Sejam  $(X_n)_{n \geq 1}$  e  $X$  variáveis aleatórias. Sejam  $(F_n)_{n \geq 1}$  e  $F$  as suas respectivas funções de distribuições tais que  $F_n \rightarrow^D F$ . Então, para toda função  $g$  contínua e limitada temos

$$E[g(X_n)] = \int_{-\infty}^{\infty} g(x) dF_n(x) \rightarrow_{n \rightarrow \infty} \int_{-\infty}^{\infty} g(x) dF(x) = E[g(X)].$$

*Observação 2.12.* Em particular, podemos aplicar o teorema acima para as funções  $\cos(t)$  e  $\sin(t)$  que são contínuas e limitadas, obtendo

$$\varphi_{X_n}(t) = E[e^{itX_n}] = \int_{-\infty}^{\infty} e^{itx} dF_n(x) = \int_{-\infty}^{\infty} (\cos(tx) + i \sin(tx)) dF_n(x) =$$

$$\int_{-\infty}^{\infty} \cos(tx) dF_n(x) + i \int_{-\infty}^{\infty} \sin(tx) dF_n(x) \rightarrow_{n \rightarrow \infty}$$

$$\int_{-\infty}^{\infty} \cos(tx) dF(x) + i \int_{-\infty}^{\infty} \sin(tx) dF(x) = \int_{-\infty}^{\infty} e^{itx} dF(x) = \varphi_X(t).$$

**Exemplo 2.13.** Se  $f : (0, 1) \rightarrow \mathfrak{R}$  é uma função contínua e limitada , então podemos representar  $f(t)$  por

$$f(t) = \lim_{n \rightarrow \infty} \sum_{k=0}^n f\left(\frac{k}{n}\right) \binom{n}{k} t^k (1-t)^{n-k}.$$

Claramente , a representação é resultado do teorema de Helly-Bray, quando consideramos variáveis aleatórias independentes e identicamente distribuidas com distribuição de Bernoulli de parâmetro  $t$ .

**Teorema 2.14. Teorema da continuidade de Paul-Levy**

Seja  $(F_{X_n})_{n \geq 1}$  uma sequência de funções de distribuições e  $(\varphi_{X_n})_{n \geq 1}$  a sequência de suas respectivas funções características. Se  $\varphi_{X_n}(t)$  converge pontualmente para  $\varphi(t)$  e  $\varphi$  é contínua no ponto 0, então:

a) Existe uma variável aleatória  $X$ , com função de distribuição  $F_X$  tal que  $F_n \rightarrow^D F$  e

b)  $\varphi$  é função característica de  $X$ .

**Prova:**

Pela fórmula da inversão temos

$$f_{X_n}(x) == \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi_{X_n}(t) dt.$$

Seja

$$f_X(x) == \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi_X(t) dt.$$

Portanto

$$\begin{aligned} P(a < X_n \leq b) &= \frac{1}{2\pi} \int_a^b \left( \int_{-\infty}^{\infty} e^{-itx} \varphi_{X_n}(t) dt \right) dx = \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_a^b e^{-itx} dx \right) \varphi_{X_n}(t) dt, \end{aligned}$$

e, pelo teorema da convergência dominada temos

$$\begin{aligned} \lim_{n \rightarrow \infty} P(a < X_n \leq b) &= \lim_{n \rightarrow \infty} \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_a^b e^{-itx} dx \right) \varphi_{X_n}(t) dt = \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_a^b e^{-itx} dx \right) \varphi_X(t) dt = \\ &= \frac{1}{2\pi} \left( \int_a^b \int_{-\infty}^{\infty} e^{-itx} dx \right) \varphi_X(t) dt = \int_a^b f_X(x) dx = P(a < X \leq b). \end{aligned}$$

Assim

$$P(X_n \leq b) = \lim_{a \rightarrow -\infty} P(a < X_n \leq b) = \lim_{a \rightarrow -\infty} P(a < X \leq b) = P(X \leq b).$$

**Exemplo 2.15.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias com  $X_n \sim B(n, p)$  e tal que  $\lim_{n \rightarrow \infty} np = \lambda$ .

A função característica de  $X_n$  é

$$\varphi_{X_n}(t) = (1 - p + pe^{it})^n = \left(1 - \frac{\lambda}{n} + \frac{\lambda}{n}e^{it}\right)^n = \left(1 - \frac{\lambda}{n}(e^{it} - 1)\right)^n$$

e

$$\lim_{n \rightarrow \infty} \varphi_{X_n}(t) = e^{\lambda(e^{it} - 1)} = \varphi_X(t)$$

que é contínua no ponto 0 e é a função característica de uma variável aleatória com distribuição de Poisson.

**Exemplo 2.16.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias com  $X_n \sim N(0, n)$  com função característica  $\varphi_{X_n}(t) = e^{-\frac{t^2 n}{2}}$ .

Assim

$$\lim_{n \rightarrow \infty} \varphi_{X_n}(t) = 1 \text{ se } t = 0 \text{ e } 0 \text{ se } t \neq 0$$

que não é contínua em  $t = 0$  e portanto não é função característica.

Observe que

$$P(X_n \leq x) = P\left(\frac{X_n}{\sqrt{n}} \leq \frac{x}{\sqrt{n}}\right) = P(Z \leq \frac{x}{\sqrt{n}}) \rightarrow_{n \rightarrow \infty} \frac{1}{2}$$

que não é função de distribuição.

*Observação 2.17.* Se  $z$  é um número complexo tal que  $|z - 1| < 1$ , podemos definir, através da série de Taylor

$$\ln z = (z - 1) - \frac{(z - 1)^2}{2} + \frac{(z - 1)^3}{3} - \dots$$

Portanto se  $|z - 1| < 1$  temos as propriedades usuais:  $z = e^{\ln z}$ ,  $\ln 1 = 0$ . Se  $X$  é uma variável aleatória, a sua função característica  $\varphi_X(t)$  é contínua,  $\varphi_X(0) = 1$  e assim  $\ln \varphi_X(t)$  é bem definida para  $t$  próximo de zero.

Se  $E[X] = \mu < \infty$ , então  $\varphi'_X(0) = i\mu$ . Portanto

$$\lim_{t \rightarrow 0} \frac{\ln \varphi_X(t)}{t} = \lim_{t \rightarrow 0} \frac{\ln \varphi_X(t) - \ln \varphi_X(0)}{t} = \left. \frac{d \ln \varphi_X(t)}{dt} \right|_{t=0} = \frac{\varphi'_X(0)}{\varphi_X(0)} = i\mu.$$

Consequentemente temos

$$\lim_{t \rightarrow 0} \frac{\ln \varphi_X(t) - i\mu t}{t} = 0.$$

Suponha que  $Var(X) = \sigma^2 < \infty$ , então  $\varphi''_X(0) = -E[X^2] = -(\mu^2 + \sigma^2)$ .

$$\lim_{t \rightarrow 0} \frac{\ln \varphi_X(t) - i\mu t}{t^2} = \lim_{t \rightarrow 0} \frac{\frac{\varphi'_X(t)}{\varphi_X(t)} - i\mu}{2t} =$$

$$\begin{aligned} \lim_{t \rightarrow 0} \frac{\varphi'_X(t) - i\mu\varphi_X(t)}{2t\varphi_X(t)} &= \\ \lim_{t \rightarrow 0} \frac{\varphi''_X(t) - i\mu\varphi'_X(t)}{2\varphi_X(t) + 2t\varphi'_X(t)} &= \\ \frac{\varphi''_X(0) - i\mu\varphi'_X(0)}{2\varphi_X(0)} &= \frac{-(\mu^2 + \sigma^2) - (i\mu)^2}{2} = -\frac{\sigma^2}{2}. \end{aligned}$$

Portanto

$$\lim_{t \rightarrow 0} \frac{\ln \varphi_X(t) - i\mu t}{t^2} = -\frac{\sigma^2}{2}.$$

### Teorema 2.18. Teorema do Limite Central

Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média  $E[X_1] = \mu$  e variância  $\text{Var}(X_1) = \sigma^2 < \infty$ . Então

$$\lim_{n \rightarrow \infty} P\left(\frac{S_n - n\mu}{\sigma\sqrt{n}} \leq x\right) = P(Z \leq x), \quad -\infty < x < \infty.$$

onde  $S_n = \sum_{i=1}^n X_i$  e  $Z$  tem distribuição normal padrão.

**Prova:** Seja  $S_n^* = \frac{S_n - n\mu}{\sigma\sqrt{n}}$ . então

$$\begin{aligned} \varphi_{S_n^*}(t) &= E[e^{itS_n^*}] = E\left[e^{it\left(\frac{S_n - n\mu}{\sigma\sqrt{n}}\right)}\right] = \\ &= e^{-\frac{itn\mu}{\sigma\sqrt{n}}} E\left[e^{\frac{itS_n}{\sigma\sqrt{n}}}\right] = \\ &= e^{-\frac{itn\mu}{\sigma\sqrt{n}}} \left(\varphi_{X_1}\left(\frac{t}{\sigma\sqrt{n}}\right)\right)^n. \end{aligned}$$

Portanto

$$\varphi_{S_n^*}(t) = \exp\left\{n\left[\ln \varphi_{X_1}\left(\frac{t}{\sigma\sqrt{n}}\right) - \frac{i\mu t}{\sigma\sqrt{n}}\right]\right\}.$$

Contudo

$$\begin{aligned} \lim_{n \rightarrow \infty} n\left[\ln \varphi_{X_1}\left(\frac{t}{\sigma\sqrt{n}}\right) - \frac{i\mu t}{\sigma\sqrt{n}}\right] &= \\ \lim_{n \rightarrow \infty} \frac{t^2 \ln \varphi_{X_1}\left(\frac{t}{\sigma\sqrt{n}}\right) - i\mu\left(\frac{t}{\sigma\sqrt{n}}\right)}{\left(\frac{t}{\sigma\sqrt{n}}\right)^2} &= \\ \frac{t^2}{\sigma^2} \left(-\frac{\sigma^2}{2}\right) &= -\frac{t^2}{2}. \end{aligned}$$

Concluimos que

$$\lim_{n \rightarrow \infty} \varphi_{S_n^*}(t) = e^{-\frac{t^2}{2}} = \varphi_Z(t).$$

Pelo teorema da unicidade temos o resultado.

Como uma extensão do Teorema do Limite Central, pode-se provar que (ver Barri James)

**Teorema 2.19.** *Sejam  $(Y_n)_{n \geq 1}$  uma sequência de variáveis aleatórias tais que*

$$\sqrt{n}(Y_n - \mu) \rightarrow^D N(0, \sigma^2).$$

*Se  $g(y)$  é uma função derivável no ponto  $\mu$ , então*

$$\sqrt{n}(g(Y_n) - g(\mu)) \rightarrow^D N(0, \sigma^2(g'(\mu))^2).$$

**Exemplo 2.20.** Pelo Teorema do limite central temos

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \rightarrow^D N(0, 1)$$

que é equivalente a

$$\frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} \rightarrow^D N(0, 1).$$

Pelo Teorema de Slutsky concluímos que

$$\sqrt{n}(\bar{X}_n - \mu) \rightarrow^D N(0, \sigma^2).$$

Pelo teorema anterior, se consideramos  $g(x) = x^2$ , temos

$$\sqrt{n}(\bar{X}_n^2 - \mu^2) \rightarrow^D N(0, 4\mu^2\sigma^2).$$

Se consideramos  $g(x) = \frac{1}{x}$  temos, se  $\mu \neq 0$

$$\sqrt{n}\left(\frac{1}{\bar{X}_n} - \frac{1}{\mu}\right) \rightarrow^D N\left(0, \frac{\sigma^2}{\mu^4}\right).$$

2.1. **Exercícios.** 1) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(-1, 1)$ . Defina a variável

$$Y_n = \min\{|X_1|, |X_2|, \dots, |X_n|\}.$$

Mostre que  $Y_n$  converge em probabilidade para  $0$ .

2) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição exponencial de parâmetro  $\lambda$ . Prove que a sequência  $(X_n^2)_{n \geq 1}$  satisfaz a Lei Forte dos Grandes Números.

3) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição de Bernoulli com

parâmetro  $p$ ,  $0 < p < 1$ . Defina  $Y_n = (\prod_{k=1}^n X_k)^{\frac{1}{n}}$

a) Calcule  $P(Y_n > 0)$  e  $E[Y_n]$ .

b) Verifique se  $Y_n$  converge em probabilidade.

4) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias,  $X_n$  com distribuição  $N(n, \sigma^2)$ . A sequência de variáveis  $(X_n)_{n \geq 1}$  converge em distribuição?

5) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição de Cauchy padrão.

Verifique se  $\frac{1}{n^2} \sum_{i=1}^n X_i \rightarrow^D ?$ .

6) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média  $\mu$  e variância  $\sigma^2 < \infty$ .

Determine o tamanho da amostra para que

$$P(|\bar{X}_n - \mu| \leq \frac{\sigma}{10}) \simeq 0,95.$$

7) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição  $N(0, 1)$ . Mostre que

$\frac{\sum_{i=1}^n X_i^2}{\sum_{i=1}^n (X_i - 1)^2}$  converge quase certamente.

8) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes, com  $X_n \sim Exp(2^{\frac{n}{2}})$ . Mostre que vale a Lei forte dos Grandes Números.

9) Seja  $(X_n)_{n \geq 2}$  uma sequência de variáveis aleatórias independentes, com

$$P(X_n = 0) = 1 - \frac{1}{\log n} \quad e \quad P(X_n = n) = \frac{1}{\log n}.$$

Mostre que  $X_n \xrightarrow{P} 0$  mas  $X_n$  não em média quadrática.

10) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média  $\mu$  e variância  $\sigma^2 < \infty$ . Prove que o coeficiente de variação amostral converge, em probabilidade, para o coeficiente de variação populacional, isto é  $\frac{S_n}{\bar{X}_n} \xrightarrow{P} \frac{\sigma}{\mu}$ .

11) Seja  $X_n$  uma variável aleatória com distribuição  $\chi_n^2$ . Prove que  $\frac{X_n - n}{\sqrt{2n}}$  converge em distribuição.

13) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas tais que  $E[X_1] = 0$ ,  $Var(X_1) = 1$  e  $E[X_1^4] < \infty$ . Defina

$$Z_n = \sqrt{n} \frac{X_1 X_2 + X_3 X_4 + \dots + X_{2n-1} X_{2n}}{X_1^2 + X_2^2 + \dots + X_{2n}^2}$$

Qual o limite em distribuição de  $Z_n$ ?

14) Sejam  $X_1, X_2, \dots$  variáveis aleatórias positivas, independentes e com funções de distribuições absolutamente contínuas  $F_1, F_2, \dots$  respectivamente. Defina

$$Y = \sum_{i=1}^n \int_0^{X_i} \frac{dF_i(x)}{1 - F_i(x)}.$$

Calcule

$$\lim_{n \rightarrow \infty} \int_0^{\infty} \frac{g(\frac{y}{n}) Y^{n-1} e^{-y}}{(n-1)!} dy.$$



**2.2. Convergência em média quadrática.** Os espaços vetoriais  $L^p, p \geq 1$  são espaços de variáveis aleatórias  $X$  tais que  $E[|X|^p] < \infty$ , sem distinção entre variáveis aleatórias  $X$  e  $Y$  que são iguais quase certamente, isto é  $P(X = Y) = 1$ . Sob a norma  $\|X\|_p = (E[|X|^p])^{\frac{1}{p}}$  é um espaço completo em que toda sequência de Cauchy converge. Pela desigualdade de Jensen, se  $1 \leq p \leq q$ ,  $\|X\|_p \leq \|X\|_q$  e  $L^q \subseteq L^p$ . Em nossas notas estudamos o caso particular em que  $p = 2$ .

**Definição 2.21.** Seja  $(X_n)_{n \geq 1}$  sequência de v.a.(s) tal que  $E[|X_n|^2] < \infty, n \geq 1$ . Dizemos que a sequência converge em média quadrática para uma variável aleatória  $X$ , com  $E[|X|^2] < \infty$ , e denotamos por  $X_n \xrightarrow{mq} X$ , se

$$\lim_{n \rightarrow \infty} E[|X_n - X|^2] = 0.$$

A convergência em média quadrática tem um papel técnico na Teoria da Probabilidade, em situações quando a informação sobre a sequência de variáveis consiste das médias  $E[X_n], n \geq 1$  e das covariâncias  $E[(X_n - \mu_{X_n})(X_m - \mu_{X_m})]$ . Em tais casos não conseguimos, em geral, trabalhar com a função característica  $E[e^{itX_n}]$  ou avaliar quantidades tais como  $P(X_n \geq \varepsilon)$  que são ferramentas para analisar convergência em distribuição e convergência quase certa, respectivamente. Ao contrário, os momentos de segunda ordem são suficientes para determinar se  $(X_n)_{n \geq 1}$  converge em média quadrática ou não. Enfim, podemos utilizar o critério de Cauchy para provar a convergência

**Teorema 2.22.** Uma sequência  $(X_n)_{n \geq 1}$  de v.a.(s) tal que  $E[|X_n|^2] < \infty$  converge em média quadrática para uma variável aleatória  $X$  se, e somente se

$$\lim_{n, m \rightarrow \infty} E[|X_n - X_m|^2] = 0.$$

**Prova:** Observe o desenvolvimento quadrático:

$$|X_n - X_m|^2 = |X_n - X|^2 + |X_m - X|^2 + 2|X_n - X||X_m - X|.$$

Pela desigualdade de Schwarz, se  $X_n \xrightarrow{mq} X$  temos

$$\lim_{n, m \rightarrow \infty} E[|X_n - X||X_m - X|] \leq \lim_{n, m \rightarrow \infty} \sqrt{E[|X_n - X|^2]E[|X_m - X|^2]} = 0.$$

Assim, sob tal hipótese

$$\lim_{n, m \rightarrow \infty} E[|X_n - X_m|^2] = \lim_{n, m \rightarrow \infty} E[|X_n - X|^2 + |X_m - X|^2 + 2|X_n - X||X_m - X|] = 0$$

e vale a condição necessária.

Por outro lado, se aceitamos que  $\lim_{n, m \rightarrow \infty} E[|X_n - X_m|^2] = 0$  concluimos a condição suficiente, pelo desenvolvimento quadrático acima, que  $\lim_{n \rightarrow \infty} E[|X_n - X|^2] = 0$ .

*Observação 2.23.* Proceda da Desigualdade de Markov que

$$P(|X_n - X| > \varepsilon) \leq \frac{E[|X_n - X|^2]}{\varepsilon^2}.$$

e concluímos que a convergência em média quadrática implica em convergência em probabilidade que, por sua vez, implica em convergência em distribuição. Como indica o exemplo seguinte a convergência quase certa não implica em convergência em média quadrática.

**Exemplo 2.24.** Seja uma sequência  $(X_n)_{n \geq 1}$  com  $P(X_n = 2^n) = \frac{1}{n(n+1)}$  e  $P(X_n = 0) = 1 - \frac{1}{n(n+1)}$  para todo  $n$ .

Temos que

$$\sum_{n=1}^{\infty} P(|X_n| > \frac{1}{m}) = \sum_{n=1}^{\infty} P(X_n = 2^n) = \sum_{n=1}^{\infty} \frac{1}{n(n+1)} < \infty$$

e portanto  $X_n \xrightarrow{qc} 0$ .

Contudo

$$\lim_{n \rightarrow \infty} E[|X_n - 0|^2] = \lim_{n \rightarrow \infty} E[X_n^2] = \lim_{n \rightarrow \infty} \frac{2^{2n}}{n(n+1)} = \infty$$

e  $X_n \not\xrightarrow{mq} 0$ .

Apesar do exemplo acima, existem situações em que a implicação é verdadeira:

**Teorema 2.25.** Se  $(X_n)_{n \geq 1}$  é uma sequência de v.a.(s) e  $X$  é uma variável aleatória tal que  $X_n \xrightarrow{qc} X$  e  $|X_n| \leq Y$ , com  $E[Y^2] < \infty$ , então  $X_n \xrightarrow{mq} X$

**Prova:** Se  $X_n \xrightarrow{qc} X$ ,  $|X_n - X|^2 \xrightarrow{qc} 0$ . Como  $|X_n| \leq Y$ , q.c. para todo  $n \geq 1$  temos também que  $|X| \leq Y$ , q.c. e então  $|X_n - X|^2 \leq 4Y^2$ , q.c.

Portanto, pelo teorema a convergência dominada temos

$$\lim_{n \rightarrow \infty} E[|X_n - X|^2] = E[\lim_{n \rightarrow \infty} |X_n - X|^2] = 0.$$

*Observação 2.26. Relação entre os tipos de convergência*

Os teoremas, propriedades e contra-exemplos analisados nos permite organizar a seguinte relação entre os tipos de convergência:

Sejam  $(X_n)_{n \geq 1}$  e  $X$  variáveis aleatórias, então

Se

$$X_n \xrightarrow{qc} X \Rightarrow X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{D} X$$

Em geral, o reverso das implicações não valem, contudo, se  $P(X = k) = 1$ , onde  $k$  é uma constante, vale  $X_n \xrightarrow{D} k \Rightarrow X_n \xrightarrow{P} k$

Em, adição

$$X_n \xrightarrow{mq} X \Rightarrow X_n \xrightarrow{P} X \Rightarrow X_n \xrightarrow{D} X$$

No existe uma relação entre convergência quase certa e convergência em média quadrática, contudo, se  $(X_n)_{n \geq 1}$  é limitada por uma variável aleatória  $Y, |X_n| \leq Y, q.c$ , com  $E[Y^2] < \infty$ , então convergência quase certa implica em convergência em média quadrática.

**2.3. O teorema do limite central.** Consideremos uma sequência de variáveis aleatórias independentes  $(X_n)_{n \geq 1}$  definidas no mesmo espaço de probabilidade  $(\Omega, \mathfrak{F}, P)$  e seja  $(S_n)_{n \geq 1}$  a sequência das somas parciais definidas por  $S_n = \sum_{i=1}^n X_i$ .

O problema do limite central trata da convergência em distribuição das somas parciais normalizadas

$$\frac{S_n - E[S_n]}{\sqrt{Var(S_n)}} \rightarrow^D N(0, 1).$$

No capítulo anterior analisamos uma solução quando as variáveis aleatórias na sequência  $(X_n)_{n \geq 1}$  são independentes e identicamente distribuídas, com média  $\mu$  e variância  $\sigma^2$  finita:

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \rightarrow^D N(0, 1).$$

Enunciamos o Teorema do limite Central de Lindeberg que dá condições gerais para a validade da convergência ( para a prova ver Barry James).

**Teorema 2.27. Lindeberg** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes com  $E[X_n] = \mu_n$  e  $Var(X_n) = \sigma_n^2 < \infty$  e pelo menos um  $\sigma_n^2 > 0$ . Sejam  $S_n = \sum_{i=1}^n X_i$  e  $s_n^2 = Var(S_n) = \sum_{i=1}^n \sigma_i^2$ . Se a condição de Lindeberg, isto é,*

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

*é satisfeita, então*

$$\frac{S_n - E[S_n]}{\sqrt{Var(S_n)}} \rightarrow^D N(0, 1).$$

*Observação 2.28.* A notação  $\int_{\{|x - \mu_k| > \varepsilon s_n\}}$  significa que o cálculo da integral é feito na região  $(-\infty, \mu_k - \varepsilon s_n) \cup (\mu_k + \varepsilon s_n, \infty)$ . Se  $X_k$  for discreta com função de probabilidade  $p_k(x_i)$ , então

$$\int_{\{|x - \mu_k| > \varepsilon s_n\}} (x - \mu_k)^2 dF_k(x) = \sum_{\{i: |x_i - \mu_k| > \varepsilon s_n\}} (x_i - \mu_k)^2 p_k(x_i).$$

Por outro lado se  $X_k$  for absolutamente contínua com função densidade de probabilidade  $f_k(x)$ , temos

$$\int_{\{|x-\mu_k|>\varepsilon s_n\}} (x-\mu_k)^2 dF_k(x) = \int_{-\infty}^{\mu_k-\varepsilon s_n} (x-\mu_k)^2 f_k(x) dx + \int_{\mu_k+\varepsilon s_n}^{\infty} (x-\mu_k)^2 f_k(x) dx.$$

Observe que

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

de modo que a condição de Lindeberg pode ser escrita da seguinte forma

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

A condição de Lindeberg significa, basicamente, que as parcelas  $\frac{X_k - \mu_k}{s_n}$  da soma  $\frac{S_n - E[S_n]}{s_n}$  são uniformemente pequenas para  $n$  grande. Por exemplo, a condição de Lindeberg implica

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

ou seja, para  $n$  grande, as variâncias das parcelas são uniformemente pequenas em relação à variância da soma. Para ver isto, observe que

Para todo  $k$ ,

$$\begin{aligned} \frac{\sigma_k^2}{s_n^2} &= \frac{1}{s_n^2} \int_{\{|x-\mu_k|>\varepsilon s_n\}} (x-\mu_k)^2 dF_k(x) + \\ &\quad \frac{1}{s_n^2} \int_{\{|x-\mu_k|\leq\varepsilon s_n\}} (x-\mu_k)^2 dF_k(x) \leq \\ &\quad \frac{1}{s_n^2} \sum_{j=1}^n \int_{\{|x-\mu_j|>\varepsilon s_n\}} (x-\mu_j)^2 dF_j(x) + \\ &\quad \frac{1}{s_n^2} \int_{\{|x-\mu_k|\leq\varepsilon s_n\}} \varepsilon^2 s_n^2 dF_k(x) \leq \\ &\quad \frac{1}{s_n^2} \sum_{j=1}^n \int_{\{|x-\mu_j|>\varepsilon s_n\}} (x-\mu_j)^2 dF_j(x) + \frac{1}{s_n^2} \int_{-\infty}^{\infty} \varepsilon^2 s_n^2 dF_k(x). \end{aligned}$$

Este último termo não depende de  $k$  pois a última parcela é igual a  $\varepsilon^2$ . Portanto temos

$$\max_{1 \leq k \leq n} \frac{\sigma_k^2}{s_n^2} \leq \varepsilon^2 + \frac{1}{s_n^2} \sum_{j=1}^n \int_{\{|x-\mu_j| > \varepsilon s_n\}} (x - \mu_j)^2 dF_j(x)$$

que converge para  $\varepsilon^2$ , pela condição de Lindeberg. Como vale para todo  $\varepsilon > 0$ , temos o resultado

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

Do ponto de vista intuitivo, isso serve para justificar a afirmação: a soma de um grande número de pequenas quantidades independentes e de médias zero tem aproximadamente a distribuição normal.

Observemos que a condição de Lindeberg é formalmente mais forte que a condição sobre o máximo das variâncias.

Como  $s_n^2 = \sum_{k=1}^n (x - \mu_k)^2 dF_k(x)$ , a condição diz que, quando  $n$  é grande, é pequena a parte da variância da soma devida às "caudas" das  $X_k$  situadas a mais de  $\varepsilon$  desvios-padrão  $s_n$  das suas respectivas médias  $\mu_k$ .

É interessante, porém, que na presença da condição sobre o máximo, a condição de Lindeberg torna-se necessária para a validade do teorema do limite central:

**Teorema 2.29. Feller**

Seja  $(X_n)_{n \geq 1}$  uma seqüência de variáveis aleatórias independentes com  $E[X_n] = \mu_n$  e  $\text{Var}(X_n) = \sigma_n^2 < \infty$  e pelo menos um  $\sigma_n^2 > 0$ . Sejam  $S_n = \sum_{i=1}^n X_i$  e  $s_n^2 = \text{Var}(S_n) = \sum_{i=1}^n \sigma_i^2$ . Se

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

e

$$\frac{S_n - E[S_n]}{\sqrt{\text{Var}(S_n)}} \rightarrow^D N(0, 1),$$

então

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

O Lema seguinte será utilizado nos exemplos e exercícios:

**Lema 2.30.** Para  $\lambda > 0$ ,

$$\lim_{n \rightarrow \infty} \frac{1}{n^{\lambda+1}} \sum_{k=1}^n k^\lambda = \frac{1}{\lambda+1},$$

de maneira que  $\sum_{k=1}^n k^\lambda$  é da ordem de  $n^{\lambda+1}$ .

**Prova:**

Como  $x^\lambda \leq k^\lambda$  se  $k-1 \leq x \leq k$  e  $k^\lambda \leq x^\lambda$  se  $k \leq x \leq k+1$  temos

$$\int_{k-1}^k x^\lambda dx \leq \int_{k-1}^k k^\lambda dx = k^\lambda = \int_k^{k+1} k^\lambda dx \leq \int_k^{k+1} x^\lambda dx.$$

Portanto

$$\int_0^n x^\lambda dx \leq \sum_{k=1}^n k^\lambda \leq \int_1^{n+1} x^\lambda dx$$

e

$$\frac{n^{\lambda+1}}{\lambda+1} \leq \sum_{k=1}^n k^\lambda \leq \frac{(n+1)^{\lambda+1} - 1}{\lambda+1} \leq \frac{(n+1)^{\lambda+1}}{\lambda+1},$$

ou equivalentemente

$$\frac{1}{\lambda+1} \leq \frac{1}{n^{\lambda+1}} \sum_{k=1}^n k^\lambda \leq \frac{1}{\lambda+1} \left(\frac{n+1}{n}\right)^{\lambda+1}.$$

como  $\lim_{n \rightarrow \infty} \left(\frac{n+1}{n}\right)^{\lambda+1} = 1$  o lema está provado.

**Exemplo 2.31.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes com  $X_n \sim U(-n, n)$ . Verifiquemos a condição de Lindeberg:

Observa-se facilmente que  $E[X_k] = 0$  e  $Var(X_k) = \frac{k^2}{3}$  para todo  $k$ .

Consideremos a parcela

$$\int_{|x| > \varepsilon s_n} x^2 dF_k(x) = \frac{1}{2k} \int_{-k}^k x^2 1_{\{|x| > \varepsilon s_n\}}(x) dx$$

e esta última integral é nula se  $n < \zeta s_n$ , pois neste caso, o integrando toma o valor zero em  $(-k, k)$ . Pelo lema acima temos

$s_n^2 = \sum_{k=1}^n \frac{k^2}{3}$  é tal que

$$\frac{1}{3} \frac{1}{n^3} \sum_{k=1}^n \frac{k^2}{3} = \frac{1}{3} \frac{1}{3} = \frac{1}{9},$$

isto é, quando  $n$  é grande,  $\frac{s_n^2}{n^3} = \frac{s_n^2}{n^2} \frac{1}{n} \approx \frac{1}{9}$  e concluímos que  $\lim_{n \rightarrow \infty} \frac{s_n}{n} = \infty$ .

Portanto,

$$\forall M > 0, \exists n_0 \mid \text{ se } n \geq n_0 \rightarrow \frac{s_n}{n} > M.$$

Basta tomar  $M = \frac{1}{\varepsilon}$  e temos  $\varepsilon s_n > n$ .

O teorema do limite central para sequências de variáveis aleatórias independentes e identicamente distribuídas, analisado no capítulo anterior, segue como um corolário do teorema de Lindeberg

**Corolário 2.32.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média  $E[X_1] = \mu$  e  $Var(X_1) = \sigma^2 < \infty$ , então*

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \rightarrow^D N(0, 1).$$

**Prova:** *Observe que  $s_n^2 = n\sigma^2$ .*

*Verifiquemos a condição de Lindeberg, para todo  $\varepsilon > 0$*

$$\begin{aligned} \frac{1}{n\sigma^2} \sum_{k=1}^n \int_{\{|x-\mu| \leq \sigma\sqrt{n}\varepsilon\}} (x-\mu)^2 dF_k(x) &= \\ \frac{1}{\sigma^2} \int_{\{|x-\mu| \leq \sigma\sqrt{n}\varepsilon\}} (x-\mu)^2 dF_1(x) &\rightarrow_{n \rightarrow \infty} \\ \frac{1}{\sigma^2} \int_{-\infty}^{\infty} (x-\mu)^2 dF_1(x) &= \frac{\sigma^2}{\sigma^2} = 1. \end{aligned}$$

O Teorema de Liapunov, a seguir, é muito útil quando as variáveis aleatórias  $X_n$  possuem momentos finitos de ordem maior que 2. O teorema afirma que a convergência normal vale se as somas dos momentos centrais absolutos de ordem  $2 + \delta$  é assintoticamente pequena em relação a  $s_n^{2+\delta}$ .

**Corolário 2.33. Liapunov**

*Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que  $E[X_n] = \mu_n$  e  $Var(X_n) = \sigma_n^2 < \infty$ , com pelo menos um  $\sigma_n^2 > 0$ . Seja  $s_n^2 = \sum_{k=1}^n \sigma_k^2$ . Se existir  $\delta > 0$  tal que*

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^{2+\delta}} \sum_{k=1}^n E[|X_k - \mu_k|^{2+\delta}] = 0,$$

*então*

$$\frac{S_n - E[S_n]}{\sqrt{Var(S_n)}} \rightarrow^D N(0, 1).$$

**Exemplo 2.34.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes,  $X_n \sim U(-n, n)$ . Verifiquemos a condição de Liapunov: Verifica-se facilmente que  $E[X_k] = 0$  e  $Var(X_k) = \frac{k^2}{3}$  para todo  $k$ . Assim  $s_n^2 = \sum_{k=1}^n \frac{k^2}{3}$  é tal que*

$$\frac{1}{n^3} \sum_{k=1}^n \frac{k^2}{3} = \frac{11}{33} = \frac{1}{9},$$

temos que para  $n$  grande,  $\frac{s_n^2}{n^3} = \frac{s_n^2}{n^2} \frac{1}{n} = \frac{1}{9}$ .  $s_n$  é da ordem de  $n^{\frac{3}{2}}$  e  $s_n^3$  é da ordem de  $n^{\frac{9}{2}}$ .

$$E[|X_k - \mu_k|^{2+1}] = E[|X_k|^3] = \frac{1}{2k} \int_{-k}^k |x|^3 dx = \frac{1}{k} \int_0^k |x|^3 dx = \frac{k^3}{4}.$$

e

$$\lim_{n \rightarrow \infty} \frac{1}{n^4} \sum_{k=1}^n \frac{k^3}{4} = \frac{1}{16}.$$

isto é,  $\sum_{k=1}^n E[|X_k|^3]$  é da ordem de  $n^4$ . Portanto

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^3} \sum_{k=1}^n E[|X_k|^3] =$$

$$\lim_{n \rightarrow \infty} \frac{n^{\frac{9}{2}}}{s_n^3} \frac{\sum_{k=1}^n E[|X_k|^3]}{n^4} \frac{n^4}{n^{\frac{9}{2}}} = \frac{27}{16} \lim_{n \rightarrow \infty} \frac{1}{n^{\frac{1}{2}}} = 0.$$



2.4. **Exercícios.** 1) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que, para cada  $j$ ,  $P(X_j = \pm j^\alpha) = \frac{1}{6j^{2(\alpha-1)}}$  e  $P(X_j = 0) = 1 - \frac{1}{3j^{2(\alpha-1)}}$ . Para que valores de  $\alpha$ ,  $\alpha > 1$  a condição de Liapunov é válida?

2) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes,  $X_n$  com função densidade de probabilidade

$$f_n(x) = \frac{1}{2n} e^{-\frac{|x|}{n}}, x \in \mathfrak{R}.$$

Verifique se a condição de Liapunov é válida?

3) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas tais que  $E[X_k] = 0$  e  $Var(X_k) = 1$ .  
Seja  $(Y_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes tais que  $P(Y_n = \pm n) = \frac{1}{2n^2}$  e  $P(Y_n = 0) = 1 - \frac{1}{2n^2}$ . Verifique que a condição de Lindeberg não vale, mas

$$\frac{1}{\sqrt{n}} \left( \sum_{k=1}^n X_k + \sum_{k=1}^n Y_k \right) \rightarrow^D N(0, 1).$$

4) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes uniformemente distribuídas no intervalo  $(-a_n, a_n)$ . Encontre condições para que

$$\lim_{n \rightarrow \infty} \frac{1}{s_n^2} \sum_{k=1}^n \int_{\{|y - E[X_k]| > \varepsilon n\}} (y - E[X_k])^2 dF_k(y) = 0.$$

5) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, 1)$ . Calcule o limite em probabilidade de  $\frac{\sum_{k=1}^n -\log X_k}{n}$ .

**2.5. Estatísticas de Ordem e distribuição assintótica de valores extremos.** Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição  $F$  definidas em um espaço de probabilidade  $(\Omega, \mathfrak{F}, P)$ . A cada realização  $w \in \Omega$ , ordenamos  $X_1(w), X_2(w), \dots, X_n(w)$  e denotamos por  $X_{(n;1)} \leq X_{(n;2)} \leq \dots \leq X_{(n;n)}$ .  $X_{(n;k)}$  é denominada  $k$ -ésima estatística de ordem dos  $X_1, X_2, \dots, X_n$ . Em particular denotamos:

$$X_{(n;1)} = \min\{X_1, X_2, \dots, X_n\}$$

$$X_{(n;n)} = \max\{X_1, X_2, \dots, X_n\}.$$

Assumiremos que  $F$  é contínua e portanto  $P(X_i = X_j) = 0, \forall i, j$  e concluímos que  $X_{(n;1)} < X_{(n;2)} < \dots < X_{(n;n)}$ .

**Teorema 2.35.** *Sob as hipóteses acima, a função densidade de probabilidade (conjunta) de  $X_{(n;k)}$ ,  $(X_{(n;i)}, X_{(n;j)})$  e de  $X_{(n;1)}, X_{(n;2)}, \dots, X_{(n;n)}$  são respectivamente*

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} (1-F(x))^{n-k} F(x)^{k-1} f(x);$$

$$f_{X_{(n;i)}, X_{(n;j)}}(x, y) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} F(x)^{i-1} [F(y)-F(x)]^{j-i-1} [1-F(y)]^{n-j} f(x) f(y) \quad \text{se } x < y;$$

$$f_{X_{(n;1)}, X_{(n;2)}, \dots, X_{(n;n)}}(x_1, x_2, \dots, x_n) = n! f(x_1) f(x_2) \dots f(x_n) \quad \text{se } x_1 < x_2 < \dots < x_n.$$

**Prova:**

$$\begin{aligned} f_{X_{(n;k)}}(x) &= \lim_{dx \downarrow 0} \frac{F_{X_{(n;k)}}(x+dx) - F_{X_{(n;k)}}(x)}{dx} = \lim_{dx \downarrow 0} \frac{P(x < X_{(n;k)} \leq x+dx)}{dx} = \\ &= \lim_{dx \downarrow 0} \frac{P((k-1) \text{ dos } X'_i \text{ s } \in (-\infty, x], \text{ um } X_i \in (x, x+dx])}{dx} \\ &= \frac{P((n-k) \text{ dos } X'_i \text{ s } \in (x+dx, \infty))}{dx} = \\ &= \lim_{dx \downarrow 0} \frac{n!}{(k-1)!(n-k)!} \frac{F(x)^{k-1} [F(x+dx) - F(x)] [1 - F(x+dx)]^{n-k}}{dx}. \end{aligned}$$

Como  $\lim_{dx \downarrow 0} 1 - F(x+dx) = 1 - F(x)$  e  $\lim_{dx \downarrow 0} \frac{F(x+dx) - F(x)}{dx} = f(x)$  concluímos que

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} (1-F(x))^{n-k} F(x)^{k-1} f(x).$$

A parte restante da prova segue com argumentos análogos.

Uma prova alternativa da demonstração acima que tem interesse em si, segue na observação abaixo.

*Observação 2.36.* Considere a função beta definida por

$$B_{n,k}(u) = \frac{n!}{(k-1)!(n-k)!} \int_0^u t^{k-1}(1-t)^{n-k} dt = \\ \frac{n!}{k!(n-k)!} \int_0^u (1-t)^{n-k} dt^k, 0 < u < 1.$$

Integrando por partes, temos:

$$B_{n,k}(u) = \binom{n}{k} t^k (1-t)^{n-k} \Big|_0^u + \binom{n}{k} \int_0^u (n-k)t^k (1-t)^{n-k-1} dt = \\ \binom{n}{k} u^k (1-u)^{n-k} + \frac{n!}{k!(n-k-1)!} \int_0^u t^k (1-t)^{n-k-1} dt.$$

Repetindo tal processo  $(n-k-1)$  vezes obtemos

$$B_{n,k}(u) = \sum_{r=k}^n \binom{n}{r} u^r (1-u)^{n-r}.$$

Consequentemente

$$P(X_{(n;k)} \leq x) = P\left(\sum_{i=1}^n 1_{\{X_i \leq x\}} \geq k\right) = \sum_{r=k}^n \binom{n}{r} F(x)^r (1-F(x))^{n-r} = \\ \frac{n!}{(k-1)!(n-k)!} \int_0^{F(x)} t^{k-1} (1-t)^{n-k} dt.$$

Se  $F$  é absolutamente contínua,

$$f_{X_{(n;k)}}(x) = \frac{n!}{(k-1)!(n-k)!} F(x)^{k-1} (1-F(x))^{n-k} f(x).$$

**2.6. Funções das Estatísticas de Ordem.** A média amostral da estatísticas de ordem  $\frac{\sum_{k=1}^n X_{(n;k)}}{n}$  é identicamente distribuída à média amostral dos  $X'_i$ 's,  $\frac{\sum_{k=1}^n X_k}{n}$ .  
A mediana é definida por

$$Md = \begin{cases} X_{(n; \frac{n+1}{2})}, n = 2k + 1 & : \\ \frac{X_{(n; \frac{n}{2})} + X_{(n; \frac{n}{2} + 1)}}{2}, n = 2k & : \end{cases}$$

A amplitude  $R$  é definida por  $R = X_{(n;n)} - X_{(n;1)}$ .

A amplitude média  $T$  é definida por  $\frac{X_{(n;n)} + X_{(n;1)}}{2}$ .

**Exemplo 2.37.** Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, 1)$ . A função de densidade conjunta de  $X_{(n;1)}, X_{(n;n)}$  é

$$f_{X_{(n;1)}, X_{(n;n)}}(x, y) = n(n-1)[F(y) - F(x)]^{n-2} f(x)f(y), \quad 0 < x < y < 1, \text{ e } 0 \text{ c.c.}$$

*Nosso objetivo é encontrar a função densidade de probabilidade da amplitude*

*R. Como variável auxiliar tomaremos a amplitude média  $T$ .*

Assim  $r = y - x$  e  $t = \frac{x+y}{2}$ ,  $x = t - \frac{r}{2}$  e  $y = t + \frac{r}{2}$  definem a transformação bijetora com Jacobiano

$$J = \frac{\delta x}{\delta r} \frac{\delta y}{\delta t} - \frac{\delta x}{\delta t} \frac{\delta y}{\delta r} = \frac{-1}{2} + \frac{-1}{2} = -1.$$

[width=5cm,height=5cm]Figura1.jpg

[width=5cm,height=5cm]Figura2.jpg

O valor absoluto do Jacobiano,  $|J| = 1$ , é 1. Se consideramos  $n = 10$

$$f_{R,T}(r, t) = 10 \cdot 9 \cdot [t + \frac{r}{2} - t + \frac{r}{2}]^8 \cdot 1 \cdot 1 = 90r^8 1_D(r, t)$$

onde  $D$  é a região de definição obtida através das regiões fechadas

$$0 < x < 1, y = 0 \Rightarrow 0 \leq t - \frac{r}{2} \leq 1, t = \frac{-r}{2} \Rightarrow -1 \leq r \leq 0;$$

$$x = 0, 0 < y < 1 \Rightarrow t - \frac{r}{2} = 0, 0 < t + \frac{r}{2} < 1 \Rightarrow 0 < r < 1;$$

$$x = 1, 0 < y < 1 \Rightarrow t - \frac{r}{2} = 1, 0 < t + \frac{r}{2} < 1 \Rightarrow -1 < r < 0;$$

$$0 < x < 1, y = 1 \Rightarrow 0 < t = \frac{-r}{2} < 1, t = 1 - \frac{-r}{2} \Rightarrow 0 < r < 1.$$

Portanto a função densidade de probabilidade da amplitude  $R$  é

$$f_R(r) = \begin{cases} \int_{-\frac{r}{2}}^{\frac{r+2}{2}} 90r^8 dt = 90r^8(r+1) & : -1 < r < 0 \\ & : \\ \int_{\frac{r}{2}}^{\frac{2-r}{2}} 90r^8 dt = 90r^8(1-r) & : 0 < r < 1 \end{cases}$$

**2.7. Função de distribuição empírica.** Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição  $F$  definidas em um espaço de probabilidade  $(\Omega, \mathfrak{F}, P)$ . A função de distribuição empírica é definida por:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n 1_{\{X_i \leq x\}}$$

Observe que a função de distribuição empírica é um estimador não viciado e consistente da função de distribuição,

$$E[F_n(x)] = \frac{1}{n} \sum_{i=1}^n E[1_{\{X_i \leq x\}}] = F(x)$$

e

$$Var(F_n(x)) = E[(F_n(x) - F(x))^2] = \frac{1}{n^2} Var\left(\sum_{i=1}^n 1_{\{X_i \leq x\}}\right) = \frac{F(x)(1 - F(x))}{n}$$

que converge para 0 quando  $n$  converge para o infinito. Portanto

$$F_n(x) \xrightarrow{mq} F(x), F_n(x) \xrightarrow{P} F(x) \text{ e } F_n(x) \xrightarrow{D} F(x).$$

Com mais rigor, Glivenko-cantelli, provou o teorema

**Teorema 2.38.** *Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição  $F$  definidas em um espaço de probabilidade  $(\Omega, \mathfrak{F}, P)$ . Então*

$$\sup_{x \in \mathfrak{R}} |F_n(x) - F(x)| \xrightarrow{qc} 0.$$

Note que

$$P\left(F_n(x) \geq \frac{k}{n}\right) = P(nF_n(x) \geq k) = P(X_{(n;k)} \leq x)$$

e

$$F_n(x) = \begin{cases} 0 & : & x < X_{(n;1)} \\ \frac{k}{n} & : & X_{(n;k)} \leq x < X_{(n;k+1)} \\ & : & \\ 1 & : & x \geq X_{(n;n)} \end{cases}.$$

[width=12cm,height=10cm]Figura3.jpg

Portanto existe uma correspondência biunívoca entre  $F_n(x)$  e as estatísticas de ordem.

[width=3.5cm,height=3.5cm]Figura4.jpg  
 [width=3.5cm,height=3.5cm]Figura5.jpg  
 [width=3.5cm,height=3.5cm]Figura6.jpg

Considere um número real  $p, 0 < p < 1$  e seja  $\zeta_p$  o  $p$ -ésimo quantil de  $F$ , isto é,  $\zeta_p$  é a única solução de  $F(x) = p$ , quando existir.

Se, para uma estatística de ordem  $X_{(n;k)}, \frac{k}{n}$  converge para  $p$  de maneira conveniente,  $X_{(n;k)}$  é chamado o  $p$ -ésimo quantil amostral,  $\hat{\zeta}_{p,n}$ . Embora existam várias maneiras de definirmos tal  $k$ , as mais adotadas são  $k = k_p = [np] + 1$  e  $k = k_p = [(n+1)p]$ .

**Exemplo 2.39.** Se  $p = \frac{1}{2}$ ,  $\zeta_p$  é a mediana de  $F$ . Se  $n$  é ímpar,  $n = 2m + 1$  temos

$$[np] + 1 = \left[ \frac{(2m+1)}{2} \right] + 1 = \left[ m + \frac{1}{2} \right] + 1 = m + 1 \text{ e } [(n+1)p] = \left[ \frac{(2m+1+1)}{2} \right] \\ = [m+1] = m+1.$$

Assim o  $p$ -ésimo quantil amostral  $\hat{\zeta}_{p,n} = X_{(n;m+1)}$ .

Se  $n$  é par,  $n = 2m$  temos

$$[np] + 1 = \left[ \frac{2m}{2} \right] + 1 = m + 1 \text{ e } [(n+1)\frac{1}{2}] = \left[ m + \frac{1}{2} \right] = m.$$

Neste caso convencionamos definir  $p$ -ésimo quantil amostral como  $\hat{\zeta}_{p,n} = \frac{X_{(n;m+1)} + X_{(n;m)}}{2}$

Desde que  $F_n$  é uma função escada, os  $p$ -ésimos quantis amostrais podem ser definidos como

$$\hat{\zeta}_{p,n}^1 = \sup\{x : F_n(x) \leq p\}$$

$$\hat{\zeta}_{p,n}^2 = \inf\{x : F_n(x) \geq p\}$$

definem um intervalo aberto onde podemos realizar uma interpolação linear

[width=6cm,height=7cm]Figura7.jpg

Considerando uma relação linear  $y = a + bx$  que relacione os pontos

$(\hat{\zeta}_{p,n}^1, \frac{k-1}{n})$  e  $(\hat{\zeta}_{p,n}^2, \frac{k}{n})$ , isto é, resolvendo

$$\frac{k}{n} = a + b\hat{\zeta}_{p,n}^2$$

$$\frac{k-1}{n} = a + b\hat{\zeta}_{p,n}^1$$

temos  $b = \frac{1}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}$  e  $a = \frac{k}{n} - \frac{\hat{\zeta}_{p,n}^2}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}$ , produzindo a reta

$$y = \frac{k}{n} - \frac{\hat{\zeta}_{p,n}^2}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)} + \frac{x}{n(\hat{\zeta}_{p,n}^2 - \hat{\zeta}_{p,n}^1)}.$$

A imagem inversa de  $p$  através dessa reta é

$$x = \hat{\zeta}_{p,n}^2(np + 1 - k) + \hat{\zeta}_{p,n}^1(k - np).$$

Tais considerações justificam a adoção de  $k_p$ .

Para valores grandes de  $n$  estas modificações são de menor importância. Observe que  $X_{(n;k)}$ ,  $(X_{(n;n-k+1)})$  é a  $k$ -ésima menor (maior) estatística de ordem. Em particular  $X_{(n;1)} = \min\{X_1, \dots, X_n\}$  e  $X_{(n;n)} = \max\{X_1, \dots, X_n\}$ .

No contexto da teoria assintótica, quando  $\frac{k}{n} \rightarrow_{n \rightarrow \infty} 0$  ou  $\frac{k}{n} \rightarrow_{n \rightarrow \infty} 1$ , estas estatísticas de ordem são denominadas de valores extremos. As populações adequadas para tais formulações são:

A) Suponha que exista  $\zeta_0 > -\infty$  tal que

$$F(x) > 0 \text{ se } x > \zeta_0 \text{ e } F(x) = 0 \text{ se } x \leq \zeta_0,$$

então  $\zeta_0$  é denominado um ponto final inferior para  $F$ . Se  $\zeta_0 = -\infty$ , dizemos que  $F$  tem um ponto final inferior infinito.

B) Suponha que exista  $\zeta_1 < \infty$  tal que

$$F(x) < 1 \text{ se } x < \zeta_1 \text{ e } F(x) = 1 \text{ se } x \geq \zeta_1,$$

então  $\zeta_1$  é denominado um ponto final superior para  $F$ . Se  $\zeta_1 = \infty$ , dizemos que  $F$  tem um ponto final superior infinito.

O comportamento das distribuições dos valores extremos dependem se a população tem pontos finais inferiores (superiores) finitos ou não.

**Teorema 2.40.** *Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição  $F$  definidas em um espaço de probabilidade  $(\Omega, \mathfrak{S}, P)$ . Se  $F$  tem um ponto final inferior finito ( $\zeta_0$ ) e um ponto final superior finito ( $\zeta_1$ ), então  $X_{(n;n)} \rightarrow_P \zeta_1$  e  $X_{(n;1)} \rightarrow_P \zeta_0$ .*

**Prova:** *Se  $\zeta_1$  é um ponto final superior finito,*

$$\forall \varepsilon > 0, \exists 0 < \eta = \eta(\varepsilon) < 1, : F(\zeta_1 - \varepsilon) = 1 - \eta.$$

*Portanto*

$$\begin{aligned} P(|X_{(n;n)} - \zeta_1| > \varepsilon) &= P(X_{(n;n)} > \varepsilon + \zeta_1) + P(X_{(n;n)} < \zeta_1 - \varepsilon) = \\ 1 - P(X_{(n;n)} \leq \varepsilon + \zeta_1) + \pi_{i=1}^n P(X_i < \zeta_1 - \varepsilon) &= 1 - \pi_{i=1}^n P(X_i < \zeta_1 + \varepsilon) + (F(\zeta_1 - \varepsilon))^n = \\ 1 - (F(\zeta_1 + \varepsilon))^n + (1 - \eta)^n &= 1 - 1 + (1 - \eta)^n = (1 - \eta)^n. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;n)} - \zeta_1| > \varepsilon) = \lim_{n \rightarrow \infty} (1 - \eta)^n = 0.$$

Em adição,  $\forall m \geq 1$ ,

$$\sum_{n=1}^{\infty} P(|X_{(n;n)} - \zeta_1| > \frac{1}{n}) = \sum_{n=1}^{\infty} (1 - \eta)^n = \frac{1 - \eta}{\eta} < \infty$$

e  $X_{(n;n)} \rightarrow_{qc} \zeta_1$ .

Se  $\zeta_0$  é um ponto final inferior finito,

$$\forall \varepsilon > 0, \exists 0 < \eta = \eta(\varepsilon) < 1, : F(\zeta_0 + \varepsilon) = \eta.$$

$$\begin{aligned} P(|X_{(n;1)} - \zeta_0| \leq \varepsilon) &= P(X_{(n;1)} > \zeta_0 - \varepsilon) - P(X_{(n;1)} > \zeta_0 + \varepsilon) = \\ &= \pi_{i=1}^n (1 - P(X_i \leq \zeta_0 - \varepsilon)) - \pi_{i=1}^n (1 - P(X_i \leq \zeta_0 + \varepsilon)) = \\ &= 1 - (1 - F(\zeta_0 + \varepsilon))^n = 1 - (1 - \eta)^n. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;1)} - \zeta_0| \leq \varepsilon) = \lim_{n \rightarrow \infty} 1 - (1 - \eta)^n = 1.$$

Em adição,  $\forall m \geq 1$ ,

$$\sum_{n=1}^{\infty} P(|X_{(n;1)} - \zeta_0| > \frac{1}{n}) = \sum_{n=1}^{\infty} (1 - \eta)^n = \frac{1 - \eta}{\eta} < \infty$$

e  $X_{(n;1)} \rightarrow_{qc} \zeta_0$ .

**Teorema 2.41.** *Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição  $F$  definidas em um espaço de probabilidade  $(\Omega, \mathfrak{S}, P)$ . Assuma que o  $p$ -ésimo quantil  $\zeta_p, 0 < p < 1$  é unicamente definido, isto é,  $\forall \varepsilon > 0, F(\zeta_p - \varepsilon) < F(\zeta_p) = p < F(\zeta_p + \varepsilon)$ . Então o  $p$ -ésimo quantil amostral  $X_{(n;k)}$ , com  $k = k_p$ , é tal que  $X_{(n;k)} \xrightarrow{P} \zeta_p$  e  $X_{(n;k)} \xrightarrow{qc} \zeta_p$ .*

**Prova:**

$$P(|X_{(n;k)} - \zeta_p| \leq \varepsilon) = P(X_{(n;k)} \leq \zeta_p + \varepsilon) - P(X_{(n;k)} \leq \zeta_p - \varepsilon).$$

Consideremos a variável aleatória  $Y^+$  com distribuição binomial de parâmetro  $n$  e  $F(\zeta_p + \varepsilon)$ , de forma que

$$P(X_{(n;k)} \leq \zeta_p + \varepsilon) = P(Y^+ \geq k) = P\left(\frac{Y^+}{n} \geq \frac{k}{n}\right).$$

Contudo  $\frac{Y^+}{n} \xrightarrow{qc} F(\zeta_p + \varepsilon) > p$  e  $\frac{k}{n} \rightarrow p$ . Concluimos que  $\lim_{n \rightarrow \infty} P(X_{(n;k)} \leq \zeta_p + \varepsilon) = 1$ .



Por outro lado, consideremos a variável aleatória  $Y^-$  com distribuição binomial de parâmetro  $n$  e  $F(\zeta_p - \varepsilon)$ , de forma que

$$P(X_{(n;k)} \leq \zeta_p - \varepsilon) = P(Y^- \geq k) = P\left(\frac{Y^-}{n} \geq \frac{k}{n}\right)$$

e  $\frac{Y^-}{n} \xrightarrow{qc} F(\zeta_p - \varepsilon) < p$  e  $\frac{k}{n} \rightarrow p$ . Concluimos que  $\lim_{n \rightarrow \infty} P(X_{(n;k)} \leq \zeta_p - \varepsilon) = 0$ .

Portanto

$$\lim_{n \rightarrow \infty} P(|X_{(n;k)} - \zeta_p| \leq \varepsilon) = 1$$

e  $X_{(n;k)} \xrightarrow{P} \zeta_p$ .

A prova da convergência quase certa não será reproduzida no texto.

**Teorema 2.42.** *Sejam  $X_1, X_2, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas definidas em um espaço de probabilidade  $(\Omega, \mathfrak{S}, P)$  com distribuição  $F$  e função densidade de probabilidade  $f(x)$  tal que  $f(\zeta_p) > 0$ . Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{\sqrt{n}(X_{(n;k)} - \zeta_p)}{\gamma} \leq x\right) = P(Z \leq x)$$

onde  $\gamma^2 = \frac{p(1-p)}{f(\zeta_p)^2}$ .

**Prova:**

Consideremos a variável aleatória  $Y_n$  com distribuição binomial de parâmetros  $n$  e  $F(\zeta_p + \frac{1}{\sqrt{n}}x)$ .

$$P(\sqrt{n}(X_{(n;k)} - \zeta_p) \leq x) = P(X_{(n;k)} \leq \zeta_p + \frac{1}{\sqrt{n}}x) = P(Y_n \geq k) =$$

$$P\left(\frac{Y_n - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}} \geq \frac{k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}}\right).$$

Para calcular o limite, quando  $n \rightarrow \infty$  da expressão à direita usaremos o teorema do valor médio ( $\int_a^b f(x)dx = (b-a)f(a+\theta(b-a))$ ,  $0 < \theta < 1$ ).

$$\begin{aligned} \frac{1}{\sqrt{n}}(k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)) &= \frac{k}{\sqrt{n}} - \frac{n}{\sqrt{n}} \left[ \int_0^{\zeta_p} \zeta f(z)dz + \int_{\zeta_p}^{\zeta_p + \frac{1}{\sqrt{n}}x} f(z)dz \right] = \\ &= \frac{k}{\sqrt{n}} - \frac{np}{\sqrt{n}} - \frac{n}{\sqrt{n}} \left[ \zeta_p + \frac{1}{\sqrt{n}}x - \zeta_p \right] f(\zeta_p + \theta(\zeta_p + \frac{1}{\sqrt{n}}x) - \zeta_p), 0 < \theta < 1. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} \frac{1}{\sqrt{n}} (k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)) = -xf(\zeta_p)$$

e

$$\lim_{n \rightarrow \infty} \frac{k - nF(\zeta_p + \frac{1}{\sqrt{n}}x)}{\sqrt{nF(\zeta_p + \frac{1}{\sqrt{n}}x)(1 - F(\zeta_p + \frac{1}{\sqrt{n}}x))}} = \frac{-xf(\zeta_p)}{\sqrt{p(1-p)}}.$$

Concluimos que, pelo teorema do limite central

$$\lim_{n \rightarrow \infty} P(\sqrt{n}(X_{(n;k)} - \zeta_p) \leq x) = P(Z \leq \frac{-xf(\zeta_p)}{\sqrt{p(1-p)}})$$

e

$$\lim_{n \rightarrow \infty} P\left(\frac{\sqrt{n}(X_{(n;k)} - \zeta_p)}{\gamma} \leq x\right) = P(Z \leq x)$$

onde  $\gamma^2 = \frac{p(1-p)}{f(\zeta_p)^2}$ .

**Exemplo 2.43.** Sejam  $x_1, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas com distribuição exponencial de parâmetro  $\lambda$ . Desde que  $P(X_1 > x) = e^{-\lambda x}$  temos que a mediana  $m$  é a solução de  $e^{-\lambda m} = 0,5$ , isto é  $m = \frac{0,7}{\lambda}$ . Portanto

$$f(m) = \lambda e^{-\frac{0,7}{\lambda}} = 0,5\lambda.$$

Pelo teorema acima

$$Md \sim N\left(\frac{0,7}{\lambda}, \frac{1}{4n(0,25\lambda^2)}\right).$$

Um intervalo de confiança para  $\lambda$ , ao nível de 0,95 de confiança é obtido através de

$$P(-1,96 \leq (Md - \frac{0,7}{\lambda})\sqrt{n}\lambda \leq 1,96) = 0,95$$

produzindo

$$\left(\frac{-1,96 + 0,7\sqrt{n}}{\sqrt{nm}}, \frac{1,96 + 0,7\sqrt{n}}{\sqrt{nm}}\right).$$

2.8. **Exercícios.** 1) A função de distribuição  $G$  é estável através do máximo se para todo inteiro positivo  $k$ , existem constantes  $\alpha_k$  e  $\beta_k$  tais que

$$G^k(\alpha_k x + \beta_k) = G(x), \forall x \in R.$$

Prove que as funções de distribuições

$$W_1^*(x) = \exp[-(-x)^\alpha], \quad x \leq 0, \quad \alpha > 0;$$

$$W_2^*(x) = \exp[-x^{-\alpha}], \quad x \geq 0, \quad \alpha > 0;$$

$$\Lambda^*(x) = \exp[-\exp(-x)], \quad -\infty < x < \infty.$$

são estáveis através do máximo. 2) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas a  $X$  que tem função densidade de probabilidade :

$$f(x) = \frac{2x}{\theta^2} 1_{(0,\theta)}(x)$$

onde  $\theta > 0$  é um parâmetro.

- a) Considere sequências  $(a_n)_{n \geq 1}$  e  $(b_n)_{n \geq 1}$  definidas por  $a_n = F^{-1}(\frac{1}{n})$  e  $b_n = 0$  e mostre que a função de distribuição de  $X$  pertence ao domínio de atração minimal da distribuição de Weibull
- $$W_1(x) = 1 - \exp[-(x)^\alpha], x \geq 0 \text{ para algum } \alpha > 0.$$
- b) Baseado no limite em distribuição de  $X_{1:n}$ , padronizada, construa um intervalo de confiança para o parâmetro  $\theta$  com coeficiente de confiança de 0,9. 3) Seja  $X_1, X_2, \dots, X_{100}$  uma amostra aleatória de

tamanho 100 da distribuição de Weibull

$$F(x) = 1 - \exp[-(\lambda x)^2], x \geq 0 \text{ para algum parâmetro } \lambda > 0 \text{ e seja } \xi_M \text{ a mediana de } F.$$

Baseado na mediana amostral  $\widehat{\xi}_M$ , encontre um intervalo de confiança com 0,95 de confiança para  $\lambda$ .

- 4) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas a  $X$  que tem função de distribuição triangular em  $[0, \theta]$ , isto é

$$F(x) = \frac{2x^2}{\theta^2} \quad \text{se } 0 \leq x < \frac{\theta}{2};$$

$$F(x) = \frac{4x}{\theta} - \frac{2x^2}{\theta^2} - 1 \quad \text{se } \frac{\theta}{2} \leq x < \theta.$$

- a) Prove que a distribuição tem contato terminal de ordem  $m$  em  $\xi_0$ . Quais os valores de  $\xi_0$  e  $m$ ?

( Uma distribuição tem contato terminal de ordem  $m$  no ponto  $\xi_0$  se  $F(\xi_0) = 0$  e  $F^{(j)}(\xi_0) = 0$  para  $1 \leq j \leq m$  e  $F^{(m+1)}(\xi_0) \neq 0$ ). Neste caso sabemos que

$$P\left(\frac{X_{n:1} - b_n}{a_n} \leq t\right) \rightarrow 1 - e^{-t(m+1)}, t \geq 0$$

onde  $a_n = \left[\frac{(m+1)!}{nF^{(m+1)}(\xi_0)}\right]^{\frac{1}{(m+1)}}$  e  $b_n = \xi_0$ .

b) Calcule  $a_n$  e  $b_n$ .

c) Considere  $\theta = 10000$  horas e um sistema em série com 100 desses componentes. Qual uma estimativa da probabilidade do sistema sobreviver 150 horas?

5) Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas a  $X$  que tem função densidade de probabilidade

$$f(x) = \frac{1}{2\lambda} e^{-\frac{|x|}{\lambda}}, \quad -\infty < x < \infty$$

a) Verifique se esta densidade é da classe exponencial, isto é

$$\frac{f(x)}{F(x)} \simeq \frac{f'(x)}{f(x)} \simeq \frac{f''(x)}{f'(x)} \simeq \dots$$

quando  $x \rightarrow -\infty$ .

b) Sabemos que

$$P\left(\frac{X_{n:1} - b_n}{a_n} \leq t\right) \rightarrow 1 - e^{-e^x}$$

em distribuição para  $-\infty < x < \infty$  e onde  $F(\xi_{0,n}) = \frac{1}{n}$ ,  $a_n = \frac{1}{nf(\xi_{0,n})}$  e  $b_n = \xi_{0,n}$ . Calcule  $a_n$  e  $b_n$ .

c) Usando a aproximação em b) construir um intervalo de confiança para  $\lambda$  com coeficiente de confiança igual a 0,9.

## TEORIA ASSINTÓTICA DOS VALORES EXTREMOS

Nas aulas anteriores aprendemos resultados assintóticos de seqüências de estatísticas obtidas de variáveis aleatórias independentes e identicamente distribuídas. Em particular estudamos a Lei Forte (Fracá) dos Grandes Números e o Teorema do Limite Central:

Sejam  $X_1, X_2, \dots, X_n \stackrel{iid}{\sim} X$ , com  $\mathbb{E}[X] = \mu$  e  $\text{Var}(X) = 1$ . Considere  $\bar{X} = \sum_{i=1}^n X_i/n$ .

Pela Lei Forte dos Grandes Números  $\bar{X} \xrightarrow{q.c.} \mu$  conseqüentemente  $\bar{X} \xrightarrow{P} \mu$ . Como a convergência em probabilidade implica convergência em distribuição, temos

$$\bar{X} \xrightarrow{D} \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases}.$$

Contudo, se de certa forma, padronizamos a média amostral temos outro resultado  $\sqrt{n} \cdot (\bar{X} - \mu) \xrightarrow{D} N(0, 1)$  que é mais interessante.

Em resumo, procuramos  $(a_n)_{n \geq 1}$ , com  $a_n > 0$  e  $(b_n)_{n \geq 1}$  tais que

$$\frac{\sum_{i=1}^n X_i - b_n}{a_n} \xrightarrow{D} N(0, 1).$$

Pelo Teorema do Limite Central

$$a_n = \sqrt{n \text{Var}(X)} \text{ e } b_n = n \mathbb{E}[X]$$

são soluções.

Assim acontece com as propriedades assintóticas dos valores extremos.

Sejam  $X_1, X_2, \dots, X_n \stackrel{iid}{\sim} X$  tal que  $X \sim U(0, 1)$ . Considere  $X_{(n;1)} = \min(X_1, \dots, X_n)$ .

$$X_{(n;1)} \xrightarrow{P} 0 \text{ e } X_{(n;1)} \xrightarrow{D} \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases}.$$

Contudo

$$n \cdot X_{(n;1)} \xrightarrow{D} \text{Exp}(1).$$

As propriedades assintóticas dos valores extremos são importantes nas aplicações estatísticas. É desejável estimar o risco máximo que decorre das aplicações financeiras ao longo de horas, dias, meses, anos consecutivos. É importante estimar o número de componentes de um sistema em série para que funcione adequadamente por um longo período de tempo. Óbvio, quando  $n$  converge para o infinito,  $X_{(n;1)}$  converge quase certamente para o extremo inferior do suporte da função de distribuição  $F$  e converge em distribuição para este mesmo valor. Para evitar tais trivialidades padronizaremos  $X_{(n;1)}$  por um parâmetro de escala  $a_n$  e um parâmetro de translação  $b_n$  e analisaremos o limite em distribuição da sequência padronizada

$$\left(\frac{X_{(n;1)} - b_n}{a_n}\right)_{n \geq 1}.$$

Assumiremos, também para evitar trivialidades, que a distribuição limite é não degenerada.

O mesmo ocorre quando analisamos a sequência de máximos de variáveis aleatórias independentes e identicamente distribuídas. Observe que  $\max\{X_1, \dots, X_n\} = -\min\{-X_1, \dots, -X_n\}$  e que se  $G(x)$  o limite em distribuição de  $X_{(n;1)}$ ,  $\bar{G}(-x)$  é o limite em distribuição de  $X_{(n;n)}$

As distribuições limites para a sequência de mínimos (máximos) de variáveis aleatórias independentes e identicamente distribuídas são de três tipos. Procuramos  $(a_n)_{n \geq 1}$ , com  $a_n > 0$  e  $(b_n)_{n \geq 1}$  tais que

$$\frac{X_{(1)} - b_n}{a_n} \xrightarrow{D} \begin{cases} W_1(x) = 1 - e^{-(x)^\alpha} \text{ se } x \geq 0, \alpha > 0 \\ W_2(x) = 1 - e^{-(-x)^{-\alpha}} \text{ se } x < 0, \alpha > 0 \\ \Lambda(x) = 1 - e^{-e^x}, \quad -\infty < x < \infty \end{cases}.$$

Procuramos  $(a_n)_{n \geq 1}$ , com  $a_n > 0$  e  $(b_n)_{n \geq 1}$  tais que

$$\frac{X_{(n)} - b_n}{a_n} \xrightarrow{D} \begin{cases} W_1^*(x) = e^{-(-x)^\alpha} \text{ se } x \leq 0, \alpha > 0 \\ W_2^*(x) = e^{-x^{-\alpha}} \text{ se } x > 0, \alpha > 0 \\ \Lambda^*(x) = e^{-e^x}, \quad -\infty < x < \infty \end{cases}.$$

A distribuição  $W_1(x)$  é denominada distribuição de Weibull, na engenharia é utilizada para analisar dureza de certos materiais. A distribuição de Fréchet,  $W_2(x)$ , é de pequeno interesse nas aplicações desde que é confinada a um suporte negativo e não pode originar-se como um limite em distribuição de variáveis aleatórias não negativas. Mesmo embora  $\Lambda(x)$  permite valores negativos em seu domínio, é de algum interesse pois pode originar-se como o limite em

distribuição de mínimos de tempos de vida, utilizados em seguros de vida e estudos de mortalidade. A distribuição  $W_2^*(x)$  é de pequeno interesse nas aplicações desde que é confinada a um suporte negativo e não pode originar-se como um limite em distribuição de variáveis aleatórias não negativas. A distribuição de Gumbel,  $\Lambda^*(x)$  apropriada para descrever medidas de valores extremos como altas temperaturas, velocidade do vento,  $\Lambda(x)$  é utilizada como modelo para descrever o mínimo de temperaturas e pressão.

Note que se  $X_1, \dots, X_n$  são variáveis aleatórias i.i.d, com distribuição  $F$ ,

$$P(X_{(n;1)} > x) = P(\min(X_1, \dots, X_n) > x) \stackrel{iid}{=} \prod_{i=1}^n P(X_1 > x) = P(X_1 > x)^n$$

e

$$P\left(\frac{X_{(n;1)} - b_n}{a_n} > x\right) = P(X_{(n;1)} > a_n x + b_n) = \bar{F}(a_n x + b_n)^n,$$

onde  $\bar{F}(x) = 1 - P(X \leq x)$ .

**Exemplo 2.44.** Considere a distribuição de Weibull,  $F(x) = 1 - e^{-x^\alpha}$ ,  $\alpha > 0$  e  $x \geq 0$

$$\bar{F}^n(a_n x + b_n) = e^{-n(a_n x + b_n)^\alpha}$$

Escolhemos  $b_n = 0$  e  $a_n = n^{-1/\alpha}$ ,  $n = 1, 2, \dots$ . Segue que  $\bar{F}^n(a_n x + b_n) = e^{-x^\alpha}$ .

Conclumos que a distribuição de Weibull é fechada na formação de mínimos de V.A.(s).

**Exemplo 2.45.** Seja  $X$  uma variável aleatória uniformemente distribuída no intervalo  $(0, 1)$ .  $X \sim U(0, 1)$ ,  $F(x) = x$ ,  $0 < x < 1$ ,  $\bar{F}(x) = 1 - x$ ,  $0 < x < 1$ ,  $a_n = \frac{1}{n}$ ,  $b_n = 0$ ,  $n = 1, 2, \dots$

$$\bar{F}^n(a_n x + b_n) = \left(1 - \frac{x}{n}\right)^n \rightarrow e^{-x}.$$

**Definição 2.46.** Duas funções de distribuições  $H(\cdot)$  e  $G(\cdot)$  são do mesmo tipo se existem constantes  $A$  e  $B$ ,  $A > 0$  tais que

$$G(Ax + B) = H(x) \forall x.$$

Se

$$X \sim N(\mu, \sigma^2) \text{ com distribuio } F$$

$$Z \sim N(0, 1) \text{ com distribuio } \phi$$

$$F(x) = \phi\left(\frac{x - \mu}{\sigma}\right)$$

e as distribuições  $F$  e  $\phi$  são do mesmo tipo.

**Lema 2.47.** (Lema Fundamental) Seja  $(F_n)_{n \geq 1}$  uma seqüência de funções de distribuições tal que, para todo  $x$  valem a) e b):

- a)  $F_n(a_n x + b_n) \xrightarrow{D} G(x)$   
 b)  $F_n(a_n^* x + b_n^*) \xrightarrow{D} G^*(x)$ ,  
 onde  $G(\cdot)$  e  $G^*(\cdot)$  não são degeneradas. Então  $G(\cdot)$  e  $G^*(\cdot)$  são do mesmo tipo.

OBS: como consequência se obtemos  $G(x)$  como o limite em distribuição, podemos obter as distribuições do mesmo tipo que  $G(\cdot)$ , modificando apropriadamente as seqüências  $(a_n)_{n \geq 1}$  e  $(b_n)_{n \geq 1}$ .

*Observação 2.48.* Se  $(X_n)_{n \geq 1}$  é uma seqüência de variáveis aleatórias iid, com função de distribuição  $F$ , inversível, observe que

$$\begin{aligned} P(nF(X_{(n;1)}) > x) &= P\left(F(X_{(n;1)}) > \frac{x}{n}\right) = P\left(X_{(n;1)} > F^{-1}\left(\frac{x}{n}\right)\right) \\ &= \left(P\left(X_1 > F^{-1}\left(\frac{x}{n}\right)\right)\right)^n = \left(1 - P\left(X_1 \leq F^{-1}\left(\frac{x}{n}\right)\right)\right)^n = \left(1 - \frac{x}{n}\right)^n \quad (*) \end{aligned}$$

**Exemplo 2.49.** Seja  $F(x) = 1 - x^{-\alpha}$ ,  $x \geq 1$

$$\begin{aligned} P\left(\frac{X_{(n;1)} - b_n}{a_n} > x\right) &= P(X_{(n;1)} > a_n x + b_n) = P(F(X_{(n;1)}) > F(a_n x + b_n)) \\ &= P(nF(X_{(n;1)}) > nF(a_n x + b_n)) \stackrel{*}{=} \left(1 - \frac{nF(a_n x + b_n)}{n}\right)^n \\ &= \left[1 - (1 - (a_n x + b_n)^{-\alpha})\right]^n = (a_n x + b_n)^{-n\alpha} \rightarrow e^{-x^{-\alpha}}, \end{aligned}$$

em que  $a_n = -\frac{1}{n}$  e  $b_n = 1$ .

**Definição 2.50.** Uma função de distribuição  $G(\cdot)$  é estável através do mínimo se para todo inteiro positivo  $k$ , existem constantes  $\alpha_k$  e  $\beta_k$  tais que

$$\overline{G}^k(\alpha_k x + \beta_k) = \overline{G}(x) \quad \forall x \in \mathbb{R}.$$



**Exemplo 2.51.** A) A distribuição de Gumbel é estável através do mínimo

$$\Lambda(x) = 1 - e^{-e^x}, -\infty < x < \infty$$

Tomando  $\alpha_k = 1$  e  $\beta_k = -\ln(k)$  temos  $e^{x-\ln(k)} = e^x e^{-\ln(k)} = e^x e^{\ln(1/k)} = \frac{1}{k} e^x$

$$\bar{\Lambda}(\alpha_k x + \beta_k) = e^{-\frac{1}{k} e^x}$$

$$\bar{\Lambda}^k(\alpha_k x + \beta_k) = \left( e^{-\frac{1}{k} e^x} \right)^k = e^{-e^x} = \bar{\Lambda}(x)$$

B) A distribuição de Weibull é estável através do mínimo  $W_1(x) = 1 - e^{-(x)^\alpha}$ ,  $x \geq 0$ . Tomando  $\alpha_k = \frac{1}{k^{1/\alpha}}$  e  $\beta_k = 0$  temos  $\bar{W}_1(x) = e^{-(x)^\alpha}$  e

$$\bar{W}_1(\alpha_k x + \beta_k) = \bar{W}_1\left(\frac{x}{k^{1/\alpha}}\right) = e^{-\left(\frac{x}{k}\right)^\alpha}$$

$$\bar{W}_1^k(\alpha_k x + \beta_k) = e^{-\left(\frac{x}{k}\right)^\alpha k} = e^{-x^\alpha} = \bar{W}_1(x).$$

**Teorema 2.52.** A função de distribuição  $G(\cdot)$  é limite em distribuição de  $X_{(n;1)}$  se, e somente se, é estável através do mínimo.

**Prova:** A condição é necessária: Por hipótese temos:  $\lim \bar{F}^n(a_n x + b_n) = \bar{G}(x)$ .

Note que

$$\begin{aligned} \bar{F}^{nk}(a_{nk}x + b_{nk}) &\xrightarrow{D} \bar{G}(x) \\ [\bar{F}^n(a_{nk}x + b_{nk})]^k &\xrightarrow{D} \bar{G}(x), \end{aligned}$$

que pode ser escrito como  $\bar{F}^n(a_{nk}x + b_{nk}) \xrightarrow{D} \bar{G}(x)^{1/k}$ . Segue do Lema Fundamental que  $\bar{G}(x)$  e  $\bar{G}^{1/k}(x)$  são do mesmo tipo e portanto existem constantes  $\alpha_k$  e  $\beta_k$  tais que

$$\bar{G}^k(\alpha_k x + \beta_k) = \bar{G}(x).$$

Para provar que a condição suficiente, basta notar que  $G(\cdot)$  é o limite em distribuição de  $X(1)$  com  $X_1, \dots, X_n$  sendo iid a  $G(\cdot)$ :

$$P\left(\frac{X_{(n;1)} - b_n}{a_n} > x\right) = \bar{G}^n(a_n x + b_n).$$

Tomando  $a_n = \alpha_n$  e  $b_n = \beta_n$ , temos

$$\begin{aligned} \lim_{n \rightarrow \infty} P\left(\frac{X_{(n;1)} - b_n}{a_n} > x\right) &= \lim_{n \rightarrow \infty} \bar{G}^n(\alpha_n x + \beta_n) = \\ &= \lim_{n \rightarrow \infty} \bar{G}(x) = \bar{G}(x). \end{aligned}$$

Seja  $G(\cdot)$  estável através do mínimo, isto é,  $\exists \alpha_k > 0$  e  $\beta_k$  tal que

$$\overline{G}^k(\alpha_k x + \beta_k) = \overline{G}(x) \quad \forall x \quad (**)$$

No que segue, as provas omitidas são encontradas no livro *Statistical Theory of Reliability and Lifetesting: probability models*, Barlow and Proschan, 1981.

**Lema 2.53.** *(Lema 1) Sejam  $\alpha_k$  e  $\beta_k$  constantes satisfazendo (\*\*) para uma distribuição  $G(\cdot)$ . Então, para todo positivo inteiro  $j$  e  $k$  temos*

$$\begin{aligned} \alpha_{jk} &= \alpha_j \alpha_k, \\ \beta_{jk} &= \beta_k + \alpha_k \beta_j = \beta_j + \alpha_j \beta_k. \end{aligned}$$

*(Prova omitida)*

**Lema 2.54.** *(Lema 2) Se em (\*\*)  $\alpha_j = 1$  para algum  $j > 1$ , então  $\alpha_j = 1$  para todo  $j$ .*

*(Prova omitida)*

**Exemplo 2.55.** A distribuição de Gumbel,  $\wedge(x) = 1 - e^{-e^x}$  é estável através do mínimo.  $\alpha_k = 1$  e  $\beta_k = -\ln(k)$ .

**Lema 2.56.** (Lema 3) Se em (\*\*)  $\alpha_j < 1$  para algum  $j > 1$ , então

- a) Existe  $x_0$  tal que  $G(x_0) = 0$  e  $G(x) > 0$  para todo  $x > x_0$ .
- b)  $\beta_k/(1 - \alpha_k) = x_0$  para todo  $k > 1$ .

(Prova omitida)

**Exemplo 2.57.** A distribuição de Weibull,  $W_1(x) = 1 - e^{-x^\alpha}$  é estável através do mínimo.  $\alpha_k = \frac{1}{k^{1/\alpha}} < 1$  e  $\beta_k = 0$ .

**Lema 2.58.** (Lema 4) Se em (\*\*)  $\alpha_j > 1$  para algum  $j > 1$ , então

- a) Existe  $x_0$  tal que  $G(x_0) = 1$  e  $G(x) < 1$  para todo  $x < x_0$ .
- b)  $\beta_k/(1 - \alpha_k) = x_0$  para todo  $k > 1$ .

(Prova omitida)

**Lema 2.59.** (Lema 5) Sejam  $\alpha_j$ ,  $j = 1, 2, \dots$  as constantes em (\*\*). Então:

- a)  $\alpha_j < 1$  para todo  $j > 1$ , ou
- b)  $\alpha_j = 1$  para todo  $j \geq 1$ , ou
- c)  $\alpha_j > 1$  para todo  $j > 1$

(Prova omitida)

No lema 3 e lema 4 podemos, sem perda de generalidade, tomar  $x_0 = 0$ . Assim o problema de encontrar uma distribuição estável através do mínimo se reduz a encontrar solução para

$$\overline{G}^n(\alpha_n x) = \overline{G}(x) \text{ com } G(x) = 0 \text{ para } x \leq 0 \text{ } (\alpha_n < 1)$$

ou

$$\overline{G}^n(\alpha_n x) = \overline{G}(x) \text{ com } G(x) = 1 \text{ para } x \geq 0 \text{ } (\alpha_n > 1)$$

ou

$$\overline{G}^n(x + \beta_n) = \overline{G}(x) \text{ } (\alpha_n = 1).$$

**2.9. Domínios de Atração.** Na aula anterior analisamos o resultado, básico, que o mínimo (máximo) de uma amostra aleatória pode ter entre três possíveis limites em distribuições. Nesta aula caracterizaremos classes de distribuições nas quais o mínimo (máximo) de amostras aleatórias converge para cada um dos três tipos, que são chamadas de domínios de atração. Precisamente

**Definição 2.60.** Uma distribuição  $F$  pertence ao domínio de atração minimal de uma distribuição  $G$  se existem constantes  $a_n$  e  $b_n$ , tais que  $\bar{F}^n(a_n x + b_n) \rightarrow^D \bar{G}(x)$ . Semelhantemente,  $F$  pertence ao domínio de atração maximal de  $G$  se existem constantes  $a_n$  e  $b_n$ , tais que  $F^n(a_n x + b_n) \rightarrow^D G(x)$ .

O nosso objetivo é determinar os domínios de atrações minimais para  $W_1, W_2$  e  $\Lambda$ , e os domínios de atrações maximais para  $W_1^*, W_2^*$  e  $\Lambda^*$ .

Necessitaremos do seguinte Lema:

**Lema 2.61.**

$$\bar{F}^n(a_n x + b_n) \rightarrow^D \bar{G}(x) \Leftrightarrow nF(a_n x + b_n) \rightarrow^D -\ln \bar{G}(x).$$

para todo ponto de continuidade de  $G(x)$ , com  $\bar{G}(x_0) \neq 0$ ,

**Prova:**

*Sob quaisquer das condições*

$$\lim_{n \rightarrow \infty} \bar{F}^n(a_n x + b_n) = \lim_{n \rightarrow \infty} (\bar{F}^n(a_n x + b_n))^{\frac{1}{n}} =$$

$$\lim_{n \rightarrow \infty} (\bar{G}(x))^{\frac{1}{n}} = 1.$$

*Note também que  $1 - y \leq \int_y^1 \frac{1}{x} dx \leq \frac{1}{y}(1 - y)$ .*

*Portanto*

$$\lim_{n \rightarrow \infty} nF(a_n x + b_n) \leq \lim_{n \rightarrow \infty} -n \ln \bar{F}(a_n x + b_n) \leq \lim_{n \rightarrow \infty} \frac{nF(a_n x + b_n)}{\bar{F}(a_n x + b_n)},$$

*e segue que*

$$\lim_{n \rightarrow \infty} nF(a_n x + b_n) = \lim_{n \rightarrow \infty} -n \ln \bar{F}^n(a_n x + b_n).$$

O teorema 3 dá condições, necessária e suficiente, para uma função de distribuição pertencer ao domínio de atração minimal da distribuição de Weibull. O Corolário 4 trata de condições, necessária e suficiente, para uma função de distribuição pertencer ao domínio de atração maximal de  $W_1^*$ .

**Teorema 2.62. Domínio de atração minimal de  $W_1(x)$** 

A distribuição  $F$  pertence ao domínio de atração minimal de  $W_1(x) = 1 - e^{-x^\alpha}$ ,  $x \geq 0$ , ( $\alpha > 0$ ) se, e somente se,

A) Existe  $x_0$  tal que  $F(x_0) = 0$  e  $F(x_0 + \varepsilon) > 0$ ,  $\forall \varepsilon > 0$ ;

B))  $\lim_{t \downarrow 0} \left[ \frac{F(xt+x_0)}{F(t+x_0)} \right] = x^\alpha$ , para  $x > 0$ , ( $\alpha > 0$ ).

**Prova:**

A condição é suficiente. Considere  $x_0 = 0$  e  $a_n = F^{-1}(\frac{1}{n})$  de maneira que  $\lim_{n \rightarrow \infty} nF(a_n) = 1$ .

Por hipótese  $\lim_{t \downarrow 0} \frac{F(xt)}{F(t)} = x^\alpha$ ,  $x > 0$ . Então

$$\lim_{n \rightarrow \infty} \frac{F(a_n x)}{F(a_n)} = \lim_{n \rightarrow \infty} \frac{nF(a_n x)}{nF(a_n)} = \lim_{n \rightarrow \infty} nF(a_n x),$$

e pelo Lema ,  $-\ln \overline{W}_1(x) = x^\alpha$  e  $\overline{W}_1(x) = e^{-x^\alpha}$ .

A condição necessária pode ser encontrada em Gnedenko (1943).

**Corolário 2.63. Domínio de atração maximal de  $W_1^*(x)$**  A distribuição  $F$  pertence ao domínio de atração maximal de  $W_1^*(x) = e^{-(x)^\alpha}$ ,  $x \leq 0$  ( $\alpha > 0$ ) se, e somente se,

A) Existe  $x_1$  tal que  $F(x_1) = 1$  e  $F(x_1 - \varepsilon) < 1$ ,  $\forall \varepsilon > 0$ ;

B))  $\lim_{t \uparrow 0} \left[ \frac{\overline{F}(xt+x_1)}{\overline{F}(t+x_1)} \right] = x^\alpha$ , para  $x > 0$ , ( $\alpha > 0$ ).

*Observação 2.64.* Observe que  $\max\{X_1, \dots, X_n\} = -\min\{-X_1, \dots, -X_n\}$  e  $F_{-X}(x) = P(-X \leq x) = P(X \geq -x) = 1 - F_X(-x)$ .

Portanto, utilizando a parte A) do teorema anterior,  $F_{-X}(x_0) = 0 \rightarrow 1 - F_X(-x_0) = 0 \rightarrow F_X(-x_0) = 1$  é suficiente considerar  $x_1 = -x_0$  de maneira que

$$F_{-X}(x_0 + \varepsilon) > 0 \rightarrow 1 - F_X(-x_0 - \varepsilon) > 0 \rightarrow F(x_1 - \varepsilon) < 1,$$

e

$$x^\alpha = \lim_{t \downarrow 0} \left[ \frac{F_{-X}(xt + x_0)}{F_{-X}(t + x_0)} \right] = \lim_{-t \uparrow 0} \left[ \frac{1 - F_X(-xt - x_0)}{1 - F_X(-t - x_0)} \right] = \lim_{t \uparrow 0} \left[ \frac{\overline{F}(xt + x_1)}{\overline{F}(t + x_1)} \right].$$

**Exemplo 2.65.** A função de distribuição

$$F(x) = 1 - k(a - x)^\alpha, \quad a - k^{\frac{-1}{\alpha}} \leq x \leq a, \quad k > 0, \alpha > 0$$

pertence ao domínio de atração minimal de  $W_1(x)$ . Considere  $x_0 = a - k^{\frac{-1}{\alpha}}$ . Portanto

$$\begin{aligned} \lim_{t \downarrow 0} \left[ \frac{F(xt + x_0)}{F(t + x_0)} \right] &= \lim_{t \downarrow 0} \frac{1 - k[a - xt - a + k^{\frac{-1}{\alpha}}]^\alpha}{1 - k[a - t - a + k^{\frac{-1}{\alpha}}]^\alpha} = \\ &= \lim_{t \downarrow 0} \frac{k\alpha[-xt + k^{\frac{-1}{\alpha}}]^{\alpha-1}(-x)}{k\alpha[-t + k^{\frac{-1}{\alpha}}]^{\alpha-1}} = x^\alpha. \end{aligned}$$

**Teorema 2.66. Domínio de atração minimal de  $W_2(x)$**

A) A distribuição  $F$  pertence ao domínio de atração minimal de  $W_2(x) = 1 - e^{-(x)^{-\alpha}}$ ,  $x \leq 0$ , ( $\alpha > 0$ ) se, e somente se,

$$\lim_{t \downarrow -\infty} \frac{F(t)}{F(tx)} = x^\alpha, \quad \forall x > 0.$$

B) A distribuição  $F$  pertence ao domínio de atração maximal de  $W_2^*(x) = e^{(-x)^{-\alpha}}$ ,  $x \geq 0$  ( $\alpha > 0$ ) se, e somente se,

$$\lim_{t \uparrow \infty} \frac{\bar{F}(t)}{\bar{F}(tx)} = x^\alpha, \quad \forall x > 0.$$

**Exemplo 2.67.** A função de distribuição

$$\bar{F}(x) = kx^{-\alpha}, \quad k > 0, \alpha > 0$$

pertence ao domínio de atração maximal de  $W_2^*(x)$ , pois

$$\lim_{t \downarrow -\infty} \frac{\bar{F}(t)}{\bar{F}(tx)} = \frac{kt^{-\alpha}}{kt^{-\alpha}x^{-\alpha}} = x^\alpha.$$

**Teorema 2.68. Domínio de atração minimal de  $\Lambda(x)$**  A distribuição  $F$  pertence ao domínio de atração de  $\Lambda(x) = 1 - e^{-e^x}$  se existe  $x_0$  tal que  $F(x_0) = 0$  e  $F(x_0 + \varepsilon) > 0$ ,  $\forall \varepsilon > 0$  e

$$\lim_{x \downarrow x_0} \frac{d}{dx} \left[ \frac{1}{\phi'(x)} \right] = 0,$$

onde  $\phi(x) = -\ln F(x)$ .

Von Mises (1939) apresentou condições para que uma função de distribuição  $F$  pertença ao domínio de atração maximal da distribuição de Gumbel,,  $\Lambda^*$ .

**Teorema 2.69. Domínio de atração maximal de  $\Lambda^*(x)$**  A) Considere a função de distribuição  $F(x)$ , com  $F(x) < 1, \forall x$  e

$$\lim_{x \uparrow \infty} \frac{d}{dx} \left[ \frac{1}{r(x)} \right] = 0,$$

onde  $r(x) = \frac{f(x)}{F(x)}$ . Então  $F$  pertence ao domínio de atração maximal de  $\Lambda^*(x) = e^{(-e)^{-x}}$ , com  $\bar{F}(b_n) = \frac{1}{n}$  e  $a_n = \frac{1}{nf(b_n)}$ .

B) Se existe  $x_1$  tal que  $F(x_1) = 1$  e  $F(x_1 - \varepsilon) < 1, \forall \varepsilon > 0$  e  $\lim_{x \uparrow x_1} \frac{d}{dx} \left[ \frac{1}{r(x)} \right] = 0$ , então  $F$  pertence ao domínio de atração maximal de  $\Lambda^*(x) = e^{(-e)^{-x}}$ .

**Exemplo 2.70.** A função de distribuição

$$F(x) = \frac{1}{1 + e^{-x}}, \quad -\infty < x < \infty$$

pertence ao domínio de atração maximal de  $\Lambda^*(x)$ .

Temos que

$$\bar{F}(x) = \frac{e^{-x}}{1 + e^{-x}}, \quad f(x) = \frac{e^{-x}}{(1 - e^{-x})^2}, \quad r(x) = \frac{1}{1 + e^{-x}}.$$

Portanto

$$\lim_{x \downarrow -\infty} \frac{d}{dx} \left[ \frac{1}{r(x)} \right] = \lim_{x \downarrow -\infty} \frac{d}{dx} [1 + e^{-x}] = \lim_{x \downarrow -\infty} -e^{-x} = 0.$$

Como  $F^{-1}(y) = -\ln\left(\frac{1}{y} - 1\right)$ ,  $\bar{F}(b_n) = \frac{1}{n}$  implica que  $b_n = F^{-1}\left(\frac{n-1}{n}\right) = \ln(n-1)$ .

Em adicãõ  $f(b_n) = \frac{n-1}{n^2}$  implica que  $a_n = \frac{1}{nf(b_n)} = \frac{n}{n-1}$ .

Portanto

$$F^n(a_n x + b_n) = F^n\left(\frac{n}{n-1}x + \ln(n-1)\right) = \left(\frac{1}{1 + e^{-\left(\frac{n}{n-1}x + \ln(n-1)\right)}}\right)^n = \left(1 - \left(-\frac{e^{-\frac{n}{n-1}x}}{n-1}\right)\right)^{-n}.$$

e  $\lim_{n \rightarrow \infty} F^n(a_n x + b_n) = e^{(-e)^{-x}}$ .

**Lema 2.71.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com uma função de distribuição contínua  $F$  e sejam  $U_n = nF(X_{(n;1)})$  e  $V_n = n[1 - F(X_{(n;n)})]$ . Então,  $U_n \rightarrow^D \text{Exp}[1]$  e  $V_n \rightarrow^D \text{Exp}[1]$ .

**Prova:**

$$\begin{aligned} P(V_n \leq v) &= P(n[1 - F(X_{(n;n)})] \leq v) = P(F(X_{(n;n)}) \geq 1 - \frac{v}{n}) = 1 - P(F(X_{(n;n)}) \leq 1 - \frac{v}{n}) = \\ &= 1 - P(X_{(n;n)} \leq F^{-1}\left(1 - \frac{v}{n}\right)) = 1 - P(X_1 \leq F^{-1}\left(1 - \frac{v}{n}\right)) = 1 - \left(1 - \frac{v}{n}\right)^n. \end{aligned}$$

Portanto

$$\lim_{n \rightarrow \infty} P(V_n \leq v) = \lim_{n \rightarrow \infty} 1 - \left(1 - \frac{v}{n}\right)^n = 1 - e^{-v}.$$

e  $V_n \rightarrow^D \text{Exp}[1]$ .

As definições e resultados que seguem estão na pg 226 do livro From finite sample asymptotic methods in statistic de P.K.Sen, J.M.Singer e A.C.P.Lima (2010)

**Definição 2.72.** Seja  $X$  uma variável aleatória com função de distribuição  $F$ , então:

A)  $F$  é do tipo Cauchy, se existirem  $k > 0$  e  $c > 0$  tais que

$$\lim_{x \rightarrow -\infty} |x|^k F(x) = c.$$

B)  $F$  é do tipo exponencial em um ponto  $\xi_{0;n}$  com  $F(\xi_{0;n}) = \frac{1}{n}$  se  $F$  é continuamente diferenciável e

$$\frac{f(x)}{F(x)} \approx \frac{f^{(1)}(x)}{f(x)} \approx \frac{f^{(2)}(x)}{f^{(1)}(x)} \approx \dots$$

quando  $x \rightarrow -\infty$ .

C)  $F$  tem um contato terminal de ordem  $m$  em um ponto  $\xi_{1;n}$  com  $F(\xi_{1;n}) = 1 - \frac{1}{n}$  se  $F(\xi_{1;n}) = 1$ , as derivadas à esquerda  $F^{(j)}(\xi_{1;n}) = 0$ ,  $j = 1, \dots, m$  e  $F^{(m+1)}(\xi_{1;n}) \neq 0$ .

*Observação 2.73.* Distribuições do tipo exponencial tem momentos finitos de todas as ordens e incluem aquelas comumente empregadas nos métodos estatísticos, tais como a exponencial, normal e gama. Por outro lado as distribuições do tipo Cauchy não tem momentos finitos de ordem  $\geq k$  e leva o nome da distribuição típica de Cauchy, para a qual,  $k = 1$ . Em geral, as distribuições assintóticas dos mínimos amostrais dependem do tipo de distribuição envolvida.

As definições A e B são adequadas para analisar distribuições assintóticas para o mínimo de variáveis aleatórias. para estudarmos as distribuições assintóticas para o máximo de variáveis aleatórias pequenas modificações devem ser consideradas: As distribuições do tipo Cauchy deve ser analisada na vizinhança de  $\infty$

$$\lim_{x \rightarrow \infty} |x|^k \bar{F}(x) = c.$$

As distribuições do tipo exponencial são tais que

$$-\frac{f(x)}{1 - F(x)} \approx \frac{f^{(1)}(x)}{f(x)} \approx \frac{f^{(2)}(x)}{f^{(1)}(x)} \approx \dots$$



**Exemplo 2.74.** A distribuição de Cauchy padrão é do tipo Cauchy com  $k = 1$  pois:

$$\lim_{x \rightarrow -\infty} \frac{\pi^{-1} \int_{-\infty}^x \frac{1}{1+y^2} dy}{\frac{1}{|x|}} \approx \lim_{x \rightarrow -\infty} \frac{\frac{1}{1+x^2}}{\frac{1}{|x|^2}} = 1.$$

A distribuição normal padrão é do tipo exponencial, pois nas vizinhança de  $-\infty$  temos

$$\begin{aligned} \frac{f(x)}{F(x)} &= \frac{(\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}}}{\int_{-\infty}^x (\sqrt{2\pi})^{-1} e^{-\frac{y^2}{2}} dy} \approx \frac{e^{-\frac{x^2}{2}}(-x)}{e^{-\frac{x^2}{2}}} \approx -x \\ \frac{f'(x)}{f(x)} &= \frac{(\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}}(-x)}{(\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}}} \approx -x \\ \frac{f''(x)}{f'(x)} &= \frac{(\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}} - (\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}} - x^2}{(\sqrt{2\pi})^{-1} e^{-\frac{x^2}{2}}(-x)} \approx -x + \frac{1}{x} \approx -x \end{aligned}$$

na vizinhança de  $-\infty$

A distribuição uniforme no intervalo  $(0, \theta)$  tem um contato terminal de ordem 0 em um ponto  $\xi_{1;n} = \theta$ .

**Teorema 2.75.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com função de distribuição  $F$  do tipo Cauchy. Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;1)}}{\xi_{0;n}} \leq t\right) = 1 - e^{-(-x)^{-k}}, \quad x < 0,$$

onde  $\xi_{0;n}$  é tal que  $F(\xi_{0;n}) = \frac{1}{n}$ .

**Prova:** Observe que

$$\begin{aligned} U_n = nF(X_{(n;1)}) &= \frac{F(X_{(n;1)})}{\frac{1}{n}} = \frac{F(X_{(n;1)})}{F(\xi_{0;n})} = \\ &= \left| \frac{\xi_{0;n}}{X_{(n;1)}} \right|^k \cdot \frac{|X_{(n;1)}|^k F(X_{(n;1)})}{F(\xi_{0;n}) |\xi_{0;n}|^k} \rightarrow \left| \frac{\xi_{0;n}}{X_{(n;1)}} \right|^k \cdot \frac{c}{c}. \end{aligned}$$

Portanto, para  $x < 0$

$$\begin{aligned} \lim_{n \rightarrow \infty} P\left(\frac{X_{(n;1)}}{\xi_{0;n}} \leq x\right) &= \lim_{n \rightarrow \infty} P\left(\left| \frac{X_{(n;1)}}{\xi_{0;n}} \right| \geq |x|\right) = \\ \lim_{n \rightarrow \infty} P\left(\left| \frac{\xi_{0;n}}{X_{(n;1)}} \right|^k \geq |x|^{-k}\right) &= 1 - e^{-|x|^{-k}} = 1 - e^{-(-x)^{-k}}. \end{aligned}$$

**Corolário 2.76.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com função de distribuição  $F$  do tipo Cauchy. Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;n)}}{\xi_{1;n}} \leq t\right) = e^{(-t)^{-k}}, \quad t \geq 0,$$

onde  $\xi_{1;n}$  é tal que  $F(\xi_{1;n}) = 1 - \frac{1}{n}$ .

**Teorema 2.77.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com função de distribuição  $F$  do tipo exponencial. Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;1)} - \xi_{0;n}}{a_n} \leq x\right) = 1 - e^{-e^x}, \quad -\infty < x < \infty,$$

onde  $F(\xi_{0;n}) = \frac{1}{n}$  e  $a_n = \frac{1}{nf(\xi_{0;n})}$ .

**Prova:** Usando a série de Taylor em torno de  $\xi_{0;n}$ , temos

$$F(\xi_{0;n} + s) = \sum_{n=0}^{\infty} \frac{F^{(n)}(\xi_{0;n})s^n}{n!} = F(\xi_{0;n}) + \sum_{k=1}^{\infty} \frac{f^{(k-1)}(\xi_{0;n})s^k}{k!}.$$

Portanto

$$F(X_{(n;1)}) = \frac{1}{n} + \sum_{k=1}^{\infty} \frac{f^{(k-1)}(\xi_{0;n})(X_{(n;1)} - \xi_{0;n})^k}{k!}$$

e

$$U_n = nF(X_{(n;1)}) = 1 + \sum_{k=1}^{\infty} n \frac{f^{(k-1)}(\xi_{0;n})(X_{(n;1)} - \xi_{0;n})^k}{k!} = 1 + \sum_{k=1}^{\infty} n \frac{f^{(k-1)}(\xi_{0;n})t^k a_n^k}{k!},$$

onde  $t = \frac{X_{(n;1)} - \xi_{0;n}}{a_n}$  e  $a_n = \frac{1}{nf(\xi_{0;n})}$ .

Contudo, podemos escrever

$$n \frac{f^{(k-1)}(\xi_{0;n})t^k}{(nf(\xi_{0;n}))^k k!} = \frac{t^k}{k!} \left[ \frac{F(\xi_{0;n})^k f^{k-1}(\xi_{0;n})}{f(\xi_{0;n})^k} \frac{f^{k-2}(\xi_{0;n})}{f^{k-2}(\xi_{0;n})} \frac{f^1(\xi_{0;n})}{f^0(\xi_{0;n})} \frac{f^0(\xi_{0;n})}{F(\xi_{0;n})} \right] \approx \frac{t^k}{k!}$$

e concluímos

$$U_n = nF(X_{(n;1)}) \approx \sum_{k=0}^{\infty} \frac{t^k}{k!} \approx e^t$$

com

$$P\left(\frac{X_{(n;1)} - \xi_{0;n}}{a_n} \leq x\right) = P(t \leq x) = P(e^t \leq e^x) = P(U_n \leq e^x)$$

e

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;1)} - \xi_{0;n}}{a_n} \leq x\right) = \lim_{n \rightarrow \infty} P(U_n \leq e^x) = 1 - e^{-e^x}.$$

**Corolário 2.78.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com função de distribuição  $F$  do tipo exponencial. Então*

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n} \leq x\right) = e^{-e^{-x}}, \quad -\infty < x < \infty,$$

onde  $F(\xi_{1;n}) = 1 - \frac{1}{n}$  e  $a_n = \frac{1}{nf(\xi_{1;n})}$ .

**Teorema 2.79.** *Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com função de distribuição  $F$  com contato terminal de ordem  $m$  no ponto  $\xi_{1;n}$ , ( $F(\xi_{1;n}) = 1 - \frac{1}{n}$ ). Então existe uma sequência de constante  $(a_n)_{n \geq 1}$  tal que*

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n} \leq t\right) = e^{-(-t)^{m+1}} \quad \text{se } t \leq 0 \text{ e } 1 \text{ se } t > 0.$$

onde  $a_n = \left[\frac{(-1)^m(m+1)!}{nF^{(m+1)}(\xi_{1;n})}\right]^{\frac{1}{m+1}}$ .

**Prova:** *Considere o desenvolvimento de Taylor em torno do ponto  $\xi_{1;n}$*

$$F(\xi_{1;n} - s) = F(\xi_{1;n}) + \sum_{k=0}^m \frac{(-1)^k s^k F^{(k)}(\xi_{1;n})}{k!} + \frac{(-1)^{m+1} s^{m+1} F^{(m+1)}(\xi_{1;n} - \theta s)}{(m+1)!} =$$

$$F(\xi_{1;n}) + \frac{(-1)^{m+1} s^{m+1} F^{(m+1)}(\xi_{1;n} - \theta s)}{(m+1)!} \quad 0 < \theta < 1.$$

Observe que

$$V_n = n[1 - F(X_{(n;n)})] = n[1 - F(\xi_{1;n})] + n[F(\xi_{1;n}) - F(X_{(n;n)})] = n[F(\xi_{1;n}) - F(X_{(n;n)})].$$

Fazendo  $s = \xi_{1;n} - X_{(n;n)}$ , temos:

$$V_n = \frac{(-1)^m n}{(m+1)!} (\xi_{1;n} - X_{(n;n)})^{m+1} F^{m+1}(\xi_{1;n}) \frac{F^{m+1}((1-\theta)\xi_{1;n} + \theta X_{(n;n)})}{F^{m+1}(\xi_{1;n})}.$$

Fazendo  $a_n = \left[\frac{(-1)^m(m+1)!}{nF^{(m+1)}(\xi_{1;n})}\right]^{\frac{1}{m+1}}$  e  $W_n = \frac{F^{m+1}((1-\theta)\xi_{1;n} + \theta X_{(n;n)})}{F^{m+1}(\xi_{1;n})}$  temos

$$V_n = \left(\frac{\xi_{1;n} - X_{(n;n)}}{a_n}\right)^{m+1} \cdot W_n = \left[-\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n}\right)\right]^{m+1} \cdot W_n.$$

Como  $W_n \xrightarrow{P} 1$ , concluímos, pelo teorema de Slutsky, que a distribuição assintótica de  $\left[-\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n}\right)\right]^{m+1}$  é a mesma de  $V_n$  e para  $t \leq 0$ ,

$$P\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n} \leq t\right) = P\left(\left[-\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n}\right)\right]^{m+1} \geq (-t)^{m+1}\right)$$

$$\lim_{n \rightarrow \infty} P\left(\frac{X_{(n;n)} - \xi_{1;n}}{a_n} \leq t\right) = e^{[-(-t)^{m+1}]}, \text{ se } t \leq 0 \text{ e } 1 \text{ se } t > 0.$$

**Exemplo 2.80.** Seja  $(X_n)_{n \geq 1}$  uma sequência de variáveis aleatórias independentes e identicamente distribuídas com distribuição uniforme no intervalo  $(0, \theta)$ . Assim  $F(x) = \frac{x}{\theta}, 0 \leq x \leq \theta$  e  $F^{(1)}(x) = \frac{1}{\theta}, 0 \leq x \leq \theta$  e portanto  $F$  tem contato terminal de ordem  $m = 0$  e temos  $a_n = \frac{\theta}{n}$  com  $\xi_{1;n} = \theta$ . Concluímos

$$\lim_{n \rightarrow \infty} P\left(\frac{n}{\theta}(X_{(n;n)} - \theta) \leq t\right) = e^t, t \leq 0.$$

*Email address:* bueno@ime.usp.br

DEPARTAMENTO DE ESTATÍSTICA, INSTITUTO DE MATEMÁTICA E ESTATÍSTICA,  
UNIVERSIDADE DE SÃO PAULO, CAIXA POSTAL 66281, CEP 05311-970, SÃO  
PAULO, BRAZIL